BEÜN

# TUFUAB XIII. Teknik Sempozyumu

18-19-20 Haziran 2025

09.30

Sezai Karakoç Kültür Merkezi
Mühendislik Fakültesi



18.06.2025: Sezai Karakoç Kültür Merkezi
19-20.06.2025: Mühendislik Fakültesi

tufuab2025.beun.edu.tr

4 NİTELİKLİ EĞİTİM

# Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) XIII. Teknik Sempozyumu

# Genişletilmiş Özet & Tam Metin Bildirileri

TASLAK

**EDİTÖRLER**

Prof. Dr. Hüseyin TOPAN
Prof. Dr. Şenol Hakan KUTOĞLU
Prof. Dr. Saygın ABDİKAN
Prof. Dr. Ayhan ATEŞOĞLU
Doç. Dr. Hakan AKÇIN
Doç. Dr. Çağlar BAYIK
Doç. Dr. Aliihsan ŞEKERTEKİN
Dr. Öğr. Üyesi Aycan Murat MARANGOZ
Dr. Öğr. Üyesi Kurtuluş Sedar GÖRMÜŞ
Dr. Öğr. Üyesi Hüseyin KEMALDERE
Dr. Öğr. Üyesi Eray KÖKSAL
Dr. Öğr. Üyesi İlke DENİZ
Dr. Öğr. Üyesi Can ATALAY
Dr. Öğr. Üyesi Volkan AKGÜL
Dr. Öğr. Üyesi Nevin Betül AVŞAR

**DİZGİ**

Doç. Dr. Çağlar BAYIK
Dr. Öğr. Üyesi Aycan Murat MARANGOZ
Mert ALPAT
Meriç BEKTAŞ

**KAPAK**

Öğr. Gör. Merve KOVANCI

**E-ISBN: DSB**

## Düzenleyenler

## Ana Sponsor

ATAY

## Platin Sponsor

NİK SİSTEM
www.nik.com.tr

## Altın Sponsor

TMMOB HARİTA VE KADASTRO MÜHENDİSLERİ ODASI
1954

## Gümüş Sponsor

MESCİOĞLU
Mühendislik ve Müşavirlik A.Ş

## Sponsorlar

ÜNAL HARİTA

Geoteknik

YILMAZLAR İNŞAAT

## Destekleyenler

PİN TEKNİK

JEODEZİ GRUP HARİTA

ZONGULDAK KÖMÜR JEOPARKI | COAL GEOPARK

**tufuab2025.beun.edu.tr**

## ÖNSÖZ

Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumunun onüçüncüsü, 18-20 Haziran 2025 tarihlerinde Üniversitemiz evsahipliğinde ve Milli Savunma Bakanlığı Harita Genel Müdürlüğü işbirliğinde Zonguldak'ta düenlenmiştir. Sempozyum konularını oluşturan fotogrametri, uzaktan algılama, görüntü işleme ve bilgisayarlı görü konuları, teknolojinin ve bilimin gelişmesine koşut olarak gündelik hayatımızda sıklıkla kullanılan pekçok uygulamanın temelini oluşturmakta ve yaşamımızın vazgeçilmezleri arasında yerini almaktadır.

Bölümümüz, Harita Genel Müdürlüğü işbirliğinde 14-16 Ekim 2004 tarihlerinde Türkiye Ulusal Jeodezi Komisyonu 2004 Yılı Bilimsel Toplantısını ve 28-30 Mart 2012 tarihlerinde Türkiye Ulusal Jeodezi Komisyonu Çalıştayını gerçekleştirmiştir. Ayrıca 2005, 2006 ve 2016 yıllarında Uzaydan Harita Yapımı kurslarına ve 2012 yılında Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumuna evsahipliği yapmıştır. Bunun yanısıra Sempozyum konularında TÜBİTAK, Avrupa Uzay Ajansı, Asya Pasifik Uzay İşbirliği Örgütü ve Avrupa Birliği gibi kurumlarca desteklenen projeler yürütülmüş ve üç adet patent alınmıştır. Bölümümüz, Avrupa Uzaktan Algılama Laboratuvarları Birliği (EARSeL) üyesidir ve Kentsel Sistemler Çalışma Grubuna eş-başkanlık ederek EARSeL Konseyinde Ülkemizi temsil etmektedir.

Sempozyumda 30 ilden 39 farklı üniversite ve 16 farklı kamu kurumu ve özel kuruluştan 101 bildiri, bir davetli konuşmacı, 18 sözlü sunum ve bir poster sunum oturumunda sunulmuştur. Sempozyuma Almanya ve Romanya'dan da katılım olmuştur.

TUFUAB XIII. Teknik Sempozyumu, Üniversitemiz Rektörlüğünün onayı ile, Üniversitemiz Mühendislik Fakültesi Dekanlığı görevinde bulunmuş, fotogametri camiasının duayen öğretim üyelerinden merhum Prof. Dr. Hayrettin GÜRBÜZ'e ve Üniversitemiz Rektör Yardımcılığı başta olmak üzere çeşitli idari görevlerde bulunan Bölümümüzün Kurucu Başkanı merhum Prof. Dr. Halil Erdal KOÇAK'a armağan edilmiştir.



Prof. Dr. Hayrettin GÜRBÜZ





Prof. Dr. Halil Erdal KOÇAK

Harita Genel Müdürlüğü ile yıllar süren işbirliğinin son örneği olan TUFUAB XIII. Teknik Sempozyumunun düzenlenmesindeki yakın işbirliği nedeniyle Sn. Tümg. Dr. Osman ALP nezdinde Harita Genel Müdürlüğü'ne, sürecin başından itibaren yakın ilgi ve destekleri nedeniyle Sn. Prof. Dr. İsmail Hakkı ÖZÖLÇER nezdinde Üniversitemize, TUFUAB Konseyine, Bilim Kuruluna, Düzenleme Kuruluna, Sempozyum Sekreteryasına, tüm destek personellere, davetli konuşmacılar Prof. Dr. Devrim AKÇA ve Prof. Dr. Andy HOOPER'e, ayrıca Ana Sponsor Atay Mühendislik'e, Platin Sponsor Nik Sistem'e, Altın Sponsor Harita ve Kadastro Mühendisleri Odası Genel Merkezine, Gümüş Sponsor Mescioğlu Mühendislik ve Müşavirlik A. Ş.'ye, Ünal Harita'ya, Geoteknik Geodezi ve Teknik Elektronik Aletleri San. Tic. Ltd. Şti.'ne, ÖDF Yılmazlar İnşaat'a, Pin Teknik'e, Jeodezi Grup Harita'ya ve Zonguldak Kömür Jeoparkı'na şükranlarımızı sunarız.
Sempozyumun tüm bilim camiasına faydalı olmasını diliyoruz.

Prof. Dr. Hüseyin TOPAN
Düzenleme Kurulu Başkanı

# TUFUAB XIII. Teknik Sempozyumu
# Kurullar

**Onur Kurulu**
Osman HACIBEKTAŞOĞLU, Zonguldak Valisi
Prof. Dr. İsmail Hakkı ÖZÖLÇER, Zonguldak Bülent Ecevit Üniversitesi Rektörü
Dr. Tümgeneral Osman ALP, Harita Genel Müdürü, Temsilci Kurum Başkanı

**Yürütme Kurulu**
Dr. Müh. Alb. Abdullah DEĞER, Temsilci Kurum Başkan Yardımcısı
Dr. Müh. Alb. Orhan FIRAT, TUFUAB Sekreteri, I. Kom. Başkanı
Yük. Müh. Ekrem AYYILDIZ, II. Kom. Başkanı
Prof. Dr. Zaide DURAN, III. Kom. Başkanı
Yük. Müh. Alb. Abdullah SAYGILI, IV. Kom. Başkanı
Prof. Dr. Bülent BAYRAM, V. Kom. Başkanı
Prof. Dr. Ferruh Yıldız, VI. Kom. Başkanı
Yük. Müh. Yb. Mustafa KAYA, VII. Kom. Başkanı
Müh. Pemra KUMTEPE, VIII. Kom. Başkanı
Prof. Dr. Hakan KARABÖRK, I. Kom. Üniversite Temsilcisi
Prof. Dr. Naci YASTIKLI, II. Kom. Üniversite Temsilcisi
Prof. Dr. Taşkın KAVZOĞLU, III. Kom. Üniversite Temsilcisi
Prof. Dr. Fevzi KARSLI, IV. Kom. Üniversite Temsilcisi
Prof. Dr. Nebiye MUSAOĞLU, V. Kom. Üniversite Temsilcisi
Prof. Dr. Cevdet Coşkun AYDIN, VI. Kom. Üniversite Temsilcisi
Doç. Dr. Mustafa DİKHAN, VII. Kom. Üniversite Temsilcisi
Prof. Dr. Mustafa TÜRKER, VIII. Kom. Üniversite Temsilcisi

**Düzenleme Kurulu**
Prof. Dr. Şenol Hakan KUTOĞLU, Zonguldak Bülent Ecevit Üniversitesi
Prof. Dr. Hüseyin TOPAN, Zonguldak Bülent Ecevit Üniversitesi, *Düzenleme Kurulu Başkanı*
Prof. Dr. Saygın ABDİKAN, Hacettepe Üniversitesi
Prof. Dr. Ayhan ATEŞOĞLU, Bartın Üniversitesi
Doç. Dr. Hakan AKÇIN, Zonguldak Bülent Ecevit Üniversitesi
Doç. Dr. Çağlar BAYIK, Zonguldak Bülent Ecevit Üniversitesi
Doç. Dr. Aliihsan ŞEKERTEKİN, Iğdır Üniversitesi
Dr. Öğr. Üyesi Aycan Murat MARANGOZ, Zonguldak Bülent Ecevit Üniversitesi
Dr. Öğr. Üyesi Kurtuluş Sedar GÖRMÜŞ, Zonguldak Bülent Ecevit Üniversitesi
Dr. Öğr. Üyesi Hüseyin KEMALDERE, Zonguldak Bülent Ecevit Üniversitesi
Dr. Öğr. Üyesi Eray KÖKSAL, Zonguldak Bülent Ecevit Üniversitesi
Dr. Öğr. Üyesi İlke DENİZ, Zonguldak Bülent Ecevit Üniversitesi
Dr. Öğr. Üyesi Can ATALAY, Zonguldak Bülent Ecevit Üniversitesi
Dr. Öğr. Üyesi Volkan AKGÜL, Zonguldak Bülent Ecevit Üniversitesi
Dr. Öğr. Üyesi Nevin Betül AVŞAR, İzmir Katip Çelebi Üniversitesi
Öğr. Gör. Murat ORUÇ, Zonguldak Bülent Ecevit Üniversitesi
Yük. Müh. Beste Kılıç GÜNGÖR, Zonguldak Bülent Ecevit Üniversitesi

**Bilim Kurulu (Akademik unvan ve soyad alfabetik sırası ile)**
Prof. Dr. Saygın ABDİKAN, Hacettepe Üniversitesi

TASLAK

Prof. Dr. Devrim AKCA, Işık Üniversitesi
Prof. Dr. Özgün AKÇAY, Çanakkale Onsekiz Mart Üniversitesi
Prof. Dr. Selim AKSOY, Bilkent Üniversitesi
Prof. Dr. Ayhan ATEŞOĞLU, Bartın Üniversitesi
Prof. Dr. Uğur AVDAN, Eskişehir Teknik Üniversitesi
Prof. Dr. Cevdet Coşkun AYDIN, Hacettepe Üniversitesi
Prof. Dr. Filiz BEKTAŞ BALÇIK, İstanbul Teknik Üniversitesi
Prof. Dr. Bülent BAYRAM, Yıldız Teknik Üniversitesi
Prof. Dr. Süha BERBEROĞLU, Çukurova Üniversitesi
Prof. Dr. Gürcan BÜYÜKSALİH, İstanbul Üniversitesi
Prof. Dr. Zaide DURAN, İstanbul Teknik Üniversitesi
Prof. Dr. Hakan KARABÖRK, Konya Teknik Üniversitesi
Prof. Dr. Fevzi KARSLI, Karadeniz Teknik Üniversitesi
Prof. Dr. Taşkın KAVZOĞLU, Gebze Teknik Üniversitesi
Prof. Dr. Şinasi KAYA, İstanbul Teknik Üniversitesi
Prof. Dr. Şenol Hakan KUTOĞLU, Zonguldak Bülent Ecevit Üniversitesi
Prof. Dr. Derya MAKTAV, İstanbul Teknik Üniversitesi
Prof. Dr. Nebiye MUSAOĞLU, İstanbul Teknik Üniversitesi
Prof. Dr. Ali Özgün OK, Hacettepe Üniversitesi
Prof. Dr. Umut Güneş SEFERCİK, Gebze Teknik Üniversitesi
Prof. Dr. Elif SERTEL, İstanbul Teknik Üniversitesi
Prof. Dr. Filiz SUNAR, İstanbul Teknik Üniversitesi
Prof. Dr. Füsun BALIK ŞANLI, Yıldız Teknik Üniversitesi
Prof. Dr. Dursun Zafer ŞEKER, İstanbul Teknik Üniversitesi
Prof. Dr. Hüseyin TOPAN, Zonguldak Bülent Ecevit Üniversitesi
Prof. Dr. Tarık TÜRK, Sivas Cumhuriyet Üniversitesi
Prof. Dr. Mustafa TÜRKER, Hacettepe Üniversitesi
Prof. Dr. Naci YASTIKLI, Yıldız Teknik Üniversitesi
Prof. Dr. Ferruh YILDIZ, Konya Teknik Üniversitesi
Doç. Dr. Hakan AKÇIN, Zonguldak Bülent Ecevit Üniversitesi
Doç. Dr. Çağlar BAYIK, Zonguldak Bülent Ecevit Üniversitesi
Doç. Dr. Süleyman Sefa BİLGİLİOĞLU, Aksaray Üniversitesi
Doç. Dr. Ramazan Gökberk CİNBİŞ, Ortadoğu Teknik Üniversitesi
Doç. Dr. İsmail ÇÖLKESEN, Gebze Teknik Üniversitesi
Doç. Dr. Mustafa DİKHAN, Karadeniz Teknik Üniversitesi
Doç. Dr. Nusret DEMİR, Akdeniz Üniversitesi
Doç. Dr. Adalet DERVİŞOĞLU, İstanbul Teknik Üniversitesi
Doç. Dr. Alp ERTÜRK, Kocaeli Üniversitesi
Doç. Dr. Esra TUNÇ GÖRMÜŞ, Karadeniz Teknik Üniversitesi
Doç. Dr. Gökhan GÜRBÜZ, Zonguldak Bülent Ecevit Üniversitesi
Doç. Dr. Mürsel Ozan İNCETAŞ, Alanya Alaaddin Keykubat Üniversitesi
Doç. Dr. Hasan Bilgehan MAKİNECİ, Konya Teknik Üniversitesi
Doç. Dr. Tuğçe Özge Onur, Zonguldak Bülent Ecevit Üniversitesi
Doç. Dr. Caner ÖZCAN, Karabük Üniversitesi
Doç. Dr. Aliihsan ŞEKERTEKİN, Iğdır Üniversitesi
Doç. Dr. Okan YELER, Van Yüzüncü Yıl Üniversitesi

TASLAK

Dr. Öğr. Üyesi Hayrettin ACAR, Karadeniz Teknik Üniversitesi
Dr. Öğr. Üyesi Volkan AKGÜL, Zonguldak Bülent Ecevit Üniversitesi
Dr. Veysel Okan ATAK, IMPRO
Dr. Öğr. Üyesi Can ATALAY, Zonguldak Bülent Ecevit Üniversitesi
Dr. Öğr. Üyesi Emin Özgür AVŞAR, Çanakkale Onsekiz Mart Üniversitesi
Dr. Öğr. Üyesi Nevin Betül AVŞAR, İzmir Katip Çelebi Üniversitesi
Dr. Öğr. Üyesi Umut AYDAR, Çanakkale Onsekiz Mart Üniversitesi
Dr. Müh. Alb. Abdullah DEĞER, Harita Genel Müdürlüğü
Dr. Öğr. Üyesi İlke DENİZ, Zonguldak Bülent Ecevit Üniversitesi
Dr. Müh. Alb. Orhan FIRAT, Harita Genel Müdürlüğü
Dr. Öğr. Üyesi Kurtuluş Sedar GÖRMÜŞ, Zonguldak Bülent Ecevit Üniversitesi
Arş. Gör. Dr. Duygu ARIKAN İSPİR, Konya Teknik Üniversitesi
Dr. Kaan KALKAN, TÜBİTAK Uzay Teknolojileri Araştırma Enstitüsü
Dr. Öğr. Üyesi Hüseyin KEMALDERE, Zonguldak Bülent Ecevit Üniversitesi
Dr. Öğr. Üyesi Eray KÖKSAL, Zonguldak Bülent Ecevit Üniversitesi
Dr. Öğr. Üyesi Aycan Murat MARANGOZ, Zonguldak Bülent Ecevit Üniversitesi
Dr. Öğr. Üyesi Ömer Gökberk NARİN, Afyon Kocatepe Üniversitesi
Dr. Öğr. Üyesi Emirhan ÖZDEMİR, Iğdır Üniversitesi
Dr. Müh. Bnb. Hakan ŞAHİN, Harita Genel Müdürlüğü
Dr. Mustafa TEKE, TÜBİTAK Uzay Teknolojileri Araştırma Enstitüsü
Dr. Öğr. Üyesi  Ahmet Tarık TORUN, Ankara Hacı Bayram Veli Üniversitesi
Öğr. Gör. Dr. Nehir UYAR, Zonguldak Bülent Ecevit Üniversitesi
Dr. Öğr. Üyesi Mustafa ÜSTÜNER, Samsun Üniversitesi

**Sekreterya:**
Yük. Müh. Beste KILIÇ GÜNGÖR, Zonguldak Bülent Ecevit Üniversitesi

**Destek Personel:**
Halil BADEM, Zonguldak Bülent Ecevit Üniversitesi
Mert ALPAT, Zonguldak Bülent Ecevit Üniversitesi
Meriç BEKTAŞ, Zonguldak Bülent Ecevit Üniversitesi

TASLAK

# TUFUAB XIII. Teknik Sempozyumu
# Kurullar

| | |
|---|---|
| **18 Haziran 2025**<br>**Sezai Karakoç Kültür Merkezi**<br>**10.00-10:45** | **AÇILIŞ TÖRENİ**<br>**Saygı Duruşu ve İstiklal Marşı**<br>**Açılış Konuşmaları**<br>**TUFUAB Temsilci Kurum Sunumu** |
| **10.45-11.00** | **Ara** |
| **11.00-11.30** | **Sponsor Sunumları** |
| **11.30-13.00** | **Davetli Konuşmacı Oturumu**<br>**Oturum Başkanları:** Prof. Dr. Şenol Hakan Kutoğlu, Prof. Dr. Hüseyin Topan<br>**Gerçek Zamanlı Fotogrametri**, *Prof. Dr. Devrim Akca*<br>**SAR ile Deformasyon Belirleme**, *Prof. Dr. Andy Hooper* |
| **13.00-14.00** | **Öğle Yemeği - Mühendislik Fakültesi Ortak Bina İç Bahçesi** |

**18 Haziran Çarşamba - 14.00-15.10**

| **Prof. Dr. Refik Fenmen Amfisi (Yeşil Amfi)** | **Prof. Dr. Saadettin Ökten Amfisi (Turkuaz Amfi)** | **ZK-03** |
|---|---|---|
| **Oturum 1/1: Fotogrametri-I** | **Oturum ½: Deformasyon Belirleme** | **Oturum 1/3: Orman Yangını** |
| **Oturum Başkanı:**<br>Prof. Dr. Fevzi Karslı | **Oturum Başkanı:**<br>Doç. Dr. Çağlar Bayık | **Oturum Başkanı:**<br>Prof. Dr. Hakan Karabörk |
| **17498** - Derin Öğrenme Modelleri Kullanılarak Tekil Hava Görüntüsünden Yükseklik Çıkarımı<br>*Fırat Erdem, Ali Özgün Ok* | **17471** - Tektonik Hareketlere Bağlı Olarak Arazi Yüzey Deformasyonlarının İzlenmesi: Yunanistan Örneği<br>*Ahmet Batuhan Polat, Füsun Balık Şanlı, Özgün Akçay* | **17466** - Ormanlardaki Aktif Yangınların ve Yanmış Alanların Optik Uydu Görüntüleri ve Derin Öğrenme Yöntemi ile Belirlenmesi<br>*Yasin Demirel, Tarık Türk* |
| **17514** - Lineer Dönüşüm Yöntemi İle Metrik Olmayan Dijital Kamera Kalibrasyonu<br>*Orhan Kurt* | **17480** - Yalova'da Tektonik Hareketlerin Yol Açtığı Yüzey Deformasyonlarının SBAS-InSAR Analiziyle Değerlendirilmesi<br>*Fatih Bursalı, R. Cüneyt Erenoğlu, Süha Özden, Seray Çınar Yıldız* | **17478** - PlanetScope Uydu Görüntülerinden Derin Öğrenme Tabanlı Bölütleme ile Yanan Ormanlık Alanların Tespiti<br>*Melih Altay, Mustafa Türker* |
| **17578** - Yerden Görüntüye RFM Yöntemi Kullanılarak Göktürk-1 Stereo Pankromatik Görüntülerinden Üç Boyutlu Koordinat Hesabı<br>*Onur Erişik, Hüseyin Topan* | **17483** - Optik ve SAR Uydu Verilerinden Yüzey Deformasyonlarının Analizi: Sabiha Gökçen Havalimanı ve Çevresi<br>*Salih Tatcı, Berkay Korik, Esra Erten, Nebiye Musaoğlu* | **17482** - Uzaktan Algılama Yöntemleri ile Orman Yangını Şiddeti ve Toprak Üstü Biyokütle Yoğunluğu Değişimlerinin İncelenmesi: Mersin/Pembecik Örneği<br>*Göktuğ Yaşar Çukurlu, Furkan Veziro, Nusret Demir, Atticus Stovall* |
| **17617** - Fotogrametrik Nirengi Dengeleme İşlemlerinde Farklı İterasyonlarda Yer Kontrol Noktası ve Detay Noktası Kullanımının Doğruluğa Etkilerinin Araştırılması<br>*Gökhan Şencan, Orhan Fırat, Ercan Emirzeoğlu* | **17527** - SAR Uydu Görüntüleri ve InSAR Tekniği ile Deformasyon Analizi<br>*İrem Bakır, Veysel Okan Atak* | **17488** - Orman Yangınlarının Çok Ajanlı Sistemler ile Simüle Edilmesi<br>*Hayati Bilgin, İsmail Ercüment Ayazlı, Göktuğ Yaşar Çukurlu, Nusret Demir* |

Ara: 15.10-15.30

**18 Haziran Çarşamba - 15.30-16.40**

| **Prof. Dr. Refik Fenmen Amfisi (Yeşil Amfi)** | **Prof. Dr. Saadettin Ökten Amfisi (Turkuaz Amfi)** | **ZK-03** |
|---|---|---|
| **Oturum 2/1: Sınıflandırma - I** | **Oturum 2/2: Tarım-Orman** | **Oturum 2/3: Afet-I** |
| **Oturum Başkanı:**<br>Prof. Dr. Derya Maktav | **Oturum Başkanı:**<br>Prof. Dr. Ayhan Ateşoğlu | **Oturum Başkanı:**<br>Prof. Dr. Cevdet Coşkun Aydın |
| **17476** - Uydu Görüntülerinden Derin Öğrenme Yöntemleri ile Elektrik Yapısal Unsurlarının Tespiti<br>*Nebiye Musaoğlu, Gülşen Taşkın, Hüseyin Kaya, Esra Özaydın, Burcu Amirgan, Hasan Nayır, Umur Deveci* | **17475** - Küre Dağları Milli Parkı'nda S-Bant NovaSAR-1 ve Landsat 9 Veri Füzyonu ile Makine ve Derin Öğrenme Tabanlı Karbon Stoku Tahmini<br>*Eren Gürsoy Özdemir, Saygın Abdikan* | **17486** - Heyelan Duyarlılık Haritalarının Lojistik Regresyon Yöntemi ile Üretilmesi<br>*Derya Dilara Köse, Tarık Türk* |
| **17479** - Destek Vektör Makineleri Kullanılarak Arazi Kullanımı ve Arazi Örtüsü Sınıflandırmasında Polinom ve | **17529** - Patates Verimi ile Sentinel-2 Uydu Görüntüleriyle Üretilen Bitki İndeksleri | **17491** - Eskişehir İlinde Deprem Riski Altında Bulunan Kritik Altyapıların Değerlendirilmesi |

| | | | |
|---|---|---|---|
| | Doğrusal Kernel Fonksiyonlarının Karşılaştırmalı Analizi<br>*Mehmet Oktay Kutrak, Duygu Arıkan İspir, Ferruh Yıldız* | Arasındaki Korelasyonun İncelenmesi<br>*Barış Sucu, Ömer Gökberk Narin* | *Ahsen Çakı, Mehtap Özenen Kavlak, Alper Çabuk* |
| | **17593** - Arazi Örtüsü ve Arazi Kullanımı Sınıflandırmasında Landsat-9 Multispektral ve Pixxel TD-1 Hiperspektral Veri Setlerinin Karşılaştırmalı Analizi<br>*Fatih Fehmi Şimşek, Mustafa Üstüner, Kaan Kalkan* | **17538** - Şeker Pancarı'nın NDVI ile Fenolojik Evreleri ve Anomali Paternlerinin Analizi<br>*Osman Salih YILMAZ , Ceren Akgül, Füsun Balık Şanlı, Ramazan Güngör, Birol Kuru* | **17494** - Afet Sonrası Kentleşmenin Ekosistem Üzerindeki Etkileri: ML Tabanlı LST ve NDVI Analiziyle Hatay İncelemesi<br>*Alanur Yavuz, Alperen İnceer, Esra Tunç Görmüş, Volkan Yılmaz* |
| | **17621** - Sentinel-2 Verilerini Kullanarak Bulut Örtüsünün Işık Şiddeti ve Hava Sıcaklığı Üzerindeki Etkisinin Değerlendirilmesi<br>*Kazimierz Becek, Oya Burcu Akgül, Volkan Akgül* | **17558** - Zaman Serisi Sentinel-2 Uydu Görüntülerinden Derin Öğrenme ile Ürün Türü Tespiti<br>*İbrahim Yeğen, Oğuzhan Tosun, Mustafa Türker* | **17499** - Çanakkale'de Mekansal Kuraklık Hassasiyeti Analizi: Uzaktan Algılama Tabanlı Çok Zamanlı Bir Değerlendirme<br>*Egehan Alumert, Ahmet Batuhan Polat, Özgün Akçay* |
| Ara: 16.40-17.00 | | | |
| | **18 Haziran Çarşamba - 17.00-18.10** | | |
| **18 Haziran Çarşamba - 17.00-18.10** | **Prof. Dr. Refik Fenmen Amfisi (Yeşil Amfi)** | **Prof. Dr. Saadettin Ökten Amfisi (Turkuaz Amfi)** | **ZK-03** |
| | **Oturum 3/1: Nesne Tanıma** | **Oturum 3/2: Fotogrametri - II** | **Oturum 3/3: Sınıflandırma - II** |
| | **Oturum Başkanı:**<br>Prof. Dr. Bülent Bayram | **Oturum Başkanı:**<br>Dr. Müh. Alb. Orhan Fırat | **Oturum Başkanı:**<br>**Prof. Dr. Nebiye Musaoğlu** |
| | **17512** - Obje Tespiti Modellerinin Taşıt Sınıflarının Zenginleştirilmesine Yönelik Yeni Bir Veri Seti Oluşturulması<br>*Diren Yılmaz, Onur Can Bayrak, Muzaffer Can İban* | **17509** - Stereo Uydu Görüntülerinden Disparite Haritası Üretimi: RAFTStereo ve More Global Matching (MGM) Yöntemlerinin Karşılaştırması<br>*Yazgı Nur Sayın, Ali Özgün Ok* | **17500** - AutoGluon Kütüphanesinin Görüntü Sınıflandırmada Kullanımı: AutoML Uygulaması<br>*Berra Nur Tunç, Ümit Haluk Atasever* |
| | **17541** - Yüksek Çözünürlüklü Hava Görüntülerinden U-Net Tabanlı Otomatik Çatı Tespiti<br>*Ebru Kaya, Ekrem Ayyıldız* | **17556** - Dijital İkiz Üretiminde Filtreleme, Obje Tespiti ve 3B Modelleme<br>*Yiğitcan Cığır, Berkay Serhan Selvi, Feridun Tolga Solak, Umut Yusuf Kınacı, Melih Altay, Berk Anbaroğlu* | **17510** - Makine ve Derin Öğrenme Yaklaşımları ile RGB İHA Verilerinden NDVI Haritası Üretimi ve Performans Analizi<br>*İlyas Aydın, Umut Güneş Sefercik* |
| | **17544** - Derin Öğrenme Modelleri ile Kentsel Alanlarda Çok Sınıflı Bina Çatı Segmentasyonu<br>*Gurbet Budak, Elif Özlem Yılmaz, Taşkın Kavzoğlu* | **17559** - GNSS'siz Navigasyon: Otokodlayıcı Derin Sinir Ağları ile İHA Konumlama Sistemi<br>*Ahmet Ertuğrul Arık* | **17516** - Derin Öğrenme Temelli Kara ve Buzul Sınıflarının Otomatik Segmentasyonu<br>*Burak Demirhan, Onur Can Bayrak, Uğur Acar, Füsun Balık Şanlı, Ömer Gökberk Narin, Çağlar Bayık, Saygın Abdikan* |
| | **17606** - Sınıf Dengesizliği Probleminde U-Net++ ve U-Net3+ Mimari Performanslarının Analizi<br>*Süheyla Piltan Altaş, Fevzi Karslı* | **17582** - Fotogrametrik Yöntemlerle Deprem Sonrası Hasarlı Yapı Tespiti ve CBS Uygulamaları ile Zemin-Yapı Etkisinin İncelenmesi<br>*Uğur Gürbüz, Hüseyin Kemaldere* | **17525** - Transformatör ve Evrişimsel Sinir Ağı Tabanlı Mimariler ile Yüksek Çözünürlüklü İHA Görüntülerinden Bireysel Zeytin Ağacı Tespiti<br>*Esra Yıldırım, İsmail Çölkesen, Umut Güneş Sefercik* |
| | **Gala Yemeği – 19.30 – 24.00**<br>**Deniz Kulübü** | | |



# TUFUAB XIII. Teknik Sempozyumu
# Kurullar

| | 19 Haziran Perşembe - 09.30-10.40 | | |
|---|---|---|---|
| 19 Haziran Perşembe - 09.30-10.40 | **Prof. Dr. Refik Fenmen Amfisi (Yeşil Amfi)** | **Prof. Dr. Saadettin Ökten Amfisi (Turkuaz Amfi)** | **ZK-03** |
| | **Oturum 4/1: Çevre** | **Oturum 4/2: Sınıflandırma - III** | **Oturum 4/3: CBS - I** |
| | **Oturum Başkanı:** Dr. Öğr. Üyesi Volkan Akgül | **Oturum Başkanı:** Prof. Dr. Saygın Abdikan | **Oturum Başkanı:** Doç. Dr. Mustafa Dikhan |
| | **17511** - Yersel ve Uydu Tabanlı NO2 ve CO Parametrelerinin Sıcaklık ile İlişkisinin İstatistiksel Olarak Değerlendirilmesi: Kocaeli Örneği *Rümeysa Karataş, Elif Özler, Nur Yağmur Aydın* | **17536** - Uydu Görüntülerinde Gemi Tespiti için Bölge Tabanlı CNN Modellerinin Karşılaştırılması *Nuri Erkin Öçer, Uğur Avdan* | **17474** - Eskişehir İlinde Deprem Kırılganlığının Çok Kriterli Karar Analizi ve Oyun Teorisi Yaklaşımı ile CBS Ortamında Değerlendirilmesi *Murat Başeğmez, Ayhan Doğan, Cevdet Coşkun Aydın* |
| | **17533** - Farklı Yoğunluklardaki Zararlı Alg Patlamalarının Sentinel-2 Görüntüleriyle Tespitinde Alg Özgü Spektral İndeksler ve Derin Öğrenme Modellerinin Entegrasyonu *Mustafacan Saygı, İsmail Çölkesen, Meltem Çelen* | **17546** - ESA WorldCover ve ESRI Land Cover 2021 Arazi Örtü Veri Setlerinin Doğruluk değerlendirilmesi *Fidan Şevval Bulut, Ayhan Ateşoğlu, Emrah Acar* | **17530** - Afet Senaryolarında Parsel Bazlı Erişilebilirlik, Yol Genişliği ve Eğim Analizi: İstanbul Fikirtepe Örneği *Veysel Akatay, Aycan Murat Marangoz* |
| | **17551** - Uzaktan Algılama Verileri Kullanarak Kentsel Alanlarda Karbon Monoksit Salınımlarının Araştırılması *Duygu Arıkan İspir, Hasan Bilgehan Makineci* | **17548** - Derin Öğrenme Kullanılarak Yüksek Çözünürlüklü Görüntülerden Bina Segmentasyonu *İrem Kavas, Bahadır Kulavuz, Tolga Bakırman, Bülent Bayram* | **17531** - CBS Yöntemleriyle Açık Kaynak Kodlu Yazılımlar Kullanılarak Afet Bilgi Sistemi Oluşturulması: Şişli İlçesi Örneği *Süleyman Yılmaz, Aycan Murat Marangoz* |
| | **17561** - Orman Yangınları Sonrası Yanmış Alan Tespiti ve Haritalanmasında Makine Öğrenme Modellerinin Transfer Edilebilirliğinin Değerlendirilmesi *Gülce Başak Selçuk, Osman Yavuz Altuntaş, İsmail Çölkesen* | **17549** - Derin Öğrenme ile Yüksek Çözünürlüklü Uydu Görüntülerinden Çok Sınıflı Askeri Uçak Tespiti *Melih Karamustafa, Bahadır Kulavuz, Bülent Bayram, Tolga Bakırman* | **17555** - Topoğrafik Vektör Veritabanı(TOPOVT) için İşletim Sistemlerinin Önemi *Duygu Balcı* |
| Ara: 10.40-11.00 | | | |
| | **19 Haziran Perşembe - 11.00-12.10** | | |
| 19 Haziran Perşembe - 11.00-12.10 | **Prof. Dr. Refik Fenmen Amfisi (Yeşil Amfi)** | **Prof. Dr. Saadettin Ökten Amfisi (Turkuaz Amfi)** | **ZK-03** |
| | **Oturum 5/1: Afet-II** | **Oturum 5/2: 3B Modelleme** | **Oturum 5/3: Fotogrametri-III** |
| | **Oturum Başkanı:** Dr. Öğr. Üyesi Hüseyin Kemaldere | **Oturum Başkanı:** Dr. Öğr. Üyesi Can Atalay | **Oturum Başkanı:** Prof. Dr. Ali Özgün Ok |
| | **17545** - Heyelan Olmayan Örneklemlerin Seçimi için Kullanılan Yöntemlerin Heyelan Duyarlılık Haritalarının Doğruluğuna Etkisinin Araştırılması *Süeda Kaş, Buse Dallı, Elif Nur Yıldız, Alihan Teke, Taşkın Kavzoğlu* | **17560** - Nokta Bulutu Verilerinden 3B Bina Modeli Üretilmesi için QGIS Eklentisinin Geliştirilmesi *İlknur Mutlu Çetin, Ekrem Ayyıldız* | **17564** - Kültürel Miras Belgelenmesinde SLAM Tabanlı El Tipi LiDAR Sistemlerinin Değerlendirmesi: Palazzo della Fraternita dei Laici Örneği *Kasım Erdal, Büşranur Güvercin, Hasan Bilgehan Makineci* |
| | **17554** - Makine Öğrenmesi Yöntemleri Kullanılarak Zonguldak İli için Taşkın Riski Değerlendirmesi *Aydın Furkan Terzi, Gülşah Kılıç, Ayşenur Koçyiğit, Koray Aksu, Hande Demirel* | **17596** - Gerçek-Zamanlı Mobil Artırılmış Gerçeklik Sistemlerinde Konumsal Entegrasyonun Fotogrametrik Yaklaşımlarla Sağlanması *Burak Tavukçu, Sefa Tavukçu* | **17616** - Baz-Yükseklik Oranının, Uydu Görüntülerinden Üretilen Sayısal Yüzey Modeli Doğruluğuna Etkisi *Ertuğrul Avşar, Orhan Fırat, Gökhan Arasan, Hasan Güner* |
| | **17557** - Bornova Havzasında Fırtına Kabarmalarından Kaynaklanan Kıyı Taşkını Riskinin Değerlendirmesi: Senaryo Tabanlı Bir Yaklaşım *Çiğdem Coşkun Hepcan, Ahsen Tuğçe Yüksel , Aybüke Cangüzel , Şerif Hepcan, Yusuf Biçer, Ioan Cristian Ioja, Jürgen Breuste* | **17613** - Panoramik Görüntülerden Derin Öğrenme Segmentasyonu ile Gökyüzü Görünüm Faktörü Tahmini ve Kentsel Morfoloji ile Nicel İlişkisi *Şükrü Burak Çetin* | **17579** - Marmara Denizi ve Adalarını Kapsayan Yüksek Çözünürlüklü Worldview-2 Uydu Görüntüsünün Geometrik Doğruluk Düzeyinin Araştırılması *Gürcan Büyüksalih, Cem Gazioğlu, Karsten Jacobsen* |
| | **17573** - İstanbul Havalimanı'nın Yakın Çevresindeki Yüzey Kentsel Isı Adası Oluşumuna Etkisinin İncelenmesi | **17614** - Yoğun Kazı Çalışması Yapılan Sahalarda Oluşan Heyelan Alanlarının M3C2 | **17623** - TUFUAB Veri Havuzuna Ait Göktürk-1 Bindirmeli Pankromatik Seviye 2A Görüntülerinin Algılayıcıya |

| | | | |
|---|---|---|---|
| | *Mitat Can Yıldız, Emirhan Özdemir, Rüştü Çallı, Fehmi Veziroğlu, Aliihsan Şekertekin* | Çıktıları Kullanarak Belirlenmesi ve Sınırlandırılması<br>*Mehmet Güven Koçak, Nilüfer Özdaş, Osman Sami Kırtıloğlu, Nevin Betül Avşar* | Bağımlı Yöneltme Yöntemi İle 3B Konum Doğruluğunun Araştırılması<br>*Hüseyin Topan, Onur Erişik, Murat Oruç* |
| | **19 Haziran Perşembe - 12.10-13.00**<br>**Poster Oturumu**<br>**Oturum Başkanı:** Dr. Öğr. Üyesi Eray Köksal | | |
| Öğle Yemeği: 13:00 – 14: 00 | | | |
| | **19 Haziran Perşembe - 14.00-15.10** | | |
| **19 Haziran Perşembe - 14.00-15.10** | **Prof. Dr. Refik Fenmen Amfisi (Yeşil Amfi)** | **Prof. Dr. Saadettin Ökten Amfisi (Turkuaz Amfi)** | **ZK-03** |
| | **Oturum 6/1: Hidrografi** | **Oturum 6/2: Isıl Uzaktan Algılama** | **Oturum 6/3: Sınıflandırma-IV** |
| | **Oturum Başkanı:**<br>Dr. Öğr. Üyesi Kurtuluş Sedar Görmüş | **Oturum Başkanı:**<br>Prof. Dr. Gürcan Büyüksalih | **Oturum Başkanı:**<br>Doç. Dr. Hasan Bilgehan Makineci |
| | **17565** - Atatürk Barajı Su Alanı Değişimlerinin Uzaktan Algılama Verileri ve Makine Öğrenimi ile Modellenmesi<br>*Çağrı Kapusuz, Osman Orhan, Ahmet Tarık Torun* | **17576** - Kentsel Alanlarda Uydu Tabanlı Yüzey Sıcaklığı ve Yüzey Albedosu Arasındaki İlişkinin İncelenmesi: Zonguldak Örneği<br>*Rüştü Çallı, Emirhan Özdemir, Mitat Can Yıldız, Fehmi Veziroğlu, Aliihsan Şekertekin* | **17568** - DLGC-ABM: Ağaç Taç Segmentasyonu İçin Grafik Kesme ve Karınca Kolonisi Optimizasyonuna Dayalı Bir Yöntem<br>*Sude Gül Yel, Esra Tunç Görmüş* |
| | **17567** - Makine Öğrenmesi Temelli Marmara Bölgesi'ndeki Göl ve Baraj Alanlarının Değişim Analizi<br>*Tolga Işık, Onur Can Bayrak, Uğur Acar* | **17590** - Baraj İnşaatının Yer Yüzey Sıcaklığı Üzerindeki Etkilerinin Termal Uydu Görüntüleri ile Değerlendirilmesi<br>*Talha Taşkanat, Tolga Kaynak* | **17589** - Makine Öğrenmesi ile Uzaktan Algılama Verilerinde Yüksek Doğruluklu Detay Sınıflandırması Uygulaması<br>*Mikail Odacı, Burak Tavukcu* |
| | **17580** - Derin Öğrenme Yöntemleri ile RADAR Görüntülerinden Su Çıkarımı<br>*Ahmet Ali SOYSAL, Abdullah KAYI* | **17602** - Arazi Yüzey Sıcaklığı ve Kentsel Isı Adası Değişimlerinin Uzaktan Algılama ve CBS Kullanılarak Analizi: Ankara Altındağ İlçesi Örneği<br>*Mine Kaya, Nida Çelik Şimşek* | **17591** - Multispektral İHA Verileri ile Bitki İndeksi Çıkarımı İçin Kalibrasyon Panellerinin Gerekliliği<br>*Alperen Erdoğan, Ömer Mutluoğlu* |
| | **17627** - Eğirdir Gölü Su Seviyesi Değişimlerinin Sentinel-2 Uydu Görüntüleri ile NDWI Tabanlı Zamansal ve İstatistiksel Analizi<br>*Onur Kayaoğlu, Nevin Betül Avşar, Mehmet Güven Koçak, Osman Sami Kırtıloğlu* | **17608** - Bina Enerji Performansı Skoru Tahmini için Mekânsal Zekâ (GeoAI) Uygulama Analiz Araçlarının Geliştirilmesi<br>*Büşra Demirci, Süleyman Şişman, Arif Çağdaş Aydınoğlu* | **17624** - Filyos Serbest Bölgesindeki Arazi Değişiminin Rastgele Orman (RF), Destek Vektör Makinesi (SVM), Sınıflandırma ve Regresyon Ağaçları (CART) Makine Öğrenme Algoritmalarıyla Karşılaştırmalı İncelenmesi<br>*Rüveyda Tercan Köse, Hakan Akçın* |
| Ara: 15:10 – 15: 30 | | | |
| | **19 Haziran Perşembe - 15.30-16.40** | | |
| **19 Haziran Perşembe - 15.30-16.40** | **Prof. Dr. Refik Fenmen Amfisi (Yeşil Amfi)** | **Prof. Dr. Saadettin Ökten Amfisi (Turkuaz Amfi)** | **ZK-03** |
| | **Oturum 7/1: Görüntü İşleme** | **Oturum 7/2: CBS-II** | **Oturum 7/3: Sınıflandırma - V** |
| | **Oturum Başkanı:**<br>Dr. Öğr. Üyesi Aycan Murat Marangoz | **Oturum Başkanı:**<br>Doç. Dr. Hakan Akçın | **Oturum Başkanı:**<br>Dr. Kaan Kalkan |
| | **17562** - Süper Çözünürlük Uygulamasının Askeri Operasyonlara Etkisi – Sentinel-2 Uydu Görüntüsü Örneği<br>*Kürşat Samet Demir, Süleyman Sefa Bilgilioğlu* | **17581** - Metaveri, ISO 19115, HGM Metaveri Profili ve HGM-Geoportal<br>*Nurettin Çağlar Durdu, Dijle Boyacı* | **17472** - Ceyhan Deltası Zamansal Kıyı Çizgisi Değişimlerinin Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Yöntemleriyle İzlenmesi<br>*Ayşe Dağlıyar, Nihal Çevik, Zehra Taş, Gültekin Erten* |
| | **17570** - Ağırlıklı 2B Dönüşüm İle İyileştirilmiş Yüz Tanıma Algoritması<br>*Türker Akbulut, Orhan Kurt* | **17587** - TOPOVT Vektör Verilerinin Konumsal Doğruluklarının Araştırılması<br>*Talat Ağdaş, Levent Kuyumcu, Abdullah Saygılı* | **17594** - 1/25000 Ölçekli Haritaların Revizyon İhtiyacının Uzaktan Algılama ve Derin Öğrenme Yöntemleri ile Belirlenmesi<br>*Orhan Fırat, Nuri Erkin Öçer, Dilek Küçük Matcı, Sayed Ishaq Deliry ,* |

| | | | |
|---|---|---|---|
| | | | *Abdullah Saygılı , Altan Yılmaz, Uğur Avdan* |
| | **17622** - C Band SAR Uydu Misyonlarına Yönelik Köşe Yansıtıcı Geometrilerinin Radar Kesit Alanı (RKA) Açısından Karşılaştırmalı İncelenmesi<br>*Can Atalay, Umut Güneş Sefercik, Hakan Akçın* | **17598** - Makine Öğrenmesi Algoritmaları ile Toplu Gayrimenkul Değerlemede Aykırı Veri Belirleme Yöntemlerinin İncelenmesi<br>*Aysun Daşdemir, Süleyman Şişman, Arif Çağdaş Aydınoğlu* | **17605** - Çok Zamanlı SAR ve Optik Verilerin Entegrasyonu ile Çeltik Bitki Boyu Analizi ve Ürün Deseni Sınıflandırması<br>*Mert Alpat, Meriç Bektaş, Çağlar Bayık, Ömer Gökberk Narin, Aliihsan Şekertekin, Mustafa Üstüner, Mustafa Tolga Esetlili, Füsun Balık Şanlı, Yusuf Kurucu, Saygın Abdikan* |
| | **17631** - Gemi Batıklarının Batimetri Tekniği ile Bulunması; Arvin Gemisi Örneği<br>*Kurtuluş Sedar Görmüş, Şevki Ünal* | **17601** - 3 Boyutlu Coğrafi Verilerden OGC Standardı 3D Tiles'ların Otomatik ve Hiyerarşik Olarak Oluşturulması<br>*Rümeysa Kabakcı, Talha Öztürk, Harun Uğuz, Hakan Şahin* | **17620** - Fotogrametrik Verilerden Yarı-Otomatik Yöntemle Üretilen CityGML Modellerinin Çatı Tipine Göre Tam Otomatik Yöntemle Sınıflandırılması<br>*Hasan Onur Işık* |
| **19 Haziran Perşembe - 16.40-17.00**<br>**Kapanış**<br>Fuaye Alanı | | | |

**Poster Oturumu**

**Oturum Başkanı: Dr. Öğr. Üyesi Eray Köksal**

19 Haziran Perşembe – 12.10-13.00

**17460** - Deniz Kazalarının Makine Öğrenmesi ile Coğrafik Olarak Kümelenmesi: Türkiye Karasuları, *Selim Durna*

**17463** - Alansal Olarak Farklı Geometrik Açıdan Benzer Akarsu Havzalarında Taşkın Potansiyeli, *Rabia Uzun, Mustafa Utlu*

**17481** - ArcSAR Radar Sisteminin Coğrafi Bilgi Sistemlerine Entegresi, *Arif Aydın*

**17487** - Mini İHA'lar ile Görüntü İşleme ve Harita Üretimi, *Abdulsamet Aktaş, Samet Küçükbıçakcı*

**17507** - Yağmur Suyu Hasadı Yapılacak Optimum Alanların Belirlenmesi ve Kuraklık Özelliklerinin İncelenmesi: Demirci İlçesi Örneği, *Ramazan Güngör, Emine Müjgan Ergene, Füsun Balık Şanlı, Ali Murat Ateş, Osman Salih Yılmaz*

**17508** - Yangınların Coğrafi Dinamikleri: Gelibolu Yarımadası'nda Uzaktan Algılama ve CBS ile Analizi, *Seda Çakır, Mesut Doğan*

**17532** - Uzaktan Algılama Verilerini Kullanarak Türkiye'deki Sıcaklık, Yağış ve Bitki Örtüsü Değişimlerinin İklim Sınıflandırması ve Analizi, *Nehir Uyar, Azize Uyar*

**17534** - Google Earth Engine Tabanlı Spektral İndeksler ve Rastgele Orman Algoritması ile Yanmış Alanların Belirlenmesi: 2022 Yılı Muğla-Marmaris Orman Yangını Örneği, *Başak Gürdal, Damlanur Alkan, Lütfiye Karasaka*

**17535** - Mekânsal Yapay Zeka Uygulamaları ve Düşündürdükleri, *Arda Günay, Bilal Erkek, Ekrem Ayyıldız*

**17540** - 3B Şehir Modellerinin İyileştirilmesi İçin Metodoloji Önerisi, *Gülay Karabaş, Bilal Erkek, Ekrem Ayyıldız*

**17552** - İnsansız Hava Araçlarında İrtifa Tahmini İçin Derin Öğrenme Yaklaşımı, *Ahmet Ertuğrul Arık*

**17563** - GEDI ve Sentinel-2 Verilerinin Yapay Zeka Tabanlı Yaklaşımlarla Entegrasyonu: Orman Bitki Örtüsü Tepe Yüksekliğinin Modellenmesi, *Sefa Karabaş, Gülay Karabaş*

**17566** - Farklı Derin Öğrenme Tabanlı Segmentasyon Mimarileri Kullanılarak Gerçek Ortofoto ve Sayısal Yüzey Modeli ile Kayıt Dışı Yapıların Belirlenmesi, *Güray Çetin, Ekrem Ayyıldız*

**17584** - Coğrafi Bilgi Sistemleri Tabanlı Çok Kriterli Sel Riski Analizi: E034N41 Hücresi Örneği, *Emre Orbay, Burak Şengül , Kadir Sencer Tapan*

**17586** - Harita Genel Müdürlüğünce Üretilen Coğrafi Verilerin Paylaşılması, *Murat Bölme, Dijle Boyacı*

**17600** - Konut Şantiyelerinde 3B Coğrafi Bilgi Sistemi Oluşturulması, *Kenan Berke Babaoğlu, Mustafa Ümit Gümüşay*

## GENİŞLETİLMİŞ ÖZET BİLDİRİLER

**Gerçek Zamanlı Fotogrametri ..... 21**

M. Devrim Akca .....21

**Deformation Identification with InSAR ..... 23**

Andy Hooper .....23

**Deniz Kazalarının Makine Öğrenmesi ile Coğrafik Olarak Kümelenmesi: Türkiye Karasuları... 24**

Selim Durna .....24

**Alansal Olarak Farklı Geometrik Açıdan Benzer Akarsu Havzalarında Taşkın Potansiyeli ..... 27**

Rabia Uzun, Mustafa Utlu .....27

**Mobil cihazlarda entegre LiDAR sensörlerinin konumsal doğruluğunun incelenmesi**Hata! Yer işareti tanımlanmamış.

Abdurahman Yasin Yiğit, Halil İbrahim Şenol, Ali Ulvi .....**Hata! Yer işareti tanımlanmamış.**

**İHA Tabanlı Fotogrametrik Ürünlerin Doğruluk Analizinde YKN ve Denetleme Noktaları Dağılımının Etkisi .....**Hata! Yer işareti tanımlanmamış.

Abdurahman Yasin Yiğit, Ali Ulvi, Osman Orhan .....**Hata! Yer işareti tanımlanmamış.**

**Ormanlardaki Aktif Yangınların ve Yanmış Alanların Optik Uydu Görüntüleri ve Derin Öğrenme Yöntemi ile Belirlenmesi ..... 30**

Yasin Demirel, Tarık Türk .....30

**Tektonik Hareketlere Bağlı Olarak Arazi Yüzey Deformasyonlarının İzlenmesi: Yunanistan Örneği ..... 33**

Ahmet Batuhan Polat, Füsun Balık Şanlı, Özgün Akçay .....33

**Eskişehir İlinde Deprem Kırılganlığının Çok Kriterli Karar Analizi ve Oyun Teorisi Yaklaşımı ile CBS Ortamında Değerlendirilmesi ..... 36**

Murat Başeğmez, Ayhan Doğan, Cevdet Coşkun Aydın .....36

**Küre Dağları Milli Parkı'nda S-Bant NovaSAR-1 ve Landsat 9 Veri Füzyonu ile Makine ve Derin Öğrenme Tabanlı Karbon Stoku Tahmini ..... 40**

Eren Gürsoy Özdemir, Saygın Abdikan .....40

**Uydu Görüntülerinden Derin Öğrenme Yöntemleri ile Elektrik Yapısal Unsurlarının Tespiti ..... 43**

Nebiye Musaoğlu, Gülşen Taşkın, Hüseyin Kaya, Esra Özaydın, Burcu Amirgan, Hasan Nayır, Umur Deveci .....43

**PlanetScope Uydu Görüntülerinden Derin Öğrenme Tabanlı Bölütleme ile Yanan Ormanlık Alanların Tespiti ..... 46**

Melih Altay, Mustafa Türker .....46

**Yalova'da Tektonik Hareketlerin Yol Açtığı Yüzey Deformasyonlarının SBAS-InSAR Analiziyle Değerlendirilmesi ..... 52**

Fatih Bursalı, R. Cüneyt Erenoğlu, Süha Özden, Seray Çınar Yıldız .....52

**ArcSAR Radar Sisteminin Coğrafi Bilgi Sistemlerine Entegresi ..... 56**

Arif Aydın .....56

TASLAK

**Uzaktan Algılama Yöntemleri ile Orman Yangını Şiddeti ve Toprak Üstü Biyokütle Yoğunluğu Değişimlerinin İncelenmesi: Mersin/Pembecik Örneği ..... 59**

Göktuğ Yaşar Çukurlu, Furkan Veziro, Nusret Demir, Atticus Stovall .....59

**Heyelan Duyarlılık Haritalarının Lojistik Regresyon Yöntemi ile Üretilmesi ..... 62**

derya Dilara Köse, Tarık Türk .....62

**Orman Yangınlarının Çok Ajanlı Sistemler ile Simüle Edilmesi ..... 68**

hayati Bilgin, İsmail Ercüment Ayazlı, Göktuğ Yaşar Çukurlu, Nusret Demir .....68

**ESKİŞEHİR İLİNDE DEPREM RİSKİ ALTINDA BULUNAN KRİTİK ALTYAPILARIN DEĞERLENDİRİLMESİ ..... 71**

Ahsen Çakı, Mehtap Özenen Kavlak, Alper Çabuk .....71

**Afet Sonrası Kentleşmenin Ekosistem Üzerindeki Etkileri: ML Tabanlı LST ve NDVI Analiziyle Hatay İncelemesi ..... 75**

Alanur Yavuz, Alperen İnceer, Esra Tunç Görmüş, Volkan Yılmaz .....75

**Derin Öğrenme Modelleri Kullanılarak Tekil Hava Görüntüsünden Yükseklik Çıkarımı..... 79**

Fırat Erdem, Ali Özgün Ok.....79

**Çanakkale'de Mekansal Kuraklık Hassasiyeti Analizi: Uzaktan Algılama Tabanlı Çok Zamanlı Bir Değerlendirme ..... 82**

Egehan Alumert, Ahmet Batuhan Polat, Özgün Akçay .....82

**AutoGluon Kütüphanesinin Görüntü Sınıflandırmada Kullanımı: AutoML Uygulaması ..... 86**

Berra Nur Tunç, Ümit Haluk Atasever .....86

**Yangınların Coğrafi Dinamikleri: Gelibolu Yarımadası'nda Uzaktan Algılama ve CBS ile Analizi ..... 90**

Seda Çakır, Mesut Doğan .....90

**Stereo Uydu Görüntülerinden Disparite Haritası Üretimi: RAFTStereo ve More Global Matching (MGM) Yöntemlerinin Karşılaştırması ..... 92**

Yazgı Nur Sayın, Ali Özgün Ok .....92

**Makine ve Derin Öğrenme Yaklaşımları ile RGB İHA Verilerinden NDVI Haritası Üretimi ve Performans Analizi ..... 95**

İlyas Aydın, Umut Güneş Sefercik .....95

**Yersel ve Uydu Tabanlı $NO_2$ ve CO Parametrelerinin Sıcaklık ile İlişkisinin İstatistiksel Olarak Değerlendirilmesi: Kocaeli Örneği..... 98**

Rümeysa Karataş, Elif Özler, Nur Yağmur Aydın .....98

**Obje Tespiti Modellerinin Taşıt Sınıflarının Zenginleştirilmesine Yönelik Yeni Bir Veri Seti Oluşturulması..... 101**

Diren Yılmaz, Onur Can Bayrak, Muzaffer Can İban .....101

**Lineer Dönüşüm Yöntemi İle Metrik Olmayan Dijital Kamera Kalibrasyonu**Hata! Yer işareti tanımlanmamış.

Orhan Kurt .....**Hata! Yer işareti tanımlanmamış.**

**Derin Öğrenme Temelli Kara ve Buzul Sınıflarının Otomatik Segmentasyonu..... 108**

TASLAK

Burak Demirhan, Onur Can Bayrak, Uğur Acar, Füsun Balık Şanlı, Ömer Gökberk Narin, Çağlar Bayık, Saygın Abdikan.....108

**Transformatör ve Evrişimsel Sinir Ağı Tabanlı Mimariler ile Yüksek Çözünürlüklü İHA Görüntülerinden Bireysel Zeytin Ağacı Tespiti.....111**

Esra Yıldırım, İsmail Çölkesen, Umut Güneş Sefercik.....111

**SAR Uydu Görüntüleri ve InSAR Tekniği ile Deformasyon Analizi.....115**

İrem Bakır, Veysel Okan Atak.....115

**Patates Verimi ile Sentinel-2 Uydu Görüntüleriyle Üretilen Bitki indeksleri Arasındaki Korelasyonun İncelenmesi.....118**

Barış Sucu, Ömer Gökberk Narin.....118

**Afet Senaryolarında Parsel Bazlı Erişilebilirlik, Yol Genişliği ve Eğim Analizi: İstanbul Fikirtepe Örneği.....121**

Veysel Akatay, Aycan Murat Marangoz.....121

**CBS Yöntemleriyle Açık Kaynak Kodlu Yazılımlar Kullanılarak Afet Bilgi Sistemi Oluşturulması: Şişli İlçesi Örneği.....124**

Süleyman Yılmaz, Aycan Murat Marangoz.....124

**Uzaktan Algılama Verilerini Kullanarak Türkiye'deki Sıcaklık, Yağış ve Bitki Örtüsü Değişimlerinin İklim Sınıflandırması ve Analizi.....127**

Nehir Uyar, Azize Uyar.....127

**Farklı Yoğunluklardaki Zararlı Alg Patlamalarının Sentinel-2 Görüntüleriyle Tespitinde Alg Özgü Spektral İndeksler ve Derin Öğrenme Modellerinin Entegrasyonu.....128**

Mustafacan Saygı, İsmail Çölkesen, Meltem Çelen.....128

**Google Earth Engine Tabanlı Spektral İndeksler ve Rastgele Orman Algoritması ile Yanmış Alanların Belirlenmesi: 2022 Yılı Muğla-Marmaris Orman Yangını Örneği.....132**

Başak Gürdal, Damlanur Alkan, Lütfiye Karasaka.....132

**Mekânsal Yapay Zeka Uygulamaları ve Düşündürdükleri.....135**

Arda Günay, Bilal Erkek, Ekrem Ayyıldız.....135

**Şeker Pancarı'nın NDVI ile Fenolojik Evreleri ve Anomali Paternlerinin Analizi.....139**

Osman Salih Yılmaz, Ceren Akgül, Füsun Balık Şanlı, Ramazan Güngör, Birol Kuru.....139

**Landsat-8 ve Sentinel-2 Görüntüleriyle Google Earth Engine Platformunda Arazi Sürdürülebilirliğinin İzlenmesi.....**Hata! Yer işareti tanımlanmamış.

Gülay Karabaş, Ekrem Ayyıldız.....**Hata! Yer işareti tanımlanmamış.**

**3B Şehir Modellerinin İyileştirilmesi İçin Metodoloji Önerisi.....142**

Gülay Karabaş, Bilal Erkek, Ekrem Ayyıldız.....142

**Yüksek Çözünürlüklü Hava Görüntülerinden U-Net Tabanlı Otomatik Çatı Tespiti.....145**

Ebru Kaya, Ekrem Ayyıldız.....145

**Derin Öğrenme Modelleri ile Kentsel Alanlarda Çok Sınıflı Bina Çatı Segmentasyonu.....148**

Gurbet Budak, Elif Özlem Yılmaz, Taşkın Kavzoğlu.....148

**Heyelan Olmayan Örneklemlerin Seçimi için Kullanılan Yöntemlerin Heyelan Duyarlılık Haritalarının Doğruluğuna Etkisinin Araştırılması.....152**

TASLAK

Süeda Kaş, Buse Dallı, Elif Nur Yıldız, Alihan Teke, Taşkın Kavzoğlu ..... 152

**ESA WorldCover ve ESRI Land Cover 2021 Arazi Örtü Veri Setlerinin Doğruluk Değerlendirilmesi ..... 156**

Fidan Şevval Bulut, Ayhan Ateşoğlu, Emrah Acar ..... 156

**Depremlerde Bina Yıkılmasına Bağlı Kapanacak Yolların Monte Carlo Simülasyonu ve Coğrafi Bilgi Sistemleri ile Tespit Edilmesi ..... 159**

Sefanur Doğan, Resul Çömert, Onur Kaplan ..... 159

**Derin Öğrenme Kullanılarak Yüksek Çözünürlüklü Görüntülerden Bina Segmentasyonu ..... 164**

İrem Kavas, Bahadır Kulavuz, Tolga Bakırman, Bülent Bayram ..... 164

**Derin Öğrenme ile Yüksek Çözünürlüklü Uydu Görüntülerinden Çok Sınıflı Askeri Uçak Tespiti ..... 167**

Melih Karamustafa, Bahadır Kulavuz, Bülent Bayram, Tolga Bakırman ..... 167

**Mekansal-Zamansal Yoğunluk Tabanlı Kümeleme Algoritması ile Deprem Analizi: 2025 Santorini Deprem Fırtınası Örneği .....** Hata! Yer işareti tanımlanmamış.

Batuhan Kılıç ..... **Hata! Yer işareti tanımlanmamış.**

**İnsansız Hava Araçlarında İrtifa Tahmini İçin Derin Öğrenme Yaklaşımı ..... 170**

Ahmet Ertuğrul Arık ..... 170

**Makine Öğrenmesi Yöntemleri Kullanılarak Zonguldak İli için Taşkın Riski Değerlendirmesi .. 171**

Aydın Furkan Terzi, Gülşah Kılıç, Ayşenur Koçyiğit, Koray Aksu, Hande Demirel ..... 171

**Dijital İkiz Üretiminde Filtreleme, Obje Tespiti ve 3B Modelleme....** Hata! Yer işareti tanımlanmamış.

Yiğitcan Cığır, Berkay Serhan Selvi, Feridun Tolga Solak, Umut Yusuf Kınacı, Melih Altay, Berk Anbaroğlu ..... **Hata! Yer işareti tanımlanmamış.**

**Bornova Havzasında Fırtına Kabarmalarından Kaynaklanan Kıyı Taşkını Riskinin Değerlendirmesi: Senaryo Tabanlı Bir Yaklaşım ..... 174**

Çiğdem Coşkun Hepcan, Ahsen Tuğçe Yüksel, Aybüke Cangüzel, Şerif Hepcan, Yusuf Biçer, Ioan Cristian Ioja, Jürgen Breuste ..... 174

**GNSS'siz Navigasyon: Otokodlayıcı Derin Sinir Ağları ile İHA Konumlama Sistemi ..... 178**

Ahmet Ertuğrul Arık ..... 178

**Nokta Bulutu Verilerinden 3B Bina Modeli Üretilmesi için QGIS Eklentisinin Geliştirilmesi..... 181**

İlknur Mutlu Çetin Ekrem Ayyıldız ..... 181

**Orman Yangınları Sonrası Yanmış Alan Tespiti ve Haritalanmasında Makine Öğrenme Modellerinin Transfer Edilebilirliğinin Değerlendirilmesi ..... 185**

Gülce Başak Selçuk, Osman Yavuz Altuntaş, İsmail Çölkesen ..... 185

**GEDI ve Sentinel-2 Verilerinin Yapay Zeka Tabanlı Yaklaşımlarla Entegrasyonu: Orman Bitki Örtüsü Tepe Yüksekliğinin Modellenmesi ..... 188**

Sefa Karabaş, Gülay Karabaş ..... 188

**Kültürel Miras Belgelenmesinde SLAM Tabanlı El Tipi LiDAR Sistemlerinin Değerlendirmesi: Palazzo della Fraternita dei Laici Örneği ..... 192**

Kasım Erdal, Büşranur Güvercin, Hasan Bilgehan Makineci ..... 192

TASLAK

**Atatürk Barajı Su Alanı Değişimlerinin Uzaktan Algılama Verileri ve Makine Öğrenimi ile Modellenmesi ..... 197**

Çağrı Kapusuz, Osman Orhan, Ahmet Tarık Torun ..... 197

**Farklı Derin Öğrenme Tabanlı Segmentasyon Mimarileri Kullanılarak Gerçek Ortofoto ve Sayısal Yüzey Modeli ile Kayıt Dışı Yapıların Belirlenmesi ..... 200**

Güray Çetin› Ekrem Ayyıldız ..... 200

**Makine Öğrenmesi Temelli Marmara Bölgesi'ndeki Göl ve Baraj Alanlarının Değişim Analizi . 204**

Tolga Işık, Onur Can Bayrak, Uğur Acar ..... 204

**DLGC-ABM: Ağaç Taç Segmentasyonu için Grafik Kesme ve Karınca Kolonisi Optimizasyonuna Dayalı Bir Yöntem ..... 207**

Sude Gül Yel, Esra Tunç Görmüş ..... 207

**Ağırlıklı 2B Dönüşüm İle İyileştirilmiş Yüz Tanıma Algoritması ..... 211**

Türker Akbulut, Orhan Kurt ..... 211

**İstanbul Havalimanı'nın Yakın Çevresindeki Yüzey Kentsel Isı Adası Oluşumuna Etkisinin İncelenmesi ..... 214**

Mitat Can Yıldız, Emirhan Özdemir, Rüştü Çallı, Fehmi Veziroğlu, Aliihsan Şekertekin ..... 214

**Kentsel Alanlarda Uydu Tabanlı Yüzey Sıcaklığı ve Yüzey Albedosu Arasındaki İlişkinin İncelenmesi: Zonguldak Örneği ..... 217**

Rüştü Çallı, Emirhan Özdemir, Mitat Can Yıldız, Fehmi Veziroğlu, Aliihsan Şekertekin ..... 217

**Marmara Denizi ve Adalarını Kapsayan Yüksek Çözünürlüklü Worldview-2 Uydu Görüntüsünün Geometrik Doğruluk Düzeyinin Araştırılması ..... 220**

Gürcan Büyüksalih, Cem Gazioğlu, Karsten Jacobsen ..... 220

**Derin Öğrenme Yöntemleri ile RADAR Görüntülerinden Su Çıkarımı ..... 223**

Ahmet Ali Soysal, Abdullah Kayı ..... 223

**Fotogrametrik Yöntemlerle Deprem Sonrası Hasarlı Yapı Tespiti ve CBS Uygulamaları ile Zemin-Yapı Etkisinin İncelenmesi ..... 227**

Uğur Gürbüz, Hüseyin Kemaldere ..... 227

**Coğrafi Bilgi Sistemleri Tabanlı Çok Kriterli Sel Riski Analizi: E034N41 Hücresi Örneği ..... 230**

Emre Orbay, Burak Şengül, Kadir Sencer Tapan ..... 230

**Baraj İnşaatının Yer Yüzey Sıcaklığı Üzerindeki Etkilerinin Termal Uydu Görüntüleri ile Değerlendirilmesi ..... 234**

Talha Taşkanat, Tolga Kaynak ..... 234

**Multispektral İHA Verileri ile Bitki İndeksi Çıkarımı İçin Kalibrasyon Panellerinin Gerekliliği 238**

Alperen Erdoğan, Ömer Mutluoğlu ..... 238

**1/25000 Ölçekli Haritaların Revizyon İhtiyacının Uzaktan Algılama ve Derin Öğrenme Yöntemleri ile Belirlenmesi ..... 241**

Orhan Fırat, Nuri Erkin Öçer, Dilek Küçük Matcı, Sayed Ishaq Deliry, Abdullah Saygılı, Altan Yılmaz, Uğur Avdan ..... 241

**Makine Öğrenmesi Algoritmaları ile Toplu Gayrimenkul Değerlemede Aykırı Veri Belirleme Yöntemlerinin İncelenmesi ..... 245**

TAPLAK

Aysun Daşdemir, Süleyman Şişman, Arif Çağdaş Aydınoğlu .....245

**Konut Şantiyelerinde 3B Coğrafi Bilgi Sistemi Oluşturulması..... 248**

Kenan Berke BABAOĞLU, Mustafa Ümit GÜMÜŞAY.....248

**3 Boyutlu Coğrafi Verilerden OGC Standardı 3D Tiles'ların Otomatik ve Hiyerarşik Olarak Oluşturulması..... 251**

Rümeysa Kabakcı, Talha Öztürk, Harun Uğuz, Hakan Şahin .....251

**Arazi Yüzey Sıcaklığı ve Kentsel Isı Adası Değişimlerinin Uzaktan Algılama ve CBS Kullanılarak Analizi: Ankara Altındağ İlçesi Örneği ..... 254**

Mine Kaya, Nida Çelik Şimşek.....254

**Yerel Yönetimlerde Fotogrametri Tabanlı Harita Üretim Süreçleri: İstanbul Büyükşehir Belediyesi Örneği .....**Hata! Yer işareti tanımlanmamış.

Ahmet Güntel, Fatih Esirtgen, Serap Sözgen, Osman Aydın, Ülger Munzuroğlu, Tayfun Baydemir, Dursun Zafer Şeker.....**Hata! Yer işareti tanımlanmamış.**

**Çok Zamanlı SAR ve Optik Verilerin Entegrasyonu ile Çeltik Bitki Boyu Analizi ve Ürün Deseni Sınıflandırması..... 260**

Mert Alpat, Meriç Bektaş, Çağlar Bayık, Ömer Gökberk Narin, Aliihsan Şekertekin,Mustafa Üstüner, Mustafa Tolga Esetlili, Füsun Balık Şanlı, Yusuf Kurucu, Saygın Abdikan .....260

**Sınıf Dengesizliği Probleminde U-Net++ ve U-Net3+ Mimari Performanslarının Analizi ..... 264**

Süheyla Piltan Altaş, Fevzi Karslı, .....264

**Attention U-Net Mimarisinin Bina Tespit Performansına Kayıp Fonksiyonlarının Etkilerinin İrdelenmesi .....**Hata! Yer işareti tanımlanmamış.

Süheyla Piltan Altaş, Fevzi Karslı .....**Hata! Yer işareti tanımlanmamış.**

**Bina Enerji Performansı Skoru Tahmini için Mekânsal Zekâ (GeoAI) Uygulama Analiz Araçlarının Geliştirilmesi ..... 267**

Büşra Demirci, Süleyman Şişman, Arif Çağdaş Aydınoğlu .....267

**Derin Öğrenme Tabanlı Yöntemlerle Göktürk-1 Uydu Görüntülerinin Çözünürlüğünün Artırılması.....**Hata! Yer işareti tanımlanmamış.

Tuğsem Çetkin, Samet Bucak, Ilgın Çiğdem, Kaan Erdoğan, Atakan Demirezen**Hata! Yer işareti tanımlanmamış.**

**İstanbul Örneği Üzerinden Fotogrametrik Stereo Modellerden Türetilen CityGML Bina Verilerinin Doğrulama Süreçleri .....**Hata! Yer işareti tanımlanmamış.

Hasan Onur Işık, Kutay Tınaz, Şeyma Perk, Osman Aydın, Ülger Munzuroğlu, Tayfun Baydemir, Dursun Zafer Şeker.....**Hata! Yer işareti tanımlanmamış.**

**Panoramik Görüntülerden Derin Öğrenme Segmentasyonu ile Gökyüzü Görünüm Faktörü Tahmini ve Kentsel Morfoloji ile Nicel İlişkisi ..... 270**

Şükrü Burak Çetin.....270

**Yoğun Kazı Çalışması Yapılan Sahalarda Oluşan Heyelan Alanlarının M3C2 Çıktıları Kullanarak Belirlenmesi ve Sınırlandırılması ..... 274**

Mehmet Güven Koçak, Nilüfer Özdaş, Osman Sami Kırtıloğlu, Nevin Betül Avşar .....274

**Türkiye'nin Ege Denizi Kıyılarında Deniz Seviyesi Değişimleri .....**Hata! Yer işareti tanımlanmamış.

TASLAK

Nilüfer Özdaş, Nevin Betül Avşar, Mehmet Güven Koçak, Osman Sami Kırtıloğlu**Hata! Yer işareti tanımlanmamış.**

**Baz-Yükseklik Oranının, Uydu Görüntülerinden Üretilen Sayısal Yüzey Modeli Doğruluğuna Etkisi ..... 277**

Ertuğrul Avşar, Orhan Fırat, Gökhan Arasan, Hasan Güner .....277

**Fotogrametrik Nirengi Dengeleme İşlemlerinde Farklı İterasyonlarda Yer Kontrol Noktası ve Detay Noktası Kullanımının Doğruluğa Etkilerinin Araştırılması ..... 281**

Gökhan Şencan, Orhan Fırat, Ercan Emirzeoğlu.....281

**Dijital Şehir İkizi Üretiminde "Mesh ve Solid" Model Karşılaştırması İstanbul Örneği**Hata! Yer işareti tanımlanmamış.

Ahmet Güntel, Fatih Esirtgen, Serap Sözgen, Osman Aydın, Ülger Munzuroğlu, Tayfun Baydemir, Dursun Zafer Şeker.....**Hata! Yer işareti tanımlanmamış.**

**Fotogrametrik Verilerden Yarı-Otomatik Yöntemle Üretilen CityGML Modellerinin Çatı Tipine Göre Tam Otomatik Yöntemle Sınıflandırılması..... 289**

Hasan Onur Işık .....289

**TUFUAB Veri Havuzuna Ait Göktürk-1 Bindirmeli Pankromatik Seviye 2A Görüntülerinin Algılayıcıya Bağımlı Yöneltme Yöntemi İle 3B Konum Doğruluğunun Araştırılması ..... 405**

Hüseyin Topan, Onur Erişik, Murat Oruç.....405

**Dijital İkiz Üretiminde Filtreleme, Obje Tespiti ve 3B Modelleme..... 409**

Yiğitcan Cığır, Berkay Serhan Selvi, Feridun Tolga Solak, Umut Yusuf Kınacı, Melih Altay, Berk Anbaroğlu .....409

TASLAK

## TAM METİN BİLDİRİLER

**Ceyhan Deltası Zamansal Kıyı Çizgisi Değişimlerinin Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Yöntemleriyle İzlenmesi ..... 293**

Ayşe Dağlıyar, Nihal Çevik, Zehra Taş, Gültekin Erten ..... 293

**Destek Vektör Makineleri Kullanılarak Arazi Kullanımı ve Arazi Örtüsü Sınıflandırmasında Polinom ve Doğrusal Kernel Fonksiyonlarının Karşılaştırmalı Analizi ..... 298**

Mehmet Oktay Kutrak, Duygu Arıkan İspir, Ferruh Yıldız ..... 298

**Optik ve SAR Uydu Verilerinden Yüzey Deformasyonlarının Analizi: Sabiha Gökçen Havalimanı ve Çevresi ..... 306**

Salih Tatcı, Berkay Korik, Esra Erten, Nebiye Musaoğlu ..... 306

**Yağmur Suyu Hasadı Yapılacak Optimum Alanların Belirlenmesi ve Kuraklık Özelliklerinin İncelenmesi: Demirci İlçesi Örneği ..... 310**

Ramazan Güngör, Emine Müjgan Ergene, Füsun Balık Şanlı, Ali Murat Ateş, Osman Salih Yılmaz310

**Uydu Görüntülerinde Gemi Tespiti için Bölge Tabanlı CNN Modellerinin Karşılaştırılması ..... 317**

Nuri Erkin Öçer, Uğur Avdan ..... 317

**Uzaktan Algılama Verileri Kullanarak Kentsel Alanlarda Karbon Monoksit Salınımlarının Araştırılması ..... 327**

Duygu Arıkan İspir, Hasan Bilgehan Makineci ..... 327

**Topoğrafik Vektör Veritabanı(TOPOVT) için İşletim Sistemlerinin Önemi ..... 334**

Duygu Balcı ..... 334

**Zaman Serisi Sentinel-2 Uydu Görüntülerinden Derin Öğrenme ile Ürün Türü Tespiti ..... 344**

ibrahim Yeğen, Oğuzhan Tosun, Mustafa Türker ..... 344

**Süper Çözünürlük Uygulamasının Askeri Operasyonlara Etkisi – Sentinel-2 Uydu Görüntüsü Örneği ..... 350**

Kürşat Samet Demir· S. Sefa Bilgilioğlu ..... 350

**Yerden Görüntüye RFM Yöntemi Kullanılarak Göktürk-1 Stereo Pankromatik Görüntülerinden Üç Boyutlu Koordinat Hesabı ..... 353**

Onur Erişik, Hüseyin Topan ..... 353

**Metaveri, ISO 19115, HGM Metaveri Profili ve HGM-Geoportal ..... 359**

Nurettin Çağlar Durdu, Dijle Boyacı ..... 359

**Harita Genel Müdürlüğünce Üretilen Coğrafi Verilerin Paylaşılması ..... 364**

murat Bölme, Dijle Boyacı ..... 364

**TOPOVT Vektör Verilerinin Konumsal Doğruluklarının Araştırılması ..... 368**

talat Ağdaş, Levent Kuyumcu, Abdullah Saygılı ..... 368

**Makine Öğrenmesi ile Uzaktan Algılama Verilerinde Yüksek Doğruluklu Detay Sınıflandırması Uygulaması ..... 372**

Mikail Odacı, Burak Tavukcu ..... 372

**Arazi Örtüsü ve Arazi Kullanımı Sınıflandırmasında Landsat-9 Multispektral ve Pixxel TD-1 Hiperspektral Veri Setlerinin Karşılaştırmalı Analizi ..... 379**

Fatih Fehmi Şimşek, Mustafa Üstüner, Kaan Kalkan ..... 379

TASLAK

**Gerçek-Zamanlı Mobil Artırılmış Gerçeklik Sistemlerinde Konumsal Entegrasyonun Fotogrametrik Yaklaşımlarla Sağlanması ..... 384**

Burak Tavukçu, Sefa Tavukçu ..... 384

**Filyos Serbest Bölgesindeki Arazi Değişiminin Rastgele Orman (RF), Destek Vektör Makinesi (SVM), Sınıflandırma ve Regresyon Ağaçları (CART) Makine Öğrenme Algoritmalarıyla Karşılaştırmalı İncelenmesi ..... 389**

Rüveyda Tercan Köse, Hakan Akçin ..... 389

**Eğirdir Gölü Su Seviyesi Değişimlerinin Sentinel-2 Uydu Görüntüleri ile NDWI Tabanlı Zamansal ve İstatistiksel Analizi ..... 397**

Onur Kayaoğlu, Nevin Betül Avşar, Mehmet Güven Koçak, Osman Sami Kırtıloğlu ..... 397

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Gerçek Zamanlı Fotogrametri

**M. Devrim Akca**[*1]

[1]*Işık Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Müh. Bölümü, Şile, İstanbul*

**Anahtar Kelimeler**
Stereoskopik görselleştirme,
Fotogrametri,
İHA,
Karma Gerçeklik

**ÖZET**

Fotogrametri yazılımında karma gerçeklik kullanımı, kullanıcıların stereoskopik modele eşzamanlı olarak uzaktan erişmelerine, görselleştirmelerine ve ölçmelerine olanak tanıyan gerçek zamanlı bir 3B inceleme sistemi sunmaktadır. Sahada bulunan bir operatör, stereo kameralarla donatılmış bir insansız hava aracını (İHA) çalıştırır ve sanal gerçeklik başlıkları sayesinde uzmanlar, ilgi duyulan nesneyi ofisten çıkmadan gözlemleyebilirler. Bu yaklaşım, büyük ve kritik yapıların incelenmesinde hem maliyet etkinliğini hem de güvenliği artırır.

# Real Time Photogrammetry

**Keywords**
Stereoscopic visualization,
Photogrammetry,
UAV,
Mixed Reality (MR)

**ABSTRACT**

The use of mixed reality in photogrammetry software has resulted in a real-time 3D inspection system that allows users to remotely access, visualize and measure the stereoscopic model simultaneously. An on-site operator runs a drone equipped with a stereo camera, and thanks to virtual reality headsets experts can observe the object of interest without leaving the office. This improves both cost-effectiveness and safety when inspecting large, critical structures.

## 1. GİRİŞ

Hem analog hem de analitik fotogrametri dönemlerinde, fotoğraf makineleri tek veri kaynağı olarak kullanılmıştır; buna karşın veri işleme, çok çeşitli cihazlarla gerçekleştirilmiştir (çeşitli türlerde analog stereo aletler, mono- ve stereo-komparatörler, rektifikatörler, triangülatörler, ortofoto projektörleri ve analitik çizerler). Daha sonra, dijital fotogrametriyle birlikte bu durum tamamen tersine dönmüştür; ki bu yaklaşım günümüzde hem endüstride hem de akademide hala güncel kullanımda olan yöntemdir. Veri elde etmek amacıyla çok farklı sensörler (CCD ve CMOS kameralar, çeşitli türlerde lineer dizi kameralar, dijital panoramik kameralar, lazer tarayıcılar, yapısal ışık sistemleri, mobil haritalama sistemleri [MMS], mikrodalga ve ultrasonik sensörler, X-ışını cihazları ve elektronik görüntüleme sistemleri) kullanılmakta; buna karşın veri işleme yalnızca özel yazılımlarla donatılmış iş istasyonları/sunucular üzerinde gerçekleştirilmektedir. Geçmişte farklı cihazlarda yürütülen tüm fotogrametrik ve uzaktan algılama işlevleri artık tek bir yazılım sistemi altında entegre edilebilmektedir (Baltsavias ve Gruen, 2003; Gruen, 2008).

Veri toplama sensörleri ile veri işleme cihazlarının birleşme eğiliminde olduğu bir gelecek trendini gözlemliyoruz. Bir sonraki çağın, "gerçek zamanlı fotogrametri" olarak adlandırılan ve çevrim içi veri işlemenin ya platform üzerindeki sensörle entegre bilgisayarlarda ya da bulut ortamında gerçekleştirildiği bir dönem olacağını öngörüyoruz. Hesaplama gücünün ve veri depolamanın ofis dışına taşınmasıyla birlikte, geleneksel iş istasyonlarının yerini basit terminaller ve monitörler, sanal gerçeklik (VR) başlıkları ve artırılmış gerçeklik (AR) gözlükleri alacaktır.

Bilgisayarla görme, fotogrametri, İHA teknolojisi ve Genişletilmiş Gerçeklik (XR) çözümlerinin entegrasyonu ile geliştirilen yenilikçi Karma Gerçeklik (MR) Fotogrametri sistemi, gerçek dünya ortamlarının gerçek zamanlı 3B görselleştirilmesini, etkileşimini ve ölçümünü mümkün kılmaktadır. Önerilen sistem, mühendislerin, fiziksel olarak ortamda bulunma gereksinimini ortadan kaldırarak; yapısal bütünlüğün değerlendirilmesi, inşaat ilerlemesinin izlenmesi ve

* **Sorumlu Yazar**

*(akca@isikun.edu.tr) ORCID ID 0000-0002-1510-8677

**Kaynak Göster (APA):**

Akca M D (2025). Gerçek zamanlı fotogrametri. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

çevresel değişimlerin zaman içindeki gözlemlenmesi (Stylianidis vd., 2020) gibi görevlerde güvenliği, verimliliği ve doğruluğu artırmaktadır.

Önerilen sistemin merkezinde, stereo kamera düzeneği ve bütünleşik veri işlem yeteneğiyle donatılmış bir İHA yer almaktadır. Sahada bir operatör tarafından kullanılan bu İHA, yüksek çözünürlüklü stereo görüntüler çeker ve bu görüntüler, bulut altyapısında çalışan merkezi bir REST API aracılığıyla gerçek zamanlı olarak işlenir. Dünyanın herhangi bir yerindeki uzmanlar ve mühendisler, sisteme VR başlıkları ya da web tabanlı bir uygulama aracılığıyla bağlanarak, tüm fotogrametrik ölçüm işlevlerini içeren sürükleyici bir 3B stereoskopik modele erişebilirler.

Sistem çoklu kullanıcı iş birliğini destekler; farklı konumlardaki kullanıcılar arasında senkronize analiz ve veri paylaşımına olanak tanır. Donanım ve yazılım bileşenlerinin tam entegrasyonu, gerçek zamanlı stereoskopik görselleştirme alanında önemli bir ilerlemeyi başarmıştır. Sistemin temel bileşenleri arasında, İHA'ya monte edilmiş 2 kameralı stereo düzeneği, VR için karma gerçeklik görselleştirme yazılımı ve web tabanlı yönetim arayüzü bulunmaktadır.

Gerçek zamanlı veri toplama, işleme ve görselleştirmeyi bir araya getiren bu sistem, geleneksel saha denetimlerinin sınırlamalarını aşarak benzersiz görselleştirmeler sunmaktadır. Maliyet etkinliği ve güvenlik ön planda tutularak tasarlanan bu yenilikçi yaklaşım, özellikle zorlu ya da tehlikeli ortamlarda bulunan büyük ölçekli ve kritik yapıların denetimi için büyük önem taşımaktadır. Önerilen sistem, uzaktan izleme ve takip projeleri için yenilikçi bir araç sunmakta ve çeşitli yönetsel süreçlerde zamanında ve doğru kararlar alınmasını sağlamaktadır.

## 2. YÖNTEM

Sistem, temel olarak gerçek zamanlı denetim ve görselleştirme için özel olarak tasarlanmış stereo kameralar taşıyan bir İHA ve MR fotogrametri yazılım paketinden oluşmaktadır. Donanım ve yazılım bileşenleri, gerçek zamanlı görüntü alımı ve fotogrametrik işleme imkânı sağlayan bütünleşik bir işlem hattı içinde sorunsuz bir şekilde entegre edilmiştir. Sistem şu bileşenleri içermektedir:

- Stereo kameralara ve ara yazılımı çalıştıran yerleşik bir PC'ye sahip bir İHA,
- VR başlıkları üzerinde çalışan bir MR fotogrametri uygulaması,
- Bulut sunucularında barındırılan bir arka uç (backend) sistem ve web tabanlı uygulama.

Asenkron monoküler kameralar (hem fotoğraf hem de video için) İHA'larda yaygın olarak kullanılmasına rağmen, eşzamanlı stereoskopik kamera sistemlerinin mekansal veri pazarında uygulanması yenidir. Bu sistem, ilgili tüm teknolojilerin henüz bir üretim seviyesine ulaşmamış olması nedeniyle yenilikçi bir çözüm sunmaktadır.

## 3. SONUÇ

Altyapı unsurlarının denetimi ve bakımı, sıklıkla uzmanlaşmış hizmet firmalarına hizmet alımı olarak verilmektedir. Uzman ekip, altyapıya yakın bir konumda bulunmadığında, sahaya erişmek ve görevlerini yerine getirmek için genellikle uzun mesafeler kat etmeleri gerekmektedir. Ayrıca, denetimler sırasında kritik bileşenlerin yakından incelenmesi gerekebilir; bu da duvarlara veya kulelere tırmanmak ya da ip yardımıyla yüksekten aşağı inmek gibi fiziksel olarak zorlayıcı ve riskli faaliyetleri içerebilir.

Gerçek zamanlı fotogrametri, bakım firmalarının altyapı unsurlarını düzenli olarak uzaktan denetlemesine olanak tanıyan pratik bir çözüm sunar; bu sayede saha ziyaretlerine olan ihtiyaç ortadan kalkar ve tehlikeli görevlere maruz kalma riski azaltılır. Sistem, bakım firmalarının yanı sıra altyapı yönetiminden sorumlu kamu ve özel sektör kuruluşları ile izleme ve bakım hizmetleri yürüten diğer organizasyonlar için de faydalıdır. Ayrıca, niteliksel ve niceliksel değerlendirmeler için saha ziyareti veya yerinde gözlem gereksinimi duyan her türlü projeye de uygundur. Bu sistemi kullanarak, kullanıcılar seyahat gereksinimlerini en aza indirirken gerçek zamanlı ve yüksek ayrıntılı 3B veriler elde edebilirler. Ayrıca, toplanan görseller arşivlenebilir ve gelecekteki referanslar veya dokümantasyon için kullanılabilir; böylece zaman içinde oluşabilecek sorunlar için değerli kayıtlar sağlanmış olur.

## KAYNAKÇA

Baltsavias, E.P. and Gruen, A., 2003. Resolution convergence - A comparison of aerial photos, LiDAR and IKONOSfor monitoring cities. In: Mesev, V. (Ed.), Remotely Sensed Cities, Taylor & Francis, London, pp. 47-82.

Gruen, A., 1988. Towards real-time photogrammetry. Photogrammetria, 42 (5-6), 209-244.

Gruen, A., 2008. Chapter 2: Scientific-technological developments in photogrammetry and remote sensing between 2004 and 2008. Advances in Photogrammetry and Remote Sensing and Spatial Information Sciences: 2008 ISPRS Congress Book – Li, Chen and Baltsavias (eds), 2008, Taylor & Francis Group, London.

Stylianidis, E., Akca, D., Poli, D., Hofer, M., Gruen, A., Martin, V.S., Smagas, K., Walli, A., Altan, O., Jimeno, E., Garcia, A., 2020. FORSAT: a 3D forest monitoring system for cover mapping and volumetric 3D change detection. International Journal of Digital Earth, 13(8), 854-885

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Deformation Identification with InSAR

**Andy Hooper**[1]

[1]*Leeds Üniversitesi, Jeodezi ve Jeofizik Bölümü, Leeds, İngiltere*

**Keywords**
InSAR
Deformation monitoring

**ABSTRACT**

Interferometric Synthetic Aperture Radar (InSAR) has revolutionized the field of geodesy by providing precise measurements of ground deformation from space. The technique provides measurement points over vast areas at low cost and is complementary to existing surveying techniques. This talk will focus on the diverse applications of InSAR in monitoring and managing geophysical and anthropogenic activities.

The presentation will begin with a brief overview of the InSAR technique, emphasizing its capability to generate high-resolution deformation maps. The core of the presentation will explore various real-world applications. InSAR is widely used in natural hazard monitoring to understand how tectonic strain builds and is released in earthquakes, and to monitor both volcanic activity and landslides. It is also used to monitor anthropogenic activities, such as tunnelling, construction and mining, as well as key infrastructure, such as railways, road networks, dams and airports.

The talk will end with a brief future perspective on InSAR. A key limitation for global InSAR coverage up until now has been the presence of vegetation, which can obscure the signal. However, the situation will improve dramatically with the upcoming launch of a global satellite mission called NISAR. The longer wavelength used by its radar is better able to penetrate through vegetation and reveal the deformation of the ground beneath. The number of other InSAR-capable satellites is also set to increase over the next five years.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Deniz Kazalarının Makine Öğrenmesi ile Coğrafik Olarak Kümelenmesi: Türkiye Karasuları

**Selim Durna**[*1]

[1]*Ulaştırma ve Altyapı Bakanlığı, Bilgi İşlem Dairesi Başkanlığı, Ankara, Türkiye*

**Anahtar Kelimeler**
Deniz kazası,
Makine öğrenmesi,
K-Means,
Türkiye Karasuları,
Konumsal Veri

**ÖZET**

Dünyada yapılan taşımacılığın büyük bölümü gemilerle yapılmaktadır. Türkiye üç tarafı denizlerle çevrili olduğu için karasularında yoğun bir gemi trafiği gözlenmektedir. Bu yoğunluk kazaların oluşmasına ve kaza kaynaklı maddi ve çevresel zararların doğmasına neden olmaktadır. Bu çalışmada Türkiye karasularında meydana gelen deniz kazaları analizlerinin kolaylaştırılması için kazaların konumsal kümelenmesi ve harita üzerinde görselleştirilmesi amaçlanmaktadır. Çalışmada açık kaynaklardan temin edilen 2013-2024 yılları arasındaki anonimleştirilmiş deniz kazaları verileri kullanılmıştır. Uygulamada Python programlama dili kullanılmış, veri ölçeklendirme, aykırı veri tesbiti, Elbow ve Silhouette metodu kullanılarak küme sayısının 4 olduğuna karar verilmiştir. K-Means denetimsiz makine öğrenmesi algoritması kullanılarak deniz kazaları verilerinin konumsal olarak kümelemesi gerçekleştirilmiş ve harita üzerinde görselleştirilmiştir. Yapılan görselleştirme sonucunda en fazla kazanın Boğazlar ve Marmara denizinde meydan geldiği tespit edilmiştir. Bu çalışmayla deniz kazaları ve kazalardan doğan zararların azaltılması için yapılacak analizlerin görselleştirilmesine ve kolaylaştırılmasına katkı sağlanmıştır.

# Geographical Clustering of Marine Accidents with Machine Learning: Türkiye Territorial Waters

**Keywords**
Marine Accident,
Machine Learning,
K-Means,
Türkiye Territorial Waters,
Spatial Data

**ABSTRACT**

The majority of transportation in the world is carried out by ships. Since Türkiye is surrounded by seas on three sides, there is intense ship traffic in its territorial waters. This density causes accidents to occur and accident-related material and environmental damages. In this study, it is aimed to cluster the accidents spatially and visualize them on the map in order to facilitate the analysis of marine accidents occurring in Turkish territorial waters. The study uses anonymized marine accident data obtained from open sources between the years 2013 - 2024. Python programming language was used in the application, and the number of clusters was decided to be 4 by using the Elbow and Silhouette methods for data scaling, outlier detection. The spatial clustering of marine accident data was performed using the K-Means unsupervised machine learning algorithm and visualized on the map. As a result of the visualization, it was determined that the most accidents occurred in the Straits and the Sea of Marmara. This study contributed to the visualization and facilitation of analyses to be made to reduce marine accidents and damages arising from accidents.

## 1. GİRİŞ

Yük taşımacılığında ekonomik olması nedeni ile en çok tercih edilen ulaştırma yöntemi deniz yolu taşımacılığıdır (Pienaar, 2013). Deniz yolu taşımacılığının çokça tercih edilmesi gemi kaynaklı kazaların oluşma riskini artırmaktadır.

Gemi kazalarındaki en büyük etken insan faktörüdür (Liu, vd., 2024). Denizlerdeki gemi kazaları denizlerin kirlenmesine, ekolojik dengenin bozulmasına, deniz

* **Sorumlu Yazar**

*(selim.durna@uab.gov.tr) ORCID ID 0009 – 0005 – 7902 – 2839

**Kaynak Göster (APA):**

Durna S (2025). Deniz Kazalarının Makine Öğrenmesi ile Coğrafik Olarak Kümelenmesi: Türkiye Karasuları, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

trafiğinin aksamasına ve ekonomik kayıplara neden olmaktadır (Yanchenko, Shumilova 2022).

Gemi kazaları sonucunda oluşan can ve mal kaybı, ekonomik zararlar ve çevre kirliliği gibi unsurlar göz önünde bulundurulduğunda bu zararların azaltılmasında rol oynayacak faktörlerden biri de makine öğrenmesi ile harita üzerinde görselleştirilmiş kaza verileriyle karar vericilerin ve denizcilerin desteklenerek farkındalığının artırılmasıdır (Chae, vd, 2021).

## 2. YÖNTEM

Bu çalışmada kümeleme işlemleri için yaygın olarak kullanılan denetimsiz makine öğrenmesi kategorisinde yer alan K-Means algoritması kullanılmıştır. 2013-2024 yılları arasında deniz kaza verileri kullanılarak K-Means algoritması ile konumsal kümelenmesi incelenmiştir.

### 2.1. Veri Seti

Kümeleme algoritması için kullanılan veri seti T.C. Ulaştırma ve Altyapı Bakanlığı Ulaşım Emniyeti İnceleme Dairesi Başkanlığı tarafından raporlaştırılan ve açık kaynak olarak yayınlanan 2013-2024 yılları arasında meydana gelen 86 adet kazadan konum bilgisi bulunan 74 adet deniz kazaları verisini içermektedir (Ulaşım Emniyeti İnceleme Dairesi Başkanlığı, 2025). Konum verisi olmayan ve denizlerimiz dışında meydana gelen kazalar veri setinden çıkarılmıştır. Ayrıca konum ve kaza türü verisi dışındaki veri alanları da veri setinden çıkarılmıştır. Kümeleme işlemi için öklidyen uzaklığını kullanan K-Means yönteminde kümelemenin daha doğru yapılabilmesi için veri seti üzerinde ölçekleme yapılmıştır (Mohamad, Usman, 2013).

### 2.2. K-Means Algoritması

K-Means algoritması verilerin kümelenmesi için J. MacQuenn tarafından 1967 yılında geliştirilmiştir (Kırmızıbiber, 2019). Kümeleme işlemi sonucunda, aynı küme içerisindeki benzerliklerin en fazla, farklı kümeler arası benzerliklerin ise en az olduğu küme grupları oluşturulur. Küme benzerlikleri bir küme içerisindeki ağırlık merkezi olarak kabul edilen bir birimine olan uzaklıkların ortalama değeri alınarak oluşturulmaktadır. K-Means algoritmasında k parametresinin seçimi algoritmanın uygulandığı alana göre bazen çok zor olabilir. Ancak Elbow yöntemi ve Silhouette yöntemi bu problemi çözmekte yardımcı olur (Saputra, vd., 2020).

### 2.3. Elbow Yöntemi

Elbow yönteminde, her kümedeki örnek noktaları ile kümenin ağırlık merkezi arasındaki uzaklığın karesi kullanılarak bir dizi K değeri elde edilir.

Kare hatalarının toplamı KHT bir performans göstergesi olarak kullanılır. K değeri üzerinde yineleme yapılarak KHT hesaplanır ve hesaplanan değer küçüldükçe küme elemanları merkeze toplanır. Bu da kümenin daha tutarlı olduğu anlamına gelir (Yuan, Yang, 2019). Grafik olarak bakıldığında kümeleme sayısı arttıkça başlangıçta KHT artar ancak belli bir sayı sonrasında hata değişim oranı azalır. Eğimin azaldığı yer küme sayısı olarak belirlenir (Şekil 1-a).

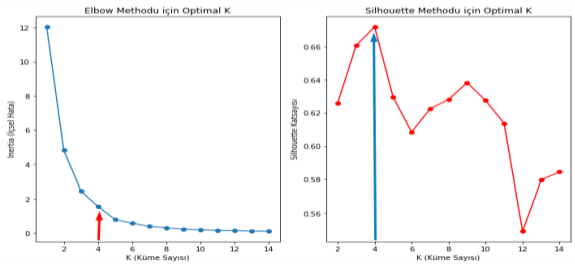


(a) (b)

**Şekil 1.** k parametresi belirleme (a: "Elbow yöntemi" b: "Silhouette yöntemi")

### 2.4. Silhouette Yöntemi

Bu yöntem ilk kez Peter J. Rousseeuw tarafından önerilmiştir (Arcagök, 2021). İki faktörden oluşur benzeme ve farklılık. Küme ve nesne arasındaki benzerlik benzemeyi, kümelere arası benzerliğin azlığı ise farklılığı ifade eder. Bu karşılaştırma, [ -1,1] aralığında olan Silhouette değeriyle sağlanır. Bir modeldeki veri kümeleri içerisindeki en yüksek Silhouette değeri o modelin küme sayısını belirler (Şekil 1-b).

## 3. BULGULAR

Çalışmada 2013 – 2024 yılları arasındaki veri seti analiz edilmiştir. Programlama dili olarak python, platform olarak anaconda3 jupyternotebook platformu, analiz aşamasında ise pandas, sklearn, matplotlib kütüphanelerinden yararlanılmıştır. Konum verilerinin kümelere dağıtılması için veriler normalize edilmiş (Çizelge 1), küme sayısının belirlenmesinde Elbow ve Silhouette yöntemi kullanılmış, Şekil 1-a, Şekil 1-b' deki grafikten de anlaşıldığı üzere küme sayısının 4 olduğuna karar verilmiştir. Verilerin görsel olarak harita üzerinde gösterilmesi Şekil 2' te görselleştirilmiştir.

**Çizelge1.** Normalize edilmiş ve kümelenmiş veri seti

| No | Kaza Türü | Latitude | Longitude | lon_scaled | lat_scled | Cluster |
|---|---|---|---|---|---|---|
| 0 | D.Araç.D | 40.972 | 27.517 | 0.137 | 0.809 | 1 |
| 1 | Çatışma | 40.892 | 29.033 | 0.270 | 0.796 | 1 |
| . | ..... | ..... | ..... | ..... | ..... | . |
| 73 | İş Kazas | 42.149 | 35.600 | 0.847 | 1.00 | 0 |

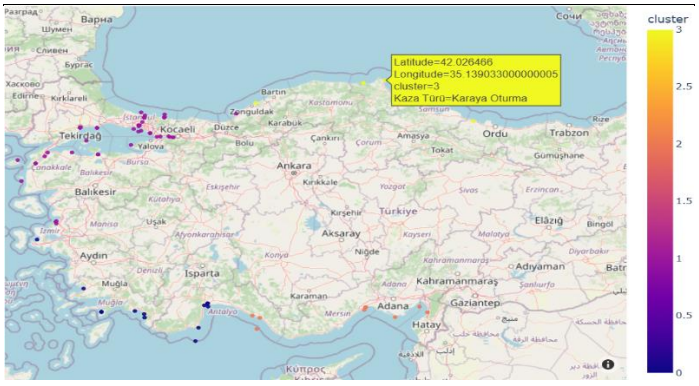


**Şekil 2.** Makine öğrenmesi ile sınıflandırılmış verilerin harita üzerinde görselleştirilmesi

## 4. TARTIŞMA

Türk karasularında meydana gelen kazaların konumsal sınıflandırması yapılmış ve harita üzerinde görselleştirilmiştir. Ancak karasularımızın dışında da meydana gelen kazalar ile kazaların türlerine, kaza konusuna göre de sınıflandırmalar yapılması ayrıca incelenmelidir.

Elde edilen sonuçlar karar destek vericiler için görsel destek sağlayarak karar vermeyi kolaylaştıran bir unsur olmaktadır. Böylece alınması gerekli tedbirlere karar verilirken hangi denizlere, hangi tür kazalara ve hangi olaylara ne tür tedbirler alınabileceği ve eğitim planlarına bu konuların dahil edilmesi gerektiği görülmektedir.

## 5. SONUÇ

Gemi kazalarının önlenmesinde insan faktörünün önemli olduğu ve insan hatasını azaltmak için eğitimlerde görsellerle desteklenmiş eğitim materyallerinin kullanımı eğitim verimini artırmaktadır. Bu çalışmada konumsal gemi kazası verilerinin makine öğrenmesi ile sınıflandırılabildiği ve harita üzerinde görselleştirilebildiği görülmüştür. Söz konusu çalışmadaki yaklaşım ile karayollarında meydana gelen kazaların da sınıflandırılarak harita üzerinde görselleştirilebileceği ve kara yollarında meydana gelen kazaların önlenmesi ve azaltılmasında farkındalığı artırmaya yönelik destekleyici görsel materyaller olarak kullanılabileceği öngörülmektedir.

**TEŞEKKÜR**

Ulaştırma ve Altyapı Bakanlığına katkılarından dolayı teşekkür ederiz.

**Yazar Katkı Oranı**
Çalışmaya yazar tam katkı sağlamıştır.

**Çıkar Çatışması/Çakışması**
Çalışmada herhangi bir kurum, kuruluş, kişi ile mali çıkar çatışması yoktur.

**Araştırma ve Yayın Etiği Beyanı**
Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur**.**

KAYNAKÇA

Arcagök, U., (2021), Sürdürülebilirlik Analizi ile Kurumların Sürdürülebilirliğinin Modellenmesi ve Yeni Bir Sürdürülebilirlik İndeksinin Geliştirilmesi. (Yüksek Lisans Tezi) İstanbul Üniversitesi, İstanbul.

Chae, C. J., Kim, K. H., Kang, S. Y., Kang, S. Y., (2021) Limiting Ship Accidents by Identifying Their Causes and Determining Barriers to Application of Preventive Measures. doi:10.3390/jmse9030302

Demir, U. C., (2021), K-Means Kümeleme Yönteminde En Uygun Küme Sayısının Tematik Kartografya Uygulamaları Açısından İncelenmesi (Yüksek Lisans Tezi) Konya Teknik Üniversitesi, Konya.

Kertanah, K., Rahadi, I., Baiq Aryani Novianti, B. A., Syahidi, K., Sapiruddin, S., Putra, H. M., Gazali, M., Hirzi, R. H., Sabar, S. (2022) Applying K-Means Algorithm For Clustering Analysis Earthquakes Data In West Nusa Tenggara Province. doi: 10.29303/ipr.v5i3.148

Kırmızıbiber, A. (2019), Hiyerarşik ve K-Ortalamalar Yöntemiyle Grid Noktalarının Kümelenmesi. (Yüksek Lisans Tezi), Yıldız Teknik Üniversitesi, İstanbul.

Liu, L., Xi, Y., Hu, S., Ham, B.-H., & Li, Z. (2024). Characteristics Exploration of Human and Organizational Factors in Maritime Traffic Accidents. 14th International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering, Harbin. https://doi.org/10.1049/icp.2024.3446

Mohamad, I., Usman, D. (2013). Standardization and Its Effects on K-Means Clustering Algorithm. Research Journal of Applied Sciences, Engineering and Technology, 6(17), 3299–3303. https://doi.org/10.19026/RJASET.6.3638

Pienaar, W. J., (2013). Salient Economic Features of the Modes of Freight Transport for Consideration in the Formulation of National Transport Policy. European Transport Conference, Frankfurt. https://aetransport.org/past-etc-papers/conference-papers-2013

Saputra, D. M., Saputra, D., Oswari, L. D., (2020). Effect of Distance Metrics in Determining K-Value in K-Means Clustering Using Elbow and Silhouette Method. doi: 10.2991/aisr.k.200424.051

Selecting The Number Of Clusters With Silhouette Analysis On K-Means Clustering,https://scikit-learn.org/stable/auto_examples/cluster/plot_kmeans_silhouette_analysis.html[Erişim tarihi: 11.03.2025].

T.C. Ulaştırma ve Altyapı Bakanlığı Kaza İnceleme Raporları, [Erişim tarihi: 27.03.2025], https://ulasimemniyeti.uab.gov.tr/deniz

Yanchenko, A. Y., Shumilova, D.A.,(2022). About the Problem of Accidents on Ships. doi: 10.24182/2073-9885-2022-15-2-77-81

Yuan, c., Yang, H., (2019), Research on K-Value Selection Method of K-Means Clustering Algorithm. https://doi.org/10.3390/j202001

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Alansal Olarak Farklı Geometrik Açıdan Benzer Akarsu Havzalarında Taşkın Potansiyeli

**Rabia Uzun*[1], Mustafa Utlu[2]**

[1]*Burdur Mehmet Akif Ersoy Üniversitesi, Sosyal Bilimler Enstitüsü Coğrafya Anabilim Dalı, Burdur, Türkiye*
[2] *Burdur Mehmet Akif Ersoy Üniversitesi, Fen Edebiyat Fakültesi, Coğrafya Bölümü, Fiziki Coğrafya Anabilim Dalı, Burdur, Türkiye*

**Anahtar Kelimeler**
Taşkın potansiyeli,
Dairesel Havza,
SYM,
Farklı Çözünürlük

**ÖZET**

Taşkın olayı şiddetli yağışlara bağlı olarak akarsu yatağının kapasitesi üstünde olan su kütlesinin taşıp çevresine yayılması olarak ta tanımlanabilir. Taşkın sonucu mal ve can kaybı meydana gelirse bu olay doğal afet olarak nitelendirilir. Sel ve taşkınların dünyada ve ülkemizde etkisi ve şiddeti günden güne artmaktadır Yanlış arazi kullanımı ve nüfus artışı, özellikle taşkın yataklarında yerleşimlerin artmasına neden olarak zarar görebilirliği yükseltmektedir. Sel ve taşkınlar akarsu yatakları boyunca ve ova tabanına kurulan yerleşim yerlerini daha çok etkilemektedir Yapılan çalışmalar, dairesel havzaların uzunlamasına havzalara göre daha fazla taşkın potansiyeline sahip olduğunu göstermektedir. Bu çalışmada, Kınık (İzmir), Şiran (Gümüşhane) ve Beyşehir (Konya) havzalarının taşkın üretme potansiyeli belirlenmiştir. 10 m çözünürlüklü TopoDEM, 30 m çözünürlüklü FABDEM ve Copernicus GLO-30 DEM verileri kullanılarakal çizgisel alansal ve rölyef olmak üzere toplam 15 farklı morfometrik indis ile değerlendirme yapılmıştır. Bulgulara göre, Şiran havzası yüksek taşkın öncelikli sınıfta yer alırken, Beyşehir ve Kınık havzaları değişen öncelik derecelerine sahip olmuştur.

# Flood Potential Assessment in Geometrically Similar but Area-Wise Different River Basins

**Keywords**
Flood potential,
Circular Basin,
DEM,
Different Resolution

**ABSTRACT**

Flood event can also be defined as the overflow of water mass exceeding the capacity of the river bed due to heavy rainfall and spreading to its surroundings. If the flood results in loss of property and life, this event is considered a natural disaster. The effects and severity of floods and inundations are increasing day by day in the world and in our country. Incorrect land use and population growth increase the vulnerability by causing an increase in settlements especially in floodplains. Floods and inundations affect settlements established along river beds and on the bottom of the plain more. Studies show that circular basins have more flood potential than longitudinal basins. In this study, the flood generation potential of Kınık (İzmir), Şiran (Gümüşhane) and Beyşehir (Konya) basins was determined. A total of 15 different morphometric indices were evaluated using 10 m resolution TopoDEM, 30 m resolution FABDEM and Copernicus GLO-30 DEM data, including linear, areal and relief. According to the findings, the Şiran basin was in the high flood priority class, while the Beyşehir and Kınık basins had varying priority degrees.

## 1. GİRİŞ

Sel ve taşkınlar, ülkemizde depremlerden sonra en fazla yıkıcı etkiye sahip doğal afetlerdendir. İklim değişikliğine bağlı olarak aşırı yağışların artması, taşkın olaylarının daha sık ve şiddetli yaşanmasına neden olmaktadır (Koç vd.,2020). Ayrıca, yanlış mühendislik uygulamaları, dere yataklarının yapılaşmaya açılması ve ormansızlaşma gibi faktörler taşkın riskini artırmaktadır (Matpay,2024). Havza morfometrisi, taşkın üretme

* **Sorumlu Yazar**

*(e-mail) ORCID ID 0009-0002-8348-3417
(mutlu@mehmetakif.edu.tr ORCID ID 0000-0002-7508-4478

**Kaynak Göster (APA):**

Uzun R & Utku M (2025). Alansal Olarak Farklı Geometrik Açıdan Benzer Akarsu Havzalarında Taşkın Potansiyeli, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

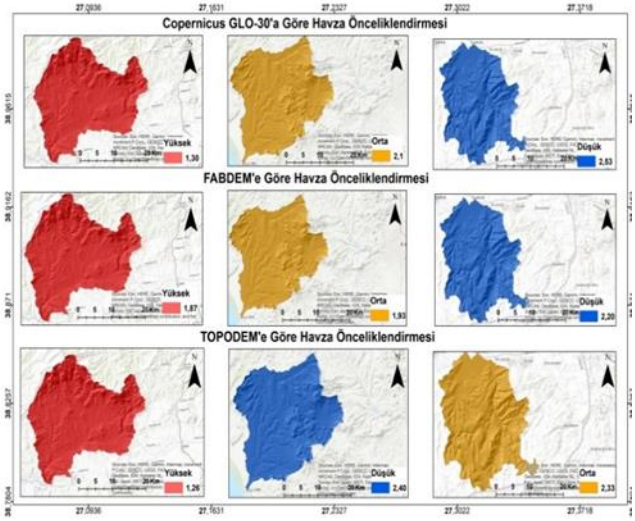


**Şekil 2.** Havza önceliklendirmesine göre oluşturulan haritalar

potansiyelini belirlemede önemli bir analiz yöntemidir (Utlu ve Özdemir, 2018). Bu çalışmada, morfometrik parametreler kullanılarak havzaların taşkın potansiyelleri bakımından önceliklendirmesi yapılmıştır

## 2. YÖNTEM

Çalışmada alanı farklı konumlarda bulunan akarsu havzalarını kapsamaktadır (Şekil 1). ArcGIS 10.8 ve Microsoft Excel 2010 programları kullanılarak morfometrik analizler gerçekleştirilmiştir. 10 m çözünürlüklü TopoDEM, 30 m çözünürlüklü FABDEM ve Copernicus GLO-30 DEM verileri üzerinden havza sınırları belirlenmiş, çizgisel, alansal ve rölyef morfometri parametreleri hesaplanmıştır. Havza drenaj ağı 250 eşik değeri ile tanımlanmış ve Strahler yöntemiyle akarsu dizinleri oluşturulmuştur.

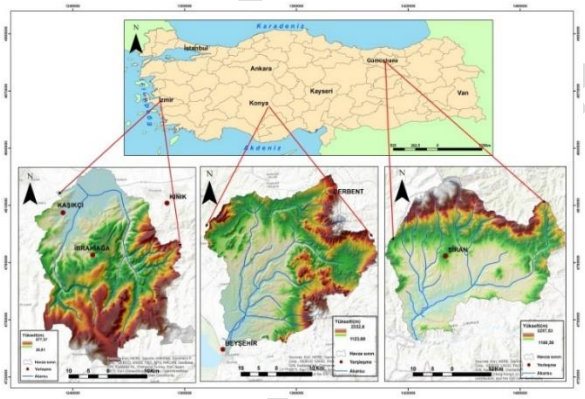


**Şekil 1.** Araştırma sahalarının konum haritası.

## 3. BULGULAR

Havza önceliklendirilmesi taşkın potansiyeli yüksek havzaları tespit etmek ve öncelikli korunması gereken havzaları tanımlayıp önlem alınmasıdır. Öncelikllendirmeyi gereken havzalar morfometrik parametreler sayesinde tespit edilebilir(Verma vd.,2023). Çalışmada kullanılan tüm morfometrik indisler taşkın önceliği açısından değerlendirildi ve değerlerin ortalamasını almak için birleşik yöntem kullanıldı(Krishnan ve Ramasamy,2024). Kullanılan bu yöntem ile bulunan sonuca göre en düşük birleşik parametre değerine sahip havza en yüksek taşkın potansiyeline sahipken en yüksek değere sahip havza en düşük taşkın potansiyeline sahiptir (Farhan vd.,2016).

Elde birleşik değerlere verileri Copernicus GLO-30'a göre Şiran(1,3),Beyşehir(2,1) ve Kınık için (2,53) olarak bulunmuştur. FABDEM'e göre Şiran(1,87), Beyşehir(1,93),Kınık için (2,20) olarak bulunmuştur. TOPODEM'e göre Şiran(1,26), Beyşehir(2,4) ve Kınık için(2,33) olarak bulunmuştur. Bulunan birleşik değerlere göre Şiran yüksek öncelikli Beysehir Copernicus GLO-30'a ve FABDEM'e göre orta öncelikli Kınık ise Copernicus GLO-30'a ve FABDEM'e göre düşük öncelikli iken TOPODEM'e göre orta öncelikli sınıfta yer alır. Bu sonuçlara göre oluşturulan harita **Şekil2.** de verilmiştir.

## 4. TARTIŞMA

Bu çalışma, taşkın potansiyeli yüksek havzaların belirlenmesi için morfometrik parametrelerin kullanılmasını ve bu parametrelerin birleşik yöntemle değerlendirilmesini ele almaktadır. Çalışmada, farklı morfometrik indislerin taşkın önceliği açısından incelenmesi, her bir havzanın taşkın riski ile ilişkili olarak sınıflandırılmasını sağlamaktadır. Copernicus GLO-30, FABDEM ve TOPODEM gibi farklı veritabanlarından elde edilen parametrelerle yapılan analiz, her havzanın taşkın potansiyeli hakkında önemli farklı DEM verileri açısından önemli bilgiler sunmaktadır.

Şiran, tüm veri setlerinde en yüksek taşkın önceliğine sahip olarak belirlenmiştir. Bu, Şiran havzasının taşkın yönetimi açısından öncelikli olarak ele alınması gerektiğini göstermektedir. Beyşehir ise, Copernicus GLO-30 ve FABDEM veri setlerine göre orta düzeyde öncelikli bir havza olarak belirlenmişken, Kınık farklı veri setlerinde farklı önceliklere sahip bulunmuştur. Bu da, havza önceliklendirilmesinin kullanılan veri setine bağlı olarak değişebileceğini ve her bir veri setinin taşkın riski ile ilişkili farklı sonuçlar doğurabileceğini ortaya koymaktadır.

## 5. SONUÇ

Bu çalışmada, taşkın risk değerlendirmesi için morfometrik indislerin etkin bir yöntem olduğu belirlenmiştir. Şiran havzasının yüksek taşkın riski taşıması nedeniyle önleyici tedbirler alınması önerilmektedir. Morfometrik analizlerin şehir planlaması, akarsu havzaları yönetimi ve sürdürülebilir çevre düzenlemelerinde katkı sağlayabileceği düşünülmektedir.

**Yazar Katkı Oranı**

Çalışma Konsepti/Tasarım- R.U., M.U.; Veri Toplama- R.U., M.U.; Veri Analizi/Yorumlama- R.U., M.U.; Yazı Taslağı- R.U.; Son Onay ve Sorumluluk- H.A., R.K

**Çıkar Çatışması/Çakışması**

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

**KAYNAKÇA**

Farhan, Y., Anbar, A., Al-Shaikh, N., & Mousa, R. (2016). Prioritization of semi-arid agricultural watershed using morphometric and principal component analysis, remote sensing, and GIS techniques, the Zerqa River Watershed, Northern Jordan. *Agricultural Sciences*, *8*(1), 113-148.

Koç, G., Petrow, T., & Thieken, A. H. (2020). Analysis of the most severe flood events in Turkey (1960–2014): which triggering mechanisms and aggravating pathways can be identified?. *Water*, *12*(6), 1562.

Krishnan, A., & Ramasamy, J. (2024). Morphometric assessment and prioritization of the South India Moyar river basin sub-watersheds using a geo-computational approach. *Geology, Ecology, and Lan*

Matpay, B. (2024). Büyükdere havzasına (Hizan-Bitlis) ait alt havzaların hidromorfometrik analizlerle taşkın duyarlılıklarının korelasyonu. *lnternational Journal of Geography and Geography Education*, (53), 242-261

Utlu, M., & Özdemir, H. (2018). Havza morfometrik özelliklerinin taşkın üretmedeki rolü Biga Çayı havzası örneği. *Coğrafya Dergisi*, (36), 49-62.

Verma, N., Patel, R. K., & Choudhari, P. (2023). Watershed prioritization for soil conservation in a drought prone watershed of Eastern India: Tel River Basin, Odisha. *Geology, Ecology, and Landscapes*, *7*(4), 405-418.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Ormanlardaki Aktif Yangınların ve Yanmış Alanların Optik Uydu Görüntüleri ve Derin Öğrenme Yöntemi ile Belirlenmesi

**Yasin Demirel**[1,2], **Tarık Türk**[*1]

[1]*Sivas Cumhuriyet Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 58140, Sivas, Türkiye*
[2]*Bartın Üniversitesi, Bilgi İşlem Daire Başkanlığı, Bartın, Türkiye*

**Anahtar Kelimeler**
Orman Yangını,
Derin Öğrenme,
Bilgisayarlı Görü,
Evrişimli Sinir Ağı

**ÖZET**

Orman yangınları, ciddi ekolojik, sosyal ve ekonomik kayıplara yol açmaktadır. Bu etkilerin en aza indirilmesi için yangınlara zamanında müdahale edilmesi ve yanmış alanların hızla tespit edilmesi kritik öneme sahiptir. Uzaktan algılama teknikleri bu süreçte hız ve maliyet açısından avantaj sağlamaktadır. Bu çalışmada, tek zamanlı Sentinel-2 uydu görüntüleri kullanılarak, derin öğrenmeye dayalı U-Net+InceptionResNetV2 mimarisi ile aktif yangınların ve yanmış alanların konum ve alan boyutu açısından otomatik tespiti amaçlanmıştır. Model, oluşturulan yeni eğitim ve doğrulama verileri ile eğitilmiş; test aşamasında yanmış alanlar için %88 IoU, aktif yangınlar için ise %82 IoU ile yüksek başarı elde etmiştir. Model, eğitim verilerinde bulunmayan görüntülerle test edildiğinde hem tutarlı sonuçlar üretmiş hem de coğrafi konumları doğru şekilde tespit edebilmiştir.

# Detection of Active Fires and Burned Areas in Forests from Optical Satellite Images with Deep Learning

**Keywords**
Wildfire,
Deep Learning,
Computer Vision,
CNN

**ABSTRACT**

Forest fires cause significant ecological, social, and economic losses. To minimize these impacts, timely intervention during active fires and rapid detection of burned areas are of critical importance. Remote sensing techniques offer considerable advantages in terms of speed and cost in this context. In this study, a deep learning-based method was developed to automatically detect the location and size of active fires and burned areas using single-date Sentinel-2 satellite imagery. The model, based on the U-Net+InceptionResNetV2 architecture, was trained with a newly created training and validation dataset. In test data, it achieved high performance with 0.88 IoU for burnt area detection and 0.82 IoU for active fire detection.When tested with images not included in the training set, the model produced consistent results and accurately identified the geographical locations of active fires and burned areas.

## 1. GİRİŞ

Ormanlar; ekosistem dengesi, su döngüsünün düzenlenmesi, biyolojik çeşitliliğin korunması ve iklim değişikliğiyle mücadele gibi hayati işlevleri nedeniyle kritik öneme sahiptir. Ancak orman yangınları, bu işlevleri tehdit ederek meşcere yapısının bozulmasına, biyolojik çeşitlilik kaybına ve sera gazı salımına yol açmaktadır. Yangınların artışında başlıca etken, küresel iklim değişikliği ve buna bağlı sıcak ve kurak yaz koşullarıdır. Ayrıca ihmal, kaza ve kasıt gibi insan kaynaklı faktörler de önemli rol oynamaktadır. Yangınların yeri, kapsamı ve sıklığına ilişkin bilgilere hızlı biçimde ulaşmak; müdahale, hasar tespiti ve iyileştirme süreçleri açısından kritik önemdedir. Bu noktada, uzaktan algılama verileri zaman ve maliyet açısından önemli avantajlar sunmaktadır (Kavzoğlu, 2021; Şeker, 2021; Zhang vd., 2021; Knopp vd., 2020).

Yanan biyokütledeki belirgin spektral değişimler nedeniyle orman yangınlarının tespiti ve yanmış alanların haritalanmasında optik algılayıcılar tercih edilmektedir. Küçük ve parçalı yangın alanlarının belirlenmesinde yüksek çözünürlüklü veriler avantaj sağlamakta olup, bu bağlamda 10–60 m konumsal ve 5 günlük zamansal çözünürlüğe sahip Sentinel-2 verileri

[*] **Sorumlu Yazar**

[*](tarikturk@gmail.com) ORCID ID 0000-0002-2671-7590
(ysndmrl58@gmail.com) ORCID ID 0000-0002-5582-984X

**Kaynak Göster (APA):**

Demirel, Y. & Türk, T (2025). Optik Uydu Görüntüleri Kullanılarak Ormanlardaki Aktif Yangınların ve Yanmış Alanların Derin Öğrenme ile Belirlenmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

son yıllarda yaygın olarak kullanılmaktadır (Knopp vd., 2020; Zhang vd., 2021).

Ücretsiz uydu verileri arasında Sentinel-2, Landsat'a kıyasla daha yüksek zamansal çözünürlüğü sayesinde bulutsuz görüntü elde etme açısından avantaj sağlamaktadır. Aktif yangın ve yanmış alanların tespitine yönelik sinir ağı modellerinin geliştirilmesindeki en büyük zorluk ise konumsal bilgi içeren yeterli eğitim verisinin teminidir. Ayrıca aktif yangın ve yanmış alanların daha doğru bir şekilde tespit edilebilmesi için, bu iki sınıfın her biri adına en uygun spektral bant kombinasyonlarının ayrı ayrı analiz edilmesi model başarımı açısından kritik öneme sahiptir.(Knopp vd., 2020; Zhang vd., 2021).

Yapılan çalışmalar doğrultusunda; veri temini, ön işleme, segmentasyon modeli oluşturulması, konumsal analizler ve alan hesaplamalarının tam otomatik bir yapıda gerçekleştirilmesi, aktif devam eden orman yangınlarına hızlı müdahale edilmesi, önleyici stratejilerin geliştirilmesi ve yanmış alanların rehabilitasyonu açısından kritik öneme sahiptir. Bu kapsamda, Sentinel-2 uydu görüntüleri kullanılarak derin öğrenme temelli bir yöntem geliştirilmiş; aktif yangınlar ve yanmış alanlar otomatik olarak sınıflandırılmıştır. Ayrıca, bu sınıflandırma sonuçlarına dayalı coğrafi ve metrik analizlerin Python programlama dili ile tam otomatik şekilde yürütülebildiği bir yazılım sistemi tasarlanmıştır. Geliştirilen bu sistem aracılığıyla, kullanıcı tarafından girilen tarih ve konuma ait Sentinel-2 görüntüleri üzerinden ilgili yangın alanları tespit edilerek mekânsal olarak analiz edilebilmektedir.

## 2. YÖNTEM

Bu çalışmada, aktif yangın ve yanmış alan segmentasyonu amacıyla etiketli bir veri seti oluşturulmuş ve yüksek konumsal ve zamansal çözünürlüğü nedeniyle Sentinel-2 uydu görüntüleri tercih edilmiştir. Sentinel-2, 10 ila 60 m arasında değişen mekânsal çözünürlüğe sahip 13 spektral bandı kapsamaktadır. Google tarafından hizmete sunulan Earth Engine platformu aracılığıyla Python programlama dili kullanılarak belirli tarih ve konumlara ait Sentinel-2 verileri indirilmeye uygun hâle getirilmiş; bu süreçte atmosferik düzeltmeler uygulanmıştır. SWIR1, SWIR2 ve Red bantları aktif yangın tespiti için; SWIR2, NIR ve Blue bantları ise yanmış alanların belirlenmesi için kullanılmıştır (Knopp vd., 2020; Zhang vd., 2021; Chuvieco vd., 2019). Tüm bantlar 20 m çözünürlüğe yeniden örneklenmiş ve yazılım tarafından belirlenen tampon bölgeler dâhilindeki sahneler indirildikten sonra etiketli maskeler üretilmiştir. Görüntüler ve maskeler, işlem yükünü azaltmak ve yapay zekâ modelinin öğrenme başarısını artırmak amacıyla 256x256 piksel boyutunda parçalara ayrılmıştır. Aktif yangınlar için 988, yanmış alanlar için ise 2304 görüntü yaması oluşturulmuş; bunlar %80 eğitim, %10 doğrulama ve %10 test olarak ayrılmıştır. Veri seti, döndürme, kaydırma, yakınlaştırma ve yansıtma gibi çeşitli veri artırma teknikleriyle genişletilmiş, toplamda aktif yangınlar için 2368 ve yanmış alanlar için 5520 yama elde edilmiştir.

Geliştirilen sistemin temel bileşenleri Python programlama dili ile tam otomatik bir iş akışı şeklinde yapılandırılmıştır. ESA Copernicus Açık Erişim Merkezi üzerinden indirilen L1C seviyesindeki Sentinel-2 verileri, atmosferik düzeltmelere tabi tutulmuş ve analiz için gerekli bant kombinasyonları yeniden örneklenmiştir. Elde edilen veriler ve üretilen maskeler, 256x256 piksel parçalara ayrılarak U-Net mimarisi ve InceptionResNetV2 backbone ile oluşturulan evrişimli sinir ağı (CNN) yapısı ile eğitilmiştir. Eğitim sürecinde Keras kütüphanesi ve TensorFlow altyapısı kullanılmış, model Google Colab ortamında eğitilmiştir. Eğitimde dice loss kayıp fonksiyonu ve Adam optimizasyon algoritması kullanılmış; doğrulama kaybı izlenerek en düşük doğruluk değerine ulaşan model kaydedilmiştir. U-Net'in güçlü segmentasyon kabiliyetleri, InceptionResNetV2'nin derin ve zengin özellik temsilleriyle birleştirilerek, geometrik dönüşümlere ve farklı konumsal çözünürlüklere karşı dayanıklı bir yapı elde edilmiştir. Sonuç olarak geliştirilen yazılım, kullanıcıdan alınan tarih ve konum bilgisine dayalı olarak Sentinel-2 görüntülerinden aktif yangın ve yanmış alanları otomatik olarak tespit edebilmekte; bu alanların konumsal bilgilerini ve metrik ölçümlerini de eş zamanlı olarak sunabilmektedir.

## 3. BULGULAR ve TARTIŞMA

Geliştirilen U-Net+InceptionResNetV2 tabanlı derin öğrenme segmentasyon modeli, aktif yangın ve yanmış alanların tespiti için test verileri üzerinde değerlendirilmiştir. Modelin doğruluğu, eğitim sırasında kullanılmayan veri seti üzerinden hesaplanmış ve performans ölçümleri doğruluk, precision, recall, F1-score, Dice skoru ve IoU metrikleriyle detaylandırılmıştır. Aktif yangın tespitinde model; %87 precision, %90 recall, %89 F1-score, %89 Dice skoru ve %82 IoU değeri elde etmiştir. Yanmış alanların tespitinde ise %94 precision, %93 recall, %93 F1-score, %93 Dice skoru ve %88 IoU değeri ile yüksek başarı sağlanmıştır. Eğitim sürecinde her epokta IoU ve loss değerleri izlenmiş, model kaybı en aza indirecek şekilde optimize edilmiştir. Geliştirilen tam otomatik sistem, belirli bir tarih ve konuma ait Sentinel-2 görüntüleri üzerinden küçük ve parçalı yangın alanlarını güvenilir biçimde tespit edebilmekte; aktif yangın ve yanmış alanlara ait konum ve alan bilgilerini hızlı ve doğru bir şekilde sunabilmektedir. Bu çıktılar, acil müdahale ve bölgesel rehabilitasyon çalışmaları açısından büyük önem taşımaktadır.

Derin öğrenme modellerinin doğruluk ve genelleme yeteneği, büyük ölçüde eğitim verisinin kalitesine ve çeşitliliğine bağlıdır. Bu çalışmada, modelin farklı yangın senaryolarını öğrenebilmesini sağlamak amacıyla yalnızca her iki sınıfı (aktif yangın/temiz alan, yanmış/yanmamış alan) içeren örnekler değil, aynı zamanda yalnızca tek bir sınıfa ait görüntüleri içeren patch'ler de veri setine dâhil edilmiştir. Dünya genelinde meydana gelen çeşitli yangınlara ait Sentinel-2 görüntüleri dikkatle seçilip görsel analizlere tabi tutulmuş ve böylece modelin daha kapsayıcı bir biçimde eğitilmesi sağlanmıştır.

Segmentasyon başarımı, başta IoU (Intersection over Union) olmak üzere farklı metriklerle değerlendirilmiş

ve modelin küçük ve dağınık yapıdaki yangın alanlarını dahi yüksek doğrulukla tespit edebildiği görülmüştür. Yanmış alanlara yönelik model, daha büyük ve homojen yapılar nedeniyle aktif yangın modeline kıyasla daha yüksek IoU skorları üretmiştir. Bununla birlikte, otomatik iş akışının bazı durumlarda tarım alanları ve küçük volkanik oluşumları yanmış alanlarla karıştırdığı da gözlemlenmiştir. Fakat genel olarak farklı coğrafi bölgelerden alınan test görüntüleri üzerinde oluşturulan referans maskelerle yapılan karşılaştırmalar, modelin tutarlı ve güvenilir sonuçlar sunduğunu ortaya koymuştur. Gelecekte, eğitim verisinin daha da çeşitlendirilmesi ve zenginleştirilmesiyle modelin doğruluk düzeyinin daha da iyileştirilebileceği öngörülmektedir. Tüm değerlendirmeler ışığında, önerilen tam otomatik işleme zinciri, aktif yangınların ve yanmış alanların coğrafi koordinatları ve alan büyüklükleri ile birlikte yüksek doğrulukla tespitini mümkün kılan etkili ve uygulanabilir bir çözüm sunmaktadır.

## 4. SONUÇ

Bu çalışmada, aktif yangınların anlık ve güvenilir şekilde tespiti ile yanmış alanların hızlı belirlenip rehabilitasyonuna katkı sağlamak amacıyla, veri toplama, ön işleme ve derin öğrenmeye dayalı tam otomatik bir iş akışı geliştirilmiştir. Sentinel-2 görüntülerinden elde edilen bant kombinasyonları kullanılarak eğitilen U-Net+InceptionResNetV2 tabanlı model, aktif yangınlar için %82, yanmış alanlar için ise %88 IoU değeri elde etmiştir. Model, daha önce karşılaşmadığı test verileri üzerinde dahi küçük ve parçalı yangınları başarıyla tespit etmiştir. Uzaktan algılama teknolojilerindeki gelişmelerle birlikte, bu tür otomatik sistemlerin yangın yönetimi ve ekosistem rehabilitasyonunda önemli katkılar sunacağı öngörülmektedir.

### Yazar Katkı Oranı

**Yasin Demirel:** Literatür araştırması, yazılım geliştirme, analiz ve yazma. **Tarık Türk:** Fikir, literatür araştırması, analiz, yazma ve yönetme.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması yoktur.

### Araştırma ve Yayın Etiği Beyanı

Bu çalışmanın detaylı ve genişletilmiş versiyonu Mersin Photogrammetry Journal, 2024, Cilt 6, Sayı 2'de yayımlanmıştır.

### KAYNAKÇA

Chuvieco, E., Mouillot, F., Van der Werf, G. R., San Miguel, J., Tanase, M., Koutsias, N., ... & Giglio, L. (2019). Historical background and current developments for mapping burned area from satellite Earth observation. Remote Sensing of Environment, 225, 45-64.

Kavzoğlu, T. (2021). Orman yangınları sebepleri, etkileri, izlenmesi, alınması gereken önlemler ve rehabilitasyon faaliyetleri, Türkiye Bilimler Akademisi Yayınları

Knopp, L., Wieland, M., Rättich, M., & Martinis, S. (2020). A deep learning approach for burned area segmentation with Sentinel-2 data. Remote Sensing, 12(15), 2422.

Şeker, M. (2021). Orman yangınları sebepleri, etkileri, izlenmesi, alınması gereken önlemler ve rehabilitasyon faaliyetleri, Türkiye Bilimler Akademisi Yayınları

Zhang, Q., Ge, L., Zhang, R., Metternicht, G. I., Liu, C., & Du, Z. (2021). Towards a deep-learning-based framework of Sentinel-2 imagery for automated active fire detection. Remote Sensing, 13(23), 4790

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Tektonik Hareketlere Bağlı Olarak Arazi Yüzey Deformasyonlarının İzlenmesi: Yunanistan Örneği

**Ahmet Batuhan Polat*[1], Füsun Balık Şanlı[2], Özgün Akçay[1]**

[1] *Çanakkale Onsekiz Mart Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Çanakkale, Türkiye*
[2] *Yıldız Teknik Üniversitesi, İnşaat Fakültesi, Harita Mühendisliği Bölümü, İstanbul, Türkiye*

**Anahtar Kelimeler**
Uzaktan algılama,
İnterferometri,
Zaman serisi analizi,
Tektonik hareketler

**ÖZET**

Depremler, tektonik hareketler sonucu oluşarak yüzeyde kalıcı değişimlere neden olan jeolojik olaylardır. Özellikle aktif fay hatlarında meydana gelen sismik aktiviteler, yüzey deformasyonlarına yol açmaktadır. Yunanistan, jeolojik yapısı gereği birçok aktif fay hattına ev sahipliği yapmaktadır. Bu çalışmada, Yunanistan'ın adalar bölgesinde 2025 yılının Ocak ve Şubat aylarında yaşanan yoğun depremlerin arazi üzerindeki etkileri InSAR teknikleri ile incelenmiştir. Santorini ve Anydros adalarının 2022-2025 yılları arasında Sentinel-1 SAR görüntüleri değerlendirilerek ilgili tarihler için zaman serisi analizi gerçekleştirilmiştir. Sonuçlar, 2025 yılı Şubat ayında meydana gelen yoğun sismik hareketlerin yüzeyde belirgin değişimlere yol açtığını göstermektedir. Ayrıca, deformasyonların bölgesel özelliklere bağlı olarak farklı yönlerde gerçekleştiği ve istatistiksel olarak anlamlı bir korelasyon gösterdiği belirlenmiştir. InSAR teknolojisinin geniş alanlarda yüksek hassasiyetli ölçüm sağlaması, aktif fay bölgelerinin uzun vadeli izlenmesi için önemli bir avantaj sunmaktadır. Özellikle 2025'te artan tektonik hareketlilik göz önüne alındığında, bu tür bölgelerde sürekli izleme çalışmaları, sismotektonik süreçlerin daha iyi anlaşılmasına ve potansiyel risklerin değerlendirilmesine katkı sağlayacaktır.

# Monitoring Land Surface Deformations Due To Tectonic Movements: The Case of Greece

**Keywords**
Remote sensing,
Interferometry,
Time-series analysis,
Tectonic movements

**ABSTRACT**

Earthquakes are geological events that occur as a result of tectonic movements and cause permanent changes on the surface. Seismic activity, especially along active fault lines, leads to surface deformations. In this study, the effects of the intense earthquakes experienced in Greece in early 2025 on the land were analyzed with InSAR techniques. Sentinel-1 SAR images of Santorini and Anydros islands between 2022 and 2025 were evaluated and time series analysis was performed. The results show that the intense seismic activity in February 2025 caused significant changes on the surface. In addition, it was determined that the deformations occurred in different directions depending on regional characteristics and showed a statistically significant correlation. The ability of InSAR technology to provide high-precision measurements over large areas offers a significant advantage for long-term monitoring of active fault zones. Especially considering the increased tectonic activity in 2025, continuous monitoring studies in such regions will contribute to a better understanding of seismotectonic processes and assessment of potential risks.

## 1. GİRİŞ

Depremler, yer kabuğundaki tektonik hareketlerin bir sonucu olarak meydana gelen en yıkıcı doğal afetlerden biridir. Özellikle aktif fay hatları boyunca yoğunlaşan sismik aktivite, yeryüzü şekillerinde önemli değişimlere neden olabilmektedir (Tiwari ve ark., 2024).

Son yıllarda, deprem kaynaklı yüzey deformasyonlarının izlenmesi için geleneksel jeodezik yöntemlere ek olarak, uzaktan algılama teknikleri giderek daha fazla kullanılmaktadır. Bu bağlamda, Diferansiyel InSAR (DInSAR) ve sürekli zaman serisi analizi yapabilen gelişmiş InSAR teknikleri (PSI ve SBAS), geniş alanlı ve yüksek hassasiyetli deformasyon ölçümleri sağlayarak

* **Sorumlu Yazar**
*(abpolat@comu.edu.tr) ORCID ID 0000-0002-7495-1998
(fbalik@yildiz.edu.tr) ORCID ID 0000-0003-1243-8299
(akcay@comu.edu.tr) ORCID ID 0000-0003-0474-7518

**Kaynak Göster (APA):**
Polat A B, Balık Şanlı F & Akçay Ö. (2025). Tektonik Hareketlere Bağlı Olarak Arazi Yüzey Deformasyonlarının İzlenmesi: Yunanistan Örneği, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

deprem araştırmalarında kritik bir rol üstlenmiştir (Suresh ve Yarrakula, 2020; Li ve ark., 2021).

Bu çalışma, Ege Denizi'nde yer alan Santorini ve Anydros adaları yakınlarında, 2025 yılının Ocak ayının sonlarında başlayan yoğun sismik aktivitenin arazi üzerindeki etkilerini InSAR yöntemleri ile incelemeyi amaçlamaktadır. Çalışma kapsamında, 2022-2025 yılları arasında Sentinel-1 uydusundan elde edilen SAR görüntüleri kullanılarak, yüzey deformasyonları belirlenmiş ve bu değişimlerin deprem aktivitesi ile olan ilişkisi değerlendirilmiştir. Özellikle, 2025 yılının Şubat ayından itibaren gözlemlenen ani arazi değişimleri, sismik aktivitenin doğrudan yüzey deformasyonları ile ilişkili olduğunu göstermektedir. Bu analizlerde, zaman serisi InSAR tekniklerinden SBAS yöntemi kullanılarak deformasyon hızları ve yer değiştirme miktarları hesaplanmıştır. Çalışma kapsamında Santorini ve Anydros adalarının çevresinde gerçekleşen yoğun sismik aktivitenin yüzey deformasyonlarına olan etkileri incelenmiştir.

## 2. YÖNTEM

Çalışmada, yüzey deformasyonlarını belirlemek amacıyla InSAR yöntemi kullanılmıştır. Santorini ve Anydros adaları için 2022 Ocak - 2025 Mart tarihleri arasında Sentinel-1 verileri kullanılarak zaman serisi analizi gerçekleştirilmiş, arazi yüzeyindeki değişimler incelenmiştir. Elde edilen deformasyon haritaları, Türkiye Afet ve Acil Durum Yönetimi Başkanlığı (AFAD) deprem kataloğundan elde edilen 2022 sonrası Mw ≥ 4.0 büyüklüğündeki sismik olaylarla karşılaştırılmıştır. Bu karşılaştırma sonucunda, bölgedeki arazi yüzey değişimlerinin tektonik süreçlerle ilişkisi değerlendirilmiş, özellikle 2025 yılının Şubat ayındaki yüksek sismik aktivitenin yüzey deformasyonuna etkisi detaylandırılmıştır.

### 2.1. Çalışma Alanı ve Kullanılan Veri

Çalışma bölgesi olarak Yunanistan'ın Kiklad Adaları Böglesinde bulunan Santorini ve Anydros adaları seçilmiştir. İlgili bölgenin seçilme sebebi özellikle 2025 yılı Şubat ayında çok sayıda Mw ≥ 4.0 üstü gerçekleşen depremlerdir. Sismik aktivitenin çok yoğun olduğu bölge aktif fay hatlarının da üzerinde bulunmaktadır. Çalışma alanının olduğu bölge Şekil 1'de verilmiştir.

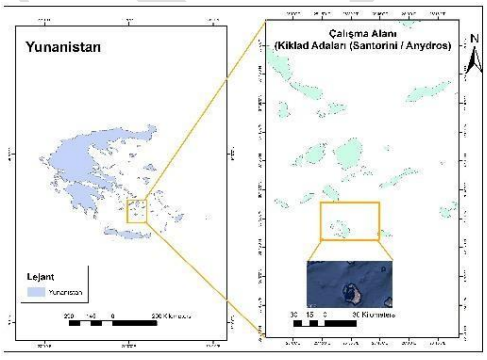


**Şekil 1.** Çalışma alanı

Çalışmada 2022 yılı Ocak ayından 2025 Mart ayına kadar elde edilen 97 adet Sentinel-1 SAR görüntüsü kullanılmıştır. İlgili veriler yükselen yörüngeye sahip görüntülerden elde edilmiştir. Bölgede gerçekleşen deprem ve büyüklük verileri ise AFAD'tan elde edilmiştir.

Görüntüler elde edildikten sonra arazi yüzey değişimi zaman serilerini elde etmek ve yıllık hız değişimlerini tespit etme amacı InSAR analizi gerçekleştirilmiş. Santorini ve Anydros adalarında iki farklı işlem gerçekleştirilmiş ve iki adanın 2022-2025 yıllarındaki arazi yüzeyindeki yıllık hız değişimi ve kümülatif deformasyon miktarı bulunmuştur. Yapılan analizler sonucunda her iki adadan da adanın farklı coğrafi konumlarında bulunan üç nokta seçilmiş ve bu noktaların yıllara göre yüzey değişimleri ile depremler karşılaştırılmıştır.

## 3. BULGULAR

2022-2025 yılları arasında bölgede gerçekleşen Mw ≥ 4.0 üstü depremlerin sayısal olarak grafiği Şekil 2.de verilmiştir.

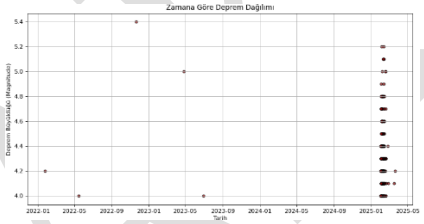


**Şekil 2.** 2022-2025 yılları bölgedeki deprem dağılımı

Şekil 2.de görüldüğü gibi Mw ≥ 4.0 üstü depremler özellikle 2025 Ocak aylarının sonunda artmaktadır. Şekil 3'te Santorini ve Anydros adaları ile depremlerin yoğun olduğu bölgeler harita üzerinden gösterilmiştir.

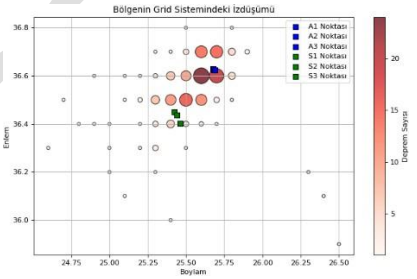


**Şekil 3.** 2022-2025 yılları arası bölgede gerçekleşen deprem yoğunluğunun harita üzerinde gösterimi

Şekil 4'te Santorini ve Anydros adalarının zamana bağlı arazi yüzey değişimlerini gösteren zaman serisi grafiği verilmiştir.

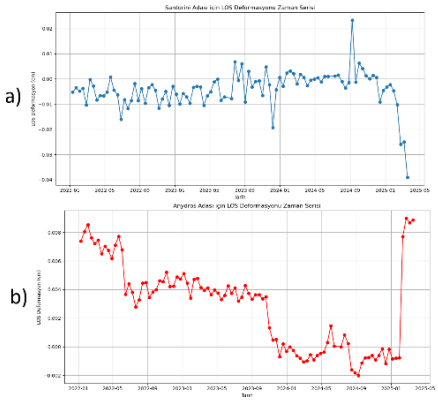


**Şekil 4.** 2022-2025 yılları arası InSAR yöntemleri ile elde edilen zaman serileri a)Santorini b)Anydros adası

Santorini Adasından alınan S1, S2, S3 noktaları ve Anydros Adasından alınan A1, A2, A3 noktalarının arazi yüzey değişim grafiği Şekil 5'te verilmiştir.

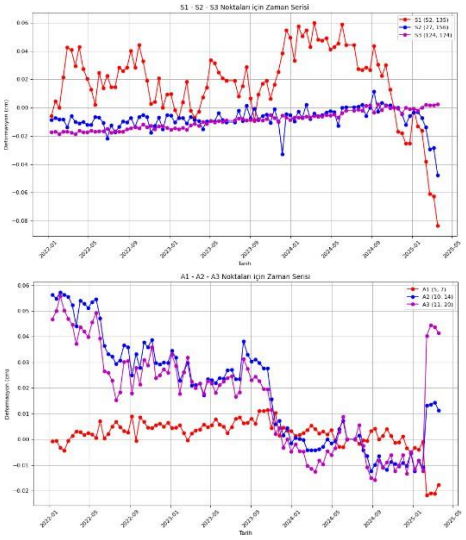


**Şekil 5.** Santorini ve Anydros Adalarında bulunan S1, S2, S3 ve A1, A2, A3 noktalarının arazi yüzeylerinin zamansal değişimi

## 4. TARTIŞMA

Analizler incelendiğinde özellikle Şubat'ta başlayan Mw ≥ 4.0 üstü deprem fırtınasının iki adanın arazi yüzeyinde de belirgin bir değişim gerçekleştirdiği gözlemlenmiştir. 2022 yılından 2025 yılı Şubat ayına kadar geçen sürede yalnızca 5 adet 4 Mw üstü deprem gerçekleşmişken 2025 Şubat ayında 194 adet 4 Mw üstü deprem gerçekleşmiştir. Bu durum arazi yüzeyindeki ani değişimlerin sebebini göstermektedir. Aynı şekilde iki farklı adadaki toplam 6 nokta incelendiğinde Anydros adasındaki arazi yüzeyinde yükselmeler gerçekleşirken Santorini adasındaki arazi yüzeyinde çökmelerin gerçekleştiği tespit edilmiştir. Bu da aynı tektonik hareketlerin etkilerini hisseden bölgelerde farklı yönlerde arazi değişimleri yaşandığını göstermektedir. Santorini adasındaki S1, S2, S3 noktaları ile Anydros Adasında bulunan A1, A2, A3 noktaları kendi içlerinde incelendiğinde tutarlı bir korelasyona sahiptir. Bu da istatistiksel olarak sonuçların anlamlı olduğunu göstermektedir.

## 5. SONUÇ

Bu çalışma, yoğun sismik aktivitelerin arazi yüzeyi üzerindeki etkilerini inceleyerek, deprem kaynaklı deformasyonların uzun vadeli izlenmesi gerekliliğini ortaya koymaktadır. Yapılan analizler, ani tektonik hareketlerin yüzeyde belirgin değişimlere neden olduğunu ve bu değişimlerin bölgesel jeolojik özelliklere bağlı olarak farklı yönlerde gerçekleşebildiğini göstermektedir. Özellikle büyük ölçekli deprem fırtınalarının, yüzeyde kalıcı deformasyonlara yol açabileceği tespit edilmiştir. Bu bulgular, aktif fay hatları boyunca meydana gelen depremlerin yalnızca anlık sarsıntılarla sınırlı olmadığını, aynı zamanda yüzey şekillerinde uzun süreli değişimlere neden olabileceğini ortaya koymaktadır.

Geleneksel GPS tabanlı jeodezik ölçüm yöntemleri yüksek doğruluk sağlamasına rağmen geniş alanlarda kapsama ve zaman/maliyet açısından sınırlamalara sahiptir. InSAR yöntemi, milimetre hassasiyetinde veri sunarak geniş alanlarda deformasyon tespitine olanak tanır. Bu çalışma, InSAR'ın özellikle aktif fay hatlarında uzun vadeli deformasyon analizlerinde güvenilir bir yöntem olduğunu ve geleneksel jeodezik tekniklere göre daha geniş ölçekli gözlemler sağladığını göstermektedir.

Elde edilen bulgular, depremlerin yüzeyde oluşturduğu değişimlerin uzun vadeli izlenmesi gerektiğini ortaya koymaktadır. Tektonik olarak aktif bölgelerdeki deformasyonların zamanla büyük ölçekli değişimlere yol açabileceği dikkate alındığında, sürekli gözlem önemlidir. 2025'teki yoğun tektonik hareketler, bölgedeki deformasyon süreçlerinin izlenmesinin gerekliliğini vurgulamaktadır. InSAR ve benzeri uzaktan algılama tekniklerinin uzun vadeli izleme çalışmalarıyla entegre edilmesi, sismotektonik süreçlerin daha iyi anlaşılmasına ve gelecekteki risklerin belirlenmesine katkı sağlar.

### Yazar Katkı Oranı

**Yazar1:** Uygulama, Metodoloji, Yazma, Literatür. **Yazar2:** Kontrol, Doğrulama, Düzenleme. **Yazar3:** Kontrol, Metodoloji, Düzenleme.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

### Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

### KAYNAKÇA

Tiwari, A., Sain, K., Tiwari, J., Kumar, A., Kumar, N., Paul, A., & Shukla, V. (2024). Seismic and radon signatures: A multiparametric approach to monitor surface dynamics of a hazardous 2021 rock–ice avalanche, Chamoli Himalaya. Earth Surface Processes and Landforms, 49(10), 2965-2979.

Suresh, D., & Yarrakula, K. (2020). InSAR based deformation mapping of earthquake using Sentinel 1A imagery. Geocarto International, 35(5), 559-568.

Li, Q., Wang, W., Wang, J., Zhang, J., & Geng, D. (2021). Exploring the relationship between InSAR coseismic deformation and earthquake-damaged buildings. Remote Sensing of Environment, 262, 112508.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Eskişehir İlinde Deprem Kırılganlığının Çok Kriterli Karar Analizi ve Oyun Teorisi Yaklaşımı ile CBS Ortamında Değerlendirilmesi

**Murat Başeğmez [1], Ayhan Doğan [2], Cevdet Coşkun Aydın [3*]**

[1]*Milli Eğitim Bakanlığı, CBS ve Emlak Daire Başkanlığı, Ankara, Türkiye*
[2]*Hacettepe Üniversitesi, Başkent OSB Teknik Bilimler Meslek Yüksekokulu, Bilgisayar Teknolojileri, Ankara, Türkiye*
[3]*Hacettepe Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği, Ankara, Türkiye*

**Anahtar Kelimeler**
Deprem Kırılganlığı,
Coğrafi Bilgi Sistemleri,
Çok Kriterli Karar Verme,
Oyun Teorisi

**ÖZET**

Bu çalışma, aktif tektonik kuşak üzerinde yer alan Eskişehir ilinin deprem kırılganlığını belirlemeye yönelik olarak Coğrafi Bilgi Sistemleri (CBS) tabanlı çok kriterli karar verme (ÇKKV) yaklaşımlarını bütüncül bir yapıda bir araya getirmektedir. Çalışmada, deprem odak derinliği, heyelan, fay hatlarına uzaklık, litoloji, deprem büyüklüğü ve en büyük yer ivmesi (PGA) olmak üzere altı temel kriter dikkate alınmıştır. Bu kriterlerin ağırlıkları Analitik Hiyerarşi Süreci (AHP) ve Entropi Ağırlık Metodu (EWM) ile hesaplanmış, ardından Oyun Teorisi (Game Theory) kapsamında Nash dengesi yaklaşımı ile optimize edilmiştir. Elde edilen ağırlıklar CBS ortamında uygulanarak çalışma alanı beş risk düzeyine ayrılmış ve deprem kırılganlık haritası oluşturulmuştur. Mekânsal analiz sonuçlarına göre, Odunpazarı, Tepebaşı ve İnönü ilçelerinde yoğunlaşan çok yüksek riskli alanlar dikkat çekmektedir. Bu alanlar arasından seçilen 28 bölge, İdeal Çözüme Benzerliğe Göre Tercih Sıralaması Tekniği (TOPSIS) yöntemi ile sıralanmış ve bu bölgelerin 4 tanesinde en kritik değere ulaşmıştır. Çalışma, çok kriterli değerlendirme yaklaşımlarının CBS ile entegrasyonu sayesinde, deprem riski taşıyan alanların belirlenmesi ve önceliklendirilmesinde etkili ve uygulanabilir bir karar destek modeli sunmakta; afet yönetimi ve kentsel planlama süreçlerine bilimsel katkı sağlamaktadır.

# Assessment of Earthquake Vulnerability in Eskişehir Province Using Multi-Criteria Decision Analysis and Game Theory Approach within a GIS Environment

**Keywords**
Earthquake Vulnerability,
Geographic Information Systems,
Multi-Criteria Decision-Making,
Game Theory

**ABSTRACT**

This study integrates Geographic Information Systems (GIS)-based multi-criteria decision-making (MCDM) approaches to comprehensively assess earthquake vulnerability in Eskişehir Province, which is located within an active tectonic zone. Six fundamental criteria were considered: earthquake hypocenter depth, landslide susceptibility, distance to fault lines, lithology, earthquake magnitude, and peak ground acceleration (PGA). The weights of these criteria were calculated using the Analytic Hierarchy Process (AHP) and the Entropy Weight Method (EWM), and subsequently optimized through the Nash equilibrium approach within the scope of Game Theory. The optimized weights were applied within the GIS environment, and the study area was classified into five seismic risk levels. The resulting vulnerability map revealed that areas of very high risk are predominantly concentrated in the districts of Odunpazarı, Tepebaşı, and İnönü. Out of the identified areas, 28 regions were evaluated and ranked using the Technique for Order Preference by Similarity to Ideal Solution (TOPSIS), and four of these regions exhibited the highest critical scores. The study demonstrates that the integration of MCDM techniques with GIS provides an effective and applicable decision support model for identifying and prioritizing earthquake-prone areas, contributing significantly to disaster risk management and urban planning processes.

* **Sorumlu Yazar**

(murat.basegmez@gmail.com) ORCID ID 0000-0002-7704-9510
(aydogan@hacettepe.edu.tr) ORCID ID 0000-0002-9872-8889
*(ceaydin@hacettepe.edu.tr) ORCID ID 0000-0003-2064-6936

**Kaynak Göster (APA):**

Başeğmez M, Doğan A & Aydın C C (2025). Eskişehir İlinde Deprem Kırılganlığının Çok Kriterli Karar Analizi ve Oyun Teorisi Yaklaşımı ile CBS Ortamında Değerlendirilmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Doğal afetler dünya genelinde ciddi can ve mal kayıplarına yol açmaya devam ederken, depremler en yıkıcı tehditlerden biri olarak öne çıkmaktadır (Lizundia et al., 2017). Aktif deformasyona maruz Eskişehir Fay Zonu üzerinde yer alan Eskişehir ili, karmaşık jeolojik yapısı, hızla artan nüfusu ve yoğun kentleşme baskısı nedeniyle yüksek düzeyde sismik kırılganlık taşımaktadır. Bu koşullar, mekânsal olarak ayrıntılı ve veri odaklı değerlendirmeleri zorunlu kılmakta; böylece riskin azaltılması ve dirençli kentsel planlama için sağlam bir temel oluşturulmaktadır (Armaş et al., 2017; Doğan et al., 2025).

Bu çalışmada, Eskişehir'in deprem kırılganlığını haritalamak ve önceliklendirmek amacıyla CBS ile bütünleştirilmiş ÇKKV yaklaşımı sunulmaktadır. Deprem odak derinliği, heyelan duyarlılığı, aktif faylara uzaklık, litoloji, deprem büyüklüğü ve PGA olmak üzere altı temel kriter, önce AHP ve EWM yöntemleri ile ağırlıklandırılmıştır. Bu kriterler, deprem kaynaklı risk analizlerinde yerel zemin koşullarını, sismik tehlikeyi ve yüzey etkilerini yansıtmaları nedeniyle literatürde sıklıkla tercih edilmektedir (Maqsoom et al., 2022; Mohammadi et al., 2025; Doğan et al., 2025).

Öznel ve nesnel ağırlık setleri, oyun teorisi perspektifinde Nash dengesi optimizasyonu ile uyumlandırılarak dengeli bir ağırlık vektörü elde edilmiştir. Bu vektör, CBS ortamında uygulanarak beş sınıflı (çok yüksek–çok düşük) kırılganlık haritası oluşturulmuş, çalışma alanı 28 alt bölgeye ayrılmış ve her bir alt bölge tanımlanan alt kriterlere göre yeniden sınıflandırılmıştır.

Elde edilen harita, çok yüksek riskli alanların Odunpazarı, Tepebaşı, İnönü ile Mahmudiye, Mihalgazi ve Sivrihisar ilçelerinin belirli kesimlerinde yoğunlaştığını ortaya koymaktadır. Söz konusu en yüksek risk sınıfındaki 28 alan, TOPSIS ile değerlendirilerek acil müdahale gerektiren öncelikli bölgeler belirlenmiştir. CBS, ÇKKV ve oyun kuramı optimizasyonunu bir araya getiren bu bütünleşik çerçeve, Eskişehir'in sismik riskini ayrıntılı biçimde ortaya koymakta; karar vericilere risk azaltımı ve kentsel planlama süreçlerinde uygulanabilir, ölçeklenebilir ve kanıta dayalı bir araç sunmaktadır.

## 2. YÖNTEM

### 2.1. Analitik Hiyerarşi Süreci (AHP)

AHP, Thomas L. Saaty'nin geliştirdiği ve karmaşık karar problemlerini hiyerarşik düzene indirgerken ikili karşılaştırmalarla kriter önceliklerini nicelleştiren bir ÇKKV yöntemidir (Saaty, 1988). Kriter çiftleri 1–9'luk önem ölçeğiyle karşılaştırılır; özvektör yöntemiyle ağırlıklar hesaplanır. Ardından tutarlılık oranı (CR) belirlenir; CR < 0,10 olduğunda yargılar kabul edilebilir düzeydedir, aksi hâlde matris yeniden düzenlenir. Böylece AHP, öznel yargıları nicel tutarlılık denetimiyle birleştirerek güvenilir kriter ağırlıkları sağlar.

### 2.2. Entropi Ağırlıklandırma Yöntemi (EWM)

EWM, yalın matematiksel algoritması ve farklı ÇKKV problemlerine kolayca uygulanabilmesi sayesinde karar vericiler arasında yaygın biçimde kullanılmaktadır. Ancak yalnızca veri varyasyonuna dayandığı için, kriterler arasındaki olası korelasyonları göz ardı edebilmekte; bu durum da düşük ağırlıklı kriterlerin yüksek ağırlıklı olanları etkilemesine yol açabilmektedir (Qin et al., 2022).

EWM'de entropi kavramı Claude Shannon tarafından tanımlanmıştır ve temel ilke, verinin dağılması arttıkça entropi değerinin azalmasıdır; bu da söz konusu kriterin daha fazla bilgi içerdiğini ve daha yüksek ağırlık alması gerektiğini gösterir (Neelakanta et al., 1992).

### 2.3. Oyun Teorisi (Game Theory)

Oyun teorisi, bağımsız ya da karşılıklı bağımlı durumlarda oyuncuların karar süreçlerini inceleyen matematiksel bir çerçevedir. Sonucun, her biri tek başına tam kontrol sahibi olmayan iki ya da daha fazla oyuncunun tercihine bağlı olduğu durumlarda kullanılır (Jiang et al., 2020; Nash, 1950). Rekabet hâlindeki seçimler ile en iyileme stratejileri arasındaki ilişkiyi araştıran bu kuramın temel amacı, tüm oyuncuların ortak çıkarlarını azamileştiren stratejik bir denge (Nash dengesi) bulmaktır.

### 2.4. İdeal Çözüme Benzerliğe Göre Tercih Sıralaması Tekniği (TOPSIS)

TOPSIS, Hwang ve Yoon (1981) tarafından geliştirilmiş, çok sayıda alternatif arasından en uygunu seçmeye yardımcı popüler bir ÇKKV yöntemidir. Temel yaklaşım, her alternatifin "ideal" (en iyi) çözüme yakınlığını ve "negatif ideal" (en kötü) çözüme uzaklığını birlikte değerlendirerek en yüksek faydayı sunan seçenekleri öne çıkarmaktır. Hem nicel hem nitel verileri normalize etmesi, fayda ve maliyet temelli kriterleri aynı anda ele alabilmesi ve uzaklık kavramına dayalı basit yapısı sayesinde, mühendislikten afet risk analizine kadar pek çok alanda yaygınlıkla kullanılmaktadır. Karar vericilere sezgisel bir "göreli yakınlık" skoru sunması ve duyarlılık analizlerine uygun olması da TOPSIS'in tercih edilmesindeki temel etmenlerdir.

## 3. BULGULAR

Çalışma kapsamında, AHP ve EWM ile belirlenen ağırlıklar, Oyun Teorisi yaklaşımıyla optimize edilmiştir. Altı kriter (deprem odak derinliği, heyelan, fay hatlarına uzaklık, litoloji, deprem büyüklüğü ve PGA) esas alınarak oluşturulan ağırlıklar, CBS ortamında mekânsal analizlere entegre edilmiştir. Bu analiz süreci, karar destek sisteminin metodolojik bütünlüğünü yansıtan Şekil 1'de sunulmuştur. Bu analizler sonucunda çalışma alanı beş risk düzeyine ayrılmıştır: çok yüksek (5), yüksek (4), orta (3), düşük (2) ve çok düşük/risk yok (1). Risk haritası, kentsel yerleşim ve jeolojik faktörlerin birlikte değerlendirildiği bütüncül bir yapıyla oluşturulmuştur.

Harita analizlerine göre, "çok yüksek" ve "yüksek" riskli alanların özellikle Odunpazarı, Tepebaşı ve İnönü ilçelerinde yoğunlaştığı, ayrıca Mahmudiye, Mihalgazi ve Sivrihisar ilçelerinin bazı kesimlerinde de benzer risk seviyelerinin görüldüğü belirlenmiştir. Bu alanlar, yüzey

jeolojisi, fay zonlarına yakınlık ve yüksek PGA değerleri gibi etkenler açısından dikkat çekmektedir.

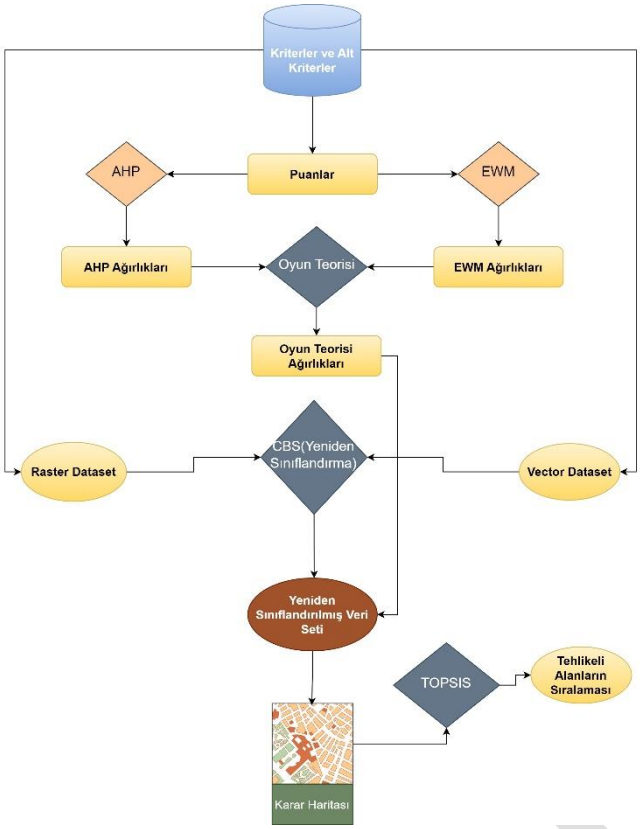


**Şekil 1.** Yöntemsel akış diyagramı.

Beş risk düzeyinden en yükseğinde yer alan bölgeler arasından toplam 28 alan seçilmiş ve bu alanlar TOPSIS ile analiz edilerek kendi içinde sıralanmıştır. Sıralama sonucunda 4 alan (DTA_27, DTA_24, DTA_5 ve DTA_22 kodlu alanlar), kırılganlık açısından en kritik bölgeler olarak tanımlanmıştır. Bu bölgeler hem yapısal hem de jeoteknik açıdan müdahale önceliği taşıyan alanlar olarak öne çıkmaktadır.

Çalışmada elde edilen bulgular, Eskişehir'de deprem riski taşıyan bölgelerin mekânsal olarak nerelerde yoğunlaştığını ortaya koymakta ve bu bölgelerin hangi ölçütlere göre kırılganlık gösterdiğini detaylı biçimde açıklamaktadır.

## 4. SONUÇ

Bu çalışma, aktif tektonik kuşakta konumlanan Eskişehir ilinin deprem kırılganlığını belirlemek amacıyla çok kriterli karar verme yöntemleri (AHP, EWM) ile CBS tabanlı mekânsal analizlerin entegre edildiği bütüncül bir çerçeve sunmaktadır. Belirlenen kriter ağırlıkları, Oyun Teorisi yaklaşımıyla optimize edilmiş ve bu doğrultuda oluşturulan kırılganlık haritası beş risk sınıfına ayrılarak sunulmuştur. Yapılan analizler, kırılganlık düzeyinin Odunpazarı, Tepebaşı ve İnönü ilçelerinde yoğunlaştığını; Mahmudiye, Mihalgazi ve Sivrihisar ilçelerinde ise yer yer yüksek riskli bölgelerin bulunduğunu göstermektedir. Yüksek risk sınıfındaki 28 alanın TOPSIS yöntemiyle değerlendirilmesi sonucunda, dört alan (DTA_27, DTA_24, DTA_5 ve DTA_22) en kritik müdahale bölgeleri olarak tanımlanmıştır.

Çalışmanın sunduğu yöntemsel yaklaşım, yalnızca Eskişehir'e özgü bir uygulama ile sınırlı kalmayıp, benzer deprem riski taşıyan diğer kentlere de kolaylıkla uyarlanabilecek esnek bir model niteliği taşımaktadır. Elde edilen bulgular, karar vericilere kentsel gelişim planlarını yeniden değerlendirme, afet öncesi hazırlık düzeyini artırma ve kaynakları en kırılgan bölgelere yönlendirme konusunda bilimsel temelli bir yol haritası sunmaktadır. Bu yönüyle çalışma hem akademik literatüre hem de afet risk yönetimine katkı sağlayan bütüncül bir model önerisi sunmaktadır.

Bununla birlikte, gelecekte yapılacak çalışmalar kapsamında modelin kapsamı daha da genişletilebilir. Özellikle yapı stoku envanterinin modele dâhil edilmesi, bina tipi, yapı yaşı, kat sayısı ve mühendislik hizmeti alma durumu gibi fiziksel kırılganlıkla doğrudan ilişkili parametrelerin değerlendirilmesini mümkün kılacaktır. Aynı şekilde, gelir düzeyi, yaşlı nüfus oranı, engelli birey yoğunluğu ve eğitim düzeyi gibi sosyo-ekonomik değişkenlerin entegre edilmesi, toplumsal kırılganlık düzeylerinin analizine olanak tanıyacak ve müdahale önceliklendirmelerinde daha adil ve etkili kararlar alınmasını sağlayacaktır. Bu tür verilerin entegre edilmesiyle sosyal kırılganlık endekslerinin oluşturulması ve mekânsal olarak görselleştirilmesi de mümkün olacaktır. Ayrıca, yapay zekâ temelli yaklaşımların, özellikle zaman serisi analizleri ile desteklenmesi sayesinde modelin dinamik ve öngörücü bir yapıya kavuşması sağlanabilir. Böylelikle değişen çevresel ve kentsel koşullara karşı erken uyarı sistemlerinin tasarlanması ve müdahale stratejilerinin sürekli güncellenmesi mümkün olacaktır.

Sonuç olarak, bu çalışma yalnızca mevcut durumun tespitiyle sınırlı kalmayıp, gelecekte yapılacak daha kapsamlı analizlere de sağlam bir zemin hazırlayan, uygulanabilir ve geliştirilebilir bir metodolojik yaklaşım sunmaktadır.

### Yazar Katkı Oranı

Yazarların bildiriye katkıları eşit orandadır.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

### Araştırma ve Yayın Etiği Beyanı

Çalışmanın araştırma ve yayın etiği hakkında herhangi bir sorunu bulunmamaktadır.

### KAYNAKÇA

Lizundia, B., Davidson, R. A., Hashash, Y. M., & Olshansky, R. (2017). Overview of the 2015 Gorkha, Nepal, earthquake and the Earthquake Spectra special issue. Earthquake Spectra, 33(S1), 1–20.

Armaş, I., Toma-Danila, D., Ionescu, R., & Gavriş, A. (2017). Vulnerability to earthquake hazard: Bucharest case study, Romania. International Journal of Disaster Risk Science, 8(2), 182–195.

Doğan, A., Başeğmez, M., & Aydın, C. C. (2025). Assessment of the seismic vulnerability in an urban area with the integration of machine learning methods and GIS. Natural Hazards. doi: 10.1007/s11069-025-07185-4.

Mohammadi, S., Balouei, F., Amini, S., & others. (2025). Beyond the Richter scale: A fuzzy inference system approach for measuring objective earthquake risk. Natural Hazards, 121(1), 245–268. doi: 10.1007/s11069-024-06786-9.

Maqsoom, A., Aslam, B., Khalil, U., Mehmood, M. A., Ashraf, H., & Siddique, A. (2022). An integrated approach based earthquake risk assessment of a seismically active and rapidly urbanizing area in Northern Pakistan. Geocarto International, 37(27), 16043–16073.

Saaty, T. L. (1988). What is the analytic hierarchy process?. In Mathematical models for decision support (pp. 109-121). Springer Berlin Heidelberg.

Qin, Y., Guan, K., Kou, J., Ma, Y., Zhou, H., & Zhang, X. (2022). Durability evaluation and life prediction of fiber concrete with fly ash based on entropy weight method and grey theory. Construction and Building Materials, 327, 126918.

Lind, N. (1993). Entropy optimization principles with applications: by JN Kapur and HK Kesavan, Academic Press, San Diego, CA, 1992, xiv+ 408 pp., ISBN 0-12-397670-7.

Jiang, Y., Zhou, K., Lu, X., & Yang, S. (2020). Electricity trading pricing among prosumers with game theory-based model in energy blockchain environment. Applied Energy, 271, 115239.

Nash Jr, J. F. (1950). Equilibrium points in n-person games. Proceedings of the national academy of sciences, 36(1), 48-49.

Yoon, K., & Hwang, C. L. (1981). TOPSIS (technique for order preference by similarity to ideal solution)–a multiple attribute decision making, w: Multiple attribute decision making–methods and applications, a state-of-the-at survey. Berlin: Springer Verlag, 128, 140.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

**TUFUAB XIII. TEKNİK SEMPOZYUMU**
https://tufuab2025.beun.edu.tr

# Küre Dağları Milli Parkı'nda S-Bant NovaSAR-1 ve Landsat 9 Veri Füzyonu ile Makine ve Derin Öğrenme Tabanlı Karbon Stoku Tahmini

**Eren Gürsoy Özdemir*[1], Saygın Abdikan[2]**

[1]*Bartın Üniversitesi, Mimarlık ve Şehir Planlama Bölümü, Ulus, Bartın, Türkiye*
[2]*Hacettepe Üniversitesi, Harita Mühendisliği Bölümü, Beytepe, Ankara, Türkiye*

**Anahtar Kelimeler**
Toprak üstü karbon stoku,
NovaSAR-1,
Landsat 9,
Makine öğrenmesi,
Derin öğrenme

**ÖZET**

Toprak üstü karbon (TÜK), ekosistem döngüsünün temel bir unsuru olup, orman karbon stoklarının izlenmesinde kritik bir role sahiptir. Bu çalışma, Küre Dağları Millî Parkı (KDMP) tampon bölgesinde yer alan doğu kayını, Uludağ göknarı ve karışık orman plantasyonlarındaki TÜK dağılımını, NovaSAR-1 S-bant SAR verileri, Landsat 9 multispektral görüntüleri ve arazi ölçümleri kullanarak analiz etmektedir. Çalışma kapsamında, 110 örnekleme alanında ağaçların göğüs yüksekliği çapı (DBH) ve boy uzunlukları ölçülmüş; tür bazlı geliştirilen alometrik denklemler ve karbona dönüşüm parametreleri ile TÜK miktarları belirlenmiştir. TÜK tahmini için NovaSAR-1 S-bant verisinin YY ve DD polarizasyonları, Landsat 9'un altı spektral bandı ve on bitki indeksi kullanılarak XGBoost ve Tek Boyutlu Evrişimsel Sinir Ağı (1D-CNN) algoritmalarıyla modelleme gerçekleştirilmiştir. Özellik seçimi sürecinde mutual information yöntemi uygulanmış ve 18 özelliğin 9'u seçilmiştir. Hiperparametre optimizasyonu için GridSearchCV yöntemi kullanılmıştır. Yirmi senaryo oluşturulmuş ve tahmin performansları karşılaştırılmıştır. En iyi sonuç, 1D-CNN yöntemiyle YY ve DD polarizasyonlarının Landsat 9'un 2. ve 4. bantları ile SAVI, MSAVI, NBR ve TVI bitki indekslerinin birlikte kullanıldığı senaryoda elde edilmiştir ($R^2$ = 0.74, RMSE = 14.745 t/ha). Sonuçlar, SAR ve optik verilerin entegrasyonunun TÜK tahmininde önemli katkılar sağladığını ortaya koymaktadır.

# Machine and Deep Learning-Based Carbon Stock Estimation in Küre Mountains National Park Using S-Band NovaSAR-1 and Landsat 9 Data Fusion

**Keywords**
Aboveground carbon stock,
NovaSAR-1,
Landsat 9,
Machine learning
Deep learning

**ABSTRACT**

Aboveground carbon (AGC) is a fundamental component of ecosystem cycles and is critical in monitoring forest carbon stocks. This study analyzes the AGC distribution in eastern beech, Uludağ fir, and mixed forest plantations located within the buffer zone of Küre Mountains National Park (KMNP) using NovaSAR-1 S-band SAR data, Landsat 9 multispectral imagery, and field measurements. Within the scope of the study, tree diameter at breast height (DBH) and height were measured across 110 sampling plots. AGC quantities were determined using species-specific allometric equations and carbon conversion parameters. For AGC estimation, modeling was performed using XGBoost, and One-Dimensional Convolutional Neural Network (1D-CNN) algorithms, incorporating HH and VV polarizations from NovaSAR-1 S-band data, six spectral bands from Landsat 9, and ten vegetation indices. The feature selection process employed the mutual information method, resulting in 9 out of 18 features being selected. Hyperparameter optimization was conducted using the GridSearchCV method. Twenty scenarios were developed, and their predictive performances were compared. The best performance was achieved in a scenario utilizing the 1D-CNN method, combining HH and VV polarizations with Landsat 9's bands 2 and 4, along with the SAVI, MSAVI, NBR, and TVI vegetation indices ($R^2$ = 0.74, RMSE = 14.745 t/ha). The results demonstrate that integrating SAR and optical data significantly enhances AGC estimation.

* **Sorumlu Yazar**

*(eozdemir@bartin.edu.tr) ORCID ID 0000-0002-1829-9624
(sayginabdikan@hacettepe.edu.tr) ORCID ID 0000-0002-3310-352X

**Kaynak Göster (APA):**

Özdemir E G & Abdikan S (2025). Küre Dağları Milli Parkı'nda S-Bant NovaSAR-1 ve Landsat 9 Veri Füzyonu ile Makine ve Derin Öğrenme Tabanlı Karbon Stoku Tahmini, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Ormanlar, karasal ekosistemlerde önemli karbon yutakları olup, küresel karbon dengesinin korunmasında kritik bir rol oynamaktadır. Toprak üstü biyokütle (TÜB), karbon döngüsünün temel bileşenlerinden biri olarak kabul edilmekte olup, doğru ölçülmesi ve izlenmesi, karbon emisyonlarının azaltılması ve iklim değişikliğiyle mücadele açısından stratejik bir öneme sahiptir (Baccini vd., 2017). Uluslararası iklim anlaşmaları kapsamında ülkelerin karbon stoklarını raporlaması zorunlu hale gelmiş olup, IPCC tarafından geliştirilen AFOLU kılavuzu bu hesaplamalara yönelik standart yöntemler sunmaktadır (IPCC, 2023; Güner vd., 2024).

Bu çalışma, Batı Karadeniz Bölgesi'ndeki Küre Dağları Milli Parkı tampon zonunda doğu kayını (*Fagus orientalis* Lipsky.) ve Uludağ göknarı (*Abies nordmanniana* subsp. *Bornmuelleriana* Mattf.) türlerine ait toprak üstü karbon (TÜK) stoklarını belirlemeyi amaçlamaktadır. Literatürde, ilk kez TÜK tahmininde S-bant çift polarimetrik (YY, DD) NovaSAR-1 radar, Landsat 9 optik görüntüleri ve bitki indeksleri entegre edilerek kullanılmıştır. TÜK tahmini, eXtreme Gradient Boosting (Xgboost) ve Tek Boyutlu Evrişimsel Sinir Ağı (1D-CNN) yöntemleri ile gerçekleştirilmiş ve tür bazında geliştirilen denklemlerle elde edilen TÜK değerleri ile karşılaştırılmıştır.

## 2. YÖNTEM

### 2.1. Çalışma Alanı

Çalışma alanı, Batı Karadeniz Bölgesi'nde Bartın ve Kastamonu illeri sınırlarında yer alan Küre Dağları'nda konumlanmaktadır. Araştırma kapsamında, Küre Dağları tampon bölgesindeki 110 örnekleme alanında (doğu kayını: 34, Uludağ göknarı: 33, karışık meşcere: 43) olmak üzere, 2022 ve 2023 yıllarının ağustos ve ekim aylarında veriler toplanmıştır (Şekil.1).

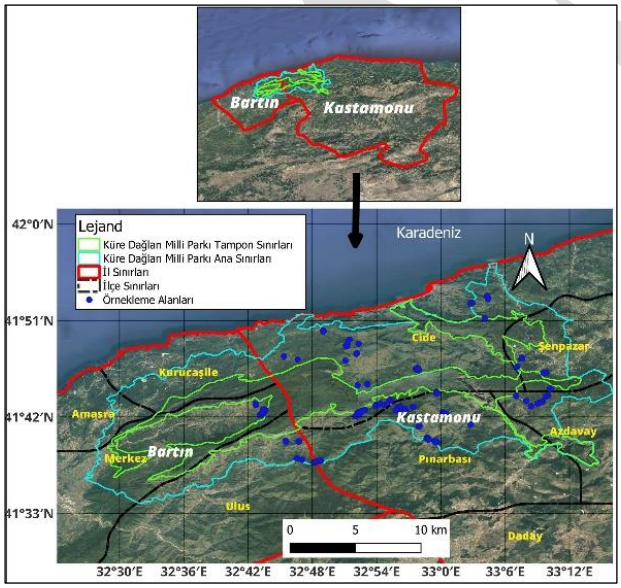


**Şekil 1.** Çalışma Alanı

Toprak üstü biyokütlenin (TÜB) tahmini için, örnekleme alanlarından elde edilen çap ve boy verilerine türlere özgü alometrik denklemler uygulanarak ağaç kütlesi hesaplanmıştır (Saraçoğlu, 1998; Karabürk, 2011). Hektara çevirme katsayısı kullanılarak hektar başına ağaç kütlesi stoku (t/ha) belirlenmiş, ardından kayın için %49,15 (Güner vd., 2025) ve göknar için %52,31 (Güner, 2019) karbona dönüşüm fraksiyonları kullanılarak karbon tutma miktarları hesaplanmıştır.

### 2.2. Verilerin ön işlenmesi ve seçimi

Çalışma kapsamında, 31 Ekim 2024 tarihli S-bant NovaSAR-1 ScanSAR uydu verisi, Avrupa Uzay Ajansı (ESA) iş birliğiyle, SSTL ve Airbus Defence & Space Ltd. tarafından geliştirilen NovaSAR-1 misyonu kapsamında temin edilmiştir. Seviye 2 işlenmiş veriler üzerinde radyometrik ve geometrik düzeltmeler uygulanmış (Novasar-1, 2025), benek azaltma amacıyla filtreleme kullanılmış, 10 m çözünürlüğe yeniden örneklendirme işlemleri SNAP 9.0 yazılımında gerçekleştirilmiştir.

03 Ekim 2024 tarihli Landsat 9 Koleksiyon 2, Seviyel-2 verisi, Google Earth Engine (GEE) ortamında ön işleme işlemleri gerçekleştirilmiştir. Mavi, Yeşil, Kırmızı, NIR, SWIR1 SWIR2 bantlar seçilmiştir. 10 m'ye yeniden örneklendirme sonrası, çalışma alanına göre kırpılmış ve GeoTIFF formatında dışa aktarılmıştır.

TÜK tahmininde bitki indislerinin spektral özelliklerini analiz etmek amacıyla NDVI (Rouse vd., 1974), EVI (Huete vd., 1997), SAVI (Huete, 1988), GNDVI (Gitelson vd., 1996), MSAVI (Qi vd., 1994), NBR (Miller ve Thode, 2007), CIgreen (Gitelson vd., 2003), EVI2 (Jiang vd., 2008), OSAVI (Rondeaux vd., 1996), TVI (Broge ve Leblanc, 2000) olmak üzere 10 farklı bitki vejetasyon indisi hesaplanmıştır. Bu çalışmada, model bileşenlerini optimize etmek ve özellik seçimini iyileştirmek için Mutual Information yöntemi kullanılmış, GridSearch ile 5 katlı çapraz doğrulama uygulanarak en iyi 9 bileşen seçilmiştir.

## 3. BULGULAR

Çalışmada, TÜK tahmini için 20 farklı veri kombinasyonu oluşturulmuş ve performansları karşılaştırılmıştır. NovaSAR-1 S-bant YY ve DD polarizasyonları ile Landsat 9 bantları ve bitki indisleri kullanılarak XGBoost ve 1D-CNN modelleri uygulanmıştır. En yüksek doğruluk, YY ve DD polarizasyonlarının Landsat 9'un mavi ve kırmızı bantları ile SAVI, MSAVI, NBR ve TVI indisleriyle birlikte kullanıldığı senaryoda elde edilmiştir ($R^2$ = 0.74, RMSE = 14.745 t/ha). XGBoost modelinde ise $R^2$ = 0.57, RMSE = 18.921 t/ha olarak hesaplanmıştır. Sonuçlar, SAR ve optik uydu verilerinin entegrasyonunun TÜK tahmininde önemli avantajlar sağladığını ve özellikle bitki indekslerinin SAR bileşenleriyle birlikte kullanıldığında tahmin doğruluğunu artırdığını göstermektedir.

## 4. SONUÇ

Bu çalışma, NovaSAR-1 S-bant radar ve Landsat 9 optik uydu verilerinin entegrasyonuna dayalı bir metodoloji sunarak orman ekosistemlerinin karbon depolama kapasitesini belirlemeyi amaçlamaktadır. Derin öğrenme yaklaşımları, radar ve optik uydu verilerinin birlikte kullanımının TÜK tahmin doğruluğunu önemli ölçüde artırdığını göstermiştir. Çalışma, Türkiye'de S-bant çift polarimetri radar verilerinin karbon stok tahmininde ilk kez kullanılması

ve farklı algoritmaların karşılaştırılması açısından önemli bir katkı sağlamaktadır. Ancak, veri erişilebilirliği, topografik karmaşıklık ve metodolojinin genellenebilirliği gibi kısıtlar bulunmaktadır. Bulgular, bölgesel orman yönetimi politikalarına katkı sağlarken, iklim değişikliğiyle mücadelede uzaktan algılama tabanlı tahmin modellerinin kritik rolünü vurgulamaktadır.

## TEŞEKKÜR

Bu çalışma, birinci yazarın doktora tez araştırmasının bir parçası olup Hacettepe Üniversitesi BAP Birimi tarafından FDK-2022-20004 proje kodu ile desteklenmiştir. Yazarlar, PP0096421 proje numarası kapsamında NovaSAR-1 uydu verisini sağlayan ESA ve Landsat 9 verilerini ücretsiz olarak sunan USGS Açık Erişim Merkezi'ne teşekkür ederler.

## KAYNAKÇA

Baccini, A., Walker, W., Carvalho, L., Farina, M., Sulla-Menashe, D. & Houghton, R. A., (2017). Tropical forests are a net carbon source based on aboveground measurements of gain and loss. Science, 358(6360), 230-234. https://doi.org/10.1126/science.aam5962.

Broge, N. H., & Leblanc, E. (2000). *Comparing predictive power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density.* Remote Sensing of Environment, 76(2), 156–172. https://doi.org/10.1016/S0034-4257(00)00197-8

Huete, A. R., Liu, H. Q., Batchily, K., & van Leeuwen, W. (1997). *A comparison of vegetation indices over a global set of TM images for EOS-MODIS.* Remote Sensing of Environment, 59(3), 440–451. https://doi.org/10.1016/S0034-4257(96)00112-5

Huete, A. R. (1988). *A soil-adjusted vegetation index (SAVI).* Remote Sensing of Environment, **25**(3), 295–309. https://doi.org/10.1016/0034-4257(88)90106-X

IPCC., (2023). Summary for Policymakers. In Core Writing Team, H. Lee, & J. Romero (Eds.), Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change (pp. 1-34). https://doi.org/10.59327/IPCC/AR6-9789291691647.001.

Gitelson, A., Kaufman, Y., & Merzlyak, M. (1996). *Use of a green channel in remote sensing of global vegetation from EOS-MODIS.* Remote Sensing of Environment, **58**(3), 289–298. https://doi.org/10.1016/S0034-4257(96)00072-7

Gitelson, A. A., Keydan, G. P., & Merzlyak, M. N. (2003). *Three-band model for noninvasive estimation of chlorophyll, carotenoids, and anthocyanin contents in higher plant leaves.* Geophysical Research Letters, 30(9). https://doi.org/10.1029/2006GL026457

Güner, Ş. T., (2019). Changes in carbon concentration of tree components for Kazdag fir Abies nordmanniana subsp. equi-trojani forests. Fresenius Environmental Bulletin, 28(1), 116-123.

Güner, Ş.T., Kiracioğlu, Ö. & Sarimehmetoğlu, A., (2024). Changes in carbon stocks according to stand development stages in oriental beech forests in the Marmara Region of Türkiye. Environmental Monitoring and Assessment, 196, 571. https://doi.org/10.1007/s10661-024-12727-7.

Güner, Ş. T., Özdemir, E. G., Çömez, A. & Kaya, S., (2025). Bartın ve Kastamonu yöresi doğu kayını ormanlarında ağaç bileşenlerine ait karbon yoğunluklarının değişimi. Anadolu Orman Araştırmaları Dergisi, 11(1), 38-44. https://doi.org/10.53516/ajfr.1599059

Jiang, Z., Huete, A.R., Didan, K., & Miura, T., (2008). Development of a two-band enhanced vegetation index without a blue band. Remote Sensing of Environment 112(10), 3833-3845. https://doi.org/10.1016/j.rse.2008.06.006

Karabürk, T., (2011). Bartın İli Göknar Meşcerelerinin Biyokütle Tablolarının Düzen-lenmesi. Bartın Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi. Bartın.

Miller, J.D. & Thode, A.E., 2007. Quantifying burn severity in a heterogeneous landscape with a relative version of the delta Normalized Burn Ratio (dNBR). *Remote Sensing of Environment*, 109(1), 66-80. https://doi.org/10.1016/j.rse.2006.12.006

Novasar-1 (2025). Terms of Applicability, https://earth.esa.int/eogateway/catalog/novasar-1-new-tasking :[Erişim tarihi: 26.03.2025].

Rondeaux, G., Steven, M., & Baret, F. (1996). *Optimization of soil-adjusted vegetation indices.* Remote Sensing of Environment, 55(2), 95–107. https://doi.org/10.1016/0034-4257(95)00186-7

Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). *Monitoring vegetation systems in the Great Plains with ERTS.* NASA Special Publication, **351**, 309. https://ntrs.nasa.gov/citations/19740022614

Saraçoğlu, N., (1998). Kayın (Fagus orientalis Lipsky) Biyokütle Tabloları, Tr. J. of Agriculture and Forestry, 22 (1998) 93-100. https://journals.tubitak.gov.tr/agriculture/vol22/iss1/14/

Qi, J., Chehbouni, A., Huete, A. R., Kerr, Y. H., & Sorooshian, S., (1994). *A modified soil adjusted vegetation index.* Remote Sensing of Environment, **48**(2), 119–126. https://doi.org/10.1016/0034-4257(94)90134-1

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Uydu Görüntülerinden Derin Öğrenme Yöntemleri ile Elektrik Yapısal Unsurlarının Tespiti

**Nebiye Musaoğlu*[1], Gülşen Taşkın[1], Hüseyin Kaya[2], Esra Özaydın[1], Burcu Amirgan[1], Hasan Nayır[2], Umur Deveci[3]**

[1]*İstanbul Teknik Üniversitesi, İstanbul, Türkiye*
[2]*Payten Teknoloji A.Ş. İstanbul, Türkiye*
[3]*BEDAŞ A.Ş., İstanbul, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Uydu Görüntüsü,
Elektrik Altyapısı,
Afet Yönetimi,
KATE-CD Veri Seti,

**ÖZET**

Son yıllarda doğal afetlerin sıklığı giderek artmakta ve bunun sonucunda çok büyük can kayıpları ve ekonomik zarar meydana gelmektedir. Afet sonrası hasar tespiti ve afetin etkilerinin belirlenmesi için uzaktan algılama verileri önemli bir kaynak oluşturmaktadır. Günümüzde uydulardan çok yüksek çözünürlüklü görüntü sağlanması ve dijital görüntü işleme yöntemlerindeki gelişmeler bilgiye erişimi oldukça hızlandırmıştır. Bu çalışmada afet sonrası elektrik altyapısında meydana gelen hasarın belirlenmesi için oluşturulan KATE-CD (Kahramanmaraş Türkiye Earthquake-Change Detection Dataset) veri seti ve bu veri seti ile elde edilen sonuçlar sunulmuştur. KATE-CD (Kahramanmaraş Türkiye Earthquake-Change Detection Dataset) veri seti, afetten fazla etkilen 7 il için mekansal çözünürlüğü 0,3 m ile 0,5 m arasında değişen, farklı uydulardan sağlanan görüntülerden oluşturulmuştur. KATE-CD, araştırmacıların deprem kaynaklı hasarı değerlendirmesinde derin öğrenme modellerini kullanmasına olanak sağlayan, etiketli, açık kaynaklı hasar veri setidir. ResNet, Fast SAM (Segment Anything Model) ve Efficient SAM (Eff SAM) derin öğrenme modelleri KATE-CD veri setinde eğitilmiş, trafo ve binalar için hasar tespiti yapılmıştır. Sonuçlar derin öğrenme yöntemlerinin hasar tespitinde önemli katkılar sağladığını göstermektedir.

# Detection of Electrical Structural Elements from Satellite Imagery Using Deep Learning Methods

**Keywords**
Remote sensing,
Satellite Image,
Electrical Infrastructure,
Disaster Management,
KATE-CD Dataset,

**ABSTRACT**

In recent years, the frequency of natural disasters has been increasing, leading to significant loss of life and substantial economic damage. Remote sensing data serve as a critical resource for post-disaster damage assessment and the evaluation of disaster impacts. The availability of ultra-high-resolution satellite imagery, coupled with advancements in digital image processing techniques, has significantly accelerated access to information. This study presents the KATE-CD (Kahramanmaraş Türkiye Earthquake-Change Detection Dataset), a dataset developed to assess damage to electrical infrastructure following a disaster, along with the results obtained using this dataset. The KATE-CD dataset comprises satellite imagery with spatial resolutions ranging from 0.3 m to 0.5 m, sourced from multiple satellites, covering seven provinces severely affected by the disaster. KATE-CD is an open-source, labeled damage dataset that enables researchers to utilize deep learning models for earthquake-induced damage assessment. The deep learning models ResNet, Fast SAM (Segment Anything Model), and Efficient SAM (Eff SAM) were trained on the KATE-CD dataset to detect damage to transformers and buildings. The results demonstrate that deep learning methods contribute significantly to damage assessment.

* **Sorumlu Yazar**

*(musaoglune@itu.edu.tr) ORCID ID 0000-0002-8022-875
(tasking@itu.edu.tr) ORCID ID 0000-0002-2294-4462
(huseyin.kaya@payten.com) ORCID ID 0000-0002-6481-5431
(esra@cscrs.itu.edu.tr) ORCID ID 0000-0002-3626-1646
(burcu.amirgan@cscrs.itu.edu.tr) ORCIS ID 0000-0002-8289-4524
Hasan Nayır
Umur Deveci

**Kaynak Göster (APA):**

Musaoğlu N, Taşkın G, Kaya H, Özaydın E, Amirgan B, Nayır H & Deveci U (2025). Uydu Görüntülerinden Derin Öğrenme Yöntemleri ile Elektrik Yapısal Unsurlarının Tespiti, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Son yıllarda doğal afetlerin sıklığı giderek artmakta ve bunun sonucunda çok büyük can kayıpları ve ekonomik zarar meydana gelmektedir. İstatistiklere göre sadece 1995-2022 yılları arasında dünyada 11,360 doğal afet meydana gelmiş bu afetlerde 1,681,173 kişi hayatını kaybetmiş, 7,599,259 kişi de yaralanmıştır (Tin vd., 2024). Türkiye de başta deprem olmak üzere birçok afet yaşamıştır ve birçok afet riskiyle de karşı karşıyadır. Ülkemizde 1900-2023 yılları arasında can ve mal kaybına neden olan 269 deprem meydana gelmiş, en son yaşanan 2023 yılı Kahramanmaraş depremlerinde ise 48 binden fazla kişi hayatını kaybetmiş, çok büyük ekonomik kayıplar oluşmuş, iletişim ve enerji altyapısı büyük oranda zarar görmüştür (SBB Deprem Sonrası Değerlendirme raporu, 2023).

Yaşamın her alanında gereksinimlerin karşılanması için en önemli bileşenlerinden biri olan elektrik enerjisine erişim ve sürdürülebilirliği herhangi bir afet ile karşı karşıya kalındığında çok büyük önem taşımaktadır. Elektrik santralleri, trafo merkezleri ve trafolar, iletim ve dağıtım hatları gibi elektrik yapısal unsurlarında oluşan hasarlar yerinde tespit veya teknolojinin sağladığı olanaklarla gerçekleştirilmektedir. Uzaktan algılama verileri günümüzde artan mekansal çözünürlüğünün yanı sıra kolay erişilebilirliği sayesinde elektrik alt yapısında oluşan hasarların ya da maruz kalacağı risklerin belirlenmesinde giderek daha yaygın olarak kullanılmaya başlamıştır. Matikanien vd. (2016)'da elektrik hatları çevresindeki bitki örtüsünün izlenmesinde yüksek çözünürlüklü uzaktan algılama verilerinin kullanılabileceğini bildirmişlerdir. Hu vd. (2020)'de Amerika Birleşik Devletleri'nde yaptıkları bir çalışmada elektrik altyapısını uzaktan algılama verilerinden derin öğrenme yöntemleri ile belirlemişlerdir. Tokmak (2025)'de trafo merkezlerinin uydu görüntülerinden otomatik belirlenmesi amacıyla İçerik Tabanlı Görüntü Erişim Yöntemini kullanmıştır.

Elektrik altyapısının uzaktan algılama verilerinden belirlenmesi amacıyla literatürde yapılan çalışmalar kısıtlıdır. Bu çalışma kapsamında trafoların, binaların ve hasar durumlarının yüksek çözünürlüklü uydu görüntülerinden derin öğrenme ile otomatik olarak belirlenmesi amaçlanmıştır.

## 2. VERİ VE YÖNTEM

Günümüzde çok yüksek mekânsal çözünürlüklü uydu görüntülerinin sağladığı zengin detay makine öğrenmesi yöntemlerinin hızlı ve doğru bilgi üretme özellikleri ile birleşince görüntüdeki nesnelerin kısa sürede belirlenmesi olanaklı hale gelmiştir. Derin öğrenme yöntemlerinin hedeflenen nesneyi görüntü üzerinden bulmasında en önemli aşama, doğru etiketlenmiş yüksek kalitede ve çeşitlikte veri ile ağın eğitilmesidir (Özaydın ve ark., 2024). Bu bağlamda Kahramanmaraş depremleri sonrası otomatik hasarın belirlenmesi ve değişimin tespiti için yüksek doğrulukta etiketlenmiş, 21'i afet öncesi ve 27'si afet sonrasına ait 48 uydu görüntüsünden oluşan hasar veri seti hazırlanmıştır. KATE-CD (Kahramanmaraş Türkiye Earthquake-Change Detection Dataset) veri seti, afetten fazla etkilen 7 il için çözünürlüğü 0,3 m ile 0,5 m arasında değişen, farklı uydulardan sağlanan görüntülerden oluşturulmuştur. Şekil 1 KATE-CD hasar verisinin kapsadığı illeri ve etiketlerin dağılımını göstermektedir.

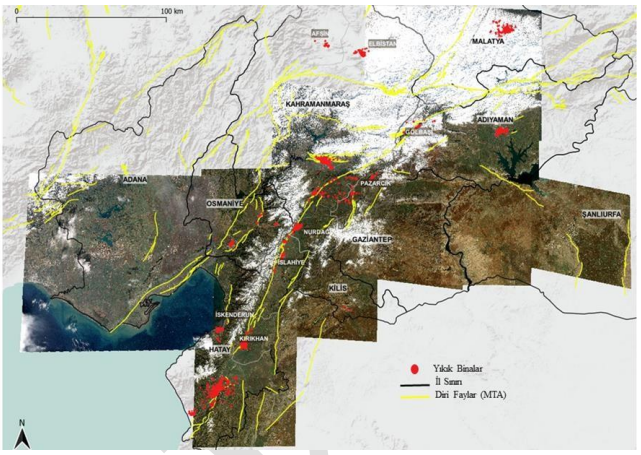


**Şekil 1.** KATE-CD veri setinin çalışma alanı.

### 2.1. Derin Öğrenme Modelleri ile Hasar Tespiti

Derin öğrenme yöntemlerinin hızlı gelişimi ve yeni ağ tasarımları, büyük boyutlu veriden kısa sürede ve yüksek doğruluklu sonuçlar üretilmesine olanak sağlamaktadır (Ps ve Aithal, 2022). Bu çalışmada, ResNet, Fast SAM (Segment Anything Model) ve Efficient SAM (Eff SAM) derin öğrenme modelleri KATE-CD veri setinde eğitilmiş, trafo ve binalar için hasar tespiti yapılmıştır.

Eğitim A100 GPU makinesinde, 0.1 öğrenme oranıyla ve yığın boyutu (batch size) 4 olacak şekilde 30 epok boyunca gerçekleştirilmiştir. Modelin genelleştirme kapasitesini arttırmak ve aşırı öğrenmesini önlemek amacıyla döndürme, ölçekleme ve rastgele boyutlandırma (random cropping) gibi çeşitli veri zenginleştirme yöntemleri uygulanmıştır. Modelin performansını değerlendirmek için ikili (binary) doğruluk ve IoU (Intersection over Union) metrikleri kullanılmıştır.

## 3. BULGULAR

Şekil 2 ResNet, Fast SAM ve Eff SAM modelleri kullanılarak KATE-CD veri setinin test görüntülerindeki hasar tahmin sonuçlarını göstermektedir. Bu üç model test_20 görüntüsünde yıkılan binaları başarıyla tespit etmiştir. ResNet kompleks arka planı moloza benzeterek yanlış pozitif üretmesine karşı diğer iki model bu alanı daha doğru belirlemiştir. Test_33 görüntüsü küçük boyutta ve gecekondu yapılarının yoğun olduğu yerleşim alanından oluşmasına rağmen, Eff SAM bölgede hasarı en iyi belirlemiştir. Tüm modeller görüntüdeki gölge etkisinden kaynaklı sağ üst köşeyi hasar olarak tespit etmiştir. Test_22 'nin deprem öncesi görüntüsü sis ve afet sonrası görüntüsü ise depremden kaynaklı toz bulutu içermektedir. Ek olarak bölgede bitişik nizam binalar bulunmaktadır. Bu gerçekçi sorunların üstesinden gelebilmek için derin öğrenme modelleri çeşitli örneklerle ve daha fazla veri ile eğitilmelidir. KATE-CD

veri seti aynı alan için farklı kaynaktan temin edilmiş görüntüleri kapsadığından test_22 görüntüsünde derin öğrenme modellerinin hepsi hasar tespitini başarılı bir şekilde gerçekleştirmiştir. En çarpıcı örnek olan test_17'nin deprem sonrası görüntüsü karla kaplıdır. ResNet bu durumda hasarı tespit edemese de hem Fast SAM hem de Eff SAM başarılı sonuçlar elde etmiştir. Son örnek test_29 görüntüsünde ise yüksek binaların ve onlara ait gölgeler Eff SAM ve Fast SAM modellerin yanlış pozitif üretmesine sebep olmuştur. Buna rağmen her üç model hasarlı binaların hepsini doğru ayırt etmiştir.

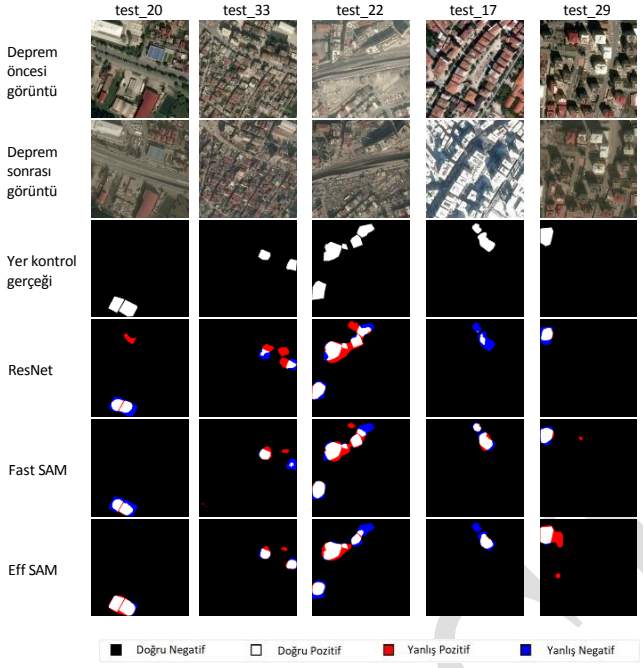


Şekil 2. Modellerin test görüntüsündeki hasar tahmin sonuçları.

## 5. SONUÇ

Geniş alanları etkileyen afet durumunda binaların ve trafoların hasar durumu bilgilerinin hızlı ve doğru şekilde üretilmesi yersel çalışmalarla mümkün değildir. Bu çalışmada KATE-CD veri setinde ResNet, Fast SAM ve Eff SAM modelleri eğitilmiş ve sonuçlar irdelenmiştir. Sonuçlar derin öğrenme yöntemlerinin hasar tespitinde önemli katkılar sağladığını göstermektedir.

## TEŞEKKÜR

Bu çalışma "Doğal Afetlerin Hemen Sonrasında Uydu Görüntüleri ve SAR Verileri Kullanılarak Yeni Nesil Yapay Zeka Modeli Tabanlı Elektrik Yapısal Unsurları Hasar Tespit Sisteminin Geliştirilmesi" başlıklı proje kapsamında gerçekleştirilmiştir. Projeye destekleri için T.C. Enerji Piyasası Düzenleme Kurumu (EPDK), Boğaziçi Elektrik Dağıtım A.Ş. ve İTÜ Uydu Haberleşme ve Uzaktan Algılama Merkezi'ne teşekkürlerimizi sunarız. Bu çalışmada kullanılan hesaplama kaynaklarının bir kısmı Ulusal Yüksek Başarımlı Hesaplama Merkezi'nin (UHeM), 016892023 ve 1019092024 numaralı destekleriyle sağlanmıştır.

## Yazar Katkı Oranı

Nebiye Musaoğlu: Yöntem, makale yazımı, Gülşen Taşkın: Yöntem, makale yazımı, Hüseyin Kaya: Analiz, Esra Özaydın: Makale yazımı, analiz, Burcu Amirgan: Makale yazımı analiz, Hasan Nayır: Analiz, Umur Deveci: Değerlendirme

## KAYNAKÇA

Hu, W., Alexander, B., Cathcart, W., Hu, A., Nair, V., Zuo, L., Malof, J., Collins, L., & Bradbury, K. (2020). Mapping Electric Transmission Line Infrastructure from Aerial Imagery with Deep Learning. IGARSS 2022 - 2022 IEEE International Geoscience and Remote Sensing Symposium, 2229–2232. https://doi.org/10.1109/igarss39084.2020.9323851

Tin, D., Cheng, L., Le, D., Hata, R., Ciottone, G. 2024. Natural disasters: a comprehensive study using EMDAT database 1995–2022. Public Health. doi.org/10.1016/j.puhe.2023.11.017.

Tokmak, Ö. 2025. İçerik tabanlı görüntü erişimi ile uzaktan algılama verilerinde obje arama, Yüksek Lisans Tezi, İTÜ Lisansüstü Eğitim Enstitüsü.

SBB Deprem Sonrası Değerlendirme Raporu (2023). T.C. Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı 2023 Kahramanmaraş ve Hatay depremleri raporu, Mart 2023.

Matikainen, L., Lehtomäki, M., Ahokas, E., Hyyppä, J., Karjalainen, M., Jaakkola, A., Kukko, A., & Heinonen, T. (2016). Remote sensing methods for power line corridor surveys. ISPRS Journal of Photogrammetry and Remote Sensing, 119, 10–31. https://doi.org/10.1016/j.isprsjprs.2016.04.011

Özaydın, E., Amirgan, B., Taşkın, G., Musaoğlu, N. (2024). Derin öğrenme uygulamalarında kullanılan uzaktan algılama verilerinden oluşturulmuş açık kaynaklı bina veri setleri: Karşılaştırmalı değerlendirme. Geomatik, 9(1), 1-11. https://doi.org/10.29128/geomatik.1257555

Ps, P., & Aithal, B. H. (2023). Building footprint extraction from very high-resolution satellite images using deep learning. Journal of Spatial Science, 68(3), 487-503. https://doi.org/10.1080/14498596.2022.2037473

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# PlanetScope Uydu Görüntülerinden Derin Öğrenme Tabanlı Bölütleme ile Yanan Ormanlık Alanların Tespiti

**Melih Altay*[1], Mustafa Türker[2]**

[1, 2]*Hacettepe Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 06800, Beytepe, Çankaya, Ankara*

**Anahtar Kelimeler**
Orman Yangını
U- Net
PlanetScope
Bölütleme

**ÖZET**

Orman yangınları, ekolojik, çevresel ve sosyo-ekonomik açıdan ciddi etkilere sahiptir. Uzaktan algılama ve derin öğrenme teknikleri, yangın sonrası hasarın tespitinde önemli avantajlar sunmaktadır. Bu çalışmada, U-Net modeli kullanılarak orman yangını sonrası yanan alanların semantik bölütlemesi gerçekleştirilmiştir. Çalışma alanı olarak Antalya ili Manavgat yangın bölgesi seçilmiş ve uydu görüntüsü olarak yangın sonrası çekilen PlanetScope uydu görüntüleri kullanılmıştır. Modelin performansı doğruluk, hassasiyet, geri çağırma ve F1-Skoru metriklerle değerlendirilmiştir. Kullanılan U-Net modeli, yanan alanların tespitinde %91 doğruluk, %95 hassasiyet ve %94 F1-Skoru ile yüksek performans sergilemiştir. Yanmamış alanlarda ise %80 hassasiyet ve %88 geri çağırma değerlerine ulaşılmıştır. Modelin genel performansını yansıtan makro ve ağırlıklı ortalama metriklerin her ikisi de %89'un üzerinde sonuç vermiştir. Bu bulgular, U-Net tabanlı yaklaşımın, yanan alanların otomatik tespiti için yüksek derecede güvenilir ve tutarlı bir çözüm sunduğunu göstermektedir. Sonuçlar, özellikle heterojen arazi yapısına sahip bölgelerde yanan alanların yüksek doğrulukla bölütlenmesinde U-Net modelinin etkinliğini göstermektedir.

# Detection of Burned Forest Areas with Deep Learning-Based Segmentation from Planetscope Satellite Images

**Keywords**
Forest Fire
U-Net
PlanetScope
Segmentation

**ABSTRACT**

Forest fires have serious ecological, environmental and socio-economic impacts. Remote sensing and deep learning techniques offer significant advantages in post-fire damage detection. In this study, semantic segmentation of burned areas after forest fires is performed using the U-Net model. Manavgat fire zone in Antalya province was selected as the study area and PlanetScope satellite images taken after the fire were used as satellite imagery. The performance of the model was evaluated with accuracy, precision, sensitivity and F1-Score metrics. The U-Net model showed high performance with 91% accuracy, 95% sensitivity and 94% F1-Score in the detection of burned areas. In unburned areas, 80% accuracy and 88% sensitivity values were achieved. Both macro and weighted average metrics reflecting the overall performance of the model yielded results above 89%. These findings show that the U-Net based approach provides a highly reliable and consistent solution for automatic detection of burned areas. The results demonstrate the effectiveness of the U-Net model in segmenting burning areas with high accuracy, especially in regions with heterogeneous terrain.

## 1. GİRİŞ

Orman yangınları, ekosistemler üzerinde ciddi tahribata yol açan doğal afetlerdir. İklim değişikliğiyle artan sıcaklık ve kuraklık, yangınların sıklığını ve şiddetini artırmaktadır (FAO, 2021; IPCC, 2022). Bu yangınlar, biyoçeşitliliğin azalması, toprak erozyonu ve atmosfere karbon salınımı yoluyla ekosistem dengesini bozmaktadır (Bowman ve ark., 2020; Jones ve Archer, 2021). Ayrıca, tarım alanlarının zarar görmesi ve turizm sektörüne olumsuz etkiler, bölgesel ekonomiler üzerinde ciddi baskılar oluşturmaktadır (Flannigan ve ark., 2016;

* **Sorumlu Yazar**

*(melihaltay17@hacettepe.edu.tr) 0009-0005-0902-3713
(mturker@hacettepe.edu.tr) 0000-0001-5604-0472

**Kaynak Göster (APA):**

Altay M & Türker M (2025).PlanetScope Uydu Görüntülerinden Derin Öğrenme Tabanlı Bölütleme ile Yanan Ormanlık Alanların Tespiti, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

Fernandes ve Loureiro, 2019). Türkiye'de özellikle Akdeniz iklimine sahip bölgeler, yüksek sıcaklık ve düşük nem oranları nedeniyle yangın riski altındadır (Çanakçıoğlu, 1993; Öztürk ve ark., 2022). 2021 yılında gerçekleşen Manavgat yangını, yaklaşık 75.000 hektarlık alanı etkileyerek Türkiye tarihinin en büyük orman yangınlarından biri olarak kaydedilmiştir (TÜBİTAK, 2022). Bu tür büyük ölçekli yangınların etkilerinin hızlı ve doğru tespiti, ekosistem restorasyonu ve yangın yönetimi açısından kritik önemdedir. Geleneksel yangın hasarı haritalama yöntemleri, zaman alıcı ve maliyetlidir (Chuvieco ve Kasischke, 2007; Giglio ve ark., 2018). Son yıllarda, uzaktan algılama teknikleri ve derin öğrenme tabanlı yöntemler, yangın sonrası yanan alanların tespitinde önemli alternatifler sunmaktadır (Veraverbeke ve ark., 2014; Roteta ve ark., 2019). Özellikle, konvolüsyonel sinir ağları (CNN) tabanlı modeller, büyük ölçekli uydu görüntülerinden yanan alanları otomatik olarak belirleyerek analiz sürecini hızlandırmaktadır (Zhu ve ark., 2017; Mou ve ark., 2018).

Literatürde, yangın sonrası yanan alan tespiti için geliştirilmiş farklı uzaktan algılama ve derin öğrenme yaklaşımları mevcuttur. CNN tabanlı modellerin yanı sıra, SegNet, DeepLabV3+ ve Mask R-CNN gibi derin öğrenme modelleri başarılı sonuçlar vermiştir (Ball ve Anderson, 2017; Zhang ve ark., 2020; Li ve ark., 2021). Ayrıca, Sentinel-2 ve PlanetScope gibi yüksek çözünürlüklü uydu görüntüleri kullanılarak indeks tabanlı yöntemler Normalize Edilmiş Yanma Şiddeti İndeksi (Normalized Burn Ratio), Fark Normalize Edilmiş Yanma Şiddeti İndeksi (differenced Normalized Burn Ratio) (NBR, dNBR) ile derin öğrenme modelleri karşılaştırılmıştır (Huang ve ark., 2022; Shen ve ark., 2023). Bu çalışmalar, U-Net modelinin özellikle detaylı bölütleme gerektiren yüksek çözünürlüklü görüntülerde avantaj sağladığını göstermektedir. U-Net, başlangıçta tıbbi görüntü bölütlemek için geliştirilmiş olup (Ronneberger ve ark., 2015), uydu görüntülerinden nesne çıkarımı, arazi örtüsü tespiti ve tarımsal ürün analizinde de başarıyla uygulanmıştır (Boulch ve ark., 2017; Persello ve Stein, 2020; Kemker ve ark., 2018; Ji ve ark., 2019). Bu çalışmada, U-Net modeli ve yangın sonrası çoklu spektral PlanetScope uydu görüntüleri kullanılarak Manavgat yangını sonrası yanmış orman alanları tespit edilmiştir. Modelin performansı, doğruluk, hassasiyet, geri çağırma ve F1-Skoru metrikleriyle değerlendirilmiş, elde edilen sonuçların ekosistem restorasyonu ve yangın yönetimine katkısı tartışılmıştır.

## 2. YÖNTEM

Uydu görüntüsü olarak PlanetScope uydusu tarafından çekilen yüksek çözünürlüklü optik görüntüler kullanılır. PlanetScope görüntüleri üzerinde atmosferik düzeltme, coğrafi hizalama ve veri artırma teknikleri uygulanarak U-Net modelin daha iyi genelleme yapması sağlanır. Yanan alanların doğru bir şekilde etiketlenmesi için yer doğrulama verileri veya önceki yangın haritaları kullanılarak referans maskeler oluşturulur. U-Net modeli, işlenmiş uydu görüntüleri ve referans maskeler kullanılarak yangın alanlarını öğrenmek üzere eğitilir. Eğitilmiş model, yeni uydu görüntüleri üzerinde yanan alanları otomatik olarak tespit ederek segmentasyon işlemini gerçekleştirir. Modelin başarımı, doğruluk, hata matrisleri gibi metrikler kullanılarak değerlendirilir. Şekil 1, çalışma iş akışını göstermektedir.

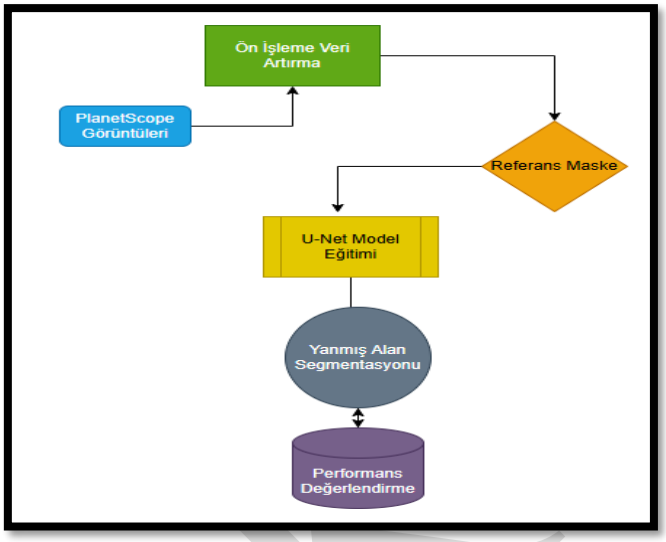


**Şekil 1.** İş Akışı

### 2.1. Çalışma Alanı ve Veri Seti

Antalya iline bağlı bir ilçe olan Manavgat (MG), Akdeniz ikliminin hâkim olduğu bölgede yer almaktadır. 2021 yılında meydana gelen orman yangını, yaklaşık 75.000 hektarlık bir alanı etkilemiştir. Çalışma alanı (Şekil 2) 36.94189°K, 31.31400°D; 36.94189°K, 31.49314°D; 36.73000°K, 31.31400°D; 36.73000°K, 31.49314°D koordinatları arasında yer almaktadır. Bu çalışmada, yüksek mekânsal çözünürlüğe sahip (3 m) PlanetScope uydu görüntüleri kullanılmıştır. Görüntüler, mavi, yeşil, kırmızı ve yakın kızılötesi olmak üzere dört spektral bant içermektedir ve yanan alanların spektral özelliklerinin analiz edilmesi için uygun veri kaynağını oluşturmaktadır.

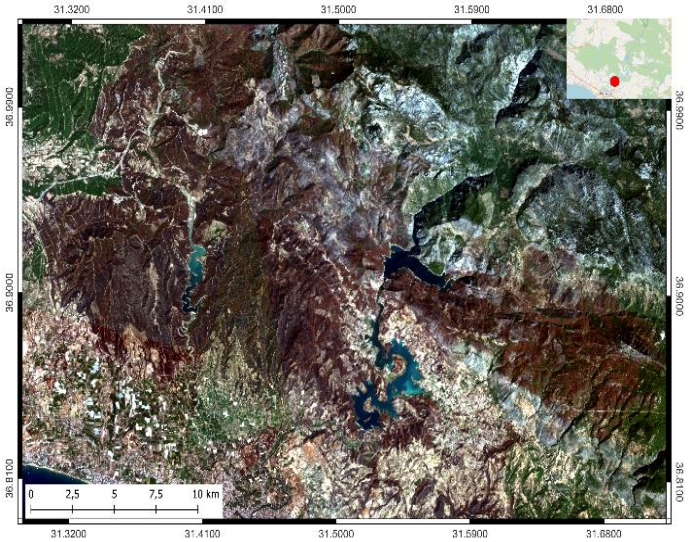


**Şekil 2.** Çalışma Alanı

### 2.2. Veri Hazırlama ve Ön İşlemeler

Çalışmada 28.08.2021 ve 03.09.2021 tarihlerine ait PlanetScope görüntüleri kullanılmıştır. Görüntüler, mavi, yeşil, kırmızı ve yakın kızılötesi olmak üzere dört spektral bant içermekte olup, 3 metre mekansal çözünürlüğü sayesinde yangının etkilediği alanların ayrıntılı olarak analiz edilmesine olanak tanımaktadır.

Model doğrulaması ve analizlerin güvenilirliğini artırmak amacıyla yangın sonrası referans haritalar yer doğrulama sürecinde kullanılmıştır. Görüntüler normalize edilerek piksel değerleri [0, 1] aralığına çekilmiştir. Bu işlem, farklı aydınlatma koşullarından kaynaklanabilecek varyasyonların giderilmesi açısından önem arz etmektedir. Yeterli sayıda örnek elde edebilmek ve modelin genelleme kabiliyetini artırmak amacıyla yama (patch) tabanlı veri artırma teknikleri kullanılmıştır. Bu kapsamda, orijinal görüntüler ve karşılık gelen referans maskeler 256×256 piksellik yamalara bölünmüştür. Bu işlem sonucunda toplamda 1188 adet görüntü yaması ve bunlara karşılık gelen referans maskeleri elde edilmiştir. Ayrıca, veri setinin çeşitliliğini artırmak ve modelin farklı mekansal varyasyonlara karşı daha dayanıklı hale gelmesini sağlamak amacıyla rastgele döndürme, yatay/dikey çevirme, ölçeklendirme ve kesme gibi veri artırma işlemi uygulanmıştır. Yanmış ve yanmamış alanların ayrımını yapabilmek için kullanılan referans maskeler, Tarım ve Orman Bakanlığı'nın Arazi Parsel Tanımlama Sistemi (LPIS) verisi (T.C. Tarım ve Orman Bakanlığı, 2021) ile CORINE arazi örtüsü sınıflandırması (Avrupa Çevre Ajansı, 2018) temel alınarak oluşturulmuş, , ardından bu veriler manuel düzeltmelerle güncellenmiştir. Şekil 3'te, referans maske verisine ilişkin örnek bir görsel sunulmuştur.

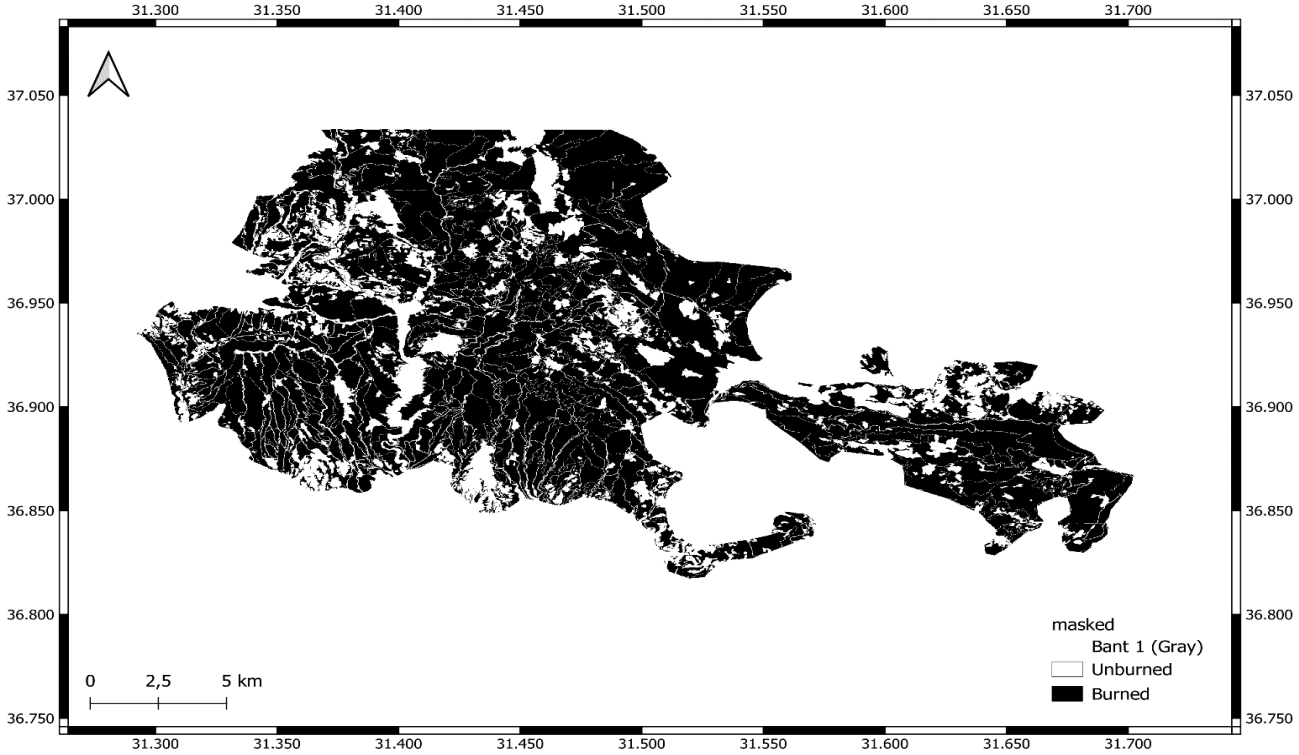


**Şekil 3.** Referans Maske Verisi

### 2.3. U-Net Modeli ve Eğitim Süreci

U-Net modeli tam evrişimli bir sinir ağı (Fully Convolutional Network - FCN) mimarisine dayanmaktadır (Ronneberger et al., 2015). Model, bir kodlayıcı (encoder) ve bir kod çözücüden (decoder) oluşarak giriş görüntüsündeki pikselleri belirli sınıflara atayan bir bölütleme yöntemi sunmaktadır. U-Net'in temel avantajı, kayıpsız bir şekilde detaylı mekansal bilgiyi yakalayabilmesi ve düşük miktarda veri ile etkili sonuçlar üretebilmesidir (Ronneberger et al., 2015; Çiçek et al., 2016).

Bu çalışmada, U-Net modeli, yanmış alanların hassas bir şekilde tespit edilmesi amacıyla uyarlanmıştır. Modelin eğitimi, titizlikle uygulanan optimizasyon stratejileriyle gerçekleştirilmiş ve yanmış alanların yüksek doğrulukla tespit edilmesi hedeflenmiştir. Parametre güncellemeleri için Adam optimizasyon algoritması tercih edilmiş, öğrenme oranı 0.001 alınmıştır (Kingma & Ba, 2015). Bu oran, modelin parametre uzayında hızlı ve istikrarlı bir şekilde optimum değere ulaşmasını sağlamıştır. Yanmış alanların tespiti için kullanılan U-Net modeli, görüntüdeki pikselleri "yanmış" veya "yanmamış" olarak sınıflandırarak ikili maskeler üretmektedir. Eğitim sürecinde, 32'lik yığın boyutu kullanılarak model 100 epoch boyunca eğitilmiş ve her epoch sonunda genel performansta sürekli iyileşmeler gözlemlenmiştir. Eğitim sırasında, bölütleme problemlerinde yaygın olarak kullanılan ikili çapraz entropi kaybı tercih edilerek süreç optimize edilmiştir. Modelin başarımı, doğruluk, hassasiyet, geri çağırma ve F1 skoru metrikleriyle değerlendirilmiştir. Elde edilen bulgular, U-Net modelin yanmış alanları yangın sonrası PlanetScope görüntülerinden yüksek doğruluk ve güvenilirlikle tespit edebildiğini göstermiştir..

## 3. BULGULAR ve TARTIŞMA

100 epoch boyunca eğitilen U-Net modeli, eğitim süreci boyunca %21,62 oranında eğitim kaybı ve %92,30 eğitim doğruluğu; doğrulama sürecinde ise %20,89 doğrulama kaybı ve %90,72 doğrulama doğruluğu ile başarılı bir performans ortaya koymuştur. Bu sonuçlar, modelin hem eğitim hem de doğrulama verileri üzerinde güçlü bir öğrenme gerçekleştirdiğini ve aşırı öğrenme

(overfitting) sorununu belirgin biçimde göstermediğini ortaya koymaktadır. Modelin test verisi üzerinde elde ettiği hata matrisi (Tablo 1), sınıflandırma başarımının oldukça yüksek olduğunu göstermektedir. Buna göre model, yanmış alanları %92,30 oranında doğru pozitif (True Positive) ve yanmamış alanları %92,20 oranında doğru negatif (True Negative) şeklinde doğru şekilde sınıflandırmıştır. Ancak model, %7,70 oranında yanlış negatif (False Negative) ve %7,80 oranında yanlış pozitif (False Positive) sınıflandırma yapmıştır. Bu durum, özellikle bazı gerçek yanmış alanların "yanmamış" olarak etiketlenmesiyle sonuçlanmakta ve bu da hassas ekosistemlerin değerlendirilmesinde çevresel etkilerin eksik tespitine yol açma riskini beraberinde getirmektedir.

**Tablo 1.** Test için, U-Net Modeline dayalı MG çalışma alanının Karışıklık Matrisi

| **Gerçekleşen / Tahmin Edilen** | **Yanmış** | **Yanmamış** |
|---|---|---|
| **Yanmış** | 91.74% | 8.26% |
| **Yanmamış** | 12.03% | 87.97% |

Modelin performans metrikleri (Tablo 2) sınıf bazında değerlendirildiğinde, her iki sınıfta da yüksek başarı elde edildiği görülmektedir. Yanmış alanlar için %95 precision, %92 recall ve %94 F1-score değerleri hesaplanmıştır. Yanmamış alanlar için ise bu değerler sırasıyla %80, %98 ve %84'dür. Bu sonuçlar, modelin özellikle yanmış alanları yüksek doğrulukla ayırt edebildiğini, ancak yanmamış alanlar için zaman zaman karışıklık yaşadığını göstermektedir. Makro ortalama (macro average) değerleri (precision: 0.90, recall: 0.92, F1-score: 0.91) ile ağırlıklı ortalama (weighted average) değerleri (her biri 0.92) modelin genel başarımını yansıtmaktadır. Ayrıca, modelin genel doğruluk oranı %92 (accuracy = 0.92) olarak elde edilmiştir. Bu yüksek oranlar, modelin test verisi üzerinde genel anlamda tatmin edici ve güvenilir bir performans sergilediğini ortaya koymaktadır.

**Tablo 2.** Test için, U-Net Modeline dayalı olarak MG çalışma alanının Performans Ölçütleri

| **Sınıf** | **Hassasiyet** | **Geri Çağırma** | **F1-Skoru** |
|---|---|---|---|
| Yanmış | 0.95 | 0.92 | 0.94 |
| Yanmamış | 0.80 | 0.88 | 0.84 |
| Makro Ortalama | 0.90 | 0.92 | 0.91 |
| Ağırlıklı Ortalama | 0.91 | 0.92 | 0.92 |
| Genel Doğruluk: **0.91** | | | |

Detaylı analizler, sınıflandırma hatalarının çoğunlukla bitki örtüsü açısından heterojen yapıya sahip farklı yoğunlukta ve türde bitkilerin birlikte bulunduğu karmaşık bölgelerde meydana geldiğini ortaya koymuştur. Ayrıca, yangının kısmen etkilediği geçiş alanlarında, özellikle de yangının tamamen etkili olmadığı, sınır bölgelerinde modelin yanmış alanları tespit etmede zorlandığı görülmektedir. Bunun yanı sıra, yanan alanların kenarlarında ve yangından etkilenmeyen ancak yanmış alanların arasında adacıklar gibi kalan küçük yanmamış bölgelerde de modelin karışıklık yaşadığı ve sıklıkla yanlış sınıflandırmalar yaptığı belirlenmiştir.

Bu zorlukların üstesinden gelmek adına, gelecekte yapılacak çalışmalarda daha yüksek mekansal çözünürlüğe sahip uydu görüntülerinin kullanılması önerilmektedir. Daha ince detayları barındıran görüntüler, özellikle küçük ölçekli yangın kalıntıları ya da geçiş bölgelerinin daha hassas tespitini mümkün kılabilir. Ayrıca, bu çalışmada kullanılan bantların ötesinde ek spektral bantlara sahip algılayıcıların kullanımı, özellikle termal veya kısa dalga kızılötesi (SWIR) gibi yangın izlerini daha belirgin hale getiren bantların modele dahil edilmesi, sınıflandırma başarısını artırabilir. Alternatif olarak, çok zamanlı analizlerin uygulanması, yangın öncesi ve sonrası görüntülerin birlikte değerlendirilerek zaman içindeki değişimlerin model tarafından daha iyi öğrenilmesini sağlayabilir. Böylece, özellikle yangın sonrası rehabilitasyon süreçlerinin izlenmesi gibi uzun vadeli değerlendirmeler de daha sağlıklı bir şekilde gerçekleştirilebilir. Elde edilen bulgular, U-Net modelinin yangın sonrası yanmış alanların belirlenmesinde etkili bir araç olduğunu kanıtlamıştır. Bununla birlikte, modelin belirli durumlarda yaşadığı sınıflandırma güçlükleri, görüntünün mekansal çözünürlüğü, spektral bilgi kapsamı ve arazi karmaşıklığı gibi faktörlerin model performansı üzerindeki etkisini ortaya koymaktadır. Bu bağlamda, modelin gelecekteki uygulamaları için farklı veri kaynaklarının ve metodolojik yaklaşımların entegrasyonu hem doğruluk hem de güvenilirlik açısından önemli kazanımlar sağlayabilir. Elde edilen bulgular, U-Net modelinin yangın sonrası yanmış alanların belirlenmesinde etkili ve başarılı bir yöntem olduğunu ortaya koymuştur. Bununla birlikte, modelin bazı durumlarda karşılaştığı sınıflandırma güçlükleri; özellikle görüntülerin mekânsal çözünürlüğü, spektral bant kapsamı ve çalışılan arazinin yapısal karmaşıklığı gibi faktörlerin model performansı üzerinde belirleyici bir etkiye sahip olduğunu göstermektedir. Bu bağlamda, modelin gelecekteki uygulamalarında farklı uydu verilerinin, spektral bileşenlerin veya ek mekânsal/sayısal veri katmanlarının entegrasyonu ile gelişmiş metodolojik yaklaşımların bir arada kullanılması, sınıflandırma doğruluğu ve genel güvenilirlik açısından anlamlı katkılar sağlayabilir.Bu çalışmada elde edilen %91 genel doğruluk oranı, literatürde Manavgat yangınına yönelik yapılan benzer çalışmalara kıyasla daha yüksek bir performansa işaret etmektedir. Örneğin, Yalçın ve ark. (2022) tarafından Sentinel-2 verisi kullanılarak geliştirilen dNBR tabanlı sınıflandırma yönteminde %87,5 doğruluk elde edilmiştir.

Benzer şekilde, Ateşoğlu ve Erkan (2022), Landsat 8 OLI verisi ve Rastgele Orman (Random Forest) algoritması kullanarak %89,3 doğruluk oranına ulaşmıştır. Bu karşılaştırma, U-Net modelinin daha yüksek mekânsal çözünürlükteki görüntülerle birlikte derin öğrenme yeteneklerini kullanarak, klasik yöntemlere kıyasla daha başarılı sonuçlar sunduğunu ortaya koymaktadır. U-Net modeli ile elde edilen sınıflandırma sonuçları, çalışma

alanındaki yanmış ve yanmamış bölgelerin mekânsal dağılımını ortaya koymaktadır. Modelin ürettiği segmentasyon çıktısı Şekil 4'te görsel olarak sunulmaktadır.

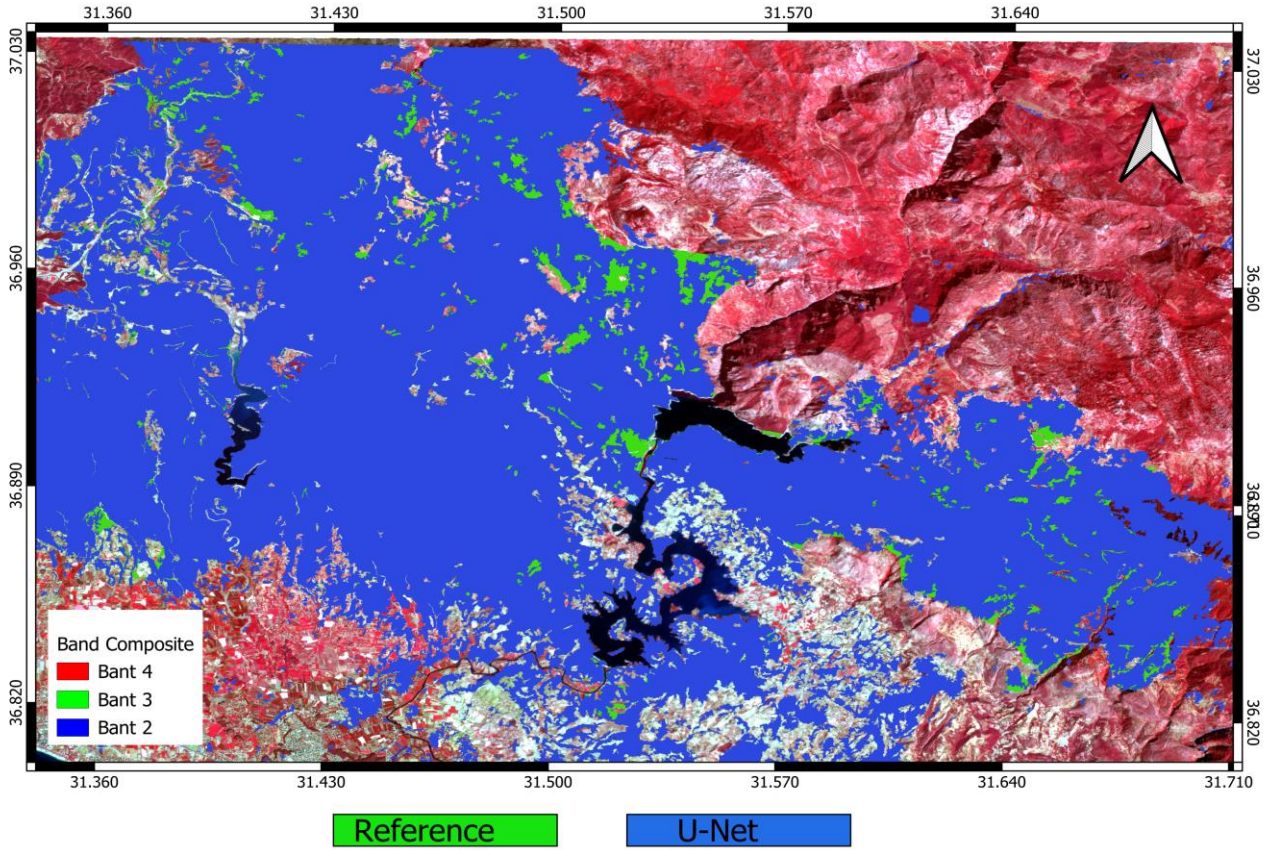


**Şekil 4.** U-Net Modeli ile Yanmış ve Yanmamış Alanların Bölütleme Sonuçları

## 4. SONUÇLAR

Bu çalışmada, U-Net CNN modeli kullanılarak 2021 yılında meydana gelen Manavgat orman yangını sonrası yanan alanların tespiti i gerçekleştirilmiştir. Çalışmada, yüksek çözünürlüklü (3 m) PlanetScope uydu görüntüleri kullanılmış olup, modelin eğitim ve test aşamalarında yüksek doğruluk ve güvenilirlik elde edilmiştir. Eğitim sürecinde elde edilen %92,30 doğruluk ve %90,72 doğrulama oranları modelin etkinliğini göstermiş, test aşamasında yanmış alanların %91,7 doğru pozitif oranı ve yanan alanlar için %95 kesinlik değerleri elde edilmiştir. Yanmamış alanlar için ise modelin doğruluğu %87,97, kesinlik oranı %80, geri çağırma oranı ise %88 olarak hesaplanmıştır. Elde edilen sonuçlar, U-Net modelinin, özellikle yangın sonrası alan tespitinde oldukça etkili olduğunu göstermektedir. Diğer taraftan, yanmamış alanların tespitinde model performansında biraz düşüş gözlemlenmiştir ve bu durum modelin iyileştirilmesi gerektiğine işaret etmektedir. Yanlış negatif ve yanlış pozitif oranlarının düşürülmesi için modelin daha fazla veri ile eğitilmesi ve parametre optimizasyonları yapılması önerilmektedir.

Bu çalışma, U-Net tabanlı bölütleme modelinin orman yangını sonrası alan tespiti için potansiyelini ortaya koyarken, gelecekteki çalışmaların daha karmaşık senaryolarda bu modelin genelleme yeteneğini artırmaya yönelik olabileceğini göstermektedir.

### Yazar Katkı Oranı

**Melih ALTAY:** Literatür Taraması, Veri Analizi, Metodoloji Geliştirme, Yazım **Mustafa TÜRKER:** Literatür Taraması, Metodoloji Düzenleme, Sonuçların Değerlendirilmesi, Revizyon

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

### KAYNAKÇA

Avrupa Çevre Ajansı (EEA). (2018). CORINE Land Cover Technical Guidelines. European Environment Agency, Copenhagen.

Ateşoğlu, A., & Erkan, T. (2022). 2021 Manavgat orman yangınının uzaktan algılama teknikleri ile analizi. Turkish Journal of Forestry, 23(3), 221-229.

Ball, J. E., & Anderson, D. T. (2017). A novel application of deep learning for single-image super-resolution and object detection in satellite imagery. Remote Sensing, 9(12), 1161.

Bowman, D. M. J. S., Williamson, G. J., Abatzoglou, J. T., Kolden, C. A., Cochrane, M. A., & Smith, A. M. S.

(2020). Vegetation fires in the Anthropocene. Nature Reviews Earth & Environment, 1(10), 500-515.

Boulch, A., Gibert, X., Teboul, O., Le Bris, A., & Marlet, R. (2017). SnapNet: Semantic segmentation of 3D point clouds. Computers & Graphics, 67, 92-104.

Çanakçıoğlu, H. (1993). Orman koruma (3. baskı). İstanbul Üniversitesi Yayınları.

Chuvieco, E., & Kasischke, E. S. (2007). Remote sensing information for fire management and fire effects assessment. Journal of Geophysical Research: Biogeosciences, 112(G1).

FAO. (2021). The impact of climate change on forest fires: A global assessment. Food and Agriculture Organization of the United Nations.

Fernandes, P. M., & Loureiro, C. (2019). A review of the effects of prescribed burning on fire behavior, fuel consumption and fire severity. Fire Ecology, 15(1), 1-15.

Flannigan, M. D., Krawchuk, M. A., de Groot, W. J., Wotton, B. M., & Gowman, L. M. (2009). Implications of changing climate for global wildland fire. International Journal of Wildland Fire, 18(5), 483-507.

Giglio, L., Randerson, J. T., & van der Werf, G. R. (2018). Analysis of daily, monthly, and annual burned area using the fourth-generation global fire emissions database (GFED4). Journal of Geophysical Research: Biogeosciences, 123(3), 1125-1140.

Huang, W., Li, Y., Shen, H., & Zhang, L. (2022). Deep learning for burned area mapping: A review on methodologies, applications, and challenges. ISPRS Journal of Photogrammetry and Remote Sensing, 188, 181-198.

IPCC. (2022). Climate Change 2022: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press.

Ji, S., Yu, B., Shen, Y., Li, D., Xu, H., & Xu, G. (2019). Land cover classification of VHR imagery using deep learning and transfer learning with Google Earth imagery. Remote Sensing, 10(5), 678.

Jones, M. W., & Archer, C. (2021). Wildfire emissions and their impact on global air quality. Environmental Science & Technology, 55(8), 4671-4680.

Kemker, R., Salvaggio, C., & Kanan, C. (2018). Algorithms for semantic segmentation of multispectral remote sensing imagery using deep learning. ISPRS Journal of Photogrammetry and Remote Sensing, 145, 60-77.

Li, Y., Lu, Y., & Yang, W. (2021). Wildfire mapping with deep learning and Sentinel-2 imagery. Remote Sensing, 13(4), 789.

Mou, L., Ghamisi, P., & Zhu, X. X. (2018). Deep recurrent neural networks for hyperspectral image classification. IEEE Transactions on Geoscience and Remote Sensing, 57(6), 4229-4241.

Öztürk, M., Yılmaz, H., & Altun, B. (2022). Akdeniz orman ekosistemlerinde yangın dinamikleri ve yangın yönetimi. Turkish Journal of Forestry, 23(2), 134-147.

Persello, C., & Stein, A. (2020). Deep learning for hyperspectral image classification: An overview and future perspectives. ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences, 5, 547-554.

Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. In Medical Image Computing and Computer-Assisted Intervention--MICCAI 2015 (Vol. 9351, pp. 234-241). Springer.

Roteta, E., Bastarrika, A., Padilla, M., Storm, T., & Chuvieco, E. (2019). Development of a Sentinel-2 burned area algorithm: Generation of a small fire database for sub-Saharan Africa. Remote Sensing of Environment, 222, 1-17.

Shen, H., Zhang, L., Huang, W., & Li, Y. (2023). A comparative analysis of deep learning and spectral index methods for wildfire burned area mapping. Remote Sensing of Environment, 272, 112959.

T.C. Tarım ve Orman Bakanlığı. (2021). Arazi Parsel Tanımlama Sistemi (LPIS) Teknik Dokümanı. Tarım Reformu Genel Müdürlüğü, Ankara.

TÜBİTAK. (2022). 2021 Manavgat orman yangınları raporu. Türkiye Bilimsel ve Teknolojik Araştırma Kurumu.

Veraverbeke, S., Hook, S. J., & Hulley, G. C. (2014). An evaluation of unmanned aerial vehicle imagery for burned area mapping in boreal forests. International Journal of Applied Earth Observation and Geoinformation, 33, 1-9.

Yalçın, M., Yılmaz, K. E., & Bilgilioğlu, B. B. (2022). Uzaktan algılama verileri ve yangın şiddet indeksleri kullanarak 2021 yılı Manavgat orman yangınının analizi. Geomatik, 7(1), 39-46.

Zhang, C., Yang, G., Jiang, Y., Zhou, Z., & Liu, X. (2022). Wildfire burned area mapping based on deep learning and thermal infrared images. Remote Sensing, 14(3), 686.

Zhang, J., Hu, S., & Sun, W. (2020). Fire mapping using deep learning and multi-source remote sensing data. Remote Sensing, 12(9), 1421.

Zhu, X. X., Tuia, D., Mou, L., Xia, G. S., Zhang, L., Xu, F., & Fraundorfer, F. (2017). Deep learning in remote sensing: A comprehensive review and list of resources. IEEE Geoscience and Remote Sensing Magazine, 5(4), 8-36.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Yalova'da Tektonik Hareketlerin Yol Açtığı Yüzey Deformasyonlarının SBAS-InSAR Analiziyle Değerlendirilmesi

**Fatih Bursalı[*1], R. Cüneyt Erenoğlu[2], Süha Özden[3], Seray Çınar Yıldız[4]**

[1]Çanakkale Onsekiz Mart Üniversitesi, Lisansüstü Eğitim Enstitüsü, Harita Mühendisliği Anabilim Dalı, Çanakkale, Türkiye
[2]Çanakkale Onsekiz Mart Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Çanakkale, Türkiye
[3]Çanakkale Onsekiz Mart Üniversitesi, Mühendislik Fakültesi, Jeoloji Mühendisliği Bölümü, Çanakkale, Türkiye
[4]Çanakkale Onsekiz Mart Üniversitesi, Lisansüstü Eğitim Enstitüsü, Jeoloji Mühendisliği Anabilim Dalı, Çanakkale, Türkiye

**Anahtar Kelimeler**
Afet Risk Yönetimi,
InSAR,
SBAS-InSAR,
Sentinel-1,
Tektonik Deformasyon

**ÖZET**

Türkiye, aktif tektonik süreçlerin etkisi altında olup, diri fay hatlarının bulunduğu bölgelerde tektonik tabanlı meydana gelen yüzey deformasyonları riski taşımaktadır. Bu çalışma, 2017-2022 yılları arasında Yalova ilinde diri fay hatlarının neden olduğu yüzey deformasyonlarını belirlemek amacıyla Sentinel-1 uydu verilerini kullanmaktadır. Bu kapsamda Kısa Baz Uzunluklu İnterferometrisi (SBAS-InSAR) yöntemiyle alçalan (descending) ve yükselen (ascending) yörüngelerden elde edilen uydu radar görüntüleri analiz edilmiştir. Bunun için otomatik bir Sentinel-1 InSAR işlemcisi LİCSAR web portalı ile açık kaynak kodlu bir zaman serisi analiz paketi olan LİCSBAS sistemleriyle zamansal ve mekânsal deformasyon haritaları oluşturulmuştur. Üretilen haritalar doğrultusunda Yalova ilindeki tektonik hareketlerin tetiklediği yükselme ve çöküntü alanlarını hem doğrusal hem de dalgalanmalı deformasyon analizleri yapılmıştır. Tektonik hareketlerin neden olduğu düşey ve yatay deformasyon bileşenleri modellenerek detaylı analizler gerçekleştirilmiştir. Sonuçlar doğrultusunda günümüz teknolojisinde yoğun bir şekilde kullanılmakta olan ileri InSAR tekniği ile bölgelere ait deformasyon haritaları üretilerek, güvenli çevre yönetimi ve kent planlamasına bilimsel katkı sağlamayı hedeflemektedir.

# Evaluation of Surface Deformations Caused by Tectonic Movements in Yalova Through SBAS-InSAR Analysis

**Keywords**
Disaster Risk Management,
InSAR,
SBAS-InSAR,
Sentinel-1,
Tectonic Deformation

**ABSTRACT**

Turkey is under the influence of active tectonic processes and is at risk of tectonically induced surface deformations in regions with active fault lines. This study utilizes Sentinel-1 satellite data to determine the surface deformations in Yalova province between 2017 and 2022. In this context, satellite radar images obtained from descending and ascending orbits using Short Base Length Interferometry (SBAS-InSAR) were analysed. For this purpose, temporal and spatial deformation maps were created with an automated Sentinel-1 InSAR processor, LICSAR web portal and LICSBAS, an open-source time series analysis package. In line with the maps produced, both linear and fluctuating deformation analyses of the uplift and subsidence areas triggered by tectonic movements in Yalova province were made. Vertical and horizontal deformation components caused by tectonic movements were modelled and detailed analyses were performed. In line with the results, it is aimed to provide scientific contribution to safe environmental management and urban planning by producing deformation maps of the regions with the advanced InSAR technique, which is used extensively in today's technology.

* **Sorumlu Yazar**

*(fatihbursali41@gmail.com) ORCID ID 0009-0002-8078-0133
(ceren@comu.edu.tr) ORCID ID 0000-0002-8212-8379
(ozden@comu.edu.tr) ORCID ID 0000-0001-6321-0812
(seraycinar@gmail.com) ORCID ID 0009-0005-7048-8456

**Kaynak Göster (APA):**

Bursalı F, Erenoğlu R C, Özden S & Çınar Yıldız S (2025). Yalova'da Tektonik Hareketlerin Yol Açtığı Yüzey Deformasyonlarının SBAS-InSAR Analiziyle Değerlendirilmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Türkiye tektonik aktivitenin oldukça yoğun olduğu bir bölgede olmasından dolayı yüzey deformasyonlarının tespit edilmesi çalışmaları büyük öneme sahiptir. Yüzey deformasyonları tektonik ve volkanik hareketlerin tetiklediği doğal olayların sonucu olduğu gibi madencilik çalışmaları ve yer altı çalışmaları gibi yapay sebeplerden dolayı meydana gelebilir (Herrera-Garcia vd., 2021). Yüzey deformasyonları izlenmesi çalışmalarında GPS/GNSS, InSAR, Total Station gibi ölçme teknikleri kullanılmaktadır. Teknolojik gelişmelerle birlikte son yıllarda yüzey deformasyonlarının hızlı, etkin ve ekonomik olarak tespit edilmesi için InSAR gibi uzaktan algılama teknikleri yoğun bir şekilde kullanılmaktadır. InSAR tekniklerinden biri olan SBAS-InSAR ile yer yüzeyinde meydana gelen deformasyonların zamansal olarak daha detaylı analiz etmemizi sağlar (Berardino vd., 2002). SBAS-InSAR tekniği tektonik tabanlı kaynaklanan deformasyon (Chen vd., 2022; Galih Dewanto vd., 2020; Lazeckỳ vd., 2020; Morishita, 2021; Rosyidy vd., 2021; Weiss vd., 2020; Yu vd., 2024; Zhou vd., 2017) hareketlerinde kullanıldığı görülmektedir.

Bu çalışmada, Marmara Bölgesi Güneyinde Kuzey Anadolu Fay Zonu üzerindeki Yalova ili civarında bölgesel olarak meydana gelen yüzey deformasyonların Sentinel-1 görüntüleri kullanılarak tespit edilmiştir. Tespit edilen bu yerlerin zaman serisi analizi ile modellenmiştir.

## 2. YÖNTEM

Bu çalışma kapsamında Sentinel-1 verilerini otomatik işleme sistemi olan LİCSAR verilerinden yararlanılmıştır. LİCSAR Deprem, Volkan ve Tektonik Gözlem ve Modelleme Merkezi (COMET/Centre for the Observation and Modelling of Earthquakes, Volcanoes and Tectonics)'nin Uzaydan Kıtaların İçine Bakmak (LiCS/Looking inside the Continents from Space) için geliştirilmiş bir projedir. LiCS projesi sayesinde sismik aktivite, deprem sonrası deformasyon döngüsü gözlemlemeyi amaçlamaktadır (Lazeckỳ vd., 2020). Bununla birlikte LİCBAS ürünü kullanılarak LİCSAR verileriyle entegre olan açık kaynaklı bir InSAR zaman serisi izleme aracıdır (Morishita vd., 2020). LİCSBAS ürünü kullanılarak çalışma bölgesine ait analiz yapmak için 2 aşamada gerçekleşir. İlk aşamada deformasyon çalışması yapacağımız bölgeye ait LİCSAR web portalı üzerinden ilgili çerçeveler belirlenerek Sentinel-1 verilerinin indirilmesi ve bu verilerin hazırlanması aşamasıdır. İkinci aşamada ise LİCSAR web portalından indirilen verilerin analiz edilerek belirlediğimiz deformasyonlarının hızı ve o bölgedeki deformasyona ait değerlerin zaman serisini oluşturmasıdır. Şekil 1. de bu çalışmaya ait LİCSBAS yazılımının iş akış şeması verilmiştir.

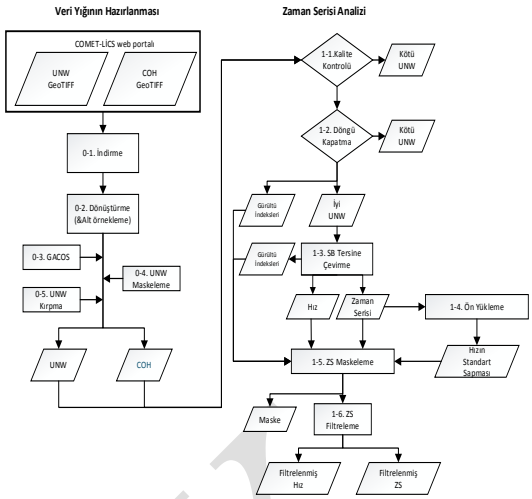


**Şekil 1.** LiCSBAS yazılımı iş akış diyagramı (Morishita vd., 2020)

### 2.1. Çalışma Alanı ve Kullanılan Veriler

Bu çalışma kapsamında, Kuzey Anadolu Fay Zonu'nun güney kolları üzerinde bulunan fay segmentlerinin bir bölümü çalışma alanı belirlenmiştir.

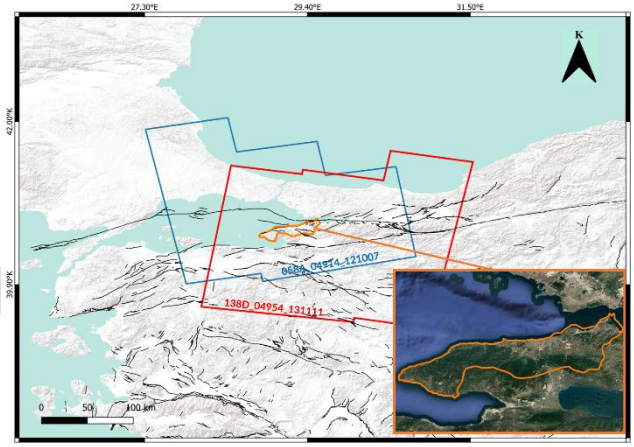


**Şekil 2.** Çalışma alanı haritası ve çalışmada kullanılan çerçevelerin görüntüsü.

Bu çalışma doğrultusunda LİCSBAS yazılımı kullanılarak veriler işlemek için COMET-LiCS Sentinel-1 web portalında kullanılması gereken çerçeve kimlikleri belirlendi. LİCSBAS yazılımına verilerin değerlendirilmesi için LİCSAR çerçevelerinden çalışma alanını kapsayan yükselen yörünge 058A_04914_121007, alçalan yörünge 138D_04954_131111 kimlikli çerçevelerin verileri 2017 ile 2022 yıllarına kadar indirildi. Çalışma alanı lokasyonuna ait alanın kırma işlemi gerçekleştirilerek veri boyutu küçültüldü. Kırma işleminde sonra veri hazırlama işlemi tamamlanarak gerekli iş akış doğrultusunda zaman serisi analizi yapılarak bölgeye ait hız değerleri bulunmuştur.

## 3. BULGULAR

Çalışma doğrultusunda 2017 ve 2022 yılları arasında Ascending (yükselen yörünge) ait 327 görüntü Descending (alçalan yörünge) ait 297 görüntü işlenmiştir. Bölgesel olarak incelediğimizde yükselen LOS hız değerleri ±10 (mm/y) iken alçalan yörünge değerleri 0 ile -10 (mm/y) değişmektedir. Çalışma

alanına ait uydu bakış doğrultusundaki maskelenmiş ve maskesiz LOS hız değerleri Şekil 3 ve 4'de verilmiştir.

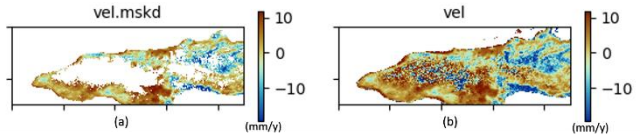


**Şekil 3.** 058A_04914_121007 Yükselen yörünge) ait LOS hız değerleri. (a) Yalova ili maskelenmiş los hız haritası. (b) Yalova ili maskesiz hız haritası.

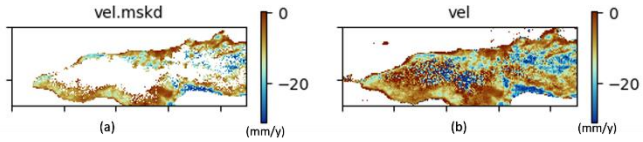


**Şekil 4.** 138D_04954_131111 Descending (alçalan yörünge) ait LOS hız değerleri. (a) Yalova ili maskelenmiş los hız haritası. (b) Yalova ili maskesiz hız haritası.

LOS hız değerlerinden decompose (ayrıştırma) işlemi yapılarak yatay ve düşey hız değerleri Şekil 5 ve 6'da verilmiştir.

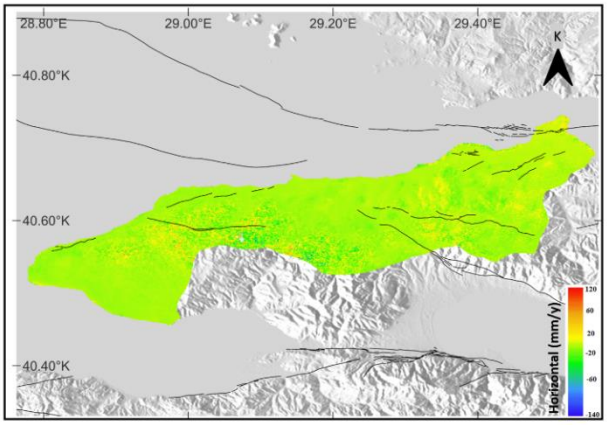


**Şekil 5.** Çalışma alanı ait yatay hız değerleri.

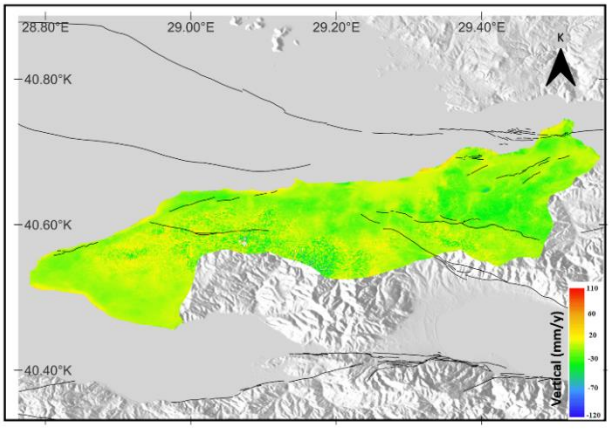


**Şekil 6.** Çalışma alanı ait düşey hız değerleri.

Elde edilen veriler kapsamında Yalova ili sınırları içinde belirlenen fay segmentleri geçtiği yerlerde bölgesel olarak ±20 mm/y deformasyonlar tespit edilmiştir. Aynı zamanda otoyol çalışmaları sırasında yapılan şev stabilizasyonları sonucunda meydana gelen -14.3 mm/y çökmeler belirlenmiştir. Bölgesel olarak incelediğimiz zamanda Yalova ili genelinde işlevini yitirmiş eski maden ocaklarının tetiklediği yüzey deformasyonları sonucunda -23.2 mm/y çökme değerleri de tespit edilmiştir. Bu sonuçlar doğrultusunda Şekil 7' de üç farklı lokasyonun pilot bölge olarak gösterilip, zaman serileri de Şekil 8'de sunulmuştur.

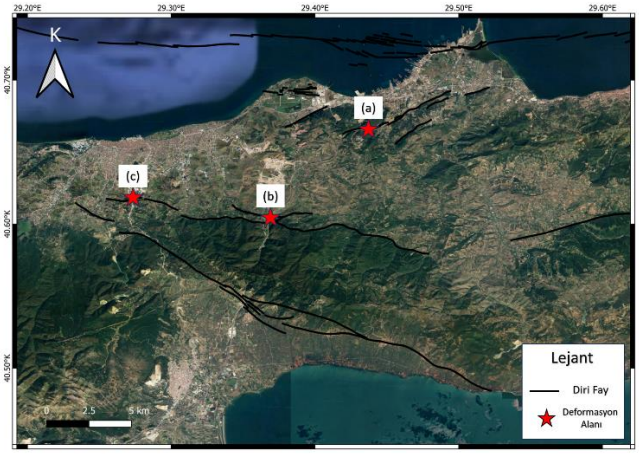


**Şekil 7.** Pilot bölge belirlenen deformasyon alanları.

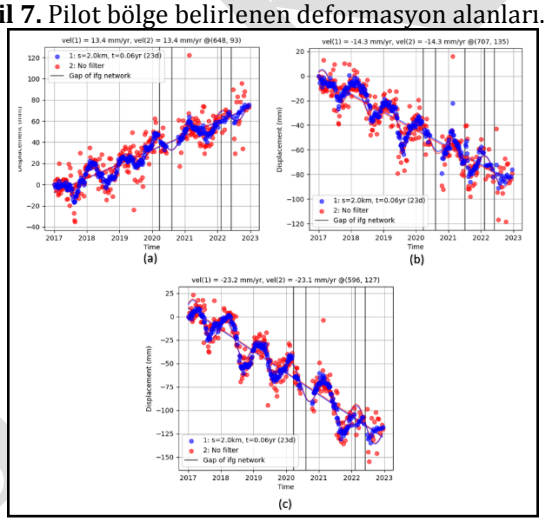


**Şekil 8.** Yüzey deformasyonlarının zaman serisi analizi;(a) fay segmentlerinin geçtiği bölge;(b) şev stabilizasyonlarına ait bölge;(c) eski maden ocaklarına ait bölge

## 4. TARTIŞMA

Yapılan çalışmalar sonucunda 2017-2022 yılları arasında LOS yönünde hız alanları belirlenmiştir. Elde edilen sonuçlara göre Yalova ili genelinde tektonik tabanlı yüzey deformasyonları gözlenmiştir. Gözlenen bu deformasyon değerleri ayrıştırma işlemi yapılmış düşey ve yatay hız değerler ile analiz edilmiş olup bölgesel olarak değerlendirilip belirlediğimiz lokasyonlar ±23 (mm/y) arasında değişmektedir. Aynı zamanda bölgede yapılmış otoyol inşaatı sonucunda şev stabilizasyonları ve işlevini yitirmiş maden ocakları gibi yerlerin oluşturduğu yapay yüzey deformasyonları da tespit edilmiştir.

## 5. SONUÇ

Gelişen uzaktan algılama teknolojileri, özellikle InSAR yöntemleri, geniş alanlardaki yüzey deformasyonlarının yüksek doğrulukla izlenmesine olanak tanımaktadır. Bu çalışmada Sentinel-1 görüntüleri kullanılarak Yalova ili özelinde yüzey deformasyonları Şekil 5 ve Şekil 6'da deformasyon aralıklarıyla analiz edilmiş, aynı zamanda

Şekil 7'de bulunan a, b ve c pilot bölgeler örnek verilerek a bölgesi yüzeyinde yükselmeler meydana geldiği belirlenmiştir. B bölgesinde ise önceki yıllarda yapılan otoyol inşaatı sonucu yapılan şev stabilizasyonlarında meydana gelen çökmeler tespit edildiği, son olarak ise c bölgesinde işlevini yitirmiş bir maden ocağının sonucunda yüzeyde çökmeler tespit edildiği hızlarıyla birlikte sunulmuştur. Elde edilen veriler doğrultusunda deformasyonların zaman içindeki değişimini belirleyerek bölgedeki riskli alanların tespitini sağlamak ve güvenli çevre yönetimi ile kent planlaması için bilimsel bir temel oluşturmaktır.

Sonuç olarak, yeni nesil InSAR teknikleri ile hızlı, etkin ve ekonomik bir şekilde afet riski değerlendirilerek gerekli önlemlerin alınması mümkün hale gelmiştir. Bu yöntem, bölgesel sürdürülebilirlik ve kentsel güvenlik açısından kritik bir karar destek mekanizması sunmaktadır.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

**TEŞEKKÜR**

Bu çalışma TÜBİTAK 123G013 numaralı proje tarafından desteklenmektedir.

**Yazar Katkı Oranı**

Çalışmaya yazarlar eşit oranda katkı sağlamıştır.

**Çıkar Çatışması/Çakışması**

Çalışmada herhangi bir kurum, kuruluş, kişi ile mali çıkar çatışması yoktur ve yazarlar arasında çıkar çatışması bulunmamaktadır.

**Araştırma ve Yayın Etiği Beyanı**

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

**KAYNAKÇA**

Berardino, P., Fornaro, G., Lanari, R., & Sansosti, E. (2002). A newYu, H., Li, B., Xiao, Y., Sun, J., Chen, C., Jin, G., & Liu, H. (2024). Surface Subsidence over a Coastal City Using SBAS-InSAR with Sentinel-1A Data: A Case of Nansha District, China. *Remote Sensing*, *16*(1). https://doi.org/10.3390/rs16010055 algorithm for surface deformation monitoring based on small baseline differential SAR interferograms. *IEEE Transactions on Geoscience and Remote Sensing*, *40*(11), 2375-2383. https://doi.org/10.1109/TGRS.2002.803792

Chen, K., Liu, G., Xiang, W., Sun, T., Qian, K., Cai, J., Pirasteh, S., & Chen, X. (2022). Assimilation of SBAS-InSAR Based Vertical Deformation Into Land Surface Model to Improve the Estimation of Terrestrial Water Storage. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *15*, 2826-2835. https://doi.org/10.1109/JSTARS.2022.3162228

Galih Dewanto, B., Bagas Setiawan, M., & Cahya Nusantara, G. (2020). *OPAK FAULT DEFORMATION MONITORING USING SENTINEL-1 INSAR DATA FROM 2016-2019 IN YOGYAKARTA INDONESIA*.

Herrera-Garcia, G., Ezquerro, P., Tomás, R., Béjar-Pizarro, M., López-Vinielles, J., Rossi, M., Mateos, R. M., Carreón-Freyre, D., Lambert, J., Teatini, P., & Cabral-Cano, E. (t.y.). Devin Galloway 2,14 , Wei-Chia Hung 2,15 , Najeebullah Kakar 2,16 , Michelle Sneed 2,17 , Luigi Tosi 2. *Shujun Ye*, *11*, 2021. https://doi.org/10.6084/m9.figshare.13312070

Lazeckỳ, M., Spaans, K., González, P. J., Maghsoudi, Y., Morishita, Y., Albino, F., Elliott, J., Greenall, N., Hatton, E., Hooper, A., Juncu, D., McDougall, A., Walters, R. J., Watson, C. S., Weiss, J. R., & Wright, T. J. (2020). LiCSAR: An automatic InSAR tool for measuring and monitoring tectonic and volcanic activity. *Remote Sensing*, *12*(15). https://doi.org/10.3390/RS12152430

Morishita, Y. (2021). Nationwide urban ground deformation monitoring in Japan using Sentinel-1 LiCSAR products and LiCSBAS. *Progress in Earth and Planetary Science*, *8*(1), 1-23. https://doi.org/10.1186/S40645-020-00402-7/FIGURES/16

Morishita, Y., Lazecky, M., Wright, T. J., Weiss, J. R., Elliott, J. R., & Hooper, A. (2020). LiCSBAS: An Open-Source InSAR Time Series Analysis Package Integrated with the LiCSAR Automated Sentinel-1 InSAR Processor. *Remote Sensing 2020, Vol. 12, Page 424*, *12*(3), 424. https://doi.org/10.3390/RS12030424

Rosyidy, M. K., Dimyati, M., Shidiq, I. P. A., Zulkarnain, F., Rahaningtyas, N. S., Syamsuddin, R. P., & Zein, F. M. (2021). Landslide surface deformation analysis using sbas-insar in the southern part of the sukabumi area, indonesia. *Geographia Technica*, *16*(Special Issue), 138-152. https://doi.org/10.21163/GT_2021.163.11

Weiss, J. R., Walters, R. J., Morishita, Y., Wright, T. J., Lazecky, M., Wang, H., Hussain, E., Hooper, A. J., Elliott, J. R., Rollins, C., Yu, C., González, P. J., Spaans, K., Li, Z., & Parsons, B. (2020). High-Resolution Surface Velocities and Strain for Anatolia From Sentinel-1 InSAR and GNSS Data. *Geophysical Research Letters*, *47*(17), e2020GL087376. https://doi.org/10.1029/2020GL087376

Zhou, L., Guo, J., Hu, J., Li, J., Xu, Y., Pan, Y., & Shi, M. (2017). Wuhan surface subsidence analysis in 2015-2016 based on sentinel-1A data by SBAS-InSAR. *Remote Sensing*, *9*(10). https://doi.org/10.3390/rs9100982

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# ArcSAR Radar Sisteminin Coğrafi Bilgi Sistemlerine Entegresi

**Arif Aydın**[*1]

[1]*Enerjisa Enerji Üretim A.Ş., Adana, Türkiye*

**Anahtar Kelimeler**
ArcSAR,
Coğrafi Bilgi Sistemleri,
Deformasyon İzleme,
Radar İnterferometrisi,
Şev Stabilitesi

**ÖZET**

Açık ocak madenciliğinde şev stabilitesinin sürekli izlenmesi, hem iş güvenliği hem de operasyonel verimlilik açısından kritik bir gerekliliktir. Deformasyon ölçümlerinde yüksek hassasiyet sağlayan ArcSAR radar sistemi, gerçek zamanlı veri üretme kapasitesi ile açık ocak sahalarında şev hareketlerini detaylı bir şekilde analiz etmeye olanak tanımaktadır. Ancak, radar verilerinin etkin kullanımı ve karar destek süreçlerine entegrasyonu için Coğrafi Bilgi Sistemleri (CBS) ile bütünleştirilmesi büyük önem arz etmektedir.

Bu çalışmada, ArcSAR radar sisteminden elde edilen deformasyon haritalarının CBS tabanlı veri yönetim sistemleri ile entegrasyonu ele alınmıştır. Radar verilerinin, saha topoğrafyası, jeoteknik modelleme ve hidrojeolojik parametrelerle ilişkilendirilmesi sayesinde, şev stabilitesi değerlendirmelerinin doğruluğu artırılmakta ve risk analizleri daha kapsamlı yapılabilmektedir. Ayrıca, CBS tabanlı entegrasyon sayesinde veri paylaşımı ve görselleştirme süreçleri hızlanmakta, saha mühendisleri, güvenlik ekipleri ve karar alıcılar için erişilebilir bir izleme altyapısı sağlanmaktadır. ArcSAR radar sisteminin CBS ile entegrasyonu, özellikle geniş ölçekli açık ocak madenciliğinde erken uyarı mekanizmalarının geliştirilmesi, kritik bölgelerin belirlenmesi ve operasyonel planlamanın optimize edilmesi açısından önemli avantajlar sunmaktadır. Çalışmanın sonuçları, maden sahalarında CBS tabanlı deformasyon izleme sistemlerinin yaygınlaştırılmasına yönelik öneriler içermektedir.

# Integration of the ArcSAR Radar System into Geographic Information Systems

**Keywords**
ArcSAR,
Deformation Monitoring,
Geographic Information Systems,
Radar Interferometry,
Slope Stability

**ABSTRACT**

Continuous monitoring of slope stability in open-pit mining is crucial for both occupational safety and operational efficiency. The ArcSAR radar system, which provides high-precision deformation measurements, enables detailed analysis of slope movements in open-pit environments through real-time data acquisition. However, the effective utilization of radar data and its integration into decision-making processes necessitate the incorporation of Geographic Information Systems (GIS). This study explores the integration of deformation maps derived from the ArcSAR radar system into GIS-based data management frameworks. By correlating radar data with site topography, geotechnical modeling, and hydrogeological parameters, the accuracy of slope stability assessments is enhanced, enabling more comprehensive risk analyses. Additionally, GIS-based integration facilitates data sharing and visualization, providing an accessible monitoring infrastructure for site engineers, safety teams, and decision-makers.

The integration of the ArcSAR radar system with GIS offers significant advantages in large-scale open-pit mining operations, particularly in the development of early warning mechanisms, identification of critical zones, and optimization of operational planning. The findings of this study present recommendations for the broader implementation of GIS-based deformation monitoring systems in mining operations.

* **Sorumlu Yazar**
*(arif.aydin@enerjisauretim.com)

**Kaynak Göster (APA):**
Aydın A (2025). ArcSAR Radar Sisteminin Coğrafi Bilgi Sistemlerine Entegresi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

TASLAK

## 1. GİRİŞ

Açık maden işletmelerinde şev stabilitesinin izlenmesi, hem iş güvenliği hemde sürdürülebilir üretim açısından kritik konudur. Geleneksel yöntemler, genellikle periyodik ölçümlerle sınırlı kalırken, gelişmiş uzaktan algılama sistemleri gerçek zamanlı izleme imkanı sağlamaktadır. ArcSAR radar sistemi, yüksek çözünürlüklü deformasyon haritaları üreterek potansiyel heyelan ve şev kaymalarını tespit etmeye olanak tanır.(Casagli et al. 2017).

Tufanbeyli linyit sahası'nda 2020 yılından itibaren ArcSAR radar sistemi kullanılmaya başlanmıştır. Başlangıçta sistem bağımsız bir izleme aracı olarak çalıştırılmış, elde edilen veriler manuuel olarak değerlendirilmiştir. Ancak, 2022 yılından itibaren ArcsSAR radar verileri Coğrafi Bilgi Sistemleri (CBS) ile entegre edilerek analiz edilmeye başlanmıştır.

Bu çalışmada, ArcSAR radar sisteminin BS ile entegrasyon süreci ele alınarak maden sahasında sağladığı avantajlar detaylı bir şekilde incelenmiştir. Radar verilerinin CBS ile birleştirilmesi sayesinde şev stabilitesinin daha etkin bir şekilde izlenebildiği ve potansiyel risklerin erken tespit edilerek kazaların önlenebildiği ortaya konmuştur.

## 2. YÖNTEM

ArcSAR radar sistemi(Şekil1), Tufanbeyli Linyit Sahası'nda 2020 yılından itibaren kullanılmaktadır. Radar 360° tarama ile sürekli veri kaydı yaparak milimetre hassasiyetinde deformasyon haritaları üretmektedir. İşlenen veriler ArcGIS gibi yazılımlara aktarılmaktadır.



**Şekil 1.** ArcSAR Radar Sistemi

### 2.1. ArcSAR Radar Sistemi

IDS Georadar tarafından geliştirilen taşınabilir ve kompakt bir radar izleme sisteminidir. Sistemin özellikleri(IDS Jeoradar, 2024);

- Tarama alanı: 360 derece,
- Kapsama Alanı: 60 derece,
- Menzil: 2.5 km,
- Hassasiyet: 0,1 mm.,
- Tarama Süresi: 4 dakidadır.

#### 2.1.1. ArGIS Online Web MAP

ArcGIS Online Web Map, ESRI tarafından geliştirilen ve bulut tabanlı bir CBS (Coğrafi Bilgi Sistemleri) platformu üzerinden çalışan etkileşimli haritalama aracıdır(Şekil 2). Kullanıcılar, bu platform aracılığıyla coğrafi verileri çevrimiçi olarak oluşturabilir, düzenleyebilir, analiz edebilir ve paylaşabilir (Esri ,2023).

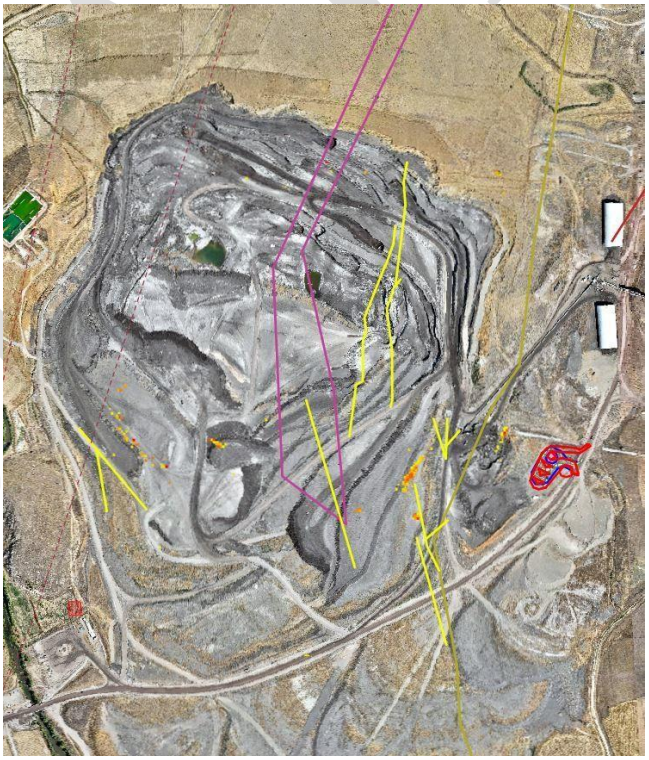

**Şekil 2.** Arcgis Online Web Map

- Şev stabilitesi izleme: ArcSAR radar verileri, deformasyon haritaları ve risk bölgeleri Web Map üzerinde görselleştirilebilir.
- Gerçek zamanlı saha yönetimi: Jeoteknik ve madencilik ekipleri, harita üzerinden anlık durumu takip edebilir ve hızlı karar alabilir.
- Tehlike bölgelerinin belirlenmesi: Heyelan ve göçme riski taşıyan alanlar, renk kodlaması ile Web Map üzerinde işaretlenebilir.
- Dijital madencilik planlaması: Üretim, sondaj ve altyapı planları Web Map ile entegre edilebilir.

## 3. ArcSAR RADAR SİSTEMİ İLE CBS ENTEGRASYONU

ArcSAR radar sisteminden elde edilen verilerin Coğrafi Bilgi Sistemleri (CBS) ile entegrasyonu, madencilik operasyonlarında deformasyon analizi ve şev stabilitesi değerlendirmelerinin daha etkin yapılmasını sağlayan kritik bir süreçtir. Bu entegrasyonun temel aşamaları, veri toplama, işleme, CBS yazılımına aktarım ve analiz-değerlendirme adımlarından oluşmaktadır.

Radar verileri öncelikle ArcSAR'ın periyodik taramalarıyla toplanarak şev hareketlerine dair deformasyon haritaları üretilir. Bu haritalar, belirlenen izleme bölgesindeki hız değişimleri, çökme ve kaymalar gibi jeoteknik hareketleri ortaya koyan detaylı veri setleri içerir.

Veri toplama sürecinin ardından, elde edilen radar çıktıları CBS ortamında işlenebilir formatlara dönüştürülür. ArcSAR tarafından üretilen ham veriler, GeoTIFF, shapefile (SHP) ve ASCII gibi CBS uyumlu veri formatlarına çevrilerek mekânsal analizlere uygun hale getirilir. Bu dönüştürme işlemi, veri kaybı olmadan en doğru ve güncel deformasyon bilgilerine erişilmesini sağlar.

CBS entegrasyonu kapsamında, dönüştürülen veriler ArcGIS yazılımlarına aktarılır. Bu aşamada, şev stabilitesi değerlendirmesi için radar verilerinin diğer jeolojik, topoğrafik ve jeoteknik katmanlarla bütünleştirilmesi sağlanır. Radar ölçümleri, CBS ortamında zamana bağlı analizlerle kıyaslanarak deformasyon eğilimleri belirlenir ve şev stabilitesi açısından riskli bölgeler haritalandırılır.

Son aşamada, CBS yazılımı aracılığıyla detaylı analizler gerçekleştirilir. Deformasyon haritaları üzerindeki hareket trendleri incelenerek eğilim analizleri yapılır ve şev stabilitesindeki değişimler istatistiksel olarak değerlendirilir. Bu analizler, mühendislerin potansiyel riskleri önceden tespit etmesine ve alınması gereken önlemleri belirlemesine yardımcı olur. Ayrıca, CBS ortamında oluşturulan tehlike bölgeleri haritaları, saha ekipleriyle paylaşılabilir ve operasyonel süreçlerde erken müdahale imkânı sunar.

Bu entegrasyon sayesinde ArcSAR radar verileri, madencilik mühendisleri tarafından daha verimli ve görsel olarak anlaşılır bir şekilde kullanılabilir hale gelir. Böylece, saha ekipleri deformasyon trendlerini anlık olarak takip edebilir, risk yönetimi daha sistematik hale gelir ve üretim planlaması daha güvenli bir şekilde gerçekleştirilebilir.

## 4. SONUÇ

Bu çalışmada ArcSAR radar sisteminden elde edilen verilerin CBS ile entegrasyonu gerçekleştirilmiş ve açık maden işletmeciliğinde kullanım alanları değerlendirilmiştir. Elde edilen sonuçlara göre, şev stabilitesi değerlendirmede yüksek doğruluk sağlamış, saha mühendisleri ve planlama ekibi için daha hızlı karar alma imkanı sunmuştur.

**TEŞEKKÜR**

Bidiri yazmam kousundaki desteğinden dolayı Maden, Performans ve Raporlama Lideri Sn. Onur Baran TEKİN'e teşekkürlerimi Proje/makale/yazar için destek teşekkürleri bu bölümde verilmelidir.

**Yazar Katkı Oranı**

Bu çalışmanın tüm aşamaları (kavramlaştırma, veri analizi, yazım ve düzenleme) Arif AYDIN tarafından gerçekleştirilmiştir.

**KAYNAKÇA**

Casagli, N., Frodella, W., Morelli, S., Tofani, V., Ciampalini, A., Intrieri, E., et al. (2017). Space- borne and ground-based SAR interferometry for landslide monitoring in civil protection and engineering geology. *Geomorphology, 283*, 167-183.

Esri (2023). ArcGIS Pro Documentation: Radar Data Integration. *https://www.esri.com* [ Erişim Tarihi: 29.03.2025].

IDS GeoRadar (2024). ArcSAR Technical Datasheet. *https://www.idsgeoradar.com* [ Erişim Tarihi: 29.03.2025].

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Uzaktan Algılama Yöntemleri ile Orman Yangını Şiddeti ve Toprak Üstü Biyokütle Yoğunluğu Değişimlerinin İncelenmesi: Mersin/Pembecik Örneği

**Göktuğ Yaşar Çukurlu[1], Furkan Veziro[1], Nusret Demir*[2], Atticus Stovall[3]**

*[1]Akdeniz Üniversitesi, Fen Bilimleri Enstitüsü, Uzay Bilimleri ve Teknolojileri Bölümü, Antalya, Türkiye*
*[2]Akdeniz Üniversitesi, Fen Fakültesi, Uzay Bilimleri ve Teknolojileri Bölümü, Antalya, Türkiye*
*[3]NASA Goddard Space Flight Center, Greenbelt, MD, Amerika Birleşik Devletleri*

**Anahtar Kelimeler**
Uzaktan Algılama,
Orman Yangınları
GEDI LiDAR,
Biyokütle,
dNBR

**ÖZET**

Bu çalışmada, 15 Temmuz 2021 tarihinde Mersin/Pembecik mevkisinde çıkan orman yangını uzaktan algılama yöntemleri ile incelenmiştir. Pasif sensörlerden olan Optik algılayıcılar ve aktif sensörlerden olan SAR ve LiDAR tabanlı analizler gerçekleştirilmiştir. Yangın öncesi ve yangın sonrası uydu görüntüleri kullanılarak NBR analizi gerçekleştirilmiş ve bu 2 NBR indeksinden dNBR analizi uygulanmıştır. dNBR Analizi ile bölgede meydana gelen orman yangınının alanı ve şiddeti hesaplanırken, SAR ve LiDAR algılayıcıları ile orman yangını öncesi ve sonrası bölgenin Yerden Yüksek Biyokütle çıkarımı yapılmıştır. Elde edilen veriler ile dNBR ve AGBD haritaları karşılaştırılmış, bu sayede orman yangınlarının biyokütleye olan etkisi ve AGBD çıkarımının tutarlılığı incelenmiştir. dNBR analizi sonuçlarına göre meydana gelen orman yangınında yaklaşık 115km² alanın zarar gördüğü gözlemlenirken, AGBD çıkarımı sayesinde ise yangın sonrasında bölgede ~%16 biyokütle kaybı olduğu gözlemlenmiştir. dNBR ile AGBD kıyaslandığında her iki verinin birbiri ile tutarlı sonuçlar verdiği ve her iki verinin de güvenilir olduğu gözlemlenmiştir.

# Examination of Forest Fire Severity and Above-Ground Biomass Density Changes Using Remote Sensing Methods: The Case of Mersin/Pembecik

**Keywords**
Remote Sensing,
Forest Fires,
GEDI LiDAR,
Biomass,
dNBR

**ABSTRACT**

In this study, the forest fire that occurred on July 15, 2021, in the Mersin/Pembecik region was analyzed using remote sensing methods. Analyses were conducted using optical sensors, which are passive sensors, as well as SAR and LiDAR-based active sensors. Pre-fire and post-fire satellite images were used to perform an NBR (Normalized Burn Ratio) analysis, and a dNBR (differenced Normalized Burn Ratio) analysis was applied based on these two NBR indices. While the area and severity of the forest fire were calculated using the dNBR analysis, Above-Ground Biomass Density (AGBD) estimations of the region before and after the fire were conducted using SAR and GEDI LiDAR sensors. The resulting data were compared through dNBR and AGBD maps, enabling an examination of the impact of forest fires on biomass and the consistency of AGBD estimations. According to the results of the dNBR analysis, approximately 115 km² of land was observed to have been damaged by the forest fire. Additionally, the AGBD estimation revealed that the region experienced a ~16% biomass loss after the fire. When comparing dNBR and AGBD, it was observed that both datasets provided consistent results and were reliable.

* **Sorumlu Yazar**

*(nusretdemir@akdeniz.edu.tr) ORCID ID 0000-0002-8756-7127
(goktugcukurlu0@gmail.com) ORCID ID 0009-0008-9233-7626
(furkanveziro@gmail.com) ORCID ID 0000-0002-1940-6970
(atticus.stovall@nasa.gov) ORCID 0000-0001-9512-3318

**Kaynak Göster (APA):**

Çukurlu G Y, Veziro F, Demir N & Stovall A (2025). Uzaktan Algılama Yöntemleri ile Orman Yangını Şiddeti ve Toprak Üstü Biyokütle Yoğunluğu Değişimlerinin İncelenmesi: Mersin/Pembecik Örneği, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Ormanlar, sahip oldukları biyolojik çeşitlilikle dünyanın en önemli ekosistemlerinden biridir. Ancak, iklim değişikliği ve küresel faktörlerin etkisiyle orman yangınlarının sıklığının ve şiddetinin artacağı öngörülmektedir. Hem doğal hem de insan kaynaklı yangınlar, orman ekosistemlerine ciddi zararlar vermekte, erozyon ve sel gibi diğer doğal afetlerin oluşumuna zemin hazırlamaktadır. Türkiye ve Akdeniz iklim kuşağındaki ülkeler, özellikle yaz aylarında yüksek oranda orman yangını riski taşımaktadır. Örneğin, 2021 yazında Türkiye ve diğer Akdeniz ülkelerinde meydana gelen yangınlar, 620.000 hektarlık alanın zarar görmesine neden olmuştur. Yangın sonrası hasar tespiti ve ekosistem rejenerasyonu için uzaktan algılama teknikleri önemli avantajlar sunmaktadır. Uydu verileri, yanan alanların tespiti, yangın şiddetinin haritalanması ve biyokütle kaybının analiz edilmesi gibi süreçlerde etkili bir şekilde kullanılmaktadır. Bu bağlamda, Sentinel-2 uydu görüntüleri ve GEDI LiDAR verileri kullanılarak Mersin/Pembecik Köyü'nde 2021 yılında gerçekleşen orman yangını analiz edilmiştir. Çalışmada, yangın öncesi ve sonrası verilerle NBR ve dNBR indeksleri hesaplanmış, yaklaşık 115 $km^2$'lik bir alanın yangından etkilendiği belirlenmiştir. Ayrıca, GEDI LiDAR verileriyle AGBD (Above Ground Biomass Density) kaybı incelenmiş ve yangın sonrası bölgede %16 oranında biyokütle kaybı tespit edilmiştir. Biyokütle, yalnızca toprak ve su yönetimi açısından değil, aynı zamanda biyoçeşitlilik ve ekosistem sağlığı açısından kritik bir öneme sahiptir. Bu çalışmada, dNBR ve AGBD haritaları karşılaştırılarak yangının etkilediği bölgelerdeki biyokütle değişimi detaylı bir şekilde değerlendirilmiştir. Elde edilen bulgular, yangın sonrası ekosistem yönetimi ve rejenerasyon çalışmalarının planlanmasında önemli bir veri kaynağı sunmaktadır.

## 2. YÖNTEM

GEE (Google Earth Engine) platformu kullanılarak Mersin/Pembecik bölgesinde meydana gelen orman yangınının hem dNBR analizi hem de AGBD çıkarımı gerçekleştirilmiştir. Çalışma alanı şekil 1 içerisinde verilirken, şekil 2 içerisinde GEE platformunda yapılan işlemler gösterilmiştir.




**Şekil 1**. Çalışma alanı (altlık harita ESRI).

Şekil 1 Türkiye'nin Akdeniz bölgesinde bulunan Mersin ilini ve 15 Temmuz 2021 tarihinde Mersin/Pembecik köyünde meydana gelen orman yangınının yerini göstermektedir.

Çalışma alanı belirlendikten sonra şekil 2 içerisinde verilen işlem adımları GEE platformu kullanılarak takip edilmiştir.

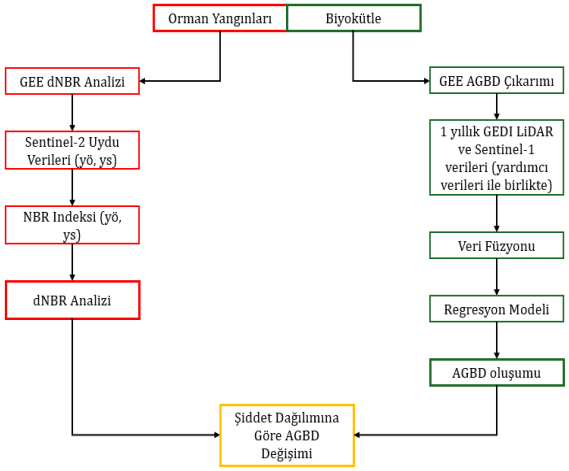


**Şekil 2.** İş akış şeması

GEE platformundan yangın öncesi ve yangın sonrasına ait iki farklı Sentinel-2 uydu görüntüsü ile yangın öncesi ve yangın sonrası NBR indeksi hesaplanmıştır. NBR ve dNBR indeksleri uydu görüntülerine uygulandıktan sonra USGS ve UN-SPIDER platformlarından eşik değerleri belirlenmiş ve elde edilen dNBR görüntüsü görselleştirilmiştir. Şekil 3 içerisinde elde edilen sonuçlar verilirken, Tablo 1 içerisinde yangın şiddet dağılımı alansal olarak verilmiştir. GEDI LiDAR ile AGBD çıkarımında, yardımcı ana veri olarak Sentinel-1 VV polarizasyonuna ait yükseklik bilgileri ve GEDI LiDAR algılayıcısının GEE (Google Earth Engine) kütüphanesinde bulunan 'agbd' dokümantasyonu kullanılmıştır. Ayrıca, NDVI (Normalized Difference Vegetation Index), MNDWI (Modified Normalized Difference Water Index), EVI (Enhanced Vegetation Index), BSI (Bare Soil Index), DEM (Digital Elevation Model), eğim ve bakı verileri gibi yardımcı verilerden faydalanılmıştır. DEM verisi, GEE kütüphanesindeki COPERNICUS DEM GLO-30 kaynağından temin edilmiştir. İlgili indekslerin hesaplamaları Sentinel-2 uydu görüntüleri kullanılarak gerçekleştirilmiştir. GEDI LiDAR'ın düşük çözünürlüğe sahip olması nedeniyle, yangın öncesi döneme ait veriler 2020-2021 yıllarını, yangın sonrası döneme ait veriler ise 2022-2023 yıllarını kapsamaktadır. Kullanılan indeksler, AGBD çıkarımı sırasında oluşabilecek hataları minimuma indirmek ve arazi bileşenlerini ayırarak model doğruluğunu artırmak amacıyla tercih edilmiştir. Tüm veriler toplandıktan sonra, Sentinel-1 SAR sensörü, Sentinel-2 sensörü ve diğer yardımcı veriler GEDI LiDAR verileriyle birleştirilmiştir.

Bu işlem sonrasında, GEDI LiDAR'ın 'agbd' düşük çözünürlüklü biyokütle verisine 1000 adet rastgele nokta atanmış ve bu noktalar üzerinden regresyon analizi yapılarak AGBD çıkarımı gerçekleştirilmiştir (Spatial Thoughts). AGBD çıkarımı tamamlandıktan sonra, dNBR

analizi ile karşılaştırılmış ve orman yangınının etkilediği bölgelerde meydana gelen biyokütle değişiminin görüntülenmesi hedeflenmiştir.

## 3. BULGULAR

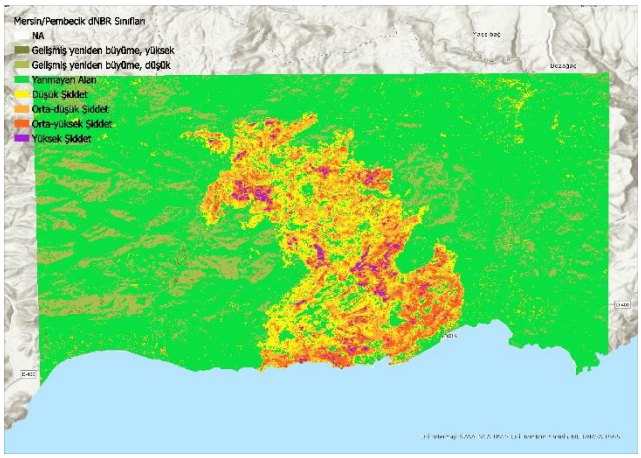


**Şekil 3**. dNBR sınıfları

**Tablo 1.** dNBR analizine bağlı olarak orman yangını şiddet dağılımları

| Mersin/Pembecik dNBR Sınıfları | Alan (km²) |
|---|---|
| Gelişmiş yeniden büyüme, yüksek | 0.8 |
| Gelişmiş yeniden büyüme, düşük | 62.2 |
| Yanmayan alanlar | 350.5 |
| Düşük şiddet | 51.1 |
| Orta-düşük şiddet | 37.8 |
| Orta-yüksek şiddet | 21.7 |
| Yüksek şiddet | 4.6 |
| **Toplam Alan** | **528.7** |

Mersin/Pembecik bölgesi için dNBR analizi tamamlandıktan sonra bölge için yangın öncesi ve yangın sonrası AGBD analizler yapılmıştır. AGBD çıkarımı yapılırken kullanılan regresyon modeli %81 doğruluk göstermiştir. Elde edilen sonuçlar Şekil 4 içerisinde verilirken, dNBR ile AGBD ilişkisi Şekil 5 içerisinde verilmiştir.

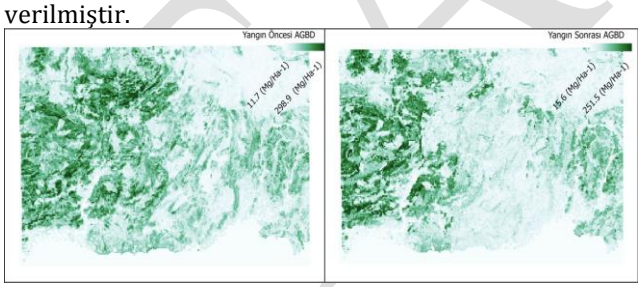


**Şekil 4**. AGBD değişimi

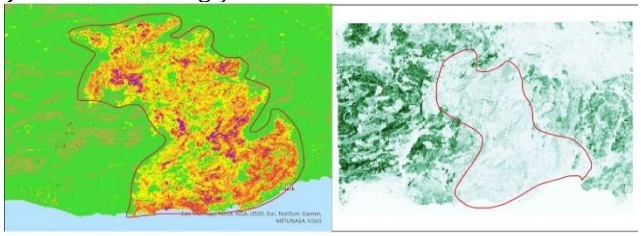

**Şekil 5.** Yangın sonrası dNBR analizine göre AGBD değişimi

Elde edilen sonuçlar doğrultusunda, Aktif algılayıcılar ile yapılan analizler ile dNBR analizi arasında tutarlı bir ilişki gözlemlenmiştir. Mersin/Pembecik köyünde meydana gelen orman yangınında yangının dağılımı ile meydana gelen biyokütle değişimi net olarak gözlemlenmektedir. Bölgede angın öncesi döneme ait yaklaşık $0.33x10^{-3}$ kg/ m² biyokütle bulunurken yangın sonrasında bu değer $0.28x10^{-3}$ kg/ m² miktarına düşmüştür. dNBR analizi sonucuna göre yaklaşık 155 km² alan yangından etkilenirken, yaklaşık %16 biyokütle kaybı gözlemlenmiştir.

## 4. TARTIŞMA

Uydu tabanlı analizlerde, saha verisine gerek duymadan orman yangınlarının analizlerinin gerçekleşebileceği gözlemlenmiştir. Aynı zamanda yoğun buluta sahip bölgelerde orman yangınlarının biyokütle çıkarımı ile ilişkilendirilip tahmini alanlarının hesaplanabileceği düşünülmektedir.

## 5. SONUÇ

Elde edilen bulgular doğrultusunda orman yangınlarında optik tabanlı ve aktif algılayıcılar ile yapılan analizler arasında tutarlı sonuçlar gözlemlenmiştir. Bu bağlamda, biyokütle çalışmalarında saha verisinin alınmasının mümkün olmadığı durumlarda yangın öncesi veya yangın sonrasında GEDI LiDAR kullanılarak bölgelerin biyokütle miktarlarının ve haritalarının güvenilir kaynaklar olduğu görülmüştür.

## TEŞEKKÜR

Bu çalışma Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) ve Bilim ve Teknolojide Avrupa iş birliği (COST) tarafından 123Y274 numaralı proje ile desteklenmiş ve finanse edilmiştir.

### Yazar Katkı Oranı

**Göktuğ Yaşar Çukurlu:** Veri Füzyonu, Biyokütle Çıkarımı, Bildiri Yazımı ve Düzenleme, Veri Çıktıları, Analizler. **Furkan Veziro:** dNBR analizleri, Bildiri Yazımı, Veri Çıktıları, Analizler. **Nusret Demir:** Denetim, Danışmanlık, Bildiri Yazımı ve Düzenleme. **Atticus Stovall:** Denetim, Danışmanlık, Bildiri Yazımı ve Düzenleme.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması yoktur.

### Araştırma ve Yayın Etiği Beyanı

Çalışmanın verileri, sonuçları ve kaynakları etik kurallar çerçevesinde elde edilmiştir.

## KAYNAKÇA

https://spatialthoughts.com/2024/02/07/agb-regression-gee

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Heyelan Duyarlılık Haritalarının Lojistik Regresyon Yöntemi ile Üretilmesi

**Derya Dilara Köse*[1], Tarık Türk[2]**

[1]*Tokat Gaziosmanpaşa Üniversitesi, Tokat Meslek Yüksekokulu, Mimarlık ve Şehir Planlama Bölümü, Tokat, Türkiye*
[2]*Sivas Cumhuriyet Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Sivas, Türkiye*

**Anahtar Kelimeler**
Coğrafi Bilgi Sistemler (CBS),
Heyelan,
Heyelan Duyarlılık Analizi,
Kullanıcı Arayüz Program,
Lojistik Regresyon (LR)

**ÖZET**

Heyelan, büyük ölçüde can ve mal kaybına neden olan doğal afetlerden birisidir. Literatürde heyelan duyarlılık analizleri ile ilgili birçok farklı yöntem ile çeşitli çalışmalar yapılmıştır. Bu çalışmada, Koyulhisar ve çevresinde Lojistik Regresyon (LR) yöntemi ile Coğrafi Bilgi Sistemi (CBS) tabanlı heyelan duyarlılık haritasının (HDH) üretilmesi, üretilen HDH'ye ait doğrulukların hesaplanması ve tüm bu işlemlerin tam otomatik olarak gerçekleştirilmesini sağlayan kullanıcı arayüz programlarının geliştirilmesi amaçlanmaktadır. HDH üretmek için eğim, bakı, yükseklik, litoloji, faya uzaklık, akarsuya uzaklık, bitki örtüsü için Normalized Difference Vegetation Index (NDVI), arazi kullanımı ve yağış parametreleri dikkate alınmıştır. Ayrıca Reciever Operator Characteristics (ROC) yöntemi ile de HDH'nin doğruluğu hesaplanarak %79.9 değeri elde edilmiştir. HDH üretim süreci genelde uzun zaman almaktadır. Bu çalışmanın literatürdeki diğer çalışmalardan en önemli farkı, LR yöntemiyle HDH'nin tam otomatik üretilmesidir. Ortaya konulan bu yöntem, dünyada herhangi bir heyelan alanında uygulanabilecek niteliğe sahiptir. Böylece heyelan duyarlılık analizini geliştirilen kullanıcı arayüz programları ile otomatik olarak gerçekleştirmek için yeni bir bakış açısı geliştirilmiştir.

# Production of Landslide Susceptibility Maps with Logistic Regression Method

**Keywords**
Geographic Information System (GIS),
Landslide,
Landslide Susceptibility Analysis,
User Interface Program,
Logistic Regression (LR)

**ABSTRACT**

Landslide is one of the natural disasters that causes a considerable loss of life and property. In the literature, various studies have been carried out with many different methods related to the landslide susceptibility analysis. In this study, it was aimed to produce Geographic Information System (GIS)-based landslide susceptibility map (LSM) by the Logistic Regression (LR) method in the Koyulhisar and its vicinity, to calculate the accuracy of the produced LSM and to perform all these operations fully-automatically. Slope, aspect, elevation, lithology, distance to fault, distance to river, Normalized Difference Vegetation Index (NDVI), land use and rainfall parameters were taken into account to produce the LSM. The accuracy of LSM was also calculated by the Reciever Operator Characteristics (ROC) method and a value of %79.9 was obtained. The LSM production process typically takes a long time. The most important difference of this study from other studies in the literature is the full-automatic production of the LSM with LR method. Consequently, this recommended method was developed in the manner that it could be applied in any landslide area in the world. Thus, a new perspective has been developed to automatically perform landslide susceptibility analysis with the developed user interface programs.

* **Sorumlu Yazar**

*(dilarakose8@gmail.com) ORCID ID 0000-0002-4014-8515
(tariktürk@gmail.com) ORCID ID 0000-0002-2671-7590

**Kaynak Göster (APA):**

Köse D D & Türk T (2025). Heyelan Duyarlılık Haritalarının Lojistik Regresyon Yöntemi ile Üretilmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Heyelan tüm dünyada olduğu gibi Türkiye'de de birçok kayba neden olan ve en çok görülen doğal afetlerden birisidir. Ülkemizde heyelan olma potansiyelinin en fazla olduğu bölgelerin başında Karadeniz bölgesi gelmektedir. Günümüz teknolojisinde heyelanlardan kaynaklanan kayıplar, heyelanlı alanların tespit edilmesi ve çevrenin buna göre planlanmasıyla azaltılabilir. Bu alanlar, heyelan duyarlılık analizleri ile Heyelan Duyarlılık Haritası (HDH) üretilmesi sonucunda belirlenebilir. Heyelan duyarlılık analizinin amacı, tehlikeli ve riskli alanların tespit edilerek heyelanın etkilerini azaltmaktır (Reis vd. 2009). Tehlike haritaları, meydana gelen doğal olayların oluşumunun tanımlanarak gelecekte bu gibi doğal olayların oluşumunun tahmin edildiği bilgileri içermektedir (Varnes, 1984). Bu gibi nedenlerden dolayı HDH'nin iyi bir şekilde üretilmesi doğal afet yönetimi açısından oldukça önemlidir.

Coğrafi Bilgi Sistemi (CBS) kullanılarak üretilen HDH için birçok farklı yöntem uygulanmaktadır. Bu süreçte iki temel adım mevcuttur. Bu adımlardan biri yöntemin seçimi diğeri ise kullanılacak parametrelerin belirlenmesidir. Literatür incelendiğinde farklı yöntemler ve parametreler kullanılarak HDH'nin üretildiği görülmektedir. Erener vd. (2017) Artvin ili Şavşat ilçesinde Lojistik Regresyon (LR), CBS tabanlı çok kriterli karar analizi ve Association Rule Mining (ARM) yöntemlerini kullanarak HDH oluşturmuştur. Colkesen vd. (2016) çekirdek tabanlı gaus proses regresyonu ve destek vektör regresyonu yöntemlerini kullanarak LR yöntemi ile karşılaştırmıştır. HDH'lerin hazırlanmasında sıklıkla kullanılan istatistiksel yöntemlerden birisi de LR yöntemidir (Nandi ve Shakoor, 2009; Bai vd. 2011). Ayrıca LR, Frekans Oranı (FR) ve Weight of Evidence (WOFE) yöntemlerinin birlikte uygulandığı çalışmalarda literatürde mevcuttur (Ozdemir ve Altural, 2013) Matematiksel olarak karmaşık olan çeşitli yöntemler uygulanırken bunlar genellikle LR yöntemiyle kıyaslanmaktadır.

HDH oluşturmak için gerekli olan ikinci adım ise parametre seçimidir. Buna ilişkin literatürde birçok çalışmaya rastlanılmaktadır (Kavzoğlu vd. 2015; Pradhan ve Lee, 2009). Yapılan bu çalışmaların kapsamı HDH üretilirken hangi parametrelerin kullanılmasının en iyi doğruluğu sağlayacağını belirlemektir. Heyelanlı alanların tespitinde kullanılması gereken faktörlerin seçimi için kesin bir görüş yoktur (Gökçeoğlu ve Ercanoğlu'na, 2001). Haritalar üretilirken çalışma alanı ve kişisel değerlendirmeye göre faktörler değişiklik göstermektedir. Buna bağlı olarak çalışma alanına göre parametreler değerlendirilip kullanılmalıdır. Ayrıca Jimenez vd. (2009), HDH ve doğruluk analizi için 4 adet parametre kullanarak CBS matris yöntemiyle ArcGIS yazılımında bir kullanıcı arayüz program geliştirmiştir. Köse ve Türk (2019), HDH ve doğruluk analizi için 9 adet parametre kullanarak ArcGIS yazılımında WOFE ve FR yöntemlerine kullanıcı arayüz programı geliştirmişlerdir.

Bu çalışma kapsamında HDH üretmek için geliştirilen kullanıcı arayüz programında özellikle literatürde yaygın olarak kullanılan yöntem dikkate alınmıştır. Matematiksel olarak karmaşık olan çeşitli yöntemler uygulanırken bunlar genellikle LR yöntemiyle kıyaslanmaktadır. Bu çalışmada ise LR yöntemiyle otomatik olarak HDH üretilmesine yönelik kullanıcı arayüz programı geliştirilerek, yapılacak olan diğer çalışmalara büyük kolaylık sağlanması hedeflenmiştir. Literatürdeki diğer çalışmalardan en önemli farkı, LR yöntemiyle toplam 9 parametre kullanılarak HDH'nin üretilmesi ve yapılan çalışmanın doğruluğunun hesaplanması işleminin CBS ortamında kullanıcı arayüz programları ile tam otomatik olarak gerçekleştirilmesidir. Üstelik, bu kullanıcı arayüz programları dünyada herhangi bir heyelan alanında uygulanabilecek nitelikte tasarlanmıştır. Çalışma alanı olarak, heyelan olaylarının en çok görüldüğü bölgelerden birisi olan Sivas ili Koyulhisar ilçesi ve çevresi seçilmiştir.

## 2. YÖNTEM

### 2.1. Çalışma Alanı

Çalışma alanı olarak Sivas'a 180 km uzaklıkta, batısında Tokat'ın Resadiye, kuzeyinde Ordu ilinin Mesudiye, doğuda Suşehri ve güneyde Zara ve Hafik ilçeleri ile çevrili, Koyulhisar ilçe ve çevresinin belli bir alanı dikkate alınmıştır.

### 2.2. LR Yöntemi ve Geliştirilen Kullanıcı Arayüz Programı ile HDH Üretimi

Heyelan duyarlılık analizinin gerçekleştirilmesinde veriler ve kullanılacak parametreler son derece önemlidir. Burada en önemli veri heyelan envanteridir. Bu çalışmada, eğim, bakı, yükseklik, litoloji, faya uzaklık, akarsuya uzaklık, Normalized Difference Vegetation Index (NDVI), arazi kullanımı ve yağış parametreleri değerlendirilmiştir.

Çoklu lojistik regresyon yöntemlerinden birisi olan LR yöntemi istatistiksel olarak heyelan duyarlılık haritalarının üretiminde kullanılan en yaygın yöntemlerden birisidir (Kleinbaum vd., 1998). LR analizi, bir olaya sebep olan olayların birden fazla olduğu anlamına gelmektedir. Heyelana sebep olan parametreler birden fazla iken heyelan meydana gelme olayı tek bir değişken olduğu için LR analizi uygulanarak HDH üretilebilir.

Çalışmada LR yöntemi için karmaşık coğrafi analiz işlemlerinin kolaylıkla gerçekleştirilmesine olanak sağlayan kullanıcı arayüz programları geliştirilmiştir (ArcGIS 10.3, Model Builder – Matlab, Gui ). Geliştirilen bu programlar dünyanın her yerinde heyelan duyarlılık analizi çalışmalarının LR yöntemiyle gerçekleştirilebilmesini sağlayabilecek niteliktedir. Bu çalışma kapsamında geliştirilen kullanıcı arayüz programı gerekli girdi verilerini göstermek suretiyle parametre haritalarının her birini otomatik olarak oluşturmaktadır. Ayrıca işlemin sonunda bölgenin HDH üretmekle beraber, arada istenilen tablo ve harita gibi çıktılarda alınabilmektedir.

Bu aşamada doğruluk analizi işlemini tam otomatik olarak gerçekleştiren kullanıcı arayüz programları geliştirilmiştir (ArcGIS 10.3 - Model Builder). Bunun yanı sıra üretilen haritaların doğruluğu Reciever Operator

Characteristics (ROC) yöntemiyle de belirlenmiştir.

## 3. BULGULAR VE TARTIŞMA

Çalışma kapsamında 9 adet parametre dikkate alınarak LR yönetiminin uygulanmasıyla, ArcGIS CBS yazılımı ve Matlab programlama dilinde kullanıcı arayüz programları geliştirilmiş ve otomatik olarak HDH'ler üretilmiştir. Parametre haritaları ile heyelan envanter haritası geliştirilen kullanıcı arayüz programıyla analiz edilerek çalışma alanının HDH'sı kısa sürede üretilmiştir.

Geliştirilen kullanıcı arayüz programları ile HDH'lerin doğrulukları test edilmektedir. Bununla beraber bu analizler dışında üretilmiş olan HDH'ler için de dinamik olarak geliştirilmiştir. Ayrıca çalışma kapsamında haritaların doğruluğunu test etmek amacıyla ROC analizi de gerçekleştirilerek üretilen HDH'nın doğruluk değeri %79.9 olarak bulunmuştur.

## 4. SONUÇ

Tüm dünyada doğal afetler yaşanmaktadır ve bunlara dikkat ederek planlama yapılması gerekmektedir.

Bu çalışmada yeni geliştirilen kullanıcı arayüz programlarının güvenilirliğini ve üretilen HDH'lerin doğruluklarını test etmek adına uygulanmıştır. Elde edilen sonuçlar literatürdeki ROC analizi değerleri ile karşılaştırıldığında başarılı sonuçlar verdiğini göstermektedir. Bu durum üretilen haritalarının yüksek doğrulukla üretildiğini ve geliştirilen kullanıcı arayüz programlarının güvenilir ve başarılı olduğunu ortaya koymaktadır. Aynı zamanda doğru ve güncel veri setleri ile çalışılması durumunda daha başarılı sonuçların elde edilmesi mümkündür.

Sonuç olarak bu çalışma, kullanılan parametreler ve gerekse uygulanan yöntem açısından heyelan duyarlılık analizine farklı bir bakış açısı getirerek, geliştirilen kullanıcı arayüz programları ile gelecekte yapılacak çalışmalara önemli katkılar sağlayacak niteliktedir.

### Yazar Katkı Oranı

**Derya Dilara Köse:** Tasarım, Fikir, Literatür Taraması, Veri Toplama ve İşleme, Analiz, Yorumlama, Makale Yazım. **Tarık Türk:** Fikir, Tasarım, Veri Toplama, Tez ve Makale Denetimi, Danışmanlık.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

### Araştırma ve Yayın Etiği Beyanı

Bu çalışma yüksek lisans tez kapsamında üretilmiştir.

### KAYNAKÇA


Bai, S.B., Lu, G.N., Wang, J.A., Zhou, P.G., ve Ding, L.A. (2011). GIS-based Rare Events Logistic Regression for Landslide-Susceptibility Mapping of Lianyungang, China, *Environmental Earth Sciences*, 62, 139-149.

Colkesen, I., Sahin, K.E., & Kavzoglu, T., Susceptibility Mapping of Shallow Landslides Using Kernel-Based Gaussian Process, Support Vector Machines and Logistic Regression, Journal of African Earth Sciences 118, 53-64, 2016.

Erener, A., Mutlu, A., & Duzgun, H.S., A Comparative study for landslide susceptibility mapping using GIS-based multi-criteria decision analysis (MCDA), logistic regression (LR) and association rule mining (ARM), Engineering Geology, 203, 45-55, 2017.

Gökçeoğlu, C., ve Ercanoğlu, M. (2001). Heyelan duyarlılık haritalarnın hazırlanmasnda kullanılan parametrelere ilişkin belirsizlikler. *Yerbilimleri*, 23, 189-206.

Nandi, A., ve Shakoor, A. (2009). A GIS-based landslide susceptibility evaluation using bivariate and multivariate statistical analyses, *Eng Geol*, 110, 11-20.

Jimenez-Peralvarez, J.D., Irigaray, C., El Hamdouni, R., ve Chacon, J. (2009). Building models for automatic landslide-susceptibility analysis, mapping and validation in ArcGIS, *Nat Hazards,* 50:571–590.

Kavzoglu, T., Şahin, E.K., Çölkesen, İ. (2015) Selecting optimal conditioning factor in shallow translational landslide susceptibility mapping using genetic algorithm. *Engineering Geology*, 192, 101-112.

Kose, D. D., & Turk, T. (2018). GIS-based fully automatic landslide susceptibility analysis by weight-of-evidence and frequency ratio methods. *Physical Geography*, *40*(5), 481–501. https://doi.org/10.1080/02723646.2018.1559583

Kleinbaum, D. G., Kupper L. L., Muller K. E., Nizam A. (1998) Applie dregression analysis and multivariable methods, 3rd Edition, *Duxbury Press*, California, 798

Özdemir, A. ve Altural, T. (2013). A comparative study of frequency ratio, weights of evidence and logistic regression methods for landslide susceptibility mapping: Sultan Mountains, SW Turkey. *Journal of Asian Earth Sciences*,64,180-192.

Pradhan, B., ve Lee, S. (2009). Delineation of landslide hazard areas on Penang Island, Malaysia, by using frequency ratio, logistic regression, and artificial neural network models, *Environ Earth Sciences*, 60:1037-1054.

Reis, S., Yalçın, A., Atasoy, M., Nişancı, R., Bayrak, T., Sancar C., & Ekercin, S, CBS ve Uzaktan Algılama Teknikleri ile Heyelan Duyarlılık Haritalarının Üretimi: Rize İli Örneği, Türkiye Ulusal Fotogrametri Ve Uzaktan Algılama Birliği V. Teknik Sempozyumu, Ankara, 2009.

Varnes, D. J. (1984). Landslide hazard zonation: A review of principles and practices commision on landslides of the IAEG, *UNESCO*, Paris.


© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Mini İHA'lar ile Görüntü İşleme ve Harita Üretimi

**Abdulsamet Aktaş*[1], Samet Küçükbıçakcı[1]**
[1]*Milli Savunma Bakanlığı, Harita Genel Müdürlüğü, Ankara, Türkiye*

**Anahtar Kelimeler**
Mini İHA,
Fotogrametri,
Ortogörüntü,
Görüntü İşleme

**ÖZET**

Mini insansız hava araçları (İHA'lar), tarım, şehir planlaması, afet yönetimi ve ormancılık gibi birçok alanda hızlı ve düşük maliyetli haritalama çözümleri sunmaktadır. Bu İHA'lar, yüksek çözünürlüklü hava görüntüleri çekerek coğrafi bilgi sistemleri (CBS) için önemli bir veri kaynağı oluşturur. Görüntü işleme süreci, veri toplama ile başlar ve çekilen görüntülerin ön işleme aşamasında distorsiyon düzeltilmesi, renk dengesi ayarlanması ve gürültü azaltılması gibi işlemler gerçekleştirilir. Daha sonra, görüntüler arazi yükseklik verileri kullanılarak coğrafi olarak düzeltilir ve birleştirilerek geniş alanları kapsayan haritalar oluşturulur. Bu süreçte sayısal yükseklik modelleri ve üç boyutlu arazi modelleri üretilerek detaylı analizler yapılır.

# Image Processing and Map Production with Mini UAVs

**Keywords**
Mini UAV,
Photogrammetry,
Orthophoto,
Image Processing

**ABSTRACT**

Unmanned aerial vehicles (UAVs) provide fast and cost-effective mapping solutions in various fields such as agriculture, urban planning, disaster management, and forestry. These UAVs capture high-resolution aerial images, serving as a valuable data source for geographic information systems (GIS). The image processing workflow begins with data collection, followed by preprocessing steps such as distortion correction, color balance adjustment, and noise reduction. Then, the images are georeferenced using terrain elevation data and merged to create maps covering large areas. In this process, digital elevation models (DEMs) and three-dimensional terrain models
are generated for detailed analysis.

## 1. GİRİŞ

Mini insansız hava araçları (İHA'lar), tarım, şehir planlaması, afet yönetimi ve ormancılık gibi birçok alanda hızlı ve düşük maliyetli haritalama çözümleri sunmaktadır. Bu İHA'lar, yüksek çözünürlüklü hava görüntüleri çekerek coğrafi bilgi sistemleri (CBS) için önemli bir veri kaynağı oluşturur.

Görüntü işleme süreci, veri toplama ile başlar ve çekilen görüntülerin ön işleme aşamasında distorsiyon düzeltilmesi, renk dengesi ayarlanması ve gürültü azaltılması gibi işlemler gerçekleştirilir. Daha sonra, görüntüler arazi yükseklik verileri kullanılarak coğrafi olarak düzeltilir ve birleştirilerek geniş alanları kapsayan haritalar oluşturulur. Bu süreçte sayısal yükseklik modelleri ve üç boyutlu arazi modelleri üretilerek detaylı analizler yapılır.

Görüntü işleme yazılımları arasında Pix4D, Agisoft Metashape ve DroneDeploy gibi fotogrametri ve 3D modelleme yazılımları öne çıkarken, ArcGIS Drone2Map ve QGIS gibi CBS yazılımları da haritalama süreçlerinde yaygın olarak kullanılmaktadır. OpenDroneMap ve Global Mapper görüntü ön işleme ve analiz için tercih edilirken, ENVI ve TensorFlow gibi yapay zeka destekli yazılımlar da gelişmiş veri analizi sağlar.

* **Sorumlu Yazar**
*(abdulsamet.aktas@harita.gov.tr) ORCID ID
(samet.kucukbicakci@@harita.gov.tr) ORCID ID

**Kaynak Göster (APA):**
Aktaş A & Küçükbıçakcı S (2025). Mini İHA'lar ile Görüntü İşleme ve Harita Üretimi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

TASLAK

## 2. YÖNTEM

Pix4D ve Agisoft Metashape, Mini İHA görüntülerini işleyerek yüksek doğruluklu haritalar ve 3D modeller üretmek için yaygın olarak kullanılan yazılımlardır.

### 2.1. Üretim Gerçekleştirme Aşamaları

- Görüntülerin İçeri Aktarılması: Mini İHA tarafından çekilen fotoğraflar yazılıma yüklenir ve GPS(PPK/RTK) verileriyle eşleştirilir. Bu eşleştirme aşaması çok önemlidir. Eşleştirme hassas bir şekilde yapılmadığı takdirde sonuç üründe hatalar meydana gelmektedir.
- Ön İşleme ve Görüntü Düzenleme: Lens distorsiyonu düzeltilir, renk dengesi ayarlanır ve gürültü azaltma işlemleri uygulanır. Bu işlem aşaması kullanılan kameraya bağlı parametrelerden oluşmaktadır. Kamera ayarları doğru girilmez ve dönüklük değer hataları gidelürilmezse üretim de kayıklıklar ve netlik sorunları oluşmaktadır.
- Nokta Bulutu Oluşturma: Yazılım, fotoğraflar arasındaki ortak noktaları belirleyerek yoğun bir nokta bulutu oluşturur. Aynı nokta bulutu LİDAR sistemleri ile de üretilmektedir. LİDAR ile üretimler için çalışmalar devam etmektedir.
- Ortofoto ve Sayısal Yükseklik Modeli (DEM) Üretimi: Görüntüler düzeltilerek coğrafi olarak hizalanmış ortofotolar ve sayısal yükseklik modelleri oluşturulur.
- 3D Modelleme: Nokta bulutundan yüzey modeli oluşturularak detaylı üç boyutlu haritalar ve modeller elde edilir. Burada sayısal yükseklik modeli veya sayısal arazi modeli üretimi, bazı yerli ve milli yazılımlara kaynak veri oluşturmaktadır. 3 boyutlu bir veri bulutu içerisinde yine 3 boyutlu analizler ve ölçümlerin yapıldığı sanal CBS uygulamalarında hassas bir şekilde kullanılmaktadır.

- Son İşlem ve Çıktı Üretimi: Kullanıcı ihtiyacına göre çıktı formatları belirlenerek, harita, model veya analiz sonuçları dışa aktarılır. Sonuç ürün olarak üretimi sağlanan yüksek çözünürlüklü ortogörüntüler, daha sonra çeşitli haritacılık ve CBS uygulamalarında altlık veri olarak kullanılmaktadır.

## 3. BULGULAR

Bu yazılımların bazı farkları bulunmaktadır. Bu farklara bağlı kalarak hem ham veriye müdahale konusunda hem de sonuç üretimlerin çıktı olarak alınmasında Agisoft Metashape yazılım daha basit ve kullanışlı bir platform olarak belirlenmiştir.

Mini İHA fotogrametrisi olarak değişen araç tiplerine, uçuş irtifasına, çözünürlüğe, kamera sistemlerine göre üretimlerin de hassasiyetleri değişmekte olup, üretimi yapılan bölgede bulunan YKN (yer kontrol noktaları)' lerin tesis edilmesi esnasında bu YKN noktalarının koordinatlarının en hassas şekilde toplanması ve üretim esnasında veri olarak girilmesi çok kritik bir aşamadır. Bu aşamada yapılan kayıklık veya yanlış koordinat hataları, bu noktaların üretim üzerinde görüntü üzerine bindirme konuları üretimler arası bindirme ve kenarlaşma esnasında sorunlar yaşatarak üretilen ortogörüntülerin tekrardan process işlemine tabi tutulmasına neden olarak zaman ve maliyet açısından kayıplara neden olmaktadır.

## 4. TARTIŞMA

Türkiye'de özellikle açık kaynaklı ve yerli yazılımlar daha fazla tercih edilmektedir. QGIS, NetCAD ve yerli CBS çözümleri, kamu kurumları ve özel sektör tarafından yaygın olarak kullanılmaktadır. Özellikle savunma ve haritalama projelerinde yerli yazılımlar ön plana çıkmaktadır.

Dünyada ise Pix4D, Agisoft Metashape ve ArcGIS gibi ticari yazılımlar daha fazla kullanılırken, özellikle büyük ölçekli haritalama projelerinde yüksek hassasiyet sunan özel çözümler tercih edilmektedir. Türkiye'de maliyet odaklı çözümler ön planda olurken, dünya genelinde gelişmiş yapay zeka destekli yazılımlar daha fazla entegre edilmektedir.

Pix4D, kullanıcı dostu arayüzü ve bulut tabanlı işlem yetenekleriyle dikkat çekerken, Agisoft Metashape daha ayrıntılı 3D modelleme ve nokta bulutu analizi sunmaktadır. Her iki yazılım da farklı sektörlerde geniş bir kullanım alanına sahiptir.

## 5. SONUÇ

Mini İHA'larla elde edilen görüntüler, gelişmiş yazılımlar sayesinde işlenerek yüksek doğrulukta haritalar ve 3D modeller oluşturulmaktadır. Türkiye ve dünya genelinde kullanılan yazılımlar arasındaki farklar, maliyet, kullanım alanı ve hassasiyet seviyelerine bağlı olarak değişmektedir. Kullanılan Mini İHA ile görüntü işleme yazılımları genellikle yabancı kaynaklı yazılımlardır.

Ülkemizde mini İHA üretimi yapan mühendislik firmalarının sayısı gün geçtikçe artmaktadır. Ancak bu görüntülerin işlenerek ortogörüntü üretimlerinin elde edilmesi için kullanılan yazılımlar arasında yerli bir ürün bulunmamaktadır. Bu konuda bir görüntü işleme yazılımı geliştirilerek hassas bir biçimde dış ülke yazılımlarına bağlı kalmadan üretim yapabileceğimiz konusu ciddi olarak düşünülmektedir.

Gelişen teknoloji ile birlikte bu sistemlerin daha yaygınlaşması sağlanmalıdır.

**TEŞEKKÜR**

Bizlere bilim yolunda verdiği öğütleri ile tuttuğu ışığın doğrultunda yürüdüğümüz yolun aydınlığını fark etmeyi öğreten Ulu Önder Gazi Mustafa Kemal ATATÜRK ve onun kahraman silah arkadaşlarına ve Sevgili eşim Öğretim Görevlisi Rumeysa Nur KARA AKTAŞ' a teşekkürü borç bilirim.

**KAYNAKÇA**

Ayyıldız, E., Özmüş, L., Açar, F., Tuna, H., Özer, E. ve Erkek, B., et al. (2015, Mayıs 21-23). İnsansız hava aracı ve uçak platformlarından elde edilen görüntülerin ortofoto üretiminde karşılaştırılması. TUFUAB VIII. Teknik Sempozyumu. Konya.

Döner, F., Özdemir, S. ve Ceylan, M., İnsansız Hava Aracı Sistemlerinin Veri Toplama Ve Haritalama Çalışmalarında Kullanımı., 2014. 5. Uzaktan Algılama-Cbs Sempozyumu (UZAL-CBS 2014), 14-17 Ekim 2014, İstanbul.

ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 3822, 57.

Karkinli, A. E., Kesikoğlu, M. H., Atasever, Ü. H. ve Erkan,

B. (2015, Temmuz 2). İnsansız Hava Araçları Ile Sayısal Arazi Modeli Üretimi.

Kılınçoğlu, D. B., 2016. Farklı insansız hava araçları ile elde edilen görüntülerin otomatik fotogrametrik yöntemlerle değerlendirilmesi ve doğruluk analizi, Yüksek Lisans Tezi, İTÜ, Fen Bilimleri Enstitüsü, İstanbul.

M. Akgül, H. Yurtseven, M. Demir, A. E. Akay, S. Gülci, T. Öztürk(2019). "İnsansız Hava Araçları ile Yüksek Hassasiyette Sayısal Yükseklik Modeli Üretimi ve Ormancılıkta Kullanım Olanakları"

Maza, I., Caballero, F., Capitán, J., Martínez-de-Dios, J. R. ve Ollero, A., 2011. Experimental results in multi-UAV coordination for disaster management and civil security applications, Journal of intelligent & robotic systems, 61(1-4), 563-585.

Manyoky, M., Theiler, P., Steudler, D. ve Eisenbeiss, H., 2011. Unmanned aerial vehicle in cadastral applications,

Öztürk, O., Bilgilioğlu, B., Çelik, M. F., Bilgilioğlu, S. ve Uluğ, R. İnsansız Hava Aracı Görüntüleri ile Ortofoto Üretiminde Yükseklik ve Kamera Açısının Doğruluğa Etkisinin Araştırılması.

Savaş, T., Karaderili, M. ve Usanmaz, Ö,. 2018. İnsansız Hava Aracı Sistemlerinin Ayrılmamış Hava Sahasına Entegrasyonu ile İlgili Mevzuatların Değerlendirilmesi. Mühendis ve Makina Dergisi, 59(691), 1-14.

Xiang, H., Tian, L., 2011. Development of a low-cost agricultural remote sensing system based on an autonomous unmanned aerial vehicle (UAV). Biosystems Engineering 108: 174-190.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Orman Yangınlarının Çok Ajanlı Sistemler ile Simüle Edilmesi

**Hayati Bilgin*[1], İsmail Ercüment Ayazlı[2], Göktuğ Yaşar Çukurlu[3], Nusret Demir[4]**

[1]*Sivas Cumhuriyet Üniversitesi, Fen Bilimleri Enstitüsü, Geomatik Mühendisliği, Sivas, Türkiye*
[2]*Sivas Cumhuriyet Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği, Sivas, Türkiye*
[3]*Akdeniz Üniversitesi, Fen Bilimleri Enstitüsü, Uzay Bilimleri Teknolojileri, Antalya, Türkiye*
[4]*Akdeniz Üniversitesi, Fen Fakültesi, Uzay Bilimleri Teknolojileri, Antalya, Türkiye*

**Anahtar Kelimeler**
Orman Yangını Modelleme,
Yangın Simülasyonu,
Çok Ajanlı Sitemler,
Uzaktan Algılama

**ÖZET**

Orman yangınları, orman ekosistemine ve yerleşim alanlarına ciddi zararlar veren, çevresel ve ekonomik etkileri büyük olan doğal afetlerdir. Yangınlara erken ve etkili müdahale etmek, yangın sırasında uygun stratejiler geliştirmek ve yangın sonrası etkileri değerlendirmek için yangın yayılımının modellenmesi ve yangın ile ilgili zamansal bilgileri elde etmek büyük önem taşımaktadır. Bu çalışmada, orman yangınlarının yayılımı, Arazi Yüzey Sıcaklığı (LST), Normalize Edilmiş Fark Bitki İndeksi (NDVI), Dijital Yüzey Modeli (DSM) ve Normalize Edilmiş Fark Yanma Oranı (dNBR) gibi uzaktan algılama tabanlı veriler ile rüzgâr hızı kullanılarak, çok ajanlı sistemler ile simüle edilmesi amaçlanmaktadır. Modelde, rüzgâr hızının ve yönünün zamana bağlı olarak değişkenliğinin yangın yayılımına etkisi ile arazi eğiminin yangın yayılımına etkisi kapsamlı bir şekilde değerlendirilmiştir. Ayrıca modelde sağlıklı bitki yoğunluğu ile toprak neminin yangın yayılım dinamiklerine etkisi incelenmiştir. Elde edilen sonuçlar, çok ajanlı sistemler tabanlı simülasyonların, yangın yayılım dinamiklerini anlamadaki potansiyelini ve yangına müdahale stratejilerini geliştirmede etkin bir yöntem olduğunu ortaya koymaktadır.

# Simulation of Forest Fires Using Multi-Agent Systems

**Keywords**
Forest Fire Modeling,
Fire Simulation,
Multi-Agent Systems,
Remote Sensing

**ABSTRACT**

Forest fires are natural disasters that cause severe damage to forest ecosystems and settlement areas, with significant environmental and economic impacts. Modeling fire spread and obtaining temporal information related to fires are of great importance for early and effective intervention, developing appropriate strategies during fires, and evaluating post-fire effects. In this study, the spread of forest fires is aimed to be simulated using multi-agent systems with remote sensing-based data such as Land Surface Temperature (LST), Normalized Difference Vegetation Index (NDVI), Digital Surface Model (DSM), and Normalized Burn Ratio (dNBR), as well as wind speed. In the model, the effect of time-dependent variability of wind speed and direction on fire spread, and the effect of terrain slope on fire spread are comprehensively evaluated. Additionally, the impact of healthy vegetation density and soil moisture on fire spread dynamics are examined in the model. The results obtained reveal that multi-agent systems-based simulations are an effective method in understanding fire spread dynamics and developing fire intervention strategies.

## 1. GİRİŞ

* **Sorumlu Yazar**

*(hayatibilgin58@gmail.com) ORCID ID 0009-0004-7782-3707
(eayazli@cumhuriyet.edu.trl) ORCID ID 0000-0003-0782-5366
(goktugcukurlu0@gmail.com) ORCID ID 0009-0008-9233-7626
(nusretdemir@akdeniz.edu.tr) ORCID ID 0000-0002-8756-7127

**Kaynak Göster (APA):**

Bilgin H, Ayazlı İ E, Çukurlu G Y & Demir N (2025). Orman Yangınlarının Çok Ajanlı Sistemler ile Simüle Edilmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

TASAK

Orman yangınları, orman ekosistemlerine ve yerleşim alanlarına ciddi zararlar verir, çevresel ve ekonomik etkiler yaratır. Bu afetlerin etkili bir şekilde yönetilebilmesi için yangın yayılımının doğru modellenmesi büyük önem taşır. Erken müdahale, etkili stratejiler geliştirme ve yangın sonrası değerlendirme için bu modeller kullanılır. Orman yangınlarının yayılımı, çevresel faktörlerle etkileşen karmaşık bir süreçtir. Çok ajanlı sistemler (MAS), yangının dinamiklerini gerçekçi bir şekilde simüle etmek için etkili bir yöntemdir. MAS, bireysel ajanların çevreyle etkileşimlerini dikkate alarak yangınların yayılmasını modellemeye olanak tanır.

Bu çalışmada, LST (Arazi Yüzey Sıcaklığı), Normalize Edilmiş Fark Bitki İndeksi (NDVI), Dijital Yüzey Modeli (DSM) ve Normalize Edilmiş Fark Yanma Oranı (dNBR) gibi uzaktan algılama verileri kullanılarak Python ortamında çok ajanlı sistemlerle orman yangınları simüle edilmiştir. Ayrıca rüzgâr, eğim ve toprak nemi gibi çevresel faktörlerin yangın üzerindeki etkisi de göz önünde bulundurulmuştur. Bu araştırma, orman yangınlarının yayılımını anlamak ve müdahale stratejilerini geliştirmek amacıyla çok ajanlı sistemlerin etkinliğini incelemektedir.

## 2. YÖNTEM

Bu çalışmada, orman yangınının yayılmasını modellemek amacıyla çok ajanlı sistemler kullanılmıştır. Simülasyon modeli, Landsat-8, Sentinel-2 ve ALOS uydularından elde edilen LST, NDVI, DSM, dNBR ve rüzgâr verileri kullanılarak oluşturulmuştur.

### 2.1. Çok Ajanlı Sistemler ile Modelleme

MAS, bireysel ajanların çevreleriyle etkileşim içinde olan ve zaman içinde birbirlerinin davranışlarını etkileyebilen bir modelleme yaklaşımıdır. Bu yöntem, karmaşık dinamik sistemlerin simülasyonunda yaygın olarak kullanılmaktadır, özellikle yangın gibi hızla yayılan ve çevresel etmenlere duyarlı sistemlerde oldukça etkilidir.

### 2.2. Ajanların Hareketleri ve Yapısı

Grid temel üzerinde oluşturulmuş her ajan bir yangın noktasını temsil eder ve çevresel faktörlere göre davranışlarını değiştirir. Her bir ajan, yangının yayılma hızını ve yönünü etkileyen parametrelerle tanımlanır. Burada parametreler olarak şunlar değerlendirilir:

- **Eğim Etkisi:** DSM verisi kullanılarak, her ajan için yangının yayılma hızı eğimle ilişkilendirilir. Eğim, yangının hızını ve yönünü etkileyen bir faktör olarak modellenir.
- **Toprak Nemi:** Ajanların yangına karşı direncini etkileyen bir başka önemli faktördür. Toprak nemi, yangının ilerleme hızını yavaşlatabilir veya hızlandırır.
- **Rüzgâr Hızı ve Yönü:** Ajanlar, rüzgârın yönüne ve hızına göre hareket eder. Ajanlar, her adımda çevresel rüzgâr bilgilerine göre yangının ilerlemesini simüle eder.
-

MAS temelli simülasyon modeli Python programlama dili kullanılarak oluşturulmuştur. Ajan tabanlı simülasyonlar, ajanların çevresel faktörlerle etkileşimde bulunmasını ve simülasyonun görselleştirilmesini sağlar. Her bir ajan, çevresindeki koşullara göre yangın noktalarını simüle eder ve yangının ilerleyişini belirler. Ajanların hareketi, çevresel verilerin (rüzgâr, toprak nemi, eğim gibi) sürekli olarak güncellenmesiyle şekillenir. Ajanlar arasındaki etkileşimler, yangının dinamik ve doğrusal olmayan doğasını modelleyerek hız ve yön üzerindeki etkileşimleri simüle eder. Örneğin, rüzgâr yönü yangının yayılma hızını etkilerken, bitki örtüsünün yoğunluğu yangının büyüklüğünü etkileyebilir. Simülasyonun doğruluğu, kullanılan çevresel verilerin kalitesine bağlıdır. Bu çalışmada LST, NDVI, DSM, dNBR ve rüzgâr hızı gibi veriler, modelin temel parametrelerini oluşturur. LST, yangının hangi alanlarda daha hızlı yayılacağını, NDVI ise bitki örtüsünün yoğunluğunu ve sağlığını göstererek yangının hızını etkiler. DSM, yer yüzeyinin eğimini ve yüksekliğini göz önünde bulundururken, dNBR yangın sonrası hasar değerlendirmelerini yaparak yangının etkilerini modelde dikkate alır. Simülasyon, belirli bir başlangıç koşuluyla başlar ve ajanlar, çevresel etmenler ve etkileşimler doğrultusunda yangının yayılmasını adım adım simüle eder.

## 3. BULGULAR

Simülasyon sonuçları, yangının yayılma hızını ve yönünü belirlemede çevresel faktörlerin önemli bir rol oynadığını ortaya koymuştur. LST verisi, yangının sıcaklıkla ilişkisini vurgulayarak, sıcaklık artışıyla birlikte yangının daha hızlı yayıldığını göstermektedir. Ayrıca, NDVI verisi, bitki örtüsünün yoğunluğunun yangın yayılımı üzerindeki etkisini göstermiş, düşük bitki örtüsüne sahip alanların yangın için daha elverişli olduğunu ortaya koymuştur. DSM kullanılarak yapılan analiz, eğimin yangının hızını etkileyen önemli bir parametre olduğunu, dik eğimli bölgelerde yangının daha hızlı yayıldığını ortaya koymuştur. Ayrıca Şekil 1'de de görüleceği üzere rüzgâr hızının da yangın yayılımı üzerinde ciddi bir etkisi olduğu görülmüştür. Yangın sonrası hasar değerlendirmesi için kullanılan dNBR verileri, yangının etkilediği alanların doğruluğunu kontrol etmek için etkin bir şekilde kullanılmış ve simülasyonun doğruluğunu artırmıştır. Bu bulgular, yangın dinamiklerini daha iyi anlamak ve yangına müdahale stratejileri geliştirmek için çevresel verilerin ve simülasyon tekniklerinin entegrasyonunun önemini vurgulamaktadır.

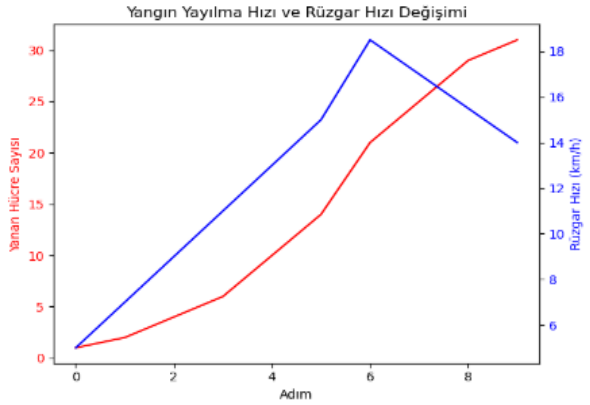


**Şekil 1.** Rüzgâr hız değişimine bağlı yangın hızı.

## 4. SONUÇ

Bu çalışmada, orman yangınlarının yayılımının simülasyonu için çevresel verilerin entegrasyonu başarılı bir şekilde gerçekleştirilmiştir. Bu simülasyon, yangının hücreler arasında yayılımını adımlar halinde gözler önüne sermiştir. Elde edilen sonuçlar, çevresel faktörlerin yangının yayılımındaki etkisini ortaya koymuş ve bu tür modellemelerin yangın müdahale stratejilerinin geliştirilmesinde önemli bir araç olabileceğini göstermiştir.

### Yazar Katkı Oranı

Yazarlar arasındaki iş birliği, çalışmaların eşit bir şekilde paylaşılmasını ve her aşamada katkıda bulunulmasını sağlamıştır. Yazar 1, çalışmanın genel tasarımını ve modelleme sürecini üstlenmiş, Yazar 2, veri toplama ve analizi süreçlerine yoğunlaşmış, Yazar 3 ise görselleştirme ve sonuçların yorumlanmasında, Yazar 4 ise yazılımın geliştirilmesi ve iyileştirilmesi süreçlerinde önemli rol oynamıştır. Bu eşzamanlı katkılar, çalışmanın başarıyla tamamlanmasını ve tüm aşamalarda etkili bir ilerleme sağlanmasını mümkün kılmıştır.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

### Araştırma ve Yayın Etiği Beyanı

Bu çalışma, etik kurallar ve yönergeler doğrultusunda gerçekleştirilmiş olup, herhangi bir çıkar çatışması bulunmamaktadır. Veriler doğru ve şeffaf şekilde kullanılmıştır.

### KAYNAKÇA

Burkhardt, J. R., Haines, S. A., & Coen, J. L. (2019). A dynamic multi-agent simulation of wildfire spread. *Journal of Environmental Management*, 243, 93-103.

Katan, J. ve Perez, L. (2021). ABWiSE v1.0: Orman yangını yayılımını simüle etmek için ajan tabanlı bir yaklaşıma doğru. *Nat. Hazards Earth Syst. Sci., 21*, 3141–3160. https://doi.org/10.5194/nhess-21-3141-2021

Ranta, K., Lauenroth, W. K., & Sisk, T. D. (2020). Modeling fire spread in complex ecosystems using multi-agent systems. *Ecological Modelling*, 421, 108-115.. Advances in Space Research.

Sumer, Y. F. (2025). *Orman yangınlarının makine öğrenmesi ve uzaktan algılama yöntemleri kullanılarak tahmin edilmesi ve duyarlılık haritasının oluşturulması* (Yayımlanmamış yüksek lisans tezi). Batman Üniversitesi Lisansüstü Eğitim Enstitüsü. Erişim adresi: [https://earsiv.batman.edu.tr/items/6bbb3212-dfbd-4872-824e-ed9c35d2c1f0].

Yıldırım, O., Günay, F. B., & Yağanoğlu, M. (2023). Makine öğrenmesi yöntemleriyle orman yangını tahmini. *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 13*(3), 1468-1481.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

**TUFUAB XIII. TEKNİK SEMPOZYUMU**
https://tufuab2025.beun.edu.tr

# Eskişehir İlinde Deprem Riski Altında Bulunan Kritik Altyapıların Değerlendirilmesi

**Ahsen Çakı*[1], Mehtap Özenen Kavlak[2], Alper Çabuk[3]**

*[1] Eskişehir Teknik Üniversitesi, Yer ve Uzay Bilimleri Enstitüsü, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Ana Bilim Dalı Eskişehir, Türkiye*
*[2] İstanbul Üniversitesi, Açık ve Uzaktan Eğitim Fakültesi, Coğrafya Bölümü*
*[3] Eskişehir Teknik Üniversitesi, Yer ve Uzay Bilimleri Enstitüsü, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Ana Bilim Dalı Eskişehir, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Afet Yönetimi,
Coğrafi Bilgi Sistemleri,
Kritik Altyapı
Zemin Büyütme

**ÖZET**

Bu çalışma, Eskişehir ilinde kritik altyapı tesislerinin deprem riskiyle ilişkisini belirlemek amacıyla gerçekleştirilmiştir. Kritik altyapı tesisleri içerisinde ulaşım ağları, su ve atık su sistemleri, sağlık kuruluşları altında, hastaneler, acil servisler, aile sağlığı merkezleri, dispanser ve ağız ve diş sağlığı merkezleri, enerji altyapısı, telekomünikasyon, önemli alanlar içerisinde acil toplanma alanları, spor tesisleri, tarihi ve turistik alanlar, devlet kuruluşları içerisinde, kaymakamlık, valilik, itfaiye, postaneler, polis merkezleri gibi tüm kritik altyapı elemanları kapsam içerisine alınarak detaylı bir şekilde deprem afeti ile ilişkisi haritalanarak incelenmiştir. Çalışmada, zemin büyütme katsayısı ve deprem ivme değerleri hesaplanarak, farklı zemin türlerinin deprem dalgalarına nasıl tepki verdiği analiz edilmiştir. Ayrıca, kritik altyapı tesislerinin konumları, diri fay hatları, jeoloji haritaları ve sosyo-ekonomik verilerle birlikte değerlendirilmiştir. Sosyo-ekonomik veriler ile çalışmada elde edilen verilerin vatandaşlar üzerindeki etkileri ile daha da detaylandırılmış olup bu sayede çalışmada yalnızca fay hatlarına mesafeye bağlı olarak tehlike haritası oluşturulmamış, zemin büyütme katsayısı ve deprem ivme değerleri ile deprem tehlikesinin neden olacağı hasarlara perspektif genişletilerek bakılmıştır. Elde edilen sonuçlar neticesinde afet yönetim basamaklarından afet öncesi önlem alma stratejileri geliştirilmiştir.

# Evaluation of Critical Infrastructures under Earthquake Risk in the Province of Eskişehir

**Keywords**
Remote sensing,
Disaster Management,
Geographic Information Systems,
Critical Infrastructure
Floor Magnification

**ABSTRACT**

This study was carried out to determine the relationship between critical infrastructure facilities and earthquake risk in Eskişehir province. All critical infrastructure elements such as transportation networks, water and wastewater systems, hospitals, emergency services, family health centers, dispensaries and oral and dental health centers, energy infrastructure, telecommunications, emergency gathering areas, sports facilities, historical and touristic areas, government institutions, district governorships, governorships, fire departments, post offices, police stations, etc. are included in the scope of critical infrastructure facilities and their relationship with earthquake disaster is mapped and examined in detail. In the study, soil magnification coefficient and earthquake acceleration values were calculated and analyzed how different soil types respond to earthquake waves. In addition, the locations of critical infrastructure facilities were evaluated together with the locations of live fault lines, geological maps and socio-economic data. Socio-economic data and the effects of the data obtained in the study on the citizens have been further elaborated with the effects of the data obtained in the study on the citizens, so that the hazard map has been created not only depending on the distance to the fault lines, but also the damage caused by the earthquake hazard has been looked at by expanding the perspective with the soil magnification coefficient and earthquake acceleration values. As a result of the results obtained, pre-disaster prevention strategies from disaster management steps have been developed.

* **Sorumlu Yazar**

*(caki_adenn@outlook.com) ORCID ID 0009-0001-5685-8108
(mehtapozenen@eskisehir.edu.tr) ORCID ID 0000-0002-5369-4494
(acabuk@eskisehir.edu.tr) ORCID ID 0000-0001-8917-6499

**Kaynak Göster (APA):**

Çakı A, Özenen Kavlak M & Çabuk A (2025). Eskişehir İlinde Deprem Riski Altında Bulunan Kritik Altyapıların Değerlendirilmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Geçmişten günümüze hızla artan dünya nüfusu ile şehirlerde çarpık kentleşme, trafik yoğunluğu, karmaşık ve yoğun yapılar, altyapı varlıklarının güvenlik sorunu, afetlere karşı daha az dirençlilik gibi sorunlar ön plana çıkmaktadır. Tüm bu olumsuzluklar karşısında, yaşanılan afetler kritik altyapı hizmetlerinde kesintilere neden olmaktadır (Amini et al., 2024). Kritik altyapı hizmetlerinde herhangi bir kesinti, sadece hizmet verdiği alanla sınırlı kalmayıp çok daha geniş kitleleri mağdur edebilmektedir (Amini et al., 2024). Özellikle jeolojik afetlerden olan deprem sonucunda şehrin kritik altyapıları zarar görmekte ve bu nedenle kesintiler yaşanarak toplumsal ve ekonomik kayıplara neden olmaktadır (Amini et al., 2024). Sık sık deprem afeti ile sarsılan Türkiye, Alp–Himalaya deprem kuşağında yer almakta olup, Avrasya, Arabistan ve Afrika kıtalarının sıkıştırması sonucu Tetis Denizi'nden ayrılarak yükselime geçmiştir (Ketin, 1966). Bu sırada Anadolu ve Toroslar şiddetli deformasyonlara uğrayarak Anadolu'nun sıradağları, Pontidler, Anatolidler, Toroslar ve Kenar kıvrımlar ile tektonik üniteler oluşmaya başlamıştır (Ketin, 1966, 1977). Bu oluşum süreçleri nedeniyle Türkiye aktif bir deprem ülkesi olma özelliğine sahiptir (Avdan & Alkış, 2010). Türkiye'nin şekillenmesinde üç aktif fay sistemi karşımıza çıkmaktadır (Kartal et al., 2015). Aktif faylara sahip olan Türkiye son yirmi beş yılda; İzmit (1999 M = 7,6), Düzce (1999 M = 7,2), Van (2011 M= 7,1), Elâzığ (2020 M =6,8), İzmir (2020 M = 7,0) gibi can ve mal kaybına neden olan deprem afetini yaşamıştır (Görüm et al., 2023). Eskişehir, Türkiye'nin aktif bir fay kuşağı olan KAFZ yakın bir hatta bulunan Eskişehir Fay Zonu (EFZ) üzerinde tektonik kökenli bir ova tabanı olarak karşımıza çıkmaktadır (Koca & Menteşe, 2020; Ocakoğlu, 2007). 17 Ağustos 1999 tarihinde merkezi Kocaeli olup aletsel büyüklüğü M= 7,4 olarak kayıtlara geçen depremde, deprem merkezine olan uzaklığa rağmen Eskişehir kent merkezinde can ve mal kayıpları yaşanmıştır (Avdan & Alkış, 2010; Tün et al., 2015). Bunun sebepleri arasında yerel zemin etkisi bulunmaktadır (Tün et al., 2015).

Bu nedenle bu çalışmanın hedefleri arasında, afetler karşısında günümüz gelişmiş teknolojilerinden Coğrafi Bilgi Sistemlerinden (CBS) yararlanarak can ve mal kayıplarını en aza indirmek, ulusal güvenliği korumak, enerji, ulaşım, su temini gibi kritik alt yapı hizmetlerinin aksamasını önlemek amacıyla kritik altyapı elemanlarının lokasyonlarını belirleyerek CBS aracılığıyla analizler elde edip afet öncesi önlem alma basamağına ilişkin stratejiler geliştirilmektir.

## 2. YÖNTEM

Bu çalışmada, Eskişehir ilindeki zemin büyütme katsayısının hesaplanması, deprem ivme değerlerinin belirlenmesi ve bu parametrelerin kritik altyapı tesisleriyle ilişkilendirilmesi amaçlanmaktadır. Bu kapsamda, çeşitli veri kaynaklarından elde edilen mekânsal ve jeolojik bilgiler CBS ortamında analiz edilerek değerlendirilmiştir.

Çalışmada öncelikle Tandem-X uydusundan elde edilen 30 metre çözünürlüklü Sayısal Yükseklik Modeli (DEM) verisi kullanılarak eğim ve yükselti haritaları türetilmiştir. Bunun yanı sıra, Şekil 1'de gösterilen Porsuk Nehri ve kolları, diri fay hatları, yerleşim alanları, Şekil 2'de gösterilen jeoloji haritaları ve Eskişehir il sınırları ile ilçelere ait idari sınır verileri CBS ortamına entegre edilmiştir. AFAD resmi sitesinde "Deprem kataloğu" bölümünden elde dilen Eskişehir iline ait geçmiş deprem kayıtları ve yine AFAD' ın resmi sitesinde bulunan açık kaynaklı deprem ivme değerleri, deprem ivme hızı, zemin özellikleri, ivmeölçer istasyonlarının kodu ve lokasyon bilgileri toplanması ile bu verilerin analiz edilmesiyle bölgenin jeolojik yapısına bağlı olarak zemin büyütme katsayıları hesaplanmış ve farklı zemin türlerinin deprem dalgaları üzerindeki etkileri değerlendirilmiştir.

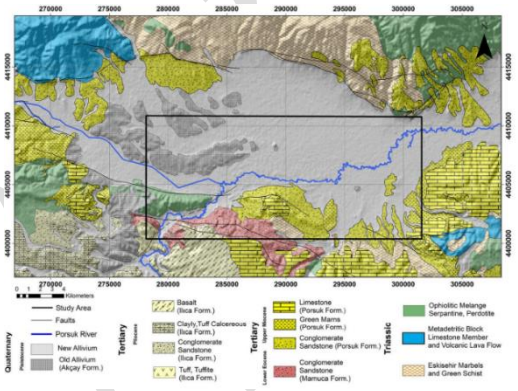


**Şekil 1.** Eskişehir Diri Fay Haritası

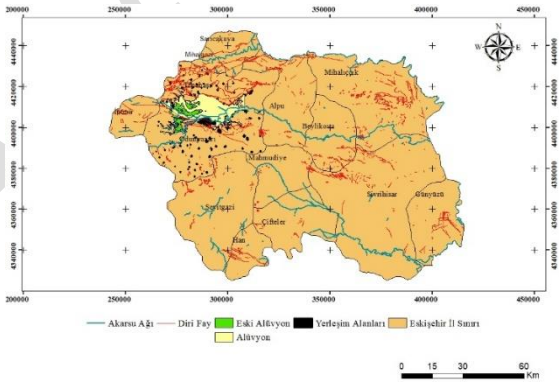


**Şekil 2.** Eskişehir'in Jeoloji Haritası (Pekkan et al., 2014)

Elde edilen verilerin analizi sonucu Eskişehir Teknik Üniversitesi EstuNet ağı ile deprem kaynağına yakın olan ivmeölçerlerin kodları ile deprem büyüklüğü, ivme hızı ve zeminde meydana gelen yer çekimi ivmeleri Şekil 3 'de ve Şekil 4 'de gösterilmiştir. Daha önce yapılan bu çalışmalar ışığında bu süreçte, yumuşak ve alüvyon zeminlerde depremin şiddetinin daha fazla hissedileceği, sert kaya zeminlerde ise sarsıntının daha az olacağı prensibinden hareketle değerlendirmeler yapılmıştır (Mutlu, 2012).

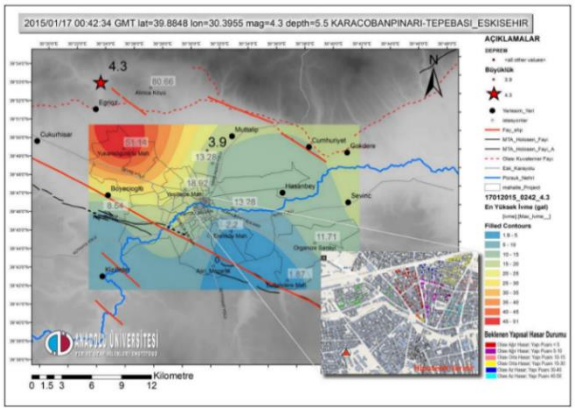


**Şekil 3.** Deprem İvme Dağılımı Haritası

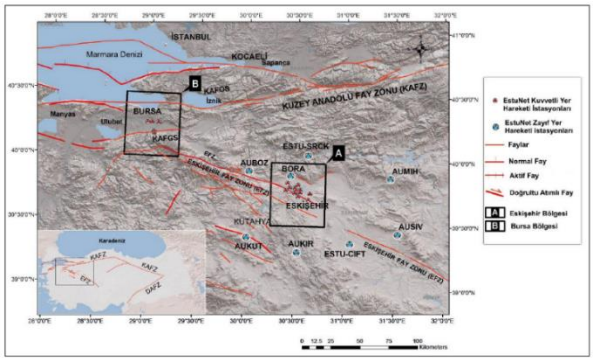


**Şekil 4.** Batı Anadolu'daki aktif fayları gösteren bölgesel harita ve EstuNet Sismik Ağı istasyonları

Son olarak, Şekil 5' de gösterilen Eskişehir il sınırları içinde yer alan kritik altyapı tesislerine ait noktasal veriler kullanılarak, bu tesislerin depremden ne derece etkileneceği analiz edilmiştir. Çalışma kapsamında, ArcMap 10.8 yazılımı kullanılarak elde edilen veriler çakıştırılmış, mekânsal analizler gerçekleştirilmiş ve elde edilen sonuçlar haritalar ve grafikler yardımıyla görselleştirilmiştir. Böylece, kritik altyapı tesislerinin deprem riski ile ilişkisi belirlenmiş ve olası zararların en aza indirilebilmesi için alınabilecek önlemler üzerinde durulmuştur.

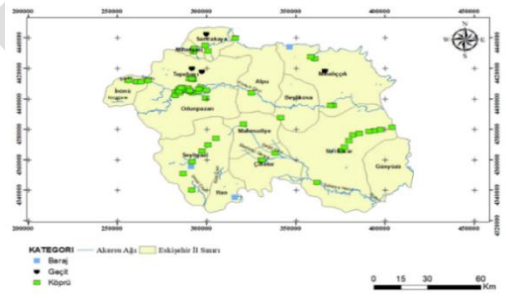


**Şekil 5.** Eskişehir İlinde Bulunan Kritik Altyapı Elemanlarından baraj, geçit ve köprü

Deprem afetine yaklaşımda iki temel yöntem vardır (Mutlu, 2012). İlki depremin zemine bağlı değişiklik göstererek büyütme etkisi: Örneğin yumuşak zeminlerde deprem dalga hızlarının daha fazla yayılım göstermesi, kaya zeminlerde ise bu dalgaların genliklerinin sönümlenmesi gözlenmektedir (Mutlu, 2012). İkinci yöntemde ise zeminin etkilenme biçimine göre karakteristik yapısının değişime uğraması ve taşıma gücü kaybının yaşanmasıdır(Mutlu, 2012). Şekil 3 ve Şekil 4' de gösterilen haritada bu değerleri hesaplayan EstuNet sismik ağ izleme istasyonlarının konumları verilmiştir (Tün et al., 2020). Bu tez çalışması kapsamında buradan elde edilen veriler ile zemin büyütme ve deprem ivme haritaları oluşturulmuştur.

## 3. BULGULAR

Çalışma kapsamında yapılan analizler sonucunda, Eskişehir ilinde farklı zemin türlerine bağlı olarak deprem sırasında meydana gelebilecek ivme değişimleri ve bu değişimlerin kritik altyapı tesisleri üzerindeki etkileri belirlenmiştir. Zemin Büyütme Katsayısı ve Deprem Davranışı Yapılan zemin büyütme analizleri sonucunda, Eskişehir'in farklı bölgelerinde değişen jeolojik yapıların deprem dalgalarının yayılmasını doğrudan etkilediği görülmüştür. Özellikle alüvyon zeminlerin yoğun olduğu bölgelerde zemin büyütme katsayısının yüksek olduğu, dolayısıyla deprem dalgalarının burada daha fazla şiddetle hissedileceği belirlenmiştir. Buna karşılık, sert kaya zeminlerin bulunduğu alanlarda ise zemin büyütme katsayısı daha düşük çıkmış, bu da deprem sırasında daha az sarsıntı yaşanacağını göstermiştir. Deprem ivme değerleri haritalandırıldığında, Eskişehir'in belirli bölgelerinde sismik hareketlerin daha güçlü hissedileceği ortaya çıkmıştır. Bu durum özellikle Porsuk Nehri çevresi ve alüvyon birikintilerinin yoğun olduğu alanlarda daha belirgin hale gelmiştir. Bu bölgelerde ivme değerleri yüksek çıkarken, kaya zeminin yaygın olduğu kuzeybatı ve güneydoğu kesimlerinde ivme değerlerinin görece daha düşük olduğu tespit edilmiştir. Kritik altyapı tesislerinin depremden etkilenme düzeyi çalışmada, Eskişehir il sınırları içinde yer alan kritik altyapı tesislerinin (hastaneler, itfaiye istasyonları, enerji santralleri, su kaynakları, iletişim merkezleri vb.) deprem ivme değerleri ve zemin büyütme katsayılarıyla çakıştırılması sonucunda, bazı tesislerin yüksek risk altında olduğu belirlenmiştir. Özellikle yumuşak zemin üzerine inşa edilmiş kritik altyapı unsurlarının deprem sırasında daha fazla zarar görebileceği tespit edilmiştir. Diri fay hatları ile çakışan bölgeler, diri fay hatları haritası ile yapılan analizler sonucunda, bazı kritik altyapı tesislerinin fay hatlarına tehlikeli derecede yakın konumlandığı görülmüştür. Fay hatlarına yakın olan bu tesislerin deprem sırasında doğrudan veya dolaylı olarak büyük zarar görebileceği değerlendirilmiştir. Kritik altyapı tesislerinin etkilendiği bölgelerdeki sosyo-ekonomik veriler incelendiğinde, yüksek ivme değerine sahip bölgelerde nüfus yoğunluğunun da fazla olduğu anlaşılmıştır. Bu durum, olası bir depremde altyapının zarar görmesi halinde afet sonrası süreçlerin daha zor yönetilebileceğini ve toplumsal etkilerin daha büyük olabileceğini göstermektedir.

## 4. TARTIŞMA

Bu çalışmada, Eskişehir ilinde kritik altyapı tesislerinin deprem tehlikesi karşısındaki durumu değerlendirilmiş, zemin büyütme katsayıları ve deprem

ivme değerleri üzerinden risk analizi yapılmıştır. Özellikle Porsuk Nehri çevresi ve fay hatlarına yakın bölgelerde zemin büyütme katsayısının yüksek olduğu ve deprem dalgalarının daha şiddetli hissedileceği belirlenmiştir. Kritik altyapı tesislerinden bazılarının yüksek ivme değerine sahip bölgelerde konumlandığı ve bu durumun afet yönetimi açısından risk oluşturduğu tespit edilmiştir. Ayrıca, sosyo-ekonomik verilerle yapılan analizler, nüfus yoğunluğunun fazla olduğu alanlarda deprem etkilerinin daha yıkıcı olabileceğini göstermektedir. Eskişehir'in deprem dirençli şehir planlamasına katkı sağlayacak stratejiler geliştirilmekte olup bu stratejilerin hayata geçirilmesi gerekmektedir.

## 5. SONUÇ

Sonuç olarak, bu çalışma Eskişehir ilinde zemin büyütme katsayısı, deprem ivme değerleri ve kritik altyapı tesisleri arasındaki ilişkileri ortaya koyarak, olası bir deprem durumunda riskleri azaltmaya yönelik önemli veriler sunmaktadır. Elde edilen bulgular, kentleşme ve altyapı planlamasında yetkililer tarafından dikkate alınarak deprem dirençli şehir planlaması için bir temel oluşturabilir. Gelecekteki çalışmalar, daha yüksek çözünürlüklü veriler ve yapısal hasar analizleri ile desteklenerek bu tür mekânsal analizlerin daha da güçlendirilmesine katkı sağlayabilir. Gelecekte yapılacak çalışmalar, daha yüksek çözünürlüklü verilerin kullanılması, mikrobölgeleme analizleri ile detaylı jeoteknik değerlendirmelerin yapılması ve yapısal hasar analizlerinin bu tür mekânsal değerlendirmelerle birleştirilmesi yönünde genişletilebilir. Böylece, deprem tehlikesine karşı daha güçlü önlemler alınabilir ve Eskişehir'in afetlere karşı daha dirençli bir şehir olması sağlanabilir.

## TEŞEKKÜR

Bu çalışma Eskişehir Teknik Üniversitesi Yer ve Uzay Bilimleri Enstitüsü Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Ana Bilim Dalı, Ahsen Çakı tarafından yazılmış yüksek lisans tez çalışmasından üretilmiştir. Bu çalışmanın gerçekleşmesinde bilgi ve desteğini esirgemeyen değerli danışman hocam Prof. Dr. Alper Çabuk ve Mehtap Özenen Kavlak hocam' a çalışmalarıyla katkı sağlayan Dr. Öğretim Üyesi Emrah Pekkan ve Araştırma Görevlisi Sunay Mutlu' ya teşekkürlerimi sunarım.

## KAYNAKÇA

Amini, F., Ghassemzadeh, S., Rostami, N., & Tabar, V. S. (2024). A stochastic two-stage microgrid formation strategy for enhancing distribution network resilience against earthquake event incorporating distributed energy resources, parking lots and responsive loads. *Sustainable Cities and Society*, *101*. https://doi.org/10.1016/j.scs.2024.105191

Avdan, U., & Alkış, A. (2010). *Bütünleşik Bir Afet (Deprem) Bilgi Sisteminin Geliştirilmesi (Eskişehir İli Örneği)*.

Görüm, T., Tanyas, H., Karabacak, F., Yılmaz, A., Girgin, S., Allstadt, K. E., Süzen, M. L., & Burgi, P. (2023). Preliminary documentation of coseismic ground failure triggered by the February 6, 2023 Türkiye earthquake sequence. *Engineering Geology*, *327*. https://doi.org/10.1016/j.enggeo.2023.107315

Kartal, F. R., Kadiroğu, T. F., & Zünbül, S. (2015). *Kuzey Anadolu Fay Zonunun Kinematigi*.

Ketin, İ. (1966). *Tectonıc Unıts Of Anatolıa (Asıa Mınor) **.

Ketin, İ. (1977). *Türkiye'nin Başlıca Orojenik Olayları Ve Paleocoğrafik Evrimi*.

Koca, S., & Menteşe, S. (2020). Eskişehir Merkez İlçelerinde (Odunpazarı Ve Tepebaşı) Topografik Faktörlere Göre Yerleşimin Dağılışı. In *Aegean Geographical Journal* (Vol. 29, Issue 2). https://dergipark.org.tr/tr/pub/ecd

Mutlu, S. (2012). Sismik Kırılma Yöntemi Ve Mikrotremör Ölçümlerinden Elde Edilen Dinamik Zemin Parametrelerinin Coğrafi Bilgi Sistemleri (Cbs) Kullanılarak Haritalanması.

Ocakoğlu, F. (2007). A re-evaluation of the Eskişehir Fault Zone as a recent extensional structure in NW Turkey. *Journal of Asian Earth Sciences*, *31*(2), 91–103. https://doi.org/10.1016/j.jseaes.2007.05.002

Pekkan, E., Tun, M., & Guney, Y. (2014). *Integrated seismic risk analysis using simple weighting method: the case of residential Eskişehir, Turkey*. https://doi.org/10.5194/nhessd-2-6883-2014

Tün, M., Mutlu, S., & Pekkan, E. (2020). EstuNet: A new Weak/Strong-Motion Network with Geodatabase for Metropolitan Eskisehir and Bursa, West Anatolia, Turkey. *Turk Deprem Arastirma Dergisi*, *2*(2), 193–208. https://doi.org/10.46464/tdad.785892

Tün, M., Pekkan, E., & Tunç, S. (2015). Seismic Network Structure for Generate of Ground Shaking Maps: A Case Study from Eskisehir. *Harita Teknolojileri Elektronik Dergisi*. https://doi.org/10.15659/hartek.15.11.77

TUFUAB, (2024). Tarihçe, Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB), Ankara, [Erişim tarihi: 05.12.2024], https://www.tufuab.org.tr/tarihce/sayfa/3

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Afet Sonrası Kentleşmenin Ekosistem Üzerindeki Etkileri: ML Tabanlı LST ve NDVI Analiziyle Hatay İncelemesi

**Alanur Yavuz*[1], Alperen İnceer[1], Esra Tunç Görmüş[1], Volkan Yılmaz[1]**

[1]*Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği, Trabzon, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Görüntü İşleme,
NDVI,
Makine Öğrenmesi,
Arazi Yüzey Sıcaklığı

**ÖZET**

Doğal afetlerin sosyo-ekonomik ve çevresel etkileri, yalnızca felaket anıyla sınırlı kalmayıp uzun vadeli konumsal dönüşümlere neden olmaktadır. 6 Şubat 2023 tarihinde Türkiye'nin güneyinde meydana gelen yıkıcı depremler, özellikle Hatay ili özelinde sadece fiziksel altyapıya zarar vermekle kalmamış, aynı zamanda kentleşme dinamiklerini ve çevresel dengeyi de köklü biçimde etkilemiştir. Bu bağlamda, afet sonrası geçici barınma ihtiyacının karşılanması amacıyla tarım arazilerinin yoğun bir şekilde konteyner alanları, prefabrik yapılar ve yeni inşaat alanlarıyla işgal edilmesi, kentsel yayılmanın kontrolsüz şekilde artmasına yol açmıştır. Bu bağlamda, çalışma kapsamında afet sonrası dönemde meydana gelen arazi kullanım değişikliklerinin bitki örtüsü sağlığı üzerindeki etkileri, NDVI (Normalized Difference Vegetation Index) kullanılarak detaylı biçimde analiz edilmiştir. Ayrıca, kentsel alanlarda artan yüzey sıcaklıkları, Makine Öğrenmesi (ML) tabanlı LST (Land Surface Temperature) verileri aracılığıyla incelenmiştir. Uzaktan algılama ve makine öğrenmesi temelli yöntemlerin birlikte ve etkili bir şekilde kullanıldığı çalışma, çevresel izleme, afet sonrası planlama ve sürdürülebilir arazi yönetimi gibi alanlara katkı sağlamayı hedeflemektedir.

# The Effects of Post-Disaster Urbanisation on Ecosystems: A Case Study of Hatay with ML Based LST and NDVI Analysis

**Keywords**
Remote Sensing,
Image Processing,
NDVI,
Machine Learning,
Land Surface Temperature

**ABSTRACT**

The socio-economic and environmental impacts of natural disasters are not only limited to the moment of disaster but also cause long-term spatial transformations. On February 6, 2023, the devastating earthquakes that struck southern Turkey, especially in Hatay province, not only damaged the physical infrastructure, but also radically affected urbanization dynamics and environmental balance. In this context, the intensive occupation of agricultural lands with container areas, prefabricated buildings and new construction sites in order to meet the need for temporary shelter after the disaster has led to an uncontrolled increase in urban sprawl. In this context, the effects of land use changes on vegetation health in the post-disaster period were analyzed in detail using NDVI (Normalized Difference Vegetation Index). In addition, increasing surface temperatures in urban areas were analyzed through Machine Learning (ML) based LST (Land Surface Temperature) data. The study, in which remote sensing and ML-based methods are used together and effectively, aims to contribute to areas such as environmental monitoring, post-disaster planning and sustainable land management.

## 1. GİRİŞ

Doğal afetler, yalnızca meydana geldikleri anda değil, sonrasında bıraktıkları izlerle de toplumsal ve çevresel sistemler üzerinde kalıcı etkiler yaratmaktadır. Bu etkiler zamanla kentleşme dinamiklerini ve arazi kullanımını dönüştürmektedir. 6 Şubat 2023'te Türkiye'nin güneyinde meydana gelen depremler, özellikle Hatay'da fiziksel yıkımın ötesinde sosyo-konumsal yapıda da önemli değişimlere yol açmıştır.

* **Alanur Yavuz**

*(alanuryavuz@ktu.edu.tr) ORCID ID 0009-0007-0145-031X
(alpereninceer@gmail.com) ORCID ID 0009-0004-4919-9388
(etunc@ktu.edu.tr) ORCID ID 0000-0002-3334-2061
(volkanyilmaz.jdz@ktu.edu.tr) ORCID ID 0000-0003-0685-8369

Yavuz A, İnceer A, Tunç Görmüş E & Yılmaz V (2025). Afet Sonrası Kentleşmenin Ekosistem Üzerindeki Etkileri: ML Tabanlı LST ve NDVI Analiziyle Hatay İncelemesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

Deprem sonrası belirsizlikler ve geçici barınma ihtiyacı, kırsal ve tarımsal alanlara yönelimi beraberinde getirmiştir (Dinç, 2023). Bu durum, plansız kentsel yayılmayı artırarak doğal kaynaklar ve ekosistem sağlığı üzerinde baskı oluşturmaktadır. Bu dönüşümün çevresel izdüşümünü izleyebilmek için uzaktan algılama tabanlı göstergelerden NDVI ve LST yaygın olarak kullanılmaktadır. NDVI, bitki örtüsü yoğunluğunu ve sağlığını zamansal olarak izleme olanağı sunarken; LST, yüzey sıcaklığı değişimleri ve kentsel ısı adası etkilerinin belirlenmesinde kritik bir ölçüttür (Weng vd., 2004). Bu çalışma, afet sonrası arazi kullanım değişimlerinin bitki örtüsü sağlığı ve yüzey sıcaklığı üzerindeki etkilerini NDVI ve LST parametreleriyle değerlendirmeyi amaçlamaktadır. Özellikle tarımsal alanların yapılaşmaya dönüşmesinin çevresel sonuçları, yüksek çözünürlüklü uydu verileri ve makine öğrenmesi tabanlı analizlerle detaylı biçimde incelenmiştir.

## 2. YÖNTEM

Bu çalışmada, Hatay ili Antakya ilçesi Derince Mahallesi ve çevresinde, 6 Şubat 2023 depreminin ardından yaklaşık 5.5 km²'lik alanda arazi örtüsü değişimi ve yüzey sıcaklığı analizi yapılmıştır. Yöntemsel süreç üç aşamada yürütülmüştür: (1) veri temini ve ön işleme, (2) NDVI tabanlı bitki örtüsü analizi, (3) ML tabanlı LST üretimi. 2021–2025 yıllarına ait Mart ayı Sentinel-2 MSI (MultiSpectral Instrument) ve Landsat 8–9 görüntüleri Google Earth Engine (GEE) üzerinden elde edilerek NDVI ve LST hesaplamalarında gerekli bantlar ve indeksler kullanılmıştır. NDVI verileri grafik ve haritalarla değerlendirilmiş; LST tahmini için eğitilen makine öğrenmesi modeli doğruluk metrikleriyle test edilmiştir.

### 2.1. Veri Temini ve Ön İşleme

NDVI hesaplamaları için, Mart aylarına ait 2021–2025 dönemine yönelik Sentinel-2 görüntüleri kullanılmıştır. LST verileri ise Landsat 8 ve 9'un TIRS (Thermal Infrared Sensor) sensörüne ait ST_B10 bandından türetilmiştir. Tüm görüntüler, bulutluluk ve atmosferik etkiler dikkate alınarak filtrelenmiş; analiz öncesinde bant seçimi, hizalama ve indeks üretimi gibi temel ön işlemler uygulanmıştır.

### 2.2. NDVI Tabanlı Bitki Örtüsü Analizi

Sentinel-2 verilerinden elde edilen NDVI değerleri, çalışma alanındaki bitki örtüsünün zamansal değişimini incelemek amacıyla Python ortamında analiz edilmiştir (Şekil 1). 2023–2021 ve 2025–2023 NDVI fark haritaları üretilerek bitki örtüsündeki değişimler konumsal olarak ortaya konmuştur.

### 2.3. ML Tabanlı LST Üretimi

LST haritalarının konumsal çözünürlüğünü 10 metreye çıkarmak amacıyla, düşük çözünürlüklü (30 m) Landsat 8–9 LST (ST_B10) verileri ile Sentinel-2'nin yüksek çözünürlüklü (10 m) bantları ve çeşitli türev indeksler kullanılarak Rastgele Orman (Random Forest) regresyon modeli eğitilmiştir. Modelin performansı Karekök Ortalama Hata (RMSE), Ortalama Mutlak Hata (MAE) ve Determinasyon Katsayısı ($R^2$) istatistikleri ile değerlendirilmiş; Landsat kaynaklı klasik LST verisi ile ML tabanlı Sentinel-2 verisi üzerinden türetilen tahmini LST haritaları karşılaştırmalı olarak analiz edilmiştir.

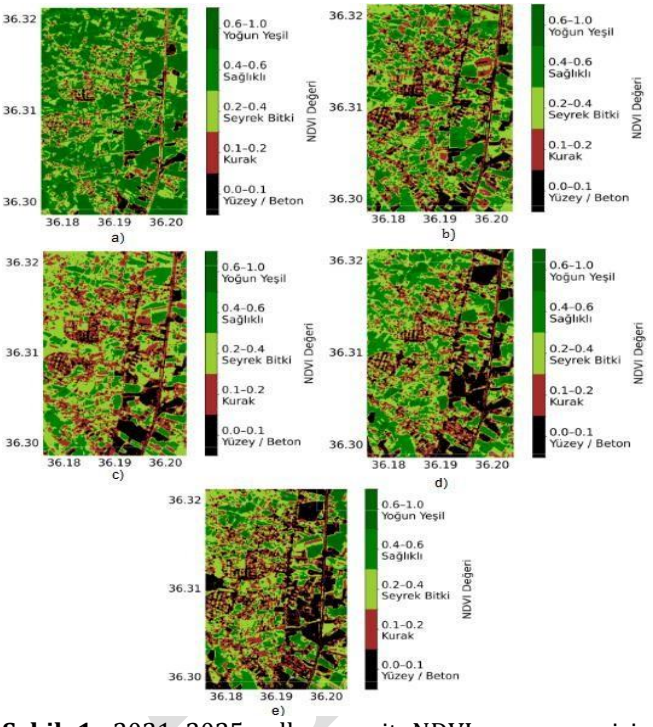


**Şekil 1**. 2021–2025 yıllarına ait NDVI zaman serisi analizi; a) 2021, b) 2022, c) 2023, d) 2024 ve e) 2025.

## 3. BULGULAR

Bu çalışmada, 6 Şubat 2023 depremi sonrası Hatay'da arazi kullanımındaki değişimlerin NDVI ve LST üzerindeki etkileri incelenmiştir. 2023–2021 ve 2025–2023 yılları arasındaki NDVI fark haritaları kullanılarak bitki örtüsündeki kayıp ve kazanımlar konumsal olarak görselleştirilmiş; eşik değerleri kullanılarak düşük ve yüksek bitki yoğunluğunu temsil eden bölgeler sınıflandırılmış ve düşük NDVI değerine sahip alanlar maskeleme yöntemiyle belirlenmiştir (Şekil 2). 2025 yılına ait LST üretiminde, LST ve ML-LST haritaları karşılaştırılmıştır (Şekil 3). Şekil 3a'daki LST haritasında, düşük çözünürlük ve bloklaşma nedeniyle sıcaklık dağılımı mekânsal olarak yetersiz temsil edilmiştir. Buna karşın, Şekil 3b'deki ML-LST haritasında sıcaklık geçişlerini daha yumuşak ve gerçekçi biçimde yansıtarak yüzeydeki heterojen yapıları daha başarılı şekilde ortaya koymuştur.

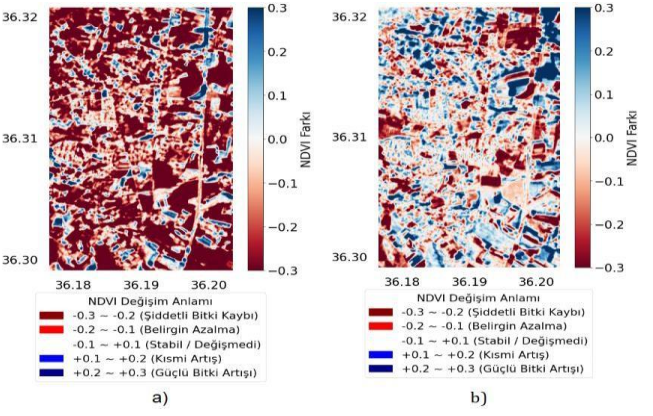


**Şekil 2.** NDVI Fark Haritası; a)2023-2021, b)2025-2023.

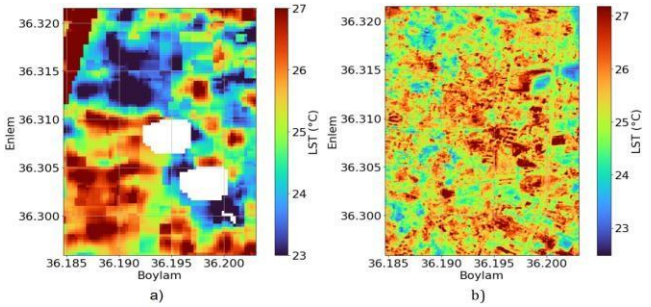


**Şekil 3.** 2025 yılına ait LST üretimi; a) LST, b) ML-LST.

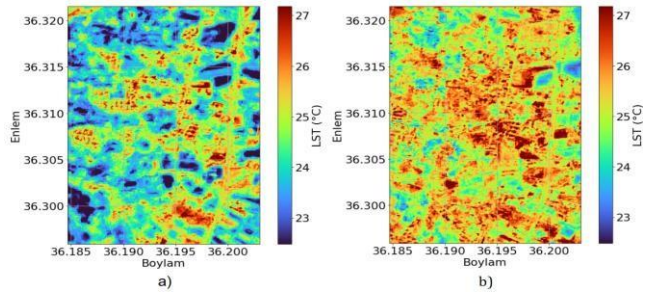


**Şekil 4.** ML Tabanlı LST üretimi; a)2023, b)2025.

2023 ve 2025 yıllarına ait ML-LST haritaları karşılaştırılarak yüzey sıcaklığı değişimleri analiz edilmiştir (Şekil 4). Modelin doğruluk metrikleri MAE: ±1.52 °C, RMSE: ±2.06 °C ve $R^2$: 0.82 olarak belirlenmiştir. LST tahminleri, referans verilerle hem sayısal metrikler hem de regresyon temelli görselleştirmelerle değerlendirilmiştir. 2023 yılına ait ML-LST haritasında (Şekil 4a), sıcaklıklar 24–26 °C aralığında yoğunlaşmakta; yerleşim alanları ve düşük bitki örtüsüne sahip bölgelerde değerler yükselmektedir. 2025 ML-LST haritasında (Şekil 4b) ise bu sıcaklık deseninin genişlediği ve yüksek sıcaklık alanlarının arttığı gözlenmiştir. NDVI fark haritalarıyla birlikte değerlendirildiğinde, 2025 yılında bitki örtüsündeki azalmaların LST artışıyla doğrudan ilişkili olduğu görülmüştür. Özellikle yeşil alan kaybı yaşanan bölgelerde sıcaklık artışları belirgindir. 2021–2025 döneminde NDVI değerleri 0.48'den 0.24'e düşerken, artan yapay yüzey oranı yüzey sıcaklığında 2–3 °C'lik artışa yol açmıştır. Bu ters yönlü ilişki, özellikle yapılaşmanın yoğunlaştığı bölgelerde belirginleşmiş; boylamsal analizler de sıcaklık artışını desteklemiştir.

## 4. TARTIŞMA

Afet sonrası dönemde artan yapılaşma baskısı, yalnızca yüzey sıcaklıklarının yükselmesine değil, aynı zamanda ekolojik denge ve kamusal güvenlik açısından da risklere yol açmaktadır. Yeşil alanların yapılaşmaya açılması, olası yeni afetlerde toplanma ve tahliye bölgelerinin kaybına neden olarak kentsel dirençliliği zayıflatmaktadır (Aksoy vd., 2009). Bu durum, afet sonrası planlamalarda yeşil altyapının korunmasının stratejik önemini vurgulamaktadır. Çalışma kapsamında, NDVI düşüşleri ve LST artışları, yapılaşmanın yoğunlaştığı alanlarla örtüşmekte ve bu durum, bitki örtüsünün soğutucu etkisinin kaybıyla ilişkilendirilmektedir. Farid vd. (2022) de benzer şekilde, yapılaşmanın arttığı alanlarda NDVI değerlerinin azaldığını ve buna bağlı olarak LST'nin yükseldiğini belirlemişlerdir. Bu çalışmada üretilen 10 m çözünürlüklü ML tabanlı LST haritası, klasik yönteme kıyasla daha ayrıntılı sıcaklık desenleri sunarak mikroklimatik değişimlerin yerel düzeyde analizini mümkün kılmıştır. Böylece kent içi ısı adalarının dağılımı net biçimde ortaya konmuştur. Benzer bir yaklaşımla, Van Thong vd., (2024), $R^2$: 0.81 ve RMSE: ±1.35 °C doğruluk değerleriyle, Sentinel-2 indeksleri ve Landsat 8 LST verilerini kullanarak çoklu doğrusal regresyon temelli 10 m çözünürlüklü bir model geliştirmişlerdir. Gelecek çalışmalarda, daha uzun dönemli veri setleri ve gelişmiş modelleme yöntemleriyle tahmin doğruluğu artırılabilir.

## 5. SONUÇ

Yeşil alan kaybı ve yapılaşmanın artışı, 2021–2025 yılları arasında yüzey sıcaklığının belirgin şekilde yükselmesine neden olmuştur. NDVI ile LST arasındaki güçlü ters ilişki, özellikle yapay yüzeylerin yoğunlaştığı bölgelerde sıcaklık artışlarının daha belirgin olduğunu göstermiştir. Bu çalışma, mekânsal değişimlerin etkili biçimde izlenmesinde ML tabanlı LST modellerinin önemini vurgulamakta ve sürdürülebilir planlama süreçlerine katkı sağlamaktadır.

### Yazar Katkı Oranı

Yazarların makaleye katkıları belirtilmelidir.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunup bulunmadığı belirtilmelidir.

### Araştırma ve Yayın Etiği Beyanı

Çalışmanın araştırma ve yayın etiği hakkında varsa açıklanması gereken bilgiler bu bölümde verilmelidir.

## KAYNAKÇA

Aksoy, Y., Çelik Turan, A., & Atalay, H. (2009). İstanbul Fatih ilçesi yeşil alan yeterliliğinin Marmara Depremi öncesi ve sonrası değerleri kullanılarak incelenmesi. *Uludağ Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, *14*(2), 137–150.

Dinç, Y. (2023). 6 Şubat 2023 Kahramanmaraş depremleri sonrası yeniden yapılanma sürecinde yere bağlılığın değerlendirilmesi: Antakya (Hatay) örneği. *Türk Coğrafya Dergisi* (*83*), 45-57. https://doi.org/10.17211/tcd.1347063

Farid, N., Moazzam, M. F. U., Ahmad, S. R., Coluzzi, R., & Lanfredi, M. (2022). Monitoring the Impact of Rapid Urbanization on Land Surface Temperature and Assessment of Surface Urban Heat Island Using Landsat in Megacity (Lahore) of Pakistan. Frontiers in Remote Sensing, 3, Article 897397. https://doi.org/10.3389/frsen.2022.897397

Van Thong, D., Tuan Cuong, H., Ha Phuong, T., Lam, N. T. N., Nguyen, T. P. C., Lap Xuan, T. T., & Le Quang, T. (2024). Analysis of urban heat islands combining

Sentinel 2 and Landsat 8 satellite images in Hochiminh city. IOP Conference Series: Earth and Environmental Science, 1349(1), 012032. https://doi.org/10.1088/1755-1315/1349/1/012032

Weng, Q., Lu, D., & Schubring, J. (2004). Estimation of land surface temperature–vegetation abundance relationship for urban heat island studies. Remote Sensing of Environment, 89(4), 467–483. https://doi.org/10.1016/j.rse.2003.11.005



© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Derin Öğrenme Modelleri Kullanılarak Tekil Hava Görüntüsünden Yükseklik Çıkarımı

**Fırat Erdem**[*1], **Ali Özgün Ok**[1]

[1]*Hacettepe Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Ankara, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Fotogrametri,
Bilgisayarlı Görü,
Görüntü İşleme,
Yükseklik Çıkarımı

**ÖZET**

Bu çalışma tekil hava görüntüsünden yükseklik bilgisi çıkarımı için farklı derin öğrenme tabanlı monoküler derinlik tahmini modellerinin performans karşılaştırılmasını amaçlamaktadır. Bu amaç için derin öğrenme tabanlı Dense Prediction Transformer (DPT), Depthformer ve Big to Small (BTS) modelleri kullanılarak Potsdam veri seti için eğitim ve test işlemleri gerçekleştirilmiştir. Potsdam veri seti Almanya'nın kuzeydoğusunda yer alan Potsdam şehrine ait 5 cm yer örnekleme aralığına sahip gerçek ortogörüntü ve sayısal yüzey modelini içermektedir. Ortogörüntü ve sayısal yüzey modeline çıktı görüntü boyutları 640 x 480 boyutlarında olacak şekilde kesme işlemi uygulanmıştır. Potsdam veri seti ile eğitilen ve test edilen derin öğrenme modellerinden elde edilen yükseklik görüntüleri Karesel Ortalama Hata (RMSE) ölçütü ile değerlendirilmiştir. DPT, Depthformer ve BTS için ortalama RMSE değerleri sırasıyla 4,17 m, 2,27 m ve 2,29 m olarak hesaplanmıştır. Dolayısıyla her ne kadar DPT modeli Depthformer ve BTS modellerine göre obje bazlı değerlendirildiğinde bazı detaylarda daha başarılı olsa da RMSE olarak değerlendirildiğinde Depthformer ve BTS modelleri her bir pikselin yüksekliğinin elde edilmesinde yer gerçeğine görece daha yakın sonuçlar üretmiştir.

# Height Extraction from a Single Aerial Image Using Deep Learning Models

**Keywords**
Remote sensing,
Photogrammetry,
Computer Vision,
Image Processing,
Height Extraction

**ABSTRACT**

This study aims to compare the performance of different deep learning-based monocular depth estimation models for height extraction from a single aerial image. For this purpose, deep learning-based Dense Prediction Transformer (DPT), Depthformer, and Big to Small (BTS) models were trained and tested using the Potsdam dataset. The Potsdam dataset includes true orthoimage and digital surface model with a ground sampling distance of 5 cm from the city of Potsdam, located in northeastern Germany. A cropping process was applied to the orthoimage and digital surface model to ensure the output image dimensions were 640 × 480 pixels. The height images obtained from the deep learning models trained and tested with the Potsdam dataset were evaluated using the Root Mean Square Error (RMSE) measure. The average RMSE values for DPT, Depthformer, and BTS were calculated as 4.17 m, 2.27 m, and 2.29 m, respectively. Therefore, although the DPT model performed better in certain object-based details compared to Depthformer and BTS, the Depthformer and BTS models produced results relatively closer to the ground truth in terms of pixel-wise height extraction.

## 1. GİRİŞ

Derinlik tahmini, her bir pikselin, belirli bir yönelimdeki görüş noktası ile sahne nesnesi arasındaki mesafeyi tahmin etme işlemidir (Ranftl vd., 2020). Bu işlem bilgisayarlı görü alanında kritik bir uygulamadır ve otonom sürüş, robotik ve artırılmış gerçeklik gibi birçok uygulama için ilgi çekmektedir (Haji-Esmaeili ve Montazer, 2024). 3B uzayda derinlik oluşturmak, monoküler görüntülerde bir stereoskopik görsel ilişki bulunmaması nedeniyle temelde belirsiz bir problemdir (Mur-Artal vd., 2015). Bu nedenle, araştırmacılar monoküler derinlik tahmini için çeşitli teknikler önermişlerdir (Bhoi, 2019). Tek bir görüntüden derinlik tahmini veya 3B geri-çatım, belirli sahne bağımlı bilgi mevcut olduğunda gerçekleştirilebilir. Ancak bu özellikler genellikle belirli koşullara veya yapıya sahip

* **Sorumlu Yazar**

*(firaterdem5@gmail.com) ORCID ID 0000-0002-6163-1979
(ozgunok@hacettepe.edu.tr) ORCID ID 0000-0001-6538-9633

**Kaynak Göster (APA):**

Erdem F & Ok A Ö (2025). Derin Öğrenme Modelleri Kullanılarak Tekil Hava Görüntülerinden Yükseklik Tahmini, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

görüntüler için çalışmaktadır (Li vd., 2018). Veri kullanarak sahne geometrisini doğrudan tahmin etmek için öğrenme tabanlı monoküler derinlik tahmini tekniklerinin kullanımı son zamanlarda popülerlik kazanmıştır. Bu yöntemler derinlik ile monoküler görüntü arasındaki ilişkiyi kullanarak, piksel düzeyinde bir sahne etiketleme iş akışına sahiptir (Li vd., 2018). Konuyla ilgili yapılan çalışmalarda bazı derin öğrenme modelleri üretilmiş veya uygulanmış olsa da Big to Small (BTS), DepthFormer ve Dense Prediction Transformer (DPT) gibi bilgisayarlı görü alanı için üretilen yeni modeller henüz uzaktan algılama verilerine uygulanmamış ve performansı değerlendirilmemiştir. Bu çalışma tekil hava görüntülerinden yükseklik çıkarımı için farklı derin öğrenme tabanlı monoküler derinlik tahmini modellerinin performansını karşılaştırılmasını amaçlamaktadır.

## 2. MATERYAL VE METOT

Monoküler derinlik tahmini modellerinin eğitilmesi ve test edilmesi işlemleri için ISPRS tarafından paylaşılan yükseklik verisinin de yer aldığı Potsdam veri seti kullanılmıştır. Potsdam veri seti semantik bölütleme amacıyla üretilen, sayısal yüzey modeli verisinin de yer aldığı bir veri setidir. Veri seti manuel olarak etiketlenerek; geçirimsiz yüzeyler, bina, düşük bitki örtüsü, ağaç, araba, dağınıklık/arka arazi kullanım sınıflarını belirten etiket görüntüleri oluşturulmuştur.

Potsdam veri seti Almanya'nın kuzeydoğusunda yer alan Potsdam şehrine ait 5 cm yer örnekleme aralığına sahip gerçek ortogörüntü ve sayısal yüzey modelini içermektedir. Sayısal yüzey modeli Trimble INPHO 5.6 yazılımı ile yoğun görüntü eşleştirme yoluyla ve gerçek ortogörüntü mozayiği ise Trimble INPHO OrthoVista yazılımıyla üretilmiştir. Potsdam veri seti, büyük bina blokları, dar sokakları ve yoğun yerleşim yapısı ile tipik bir tarihi şehir görünümündedir.

Evrişimsel sinir ağı modellerinin eğitilmesi çok fazla işlem gücü gerektirmesi sebebiyle ortogörüntü ve sayısal yüzey modeline çıktı görüntü boyutları 640 x 480 boyutlarında olacak şekilde kesme işlemi uygulanmıştır.

DPT, Depthformer ve BTS modelleri Potsdam veri seti kullanılarak eğitilmiş ve test edilmiştir. Bu modellerin özellikleri aşağıda belirtilmiştir.

DPT yöntemi Ranftl vd. (2021) tarafından yoğun tahmin görevlerinde evrişimsel sinir ağlarının neden olduğu özellik kaybı problemini engellemek için geliştirilmiştir. Model görsel dönüştürücü (vision transformer) katmanlarının kullanmaktadır.

DepthFormer mimarisi Li vd. (2022) tarafından derin sinir ağının otomatik özellik (feature) çıkarımı aşamasında derinliği daha doğru temsil eden özelliklerin çıkarılması için geliştirilmiştir. Depthformer modeli iki temel aşamadan oluşmaktadır. İlk aşamada bir dönüştürücü ve bir evrişim dalından oluşan bir kodlayıcıyı kapsamaktadır. Ağın bu bölümü uygun özelliklerin çıkarılması için geliştirilmiştir. Ağın ikinci bölümü ise çıkarılan özelliklerin iyileştirilmesi ve dönüştürülmesi için Hiyerarşik Toplama ve Heterojen Etkileşim (Hierarchical Aggregation and Heterogeneous Interaction - HAHI) modülünü içermektedir.

BTS yöntemi kodlayıcı-kod çözücü (encoder-decoder) yapısına sahip bir derin öğrenme modelidir. BTS modeli, yoğun şekilde kodlanmış özelliklerin istenen derinlik tahminine daha etkili yönlendirilmesi için, kod çözme aşamasının çeşitli noktalarına yerleştirilmiş yeni yerel düzlemsel yönlendirme (local planar guidance) katmanlarını kullanan bir ağ mimarisine sahiptir (Lee, vd., 2021).

Her üç model de, Monocular-Depth-Estimation-Toolbox (https://github.com/zhyever/Monocular-Depth-Estimation-Toolbox/) kütüphanesi kullanılarak eğitilmiş ve test edilmiştir. Modellerinin eğitimi öncesi Potsdam veri seti kullanılan kaynak kodların gerektirdiği şekilde NYU veri setinin gerektirdiği formata uyarlanmıştır. Bu formatta her bir piksele ait yükseklik/derinlik değerinin 0-10000 arasında olması gerekmektedir. Bunun için Potsdam veri setindeki minimum ve maksimum değerler %0.05 uç değer eliminasyonu yapıldıktan sonra tespit edilmiştir. Bu işlem sonucunda tespit edilen maksimum ve minimum yükseklik değeri 82.98 m ve 14.55 m olarak tespit edilmiştir. Ardından tüm görüntüler minimum ve maksimum değerlere göre normalizasyon işlemine tabi tutulmuştur. Normalizasyon için kullanılan formülasyon aşağıda ifade edilmiştir.

$$h_{norm} = \left(\frac{h - h_{min}}{h_{max} - h_{min}}\right) \times 10000$$

Normalizasyon işleminin ardından görüntüler %70 eğitim, %30 test için kullanılmak üzere rastgele görüntüler seçilerek iki gruba ayrılmıştır. Bu işlem sonucunda eğitim için 2873, test için 1231 görüntü parçası oluşturulmuştur.

Modellerin eğitimi ve test işlemi sonrasında çıktı yükseklik görüntülerinin 0-10000 aralığından yükseklik değerlerine dönüştürülmesi için normalizasyon eşitliğinin tersi uygulanmış ve yükseklik değerleri elde edilmiştir.

Test veri setinde her üç model için elde edilen yükseklik görüntüleri yer gerçeği görüntüleri ile Karesel Ortalama Hata (Root Mean Square Error - RMSE) ölçütü kullanılarak değerlendirilmiştir. Tüm test görüntüleri için RMSE değeri hesaplandıktan sonra test veri seti içerisinde yer alan ortogörüntünün üretim hatasından meydan gelen ve tamamen su alanlarından oluşan kısımlar hariç tutularak üç model için de RMSE değerlerinin ortalaması hesaplanmıştır.

## 3. BULGULAR

Örnek test görüntülerinden sonuçlar Şekil-1, Şekil-2, ve Şekil-3'te verilmiştir. Modellerin örnek test görüntülerinden ürettiği yükseklik görüntüleri incelendiğinde aşağıdaki sonuçlara ulaşılmıştır:

Taşıtlar gibi zemin ile olan yükseklik farkının görece az olduğu objelerin yüksekliğinin tahmin edilmesinde DPT modeli Depthformer ve BTS modellerine göre üstünlük sağlamıştır (Şekil-1).

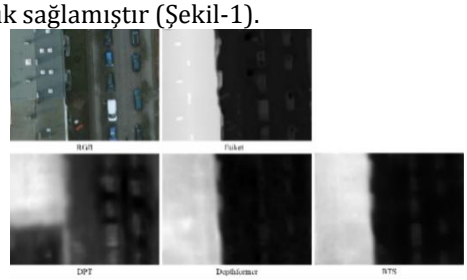

**Şekil-1.** Birinci örnek test görüntüsü sonuçları

Bina kenarlarının geometrilerinin yansıtılması konusunda DPT modeli Depthformer ve BTS modellerine göre daha başarılı olmuştur (Şekil-2).

İki bitişik binanın yer aldığı ve binalar arasında yükseklik farkı bulunması durumlarında her üç yöntem de yüksek başarı elde edememiştir (Şekil-2).

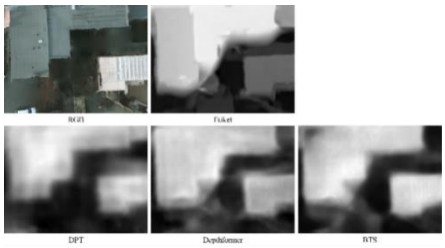

**Şekil-2.** İkinci örnek test görüntüsü sonuçları

Depthformer ve BTS modelleri ağaçların yüksekliklerini DPT'ye göre daha iyi tahmin etmiştir (Şekil-3).

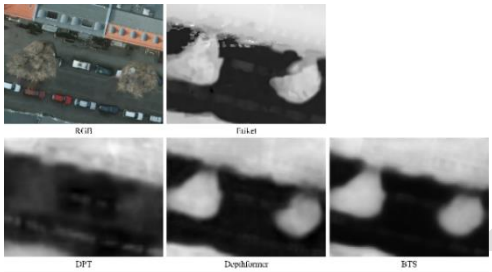

**Şekil-3.** Üçüncü örnek test görüntüsü sonuçları

Genel olarak DPT tarafından üretilen yükseklik görüntüleri Depthformer ve BTS modellerine göre daha kontrastlıdır. Buna karşın Depthformer ve BTS modelleri daha homojen yükseklik görüntüleri üretmiştir.

DPT, Depthformer ve BTS için ortalama RMSE değerleri sırasıyla 4,17 m, 2,27 m ve 2,29 m olarak hesaplanmıştır.

## 4. SONUÇ

Her ne kadar DPT modeli Depthformer ve BTS modellerine göre obje bazlı değerlendirildiğinde bazı detaylarda daha başarılı olsa da nicel olarak değerlendirildiğinde Depthformer ve BTS modelleri her bir pikselin yüksekliğinin tahmin edilmesinde yer gerçeğine görece yakın sonuçlar üretmiştir. Depthformer ve BTS modelleri kendi aralarında kıyaslandığında ise RMSE ölçütü baz alındığında Depthformer, BTS modeline göre çok az farkla yer gerçeğine görece yakın sonuçlar üretmiştir. Elde edilen bulgular sonucunda hava görüntülerinden derin öğrenme tabanlı Monoküler Derinlik Tahmini (Monocular Depth Estimation) modelleri kullanılarak yükseklik çıkarımının belirli bir karesel ortama hata miktarı sağlanarak gerçekleştirilebileceği çıkarımı yapılmıştır.

## TEŞEKKÜR

Sunulan çalışma TÜBİTAK tarafından "Derin Öğrenme Modelleri Kullanılarak Tekil Hava Görüntülerinden Yükseklik Tahmini" başlıklı TÜBİTAK Projesi (Proje No: 123C162) kapsamında desteklenmiştir.

### Yazar Katkı Oranı

Bu çalışmada, Dr. Fırat Erdem araştırmaya ait veri işleme, metodoloji geliştirme, analiz ve yazım kısımlarını gerçekleştirmiştir. Prof. Dr. Ali Özgün Ok ise araştırma fikri, danışmanlık ve bildirinin gözden geçirilmesi süreçlerinde katkı sağlamıştır.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

## KAYNAKÇA

Bhoi, A. (2019). Monocular depth estimation: A survey. arXiv preprint arXiv:1901.09402.

Haji-Esmaeili, M.M. & Montazer, G. (2024). Large-scale Monocular Depth Estimation in the Wild. Engineering Applications of Artificial Intelligence 127, 107189.

Lee, J. H., Han, M. K., Ko, D. W. & Suh, I. H. (2019). From big to small: Multi-scale local planar guidance for monocular depth estimation. arXiv preprint arXiv:1907.10326.

Li, B., Dai, Y. & He, M. (2018). Monocular depth estimation with hierarchical fusion of dilated cnns and soft-weighted-sum inference. Pattern Recognition 83, 328-33

Li, Z., Wang, X., Liu, X. & Jiang, J. (2022). Binsformer: Revisiting adaptive bins for monocular depth estimation. arXiv preprint arXiv:2204.00987.

Mur-Artal, R., Montiel, J.M.M. & Tardos, J.D. (2015). ORB-SLAM: a versatile and accurate monocular SLAM system. IEEE transactions on robotics 31, 1147-1163.

Ranftl, R., Bochkovskiy, A. & Koltun, V. (2021). Vision transformers for dense prediction, Proceedings of the IEEE/CVF international conference on computer vision, pp. 12179-12188.

Ranftl, R., Lasinger, K., Hafner, D., Schindler, K. & Koltun, V. (2020). Towards robust monocular depth estimation: Mixing datasets for zero-shot cross-dataset transfer. IEEE transactions on pattern analysis and machine intelligence 44, 1623-1637.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Çanakkale'de Mekansal Kuraklık Hassasiyeti Analizi: Uzaktan Algılama Tabanlı Çok Zamanlı Bir Değerlendirme

**Egehan Alumert*[1], Ahmet Batuhan Polat[1], Özgün Akçay[2]**

[1]*Çanakkale Onsekiz Mart Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği, Çanakkale, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Kuraklık,
Google Earth Engine,
Kuraklık Analizi

**ÖZET**

Kuraklık, su kaynaklarının azalması ve ekosistem dengesinin bozulmasıyla sonuçlanan, iklim değişikliğinin en belirgin etkilerinden biridir. Yetersiz yağış ve yüksek sıcaklıklar, tarımsal üretimden içme suyu kaynaklarına kadar pek çok alanı olumsuz etkilemektedir. Bu çalışmada, kuraklık olgusu Çanakkale ili özelinde, 2018-2024 yılları arasında uzaktan algılama yöntemleriyle incelenmiştir. Google Earth Engine platformu kullanılarak MODIS ve Sentinel-2 sensörlerinden elde edilen veriler analiz edilmiştir. NDVI değerleri 0,32-0,55 arasında değişmiş, 2018'de en yüksek (0,55), 2024'te en düşük (0,33) seviyede ölçülmüştür. LST değerleri 20,68-21,82°C arasında seyretmiş, en yüksek değere 2020'de, en düşük değere 2021'de ulaşmıştır. SPI değerleri -0,33 ile 0,36, SMCI değerleri -1,14 ile 0,58 aralığında dalgalanmıştır. Korelasyon analizleri, LST ile NDVI arasında negatif, SPI ile SMCI arasında pozitif ilişki göstermiştir. Kuzey yarımadada (Gelibolu) 2°C sıcaklık artışı ve %42 SPI azalması tespit edilmiştir. İlin %38'inde NDVI değerlerinde azalma görülürken, güneybatı kısmının %22'sinde artış saptanmıştır. Sonuçlar, bölgedeki kuraklık eğiliminin mekânsal olarak farklılaştığını göstermekte ve uzaktan algılama verilerinin kuraklık izlemedeki etkinliğini ortaya koymaktadır.

# Spatial Drought Sensitivity Analysis in Çanakkale: A Remote Sensing Based Multi-Temporal Assessment

**Keywords**
Remote Sensing,
Drought,
Google Earth Engine,
Drought Analysis

**ABSTRACT**

Drought is one of the most significant impacts of climate change, resulting in reduced water resources and disrupted ecosystem balance. Insufficient precipitation and high temperatures negatively affect many areas from agricultural production to drinking water resources. In this study, drought phenomenon was analyzed in Çanakkale province between 2018 and 2024 using remote sensing methods. The data obtained from MODIS and Sentinel-2 sensors were analyzed using the Google Earth Engine platform. NDVI values ranged between 0.32-0.55, with the highest level (0.55) in 2018 and the lowest level (0.33) in 2024. LST values hovered between 20.68-21.82°C, reaching the highest value in 2020 and the lowest in 2021. SPI values fluctuated between -0.33 and 0.36 and SMCI values between -1.14 and 0.58. Correlation analyses showed a negative relationship between LST and NDVI and a positive relationship between SPI and SMCI. In the northern peninsula (Gelibolu), a 2°C temperature increase and 42% SPI decrease were detected. While 38% of the province showed a decrease in NDVI values, 22% of the southwestern part showed an increase. The results show that the drought trend in the region is spatially differentiated and demonstrate the effectiveness of remote sensing data in drought monitoring.

* **Sorumlu Yazar**

*(24414956007@ogr.comu.edu.tr) ORCID ID 0009-0006-1815-4886
(akcay@comu.edu.tr) ORCID ID 0000-0003-0474-7518
(abpolat@comu.edu.tr) ORCID ID 0000-0002-7495-1998

**Kaynak Göster (APA):**

Alumert E, Polat A B & Akçay Ö (2025). Çanakkale'de Mekansal Kuraklık Hassasiyeti Analizi: Uzaktan Algılama Tabanlı Çok Zamanlı Bir Değerlendirme, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

TASLAK

## 1. GİRİŞ

İklim değişikliğinin etkilerinin belirginleştiği günümüzde, kuraklık özellikle tarımsal üretim, su kaynakları yönetimi ve ekosistem sağlığı açısından kritik bir çevresel sorundur (Mishra ve Shing, 2010). Kuraklık, meteorolojik, hidrolojik ve tarımsal boyutları olan karmaşık bir süreçtir (Wilhite ve Glantz, 1985).

Uzaktan algılama teknolojileri, geniş alanların yüksek çözünürlüklü verilerle izlenmesini sağlayarak kuraklık analizi için önemli bir araç haline gelmiştir (AghaKouchak vd., 2015). Bu teknolojiler, geleneksel yersel ölçümlerin sınırlılıklarını aşarak, geniş alanların sürekli izlenmesine olanak tanır (Petropoulos vd., 2015).

Optik, termal ve mikrodalga sensörlü uydular, NDVI, LST gibi kuraklık parametrelerinin hesaplanmasını ve analizini sağlar (Gu vd., 2007). Bu teknolojiler, ölçüm istasyonlarının seyrek olduğu bölgelerde, kuraklık izleme ve erken uyarı sistemleri için hayati önem taşır (Sheffield vd., 2014).

Kuraklık parametrelerinin ilişkilerinin anlaşılması, kuraklık dinamiklerinin kavranması ve gelecekteki eğilimlerin tahmin edilmesi açısından önemlidir (Quiring ve Ganesh, 2010). Korelasyon analizleri, parametreler arasındaki doğrusal ilişkileri belirlemede kullanılır (Vicente-Serrano vd., 2013). Gecikmeli korelasyon analizleri, bir parametredeki değişimin diğerleri üzerindeki zamansal etkisini gösterir (Lotsch vd, 2003). Mevsimsel korelasyon analizleri ise, ilişkilerin mevsimsel değişkenliğini inceleyerek, farklı mevsimlerdeki kuraklık dinamiklerini anlamamıza yardımcı olur (Du vd., 2013).

## 2. YÖNTEM

### 2.1. Çalışma Alanı

Çalışma alanı olarak seçilen Çanakkale ili, Türkiye'nin kuzeybatısında, Marmara Bölgesi'nin güneybatı kesiminde yer almaktadır. İlin toplam yüzölçümü 9.887 $km^2$ olup, Akdeniz ve Karadeniz iklimlerinin geçiş bölgesinde bulunmaktadır (Türkeş vd., 2020).

### 2.2. Kuraklık Parametreleri

Çalışmada dört temel kuraklık parametresi kullanılmıştır. Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI), bitki örtüsü yoğunluğunu ve sağlığını değerlendirmek için kullanılmıştır (Rouse vd., 1974; Tucker, 1979). Arazi Yüzey Sıcaklığı (LST), yeryüzü termal karakteristiklerinin belirlenmesinde kullanılan önemli bir parametredir (Wan vd., 2015). Standartlaştırılmış Yağış İndeksi (SPI), meteorolojik kuraklığın değerlendirilmesinde kullanılan istatistiksel bir yaklaşımdır (McKee vd., 1993; Guttman, 1999). Toprak Nemi Koşul İndeksi (SMCI) ise toprak nem durumunun izlenmesinde kullanılan önemli bir göstergedir (Hunt vd., 2009).

## 3. BULGULAR

Bu çalışmada, Çanakkale ili için 2018-2024 döneminde Google Earth Engine platformuyla çok zamanlı uzaktan algılama verileri analiz edilmiştir. Çalışmada bitki örtüsü için NDVI, termal özellikler için LST, meteorolojik kuraklık için SPI ve toprak nemi için SMCI parametreleri kullanılmıştır. Bu parametreler arasındaki temporal ve mevsimsel korelasyonlar istatistiksel olarak analiz edilmiş, sonuçlar Çanakkale'deki kuraklık hassasiyeti ve risk değerlendirmesine katkı sağlamıştır. Yıllık ortalama değerler Tablo 1'de sunulmuştur.

**Tablo 1.** Yıllık Ortalama Kuraklık Parametreleri

| | LST(°C) | NDVI | SPI | SMCI |
|---|---|---|---|---|
| 2018 | 20.84658 | 0.55168 | 0.35592 | -0.0764 |
| 2019 | 21.62067 | 0.54168 | 0.2315 | -0.0308 |
| 2020 | 21.78208 | 0.54183 | -0.2952 | -0.8266 |
| 2021 | 20.68233 | 0.55117 | 0.2895 | 0.5795 |
| 2022 | 21.213 | 0.34175 | -0.1129 | -0.3201 |
| 2023 | 21.31875 | 0.3295 | 0.0245 | -1.1374 |
| 2024 | 20.9205 | 0.33358 | -0.333 | -0.1502 |

Çanakkale ilinde 2018-2024 yılları arasındaki kuraklık parametrelerinin yıllık ortalama değerleri incelendiğinde, LST değerlerinin 20.68°C ile 21.82°C arasında değişim gösterdiği, en yüksek değere 2020 yılında, en düşük değere ise 2021 yılında ulaştığı gözlemlenmiştir. NDVI değerleri 0.32-0.55 aralığında seyretmiş olup, 2018 yılında maksimum (0.55168), 2024 yılında minimum (0.33358) değerler kaydedilmiştir. SPI değerleri -0.3333 ile 0.35592 arasında değişim göstermiş, en yüksek değer 2018 yılında, en düşük değer ise 2024 yılında tespit edilmiştir. SMCI değerleri ise -1.1502 ile 0.5795 aralığında dalgalanma göstermiş, maksimum değere 2021 yılında, minimum değere ise 2023 yılında ulaşmıştır.

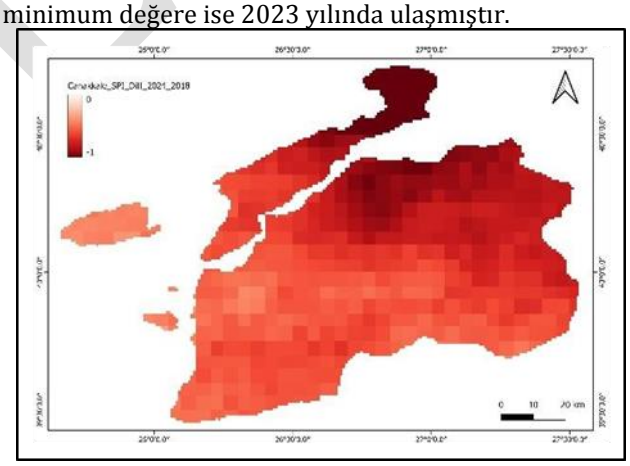

**Şekil 2.** 2024-2018 SPI Fark Haritası

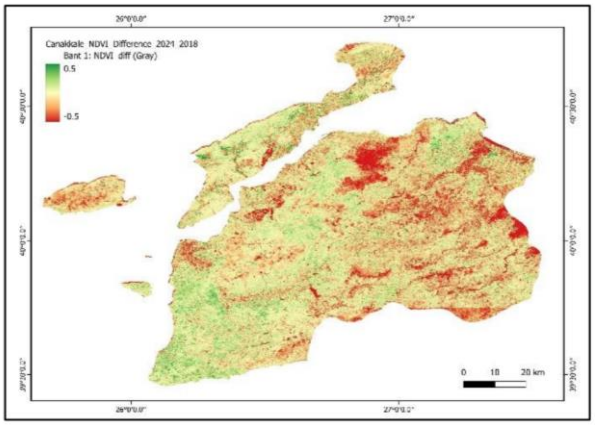

**Şekil 3.** 2024-2018 NDVI Fark Haritası

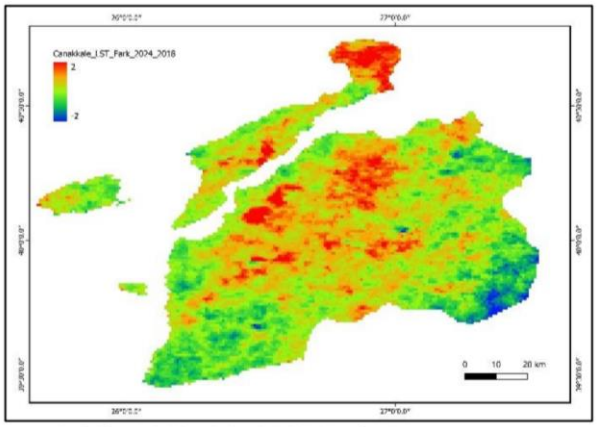


**Şekil 4.** 2024-2018 LST Fark Haritası

Şekil 2.'de verilen SPI fark haritası incelendiğinde, değerlerin 0 ile -1 arasında değiştiği görülmektedir. İlin kuzey kesimlerinde, özellikle Gelibolu Yarımadası'nın kuzey bölümünde koyu kırmızı tonların hakim olduğu, dolayısıyla en yüksek SPI değişim değerlerinin bu bölgede yoğunlaştığı tespit edilmiştir. Güney kesimlere doğru gidildikçe açık kırmızı tonların artması, SPI değerlerindeki negatif değişimin nispeten azaldığını göstermektedir. Gökçeada'da ise en açık kırmızı tonların gözlemlenmesi, ada bölgesinde SPI değişiminin daha az olduğuna işaret etmektedir.

Şekil 3'te verilen NDVI fark haritası incelendiğinde, -0.5 ile 0.5 arasında değişen değerler gözlemlenmiştir. İlin güneybatı kesimlerinde yeşil tonların hakim olduğu, dolayısıyla pozitif NDVI değişiminin yoğunlaştığı tespit edilmiştir. Buna karşın, ilin kuzeydoğu kesimlerinde ve özellikle merkez bölgesinde kırmızı tonların baskın olduğu, negatif NDVI değişiminin belirgin olduğu görülmektedir.

Şekil 4'te verilen LST fark haritası, bölge genelinde önemli bir mekansal değişkenlik göstermektedir. Kuzey yarımada baskın şekilde yüksek pozitif sıcaklık farklarına sahip olup, bu alanda 2°C'ye varan belirgin bir ısınma eğilimi görülmektedir. Merkezi kısımlar, orta düzeyde ısınma ile daha yoğun sıcaklık artışı gösteren bölgelerin karışık bir desenini sergilemektedir. Haritanın güney ve güneydoğu kesimleri daha serin eğilimler göstermekte olup, bazı alanlarda bu altı yıllık dönemde -2°C'ye kadar sıcaklık düşüşleri yaşanmıştır.

## 4. TARTIŞMA

Çanakkale ili genelinde 2018-2024 yılları arasındaki kuraklık analizi önemli eğilimler göstermektedir. SPI değerlerinin ilin kuzey kesimlerinde düşüş göstermesi, Gelibolu Yarımadası'nın meteorolojik kuraklığa karşı hassasiyetinin arttığını işaret ediyor. Bu bulgu, Türkeş vd. (2020)'nin Türkiye'nin batı bölgelerindeki yağış rejimi değişimleriyle uyumludur.

NDVI değerlerinde mekansal farklılaşma görülmektedir. Güneybatıda gözlenen NDVI artışı muhtemelen tarımsal faaliyetlerden kaynaklanırken, kuzeydoğudaki azalış AghaKouchak vd. (2015)'in vurguladığı bitki stresi-kuraklık ilişkisiyle açıklanabilir.

LST değerlerindeki mekansal desen, Kurnaz ve Öztürk (2019)'ün belirttiği ısı adası etkisi ve arazi örtüsü değişimi ilişkisini destekliyor. Kuzey yarımadadaki 2°C'ye varan ısınma eğilimi, Sheffield vd. (2014)'nin vurguladığı kuraklık-termal anomali etkileşimiyle uyumludur.

Çalışmadaki dört kuraklık parametresi arasındaki ilişkiler, Vicente-Serrano vd. (2013)'nin çoklu parametre yaklaşımının etkinliğini göstermektedir. LST-NDVI arasındaki negatif korelasyon bitki örtüsünün termal düzenleme etkisini, SPI-SMCI arasındaki pozitif ilişki ise meteorolojik kuraklığın toprak nemi üzerindeki etkisini ortaya koymaktadır. Bu bulgular, Du vd. (2013) ve Quiring ve Ganesh (2010)'in çalışmalarındaki mevsimsel ve zamansal ilişkilerin önemini doğrulamaktadır.

## 5. SONUÇ

Çalışmada, Çanakkale ilinin 2018-2024 yılları arasındaki kuraklık dinamikleri uzaktan algılama parametreleriyle analiz edilmiştir. Bulgular, bölgenin kuraklık hassasiyetinde zamansal ve mekansal farklılaşmalar olduğunu göstermektedir.

SPI değerlerindeki analizler, özellikle ilin kuzeyinde artan kuraklık eğilimini işaret etmektedir. 2018'den 2024'e SPI değerlerinin negatif yönde değişmesi, bölgenin meteorolojik kuraklığa karşı hassasiyetinin arttığını gösteriyor.

NDVI analizleri, bitki örtüsünün kuraklığa tepkisinin mekansal olarak heterojen olduğunu ortaya koymaktadır. Güneybatıdaki pozitif NDVI değişimi bu alanların dirençli olduğunu, kuzeydoğudaki negatif değişim ise artan bitki stresini göstermektedir.

LST analizleri, kuzey yarımadada 2°C'ye varan sıcaklık artışlarını ortaya koymuştur. Güney ve güneydoğuda gözlemlenen daha düşük sıcaklık değişimleri, bölgesel iklim dinamiklerinin karmaşıklığını göstermektedir.

Korelasyon analizleri, NDVI ile LST arasında negatif, SPI ile SMCI arasında pozitif ilişki olduğunu göstermiştir. Bu ilişkiler, kuraklık izlemede çoklu parametre yaklaşımının önemini vurgulamaktadır.

Sonuç olarak, çalışma Çanakkale'deki kuraklık parametrelerinin dinamiklerini ortaya koyarak bölgesel iklim değişikliği etkilerinin anlaşılmasına ve sürdürülebilir kaynak yönetimi stratejilerine katkı sağlamaktadır. Gelecek çalışmalarda daha uzun zaman serileri ve ek parametrelerle analizlerin genişletilmesi önerilmektedir.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

### Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

### KAYNAKÇA

AghaKouchak, A., Farahmand, A., Melton, F.S., Teixeira, J., Anderson, M.C., Wardlow, B.D., & Hain, C.R. (2015). Remote sensing of drought: Progress, challenges

and opportunities. Reviews of Geophysics, 53(2), 452-480.

Du, L., Tian, Q., Yu, T., Meng, Q., Jancso, T., Udvardy, P., & Huang, Y. (2013). A comprehensive drought monitoring method integrating MODIS and TRMM data. International Journal of Applied Earth Observation and Geoinformation, 23, 245-253.

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. Remote Sensing of Environment, 202, 18-27.

Gu, Y., Brown, J.F., Verdin, J.P., & Wardlow, B. (2007). A five-year analysis of MODIS NDVI and NDWI for grassland drought assessment over the central Great Plains of the United States. Geophysical Research Letters, 34(6).

Kumar, L., & Mutanga, O. (2018). Google Earth Engine applications since inception: Usage, trends, and potential. Remote Sensing, 10(10), 1509.

Kurnaz, L., & Öztürk, Ş. (2019). Isı Adası Etkisi ve Arazi Örtüsü Değişimleri Arasındaki İlişki: Türkiye Örneği. İklim Değişikliği ve Çevre, 4(2), 78-92.

Lotsch, A., Friedl, M.A., Anderson, B.T., & Tucker, C.J. (2003). Coupled vegetation-precipitation variability observed from satellite and climate records. Geophysical Research Letters, 30(14).

Mishra, A.K., & Singh, V.P. (2010). A review of drought concepts. Journal of Hydrology, 391(1-2), 202-216.

Petropoulos, G.P., Ireland, G., & Barrett, B. (2015). Surface soil moisture retrievals from remote sensing: Current status, products & future trends. Physics and Chemistry of the Earth, Parts A/B/C, 83, 36-56.

Quiring, S.M., & Ganesh, S. (2010). Evaluating the utility of the Vegetation Condition Index (VCI) for monitoring meteorological drought in Texas. Agricultural and Forest Meteorology, 150(3), 330-339.

Sheffield, J., Wood, E.F., Chaney, N., Guan, K., Sadri, S., Yuan, X., ... & Ogallo, L. (2014). A drought monitoring and forecasting system for sub-Sahara African water resources and food security. Bulletin of the American Meteorological Society, 95(6), 861-882.

Türkeş, M., Akgündüz, A. S., & Demirörs, Z. (2020). Türkiye'nin Batı Bölgelerinde Gözlenen Yağış Rejimi Değişimleri ve Kuraklık Olayları. Coğrafi Bilimler Dergisi, 18(1), 1-20.

Vicente-Serrano, S.M., Gouveia, C., Camarero, J.J., Beguería, S., Trigo, R., López-Moreno, J.I., ... & Sanchez-Lorenzo, A. (2013). Response of vegetation to drought time-scales across global land biomes. Proceedings of the National Academy of Sciences, 110(1), 52-57.

Wilhite, D. A., & Glantz, M. H. (1985). Understanding: the Drought Phenomenon: The Role of Definitions. Water International, 10(3), 111–120. https://doi.org/10.1080/02508068508686328

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# AutoGluon Kütüphanesinin Görüntü Sınıflandırmada Kullanımı: AutoML Uygulaması

**Berra Nur Tunç*[1], Ümit Haluk Atasever[1]**

[1]*Erciyes Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Kayseri, Türkiye*

**Anahtar Kelimeler**
Sınıflandırma,
Makine Öğrenimi,
AutoML,
AutoGluon

**ÖZET**

Bu çalışmada hiperspektral görüntülerin sınıflandırılmasında Amazon tarafından geliştirilen açık kaynaklı otomatik makine öğrenimi (AutoML) kütüphanesi AutoGluon'un kullanımını değerlendirmiştir. Hiperspektral görüntüler, her piksel için çok sayıda spektral bantta bilgi içerdiğinden yüksek boyutlu ve karmaşık veri yapılarına sahiptir. Çalışmada kullanılan WHU-Hi-LongKou veri kümesi, 270 spektral banta ve 9 sınıfa sahip olup, %70 eğitim ve %30 test oranında bölünmüştür. Veriler tabular formata dönüştürüldükten sonra AutoGluon kullanılarak otomatik sınıflandırma işlemi gerçekleştirilmiştir. AutoGluon, farklı sınıflandırıcıları (GBM, CatBoost, XGBoost, Rastgele Orman, vb.) otomatik olarak eğitmiş, hiperparametre optimizasyonu uygulamış ve en başarılı modellerden ağırlıklı bir topluluk modeli oluşturmuştur. Model performansı doğruluk, hassasiyet, duyarlılık, F1 skoru ve dengelenmiş doğruluk metrikleriyle değerlendirilmiştir. Elde edilen sonuçlara göre doğrulama setinde %95.10 ve test setinde %94.86 doğruluk oranı elde edilmiştir. Tüm görüntü verisi üzerinde de yüksek sınıflandırma başarısı gözlemlenmiştir.

# Use of AutoGluon Library in Image Classification: An AutoML Application

**Keywords**
Classification,
Machine Learning,
AutoML,
AutoGluon

**ABSTRACT**

This study addresses the problem of hyperspectral image classification using AutoGluon , an open-source automated machine learning (AutoML ) library developed by Amazon. Hyperspectral images contain spectral information across numerous bands for each pixel, making them high-dimensional and complex in terms of classification. The WHU-Hi-LongKou dataset used in this study is a hyperspectral image with 270 spectral bands and 9 classes. The data were tabularized and partitioned into 70% training and 30% test sets, upon which the automatic classification process was conducted using AutoGluon. AutoGluon automatically trains various classifiers, performs hyperparameter optimization, and combines the outputs of the best-performing models into a weighted ensemble model to achieve maximum accuracy. According to the results, an accuracy of 95.10% on the validation set and 94.86% on the test set were achieved, demonstrating that AutoGluon provides high performance on complex datasets.

## 1. GİRİŞ

Veri bilimi ve makine öğrenimi alanlarında tabular verileri üzerinde sınıflandırma sıkça karşılaşılan problemlerden biridir. Klasik modelleme yaklaşımları veri ön işleme, model seçimi, hiperparametrelerin ayarlanması gibi birçok karmaşık aşamayı kapsamaktadır. Bu nedenle makine öğrenimi süreci hem zaman alıcı hem de hatalara açık hale gelmektedir. Otomatik Makine Öğrenimi (AutoML) bu sorunlara çözüm olarak geliştirilmiştir. AutoML (He vd., 2021) klasik makine öğrenimi süreçlerini otomatikleştirmeyi amaçlayan bir yaklaşımdır. Bu yöntem veri ön işleme, model seçimi, hiperparametre ayarlaması ve model değerlendirme gibi aşamaları kullanıcı müdahalesini en aza indirerek modelleme sürecini hızlandırmakta ve daha doğru sonuçlar elde edilmesini sağlamaktadır. Geleneksel süreçlerde zaman alıcı olan işlemler AutoML araçları sayesinde kısa süre içerisinde tamamlanabilmektedir. Bu yönüyle AutoML hem akademik araştırmalarda hem de endüstriyel uygulamalarda önemli bir rol oynamaktadır (Dietterich, 2000).

* **Sorumlu Yazar**

*(berranursen@erciyes.edu.tr) ORCID ID 0009-0003-9063-5439
(uhatasever@erciyes.edu.tr) ORCID ID 0000-0002-3011-9868

**Kaynak Göster (APA):**

Tunç B N & Atasever Ü H (2025). AutoGluon Kütüphanesinin Görüntü Sınıflandırmada Kullanımı: AutoML Uygulaması, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

Amazon Web Services (AWS) tarafından geliştirilen AutoGluon kütüphanesi (Erickson vd., 2020) özellikle tabular veri üzerinde sınıflandırma, regresyon, metin analizi ve görüntü işleme gibi alanlarda kullanılan güçlü bir AutoML kütüphanesidir. AutoGluon'un öne çıkan özelliklerinden biri model geliştirme sürecinin birkaç satır kod ile gerçekleştirilebilmesidir. AutoGluon bu yönü ile hem başlangıç seviyesindeki kullanıcılar hem de ileri düzey veri bilimciler için oldukça etkili bir yol sunmaktadır (Zöller ve Huber, 2021; Erickson vd., 2020). Bu çalışmanın temel amacı ise AutoGluon'un hiperspektral sınıflandırma problemlerindeki etkinliğini ortaya koymak ve gerçekleştirilen uygulama ile bu aracın kapasitesinin değerlendirilmesidir.

## 2. YÖNTEM

Bu çalışmada hiperspektral görüntü sınıflandırması için AutoGluon kütüphanesi kullanılmıştır (Zhong vd., 2020). Veri önişleme aşamasında, üç boyutlu hiperspektral görüntü satır vektörlerine dönüştürülerek tabular (tablolu) veri yapısına getirilmiştir. Böylece veri, AutoGluon gibi makine öğrenimi kütüphanelerinin doğrudan işleyebileceği yapıya uygun hale gelmiştir. Daha sonra veri seti rastgele olarak %70 eğitim ve %30 test olacak şekilde bölünmüştür.

Sınıflandırma işlemi için AutoGluon'un Sınıflandırıcı Modülü kullanılmıştır. Bu modül, kullanıcı müdahalesi olmadan birçok farklı makine öğrenimi algoritmasını otomatik olarak eğitmekte, hiperparametre optimizasyonu gerçekleştirmekte ve en başarılı modellerden oluşan topluluk (ensemble) modeli oluşturarak en yüksek doğruluğu sağlamayı hedeflemektedir. Çalışmada denenen temel sınıflandırıcılar şunlardır: GBM (Gradient Boosting Machine), XGBoost (XGB), CatBoost (CAT), Rastgele Orman (Random Forest-RF), Ekstra Ağaçlar (Extra Trees-XT), K-En Yakın Komşu (KNN) ve Lojistik Regresyon (Logistic Regression-LR). Bu modeller paralel olarak eğitilmiş ve sonuçları karşılaştırılmıştır.

Model değerlendirme sürecinde hem eğitim hem de test veri setleri üzerinde çeşitli performans ölçütleri kullanılmıştır.

### 2.1. Veri Seti

Bu çalışmada sınıflandırma performansının otomatik makine öğrenimi kütüphanesi AutoGluon ile değerlendirilmesinde Whu-Hi-LongKou hiperspektral görüntü veri seti kullanılmıştır.

Veri seti Wuhan Üniversitesi tarafından yayınlanmıştır. Çin'in Shandong eyaletinde yer alan Longkou Limanı bölgesine ait yüksek spektral çözünürlüklü hava fotoğraflarını içermektedir. Veri seti 550 x 400 piksel boyutlarında olup 270 adet spektral bant bilgisi içermektedir. Veri setinde zemin doğrulamasına dayalı olarak etiketlenmiş 9 farklı arazi örtüsü sınıfı bulunmaktadır. Kentsel ve tarımsal alanları yollar, binalar, su kütleleri ve pirinç, mısır ve buğday gibi mahsullerle birleştirmesi nedeniyle arazi örtüsü sınıflandırma çalışmaları için uygun bir yapıya sahiptir. (Zhong vd., 2020).

Çalışmada kullanılan WHU-Hi-LongKou veri setine ait görüntü küpü ve etiketli sınıflandırma haritası Şekil 1'de verilmiştir.

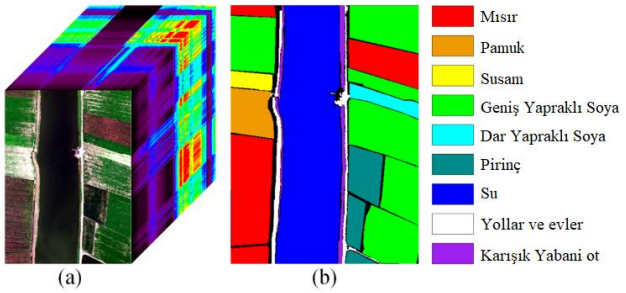


**Şekil 1.** WHU-Hi-LongKou veri seti. (a) Görüntü küpü. (b) Gerçek etiketli görüntü (Zhong vd., 2020).

### 2.2. AutoGluon

Bu çalışmada AutoML (Olson ve Moore, 2016) sürecinin yürütülmesi için AutoGluon tercih edilmiştir. Amazon tarafından geliştirilen bu açık kaynaklı Python kütüphanesi çok çeşitli algoritmalarla birlikte çalışarak modelleri otomatik biçimde eğitip ve değerlendirip en iyi performanslı olanları seçmektedir.

AutoGluon'un (Erickson vd., 2020; Truong ve Tugcu, 2019) öne çıkan bileşeni olan *AutoGluon Sınıflandırıcı Modülü* sınıflandırma ve regresyon problemleri için özelleştirilmiştir. AutoGluon başlıca sınıflandırıcıları otomatik olarak denemektedir. Çeşitli algoritmalar aynı anda eğitilip topluluk öğrenme yöntemleri ile bu modellerin çıktıları birleştirilmekte ve model eğitimi sırasında hiperparametre optimizasyonu otomatik biçimde uygulamaktadır. Sonuçlar bir sıralama tablosu formatında sunulmaktadır. Bu modül sayesinde bu işlemler otomatik olarak gerçekleştirilmektedir. Model eğitimi başlatılıp AutoGluon'un kendi belirlediği optimizasyon algoritmalarıyla tamamlanmaktadır. Analiz sonucunda doğruluk oranı en yüksek olan model tercih edilmektedir. Bu yöntem sayesinde model geliştirme süreci hem sadeleştirilmekte hem de daha yüksek doğruluk oranları elde edilerek model performansı artırılmaktadır (Autogluon, 2025).

### 2.3. Değerlendirme Metrikleri

Model başarımı eğitim ve test veri setleri üzerinde doğruluk, hassasiyet, duyarlılık, F1 skoru ve dengeli doğruluk metrikleri kullanılarak değerlendirilmiştir. Doğruluk modelin doğru sınıflandırdığı örneklerin oranını, hassasiyet modelin pozitif sınıfı doğru sınıflandırma yeteneğini, duyarlılık gerçek pozitiflerin ne kadarını doğru tahmin ettiğini, F1 skoru hassasiyet ve duyarlılık değerlerinin dengeli ortalamasını, dengelenmiş doğruluk ise her sınıf için doğruluk ortalamasını ifade etmektedir. Model başarımının görsel analizi kapsamında oluşturulan doğruluk grafiği ve farklı modellerin eğitim sürelerinin karşılaştırılması şeklinde analizler gerçekleştirilmiştir (Ke vd., 2017).

## 3. BULGULAR

Elde edilen bulgular modelin eğitim ve test veri setleri daha sonrasında tüm görüntü üzerinde gerçekleştirilen değerlendirmeler sonucunda oldukça başarılı sonuçlar elde edildiğini göstermektedir. Analiz sonucunda elde edilen eğitim ve test verilerine ait metrikler Çizelge 1 ve 2'de, tüm görüntü verilerine ait metrikler ise Çizelge 3'de verilmiştir.

**Çizelge 1.** Eğitim verisine ait sınıflandırma modellerinin performans metrikleri

| Model | Doğruluk | Hassasiyet | Duyarlılık | F1 skoru | Dengelenmiş doğruluk |
|---|---|---|---|---|---|
| GBM | 0,9946 | 0,9945 | 0,9946 | 0,9945 | 0,9910 |
| CAT | 0,9788 | 0,9786 | 0,9788 | 0,9781 | 0,9621 |
| RF | 0,9954 | 0,9954 | 0,9954 | 0,9954 | 0,9913 |
| XT | 0,9818 | 0,9818 | 0,9818 | 0,9812 | 0,9616 |
| KNN | 0,9418 | 0,9397 | 0,9418 | 0,9395 | 0,8750 |
| LR | 0,8988 | 0,8933 | 0,8988 | 0,8948 | 0,7702 |
| XGB | 0,9936 | 0,9936 | 0,9936 | 0,9935 | 0,9895 |

**Çizelge 2.** Test verisine ait sınıflandırma modellerinin performans metrikleri

| Model | Doğruluk | Hassasiyet | Duyarlılık | F1 skoru | Dengelenmiş doğruluk |
|---|---|---|---|---|---|
| GBM | 0,9479 | 0,9458 | 0,9479 | 0,9460 | 0,8907 |
| CAT | 0,9486 | 0,9465 | 0,9486 | 0,9463 | 0,8931 |
| RF | 0,9424 | 0,9404 | 0,9424 | 0,9400 | 0,8734 |
| XT | 0,9373 | 0,9357 | 0,9373 | 0,9335 | 0,8528 |
| KNN | 0,9227 | 0,9191 | 0,9227 | 0,9190 | 0,8313 |
| LR | 0,9001 | 0,8937 | 0,9001 | 0,8953 | 0,7745 |
| XGB | 0,9482 | 0,9462 | 0,9482 | 0,9464 | 0,8933 |

**Çizelge 3.** Tüm görüntü verisine ait sınıflandırma modellerinin performans metrikleri

| Model | Doğruluk | Hassasiyet | Duyarlılık | F1 skoru | Dengelenmiş doğruluk |
|---|---|---|---|---|---|
| GBM | 0,9922 | 0,9922 | 0,9922 | 0,9921 | 0,9860 |
| CAT | 0,9773 | 0,9771 | 0,9773 | 0,9766 | 0,9587 |
| RF | 0,9928 | 0,9927 | 0,9928 | 0,9927 | 0,9854 |
| XT | 0,9796 | 0,9795 | 0,9796 | 0,9789 | 0,9562 |
| KNN | 0,9408 | 0,9387 | 0,9408 | 0,9385 | 0,8728 |
| LR | 0,8989 | 0,8933 | 0,8989 | 0,8949 | 0,7704 |
| XGB | 0,9913 | 0,9913 | 0,9913 | 0,9912 | 0,9847 |

Şekil 2'de verilen doğruluk metriğine ait grafik incelendiğinde modelin genel sınıflandırma başarısının yüksek olduğu ve farklı modeller arasında tutarlı performans sergilediği görülmüştür.

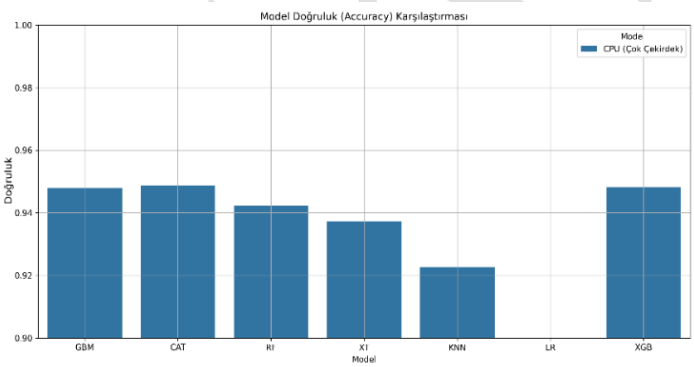


**Şekil 2.** Sınıflandırma modellerinin doğruluk performans karşılaştırması

AutoGluon farklı modellerin güçlü yönlerini bir araya getirerek daha kararlı ve yüksek doğrulukta sonuçlar üretmeyi amaçlayan ve en iyi performans gösteren modellerin tahminlerini ağırlıklı olarak birleştirerek bir meta model oluşturmaktadır. Bu çalışmada Ağırlıklı Topluluk Modeli doğrulama verisinde %95.10 test verisinde ise %94.86 şeklinde yüksek doğruluk elde etmiştir.

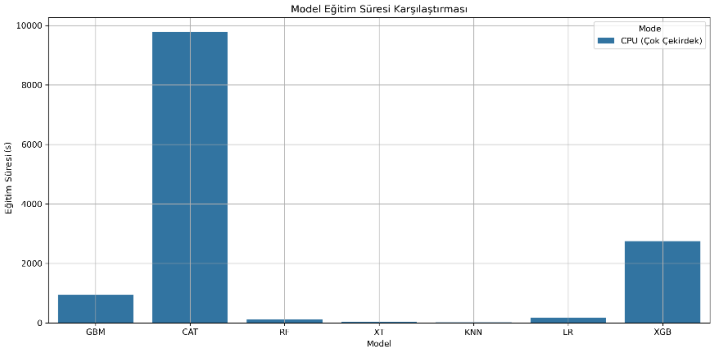


**Şekil 3.** Sınıflandırma modellerinin eğitim süresi karşılaştırması

Şekil 3 modellerin eğitim süresi açısından karşılaştırmasını göstermektedir. CatBoost modelinin hiperparametre ayarlaması ve modelin detaylı hesaplama gereksinimleri sebebiyle eğitim süresi oldukça yüksektir.

Şekil 4'de görüntü verisine ait gerçek etiketler ve AutoGluon'un en iyi tahmini sonucu elde ettiği sınıflandırılmış görüntünün karşılaştırması verilmiştir. Şekle bakıldığında modelin genel yapıyı ve sınıf dağılımını başarılı şekilde elde etmiş ve özellikle ana bölgelerdeki sınıflandırma ile gerçek etiketler arasında yüksek tutarlılık sağlanmıştır.

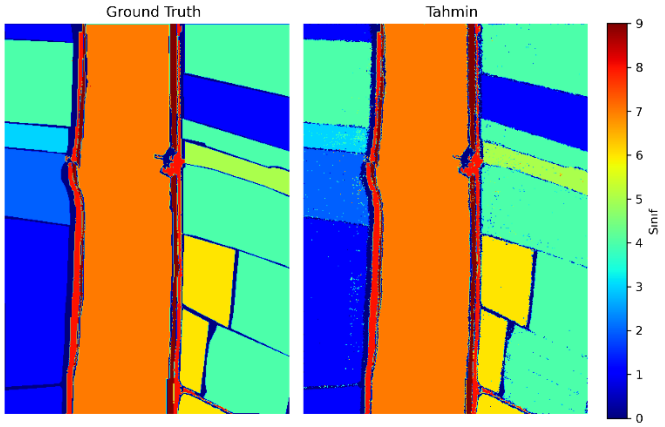


**Şekil 4.** Gerçek etiketler (gt) ve model tahminlerinin görsel karşılaştırması

Eğitim aşamasındaki sonuçlar modelin öğrenme sürecinde güvenilir bir yapı sergilediğini ve test aşamasındaki sonuçlar ise modelin genelleme yeteneğinin başarılı olduğunu göstermektedir. Elde edilen bulgular AutoGluon tabanlı sınıflandırma modellerinin yüksek doğruluk ve tutarlı sonuçlar sağladığını ortaya koymaktadır.

## 4. TARTIŞMA

AutoGluon'un (Feurer ve Hutter, 2019) sunduğu en önemli avantajlardan biri kapsamlı bir model havuzu ve otomatik hiperparametre optimizasyonunu entegre bir biçimde sunmasıdır. AutoGluon arka planda çok sayıda güçlü sınıflandırıcıyı paralel olarak eğiterek en iyi sonucu veren modelleri belirler ve bu modellerin kombinasyonunu kullanarak yüksek doğruluğa ulaşmayı hedeflemektedir. Model eğitimi sırasında oluşan performans tablosu her bir modelin doğruluk ve eğitim

süresi gibi metrikler açısından karşılaştırılmasını gerçekleştirmiştir (Erickson vd., 2020).

Bu çalışmada elde edilen sonuçlar AutoGluon'un karmaşık sınıflandırma problemleri karşısındaki güçlü performansını açık bir şekilde ortaya koymaktadır. Hem eğitim ve test hem de tüm görüntü verisi üzerinde yüksek sınıflandırma doğruluğu elde edilmiştir.

## 5. SONUÇ

Bu çalışma çok bantlı görüntü verilerinin sınıflandırılması problemine modern ve otomatik bir bakış açısı sunmayı amaçlamıştır. Bu amaç doğrultusunda AutoGluon kütüphanesi kullanılarak bir sınıflandırma modeli geliştirilmiştir. Modelleme süreci boyunca AutoGluon'un sunduğu otomatikleştirilmiş yapı geleneksel makine öğrenmesi yöntemlerine kıyasla daha verimli bir geliştirme süreci sağlamış ve hem eğitim hem de test verileri üzerinde yüksek performans elde edilmiştir. Elde edilen sonuçlar sınıflandırma açısından modelin güvenilir, istikrarlı ve kararlı çıktılar sunduğunu ortaya koymaktadır.

AutoGluon'un sınıflandırma görevlerindeki başarısı farklı model türlerini bir araya getirerek oluşturduğu topluluk öğrenmesi yaklaşımından kaynaklanmaktadır. Bu durum özellikle sınıf sayısı fazla olan, örnek dağılımı dengesiz veya bant sayısı yüksek olan veri kümelerinde önemli avantajlar sağlamaktadır.

Bu çalışmanın sunduğu başarılı sonuçlar AutoGluon'un özellikle tabular yapıdaki görüntü verilerinde etkili bir sınıflandırma aracı olduğunu göstermektedir. Bu analiz yalnızca sınıflandırma doğruluğu ve eğitim süresi açısından değerlendirilmiştir. Gelecek çalışmalarda farklı veri boyutlarında performans testleri yapılabilir ve AutoGluon'un ölçeklenebilirliği değerlendirilebilir. Sonuç olarak bu çalışma AutoGluon'un hem akademik hem de pratik sınıflandırma problemleri için güvenilir, hızlı ve etkili bir çözüm sunduğunu göstermektedir.

### Yazar Katkı Oranı

**Berra Nur Tunç:** Literatür taraması, Kodlama, Makale yazımı
**Ümit Haluk Atasever:** Metot düzenleme, Kodlama, Makale yazımı

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

### KAYNAKÇA

AutoGluon, (2025). [Erişim tarihi: 12.01.2025], https://auto.gluon.ai/dev/index.html

Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining (pp. 785-794).

Dietterich, T. G. (2000). Ensemble methods in machine learning. In International workshop on multiple classifier systems (pp. 1–15). Springer.

Erickson, N., Mueller, J., Zhang, H., Larroy, P., Li, M., & Smola, A. (2020). AutoGluon-Tabular: Robust and Accurate AutoML for Structured Data. arXiv preprint arXiv:2003.06505.

Feurer, M., & Hutter, F. (2019). Hyperparameter Optimization. In Automated Machine Learning (pp. 3–33). Springer.

He, X., Zhao, K., & Chu, X. (2021). AutoML: A survey of the state-of-the-art. Knowledge-Based Systems, 212, 106622.

Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., ... & Liu, T. Y. (2017). LightGBM: A highly efficient gradient boosting decision tree. Advances in Neural Information Processing Systems, 30.

Lundberg, S. M., & Lee, S.-I. (2017). A Unified Approach to Interpreting Model Predictions. In Advances in Neural Information Processing Systems (pp. 4765–4774).

Olson, R. S., & Moore, J. H. (2016). TPOT: A Tree-based Pipeline Optimization Tool for Automating Machine Learning. In Workshop on Automatic Machine Learning (pp. 66–74).

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... & Duchesnay, É. (2011). Scikit-learn: Machine Learning in Python. Journal of Machine Learning Research, 12, 2825–2830.

Truong, A., Walters, A., & Tugcu, N. (2019). Towards automated machine learning: Evaluation and comparison of AutoML approaches and tools. arXiv preprint arXiv:1908.00709.

Waring, J., Lindvall, C., & Umeton, R. (2020). Automated machine learning: Review of the state-of-the-art and opportunities for healthcare. Artificial Intelligence in Medicine, 104, 101822.

Zhong Y, Hu X, Luo C, Wang X, Zhao J, Zhang L (2020). WHU-Hi: UAV-borne hyperspectral with high spatial resolution (H2) benchmark datasets and classifier for precise crop identification based on deep convolutional neural network with CRF. Remote Sensing of Environment 250:112012

Zöller, M. A., & Huber, M. F. (2021). Benchmark and Survey of Automated Machine Learning Frameworks. Journal of Artificial Intelligence Research, 70, 409–472

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Yangınların Coğrafi Dinamikleri: Gelibolu Yarımadası'nda Uzaktan Algılama ve CBS ile Analizi

**Seda Çakır*[1], Mesut Doğan[2]**

[1]İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Coğrafya Bölümü, İstanbul, Türkiye
[2]İstanbul Üniversitesi, Edebiyat Fakültesi, Coğrafya Bölümü, İstanbul, Türkiye

**Anahtar Kelimeler**
Coğrafi Bilgi Sistemleri,
Uzaktan Algılama,
Yangın Risk Haritaları,
Çanakkale,
Gelibolu,

**ÖZET**

Gelibolu Yarımadası, Çanakkale ilinin batısında, Eceabat ilçesinin büyük bir kısmını kapsar ve Çanakkale Boğazı'nın Avrupa yakasında yer alır. Saha stratejik olarak büyük bir öneme sahiptir. Bölge, engebeli dağlık yapısı ve zengin bitki örtüsü ile özellikle yaz aylarındaki sıcak, kuru yaz iklimiyle dikkat çeker. Söz konusu bu doğal özellikler, aynı zamanda bölgenin yangın riskini artıran temel faktörleri arasında yer alır. Bu çalışma, yangınların coğrafi dinamiklerini uzaktan algılama teknolojileri ve Coğrafi Bilgi Sistemleri (CBS) kullanarak inceleyecektir. Çalışmada kullanılan temel verilerden olan MODIS ve Landsat uydu verileriyle yangınların coğrafi dağılımı ve zamansal değişimleri analiz edilerek etki alanları haritalanacaktır. Doğal faktörler (topografya, iklim) ve beşerî faktörler (arazi kullanımı, tarım alanları, altyapı, nüfus yoğunluğu ve insan kaynaklı yangın nedenleri) dikkate alınarak yangın risk haritaları oluşturulacak ve riskli bölgelerde yangın öncesi hazırlıklar değerlendirilecektir. Yangınların çevresel etkileri, Normalized Difference Vegetation Index (NDVI) ile biyoçeşitlilikteki değişimler ve Normalized Burn Ratio (NBR) ile yanma şiddeti analiz edilerek etki alanları belirlenecektir. Bu haritalar, riskli bölgelerde yangınları önlemek ve yangının zararlı etkilerini azaltmak amacıyla yeni ve sürdürülebilir stratejilerin de geliştirilmesine yardımcı olacaktır. Ayrıca, arazi kullanım verileri ve bitki örtüsü türleri incelenerek yangın riski taşıyan alanlar da tespit edilecek, yangın öncesi ve sonrası arazi durumu karşılaştırılacaktır. Yangın sonrası yapılan analizlerle, çalışma sahasında bulunan bitki ve hayvanların biyoçeşitlilik açısından kayıpları ve yanma şiddetine bağlı çevresel etkiler de incelenecektir. Ayrıca, yangın bariyerleri, alternatif yangın müdahale yolları, erken uyarı sistemleri ve acil toplanma alanları gibi müdahale yöntemleri değerlendirilecektir. Bu çalışmanın sonucunda elde edilen çıktıların, bölgenin doğal zenginliklerini koruyarak yangın sonrası kayıpları en aza indirmesi amaçlanmaktadır.

# Geographic Dynamics of Wildfires: Remote Sensing and GIS Analysis in the Gallipoli Peninsula

**Keywords**
Geographic Information Systems (GIS),
Remote Sensing,
Fire Risk Maps,
Çanakkale,
Gelibolu

**ABSTRACT**

The Gallipoli Peninsula is located to the west of Çanakkale province, encompassing a large part of the Eceabat district and situated on the European side of the Dardanelles Strait. The area holds significant strategic importance. The region stands out with its rugged mountainous terrain, rich vegetation, and particularly the hot, dry summer climate. These natural features are also among the main factors that increase the fire risk in the region. This study will examine the geographical dynamics of wildfires using remote sensing technologies and Geographic Information Systems (GIS). The primary data used in the study, including MODIS and Landsat satellite data, will be analyzed to map the geographical distribution and temporal changes of wildfires. Natural factors (topography, climate) and human factors (land use, agricultural areas, infrastructure, population density, and human-caused fire reasons) will be taken into account to create fire risk maps, and wildfire preparedness in high-risk areas will be evaluated. The environmental impacts of wildfires, including changes in biodiversity through the Normalized Difference Vegetation Index (NDVI) and burn intensity through the Normalized Burn Ratio (NBR), will be analyzed to determine their affected areas.

These maps will assist in the development of new and sustainable strategies to prevent wildfires and reduce their harmful effects in high-risk areas. Additionally, land use data and vegetation types will be examined to identify areas at fire risk, and pre- and post-fire land conditions will be compared. Post-fire analyses will also assess biodiversity losses in plant and animal species and the environmental effects related to burn intensity in the study area. Furthermore, intervention methods such as fire barriers, alternative fire response routes, early warning systems, and emergency assembly areas will be evaluated. The outcome of this study aims to minimize post-fire losses while preserving the region's natural resources.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Stereo Uydu Görüntülerinden Disparite Haritası Üretimi: RAFTStereo ve More Global Matching (MGM) Yöntemlerinin Karşılaştırması

**Yazgı Nur Sayın*[1,2], Ali Özgün Ok[1]**

[1]*Hacettepe Üniversitesi. Mühendislik Fakültesi, Harita Mühendisliği, Ankara, Türkiye*
[2]*TÜBİTAK Uzay Teknolojileri Araştırma Enstitüsü, ODTÜ Yerleşkesi, Ankara, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Fotogrametri
Derin Öğrenme,
Disparite Haritası,
Uydu Görüntü İşleme

**ÖZET**

Uydu görüntülerinden disparite haritası üretmek için stereo eşleme teknikleri kullanılır. Bu teknikler, stereo uydu görüntü çiftleri arasındaki piksellerin yatay yöndeki kaymalarını (dispariteyi) hesaplayarak 3 boyutlu yükseklik modelleri üretmeye olanak tanır. Disparite haritaları, özellikle coğrafi bilgi sistemleri (GIS) ve uzaktan algılama uygulamalarında yüksek çözünürlüklü yüzey modellerinin elde edilmesinde yaygın olarak kullanılmaktadır. Bu haritalar, arazi analizi, şehir planlaması ve çevresel izleme gibi birçok farklı alanda kullanılabilir. Bu çalışmada, stereo görüntülerden disparite haritası üretmek amacıyla kullanılan iki farklı yöntem, RAFTStereo ve More Global Matching (MGM), karşılaştırılmaktadır. RAFTStereo, derin öğrenme tabanlı bir yöntem olup, iteratif akış tahmini mekanizmasıyla hassas ve yoğun disparite haritaları üretir. Öte yandan, MGM optimizasyon tabanlı bir yaklaşım benimseyerek hesaplama maliyetlerini düşürmeyi amaçlar. Çalışma, her iki yöntemin teorik altyapılarını, algoritma yapılarını, avantajlarını ve dezavantajlarını detaylı şekilde incelemektedir. Deneysel sonuçlar, MGM'nin yüksek doğruluk sağladığını, RAFTStereo'nun ise hesaplama verimliliği açısından daha avantajlı olduğunu göstermektedir. Bu karşılaştırma, her iki yöntemin kullanım alanlarına göre seçim yapmada yardımcı olabilecek önemli bilgiler sunmaktadır.

# Disparity Map Generation from Stereo Satellite Images: A Comparison of RAFTStereo and More Global Matching (MGM) Methods

**Keywords**
Remote Sensing,
Photogrammetry,
Deep Learning,
Disparity Map,
Satellite Image Processing

**ABSTRACT**

Stereo matching techniques are used to generate disparity maps from satellite images. These techniques enable the creation of 3D elevation models by calculating the horizontal shifts (disparity) between pixels of stereo satellite image pairs. Disparity maps are widely used in geographic information systems (GIS) and remote sensing applications to obtain high-resolution surface models. This study compares two different methods used for generating disparity maps from stereo images: RAFTStereo and More Global Matching (MGM). RAFTStereo, a deep learning-based method, generates precise and dense disparity maps through an iterative flow estimation mechanism. On the other hand, MGM adopts an optimization-based approach aiming to reduce computational costs. The study thoroughly examines the theoretical foundations, algorithm structures, advantages, and disadvantages of both methods. Experimental results show that MGM provides high accuracy, while RAFTStereo is more advantageous in terms of computational efficiency. This comparison offers valuable insights that can help in selecting the appropriate method based on specific application needs.

* **Sorumlu Yazar**

*(yazgisayin@gmail.com) ORCID ID 0009-0004-5367-9405
(ozgunok@hacettepe.edu.tr) ORCID ID 0000-0001-6538-9633

**Kaynak Göster (APA):**

Sayın Y N & Ok A Ö (2025). Stereo Uydu Görüntülerinden Disparite Haritası Üretimi: RAFTStereo ve More Global Matching (MGM) Yöntemlerinin Karşılaştırması, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

TAM METİN

## 1. GİRİŞ

Stereo görüntü analizi bilgisayarlı görü, robotik, coğrafi bilgi sistemleri ve uzaktan algılama gibi birçok alanda önemli bir rol oynamaktadır. Disparite haritaları, stereo görüntü çiftlerinden derinlik bilgisini çıkarmak için kullanılır ve 3 boyutlu modelleme ile arazi haritalama gibi uygulamalarda kritik bir öneme sahiptir. Semi-Global Matching (SGM) ve More Global Matching (MGM) gibi geleneksel yöntemler, optimize edilmiş maliyet fonksiyonları ile doğruluğu artırmayı hedeflerken, derin öğrenme tabanlı yöntemler bu süreci daha genelleyici ve ölçeklenebilir hale getirmektedir. RAFTStereo, stereo eşleme için derin öğrenme tabanlı yaklaşımların en güncellerinden biri olup, iteratif bir yapı ile doğruluğu artırmaktadır. Bu çalışmada, MGM ve RAFTStereo yöntemleri detaylı olarak incelenmiş, avantaj ve dezavantajları tartışılmış ve deneysel sonuçlar sunulmuştur.

## 2. YÖNTEM

Bu çalışmada, Gaofen-7 uydusuna ait stereo görüntüler kullanılarak MGM ve RAFTStereo yöntemleri karşılaştırılmıştır. İlk olarak, uydu görüntülerine epipolar rektifikasyon uygulanarak stereo eşleşme için gerekli hizalama sağlanmıştır. Daha sonra, her iki yöntem kullanılarak disparite haritaları üretilmiş ve sonuçların doğruluğunu artırmak için çeşitli ön işleme adımları gerçekleştirilmiştir. MGM ve RAFTStereo modelleri, belirlenen eğitim veri kümesi üzerinde eğitilmiş ve sonrasında doğruluk analizi yapılmıştır.

### 2.1. RAFTStereo

RAFTStereo, Recurrent All-Pairs Field Transforms (RAFT) modelinin stereo uyarlamasıdır. Model, Özellik Çıkarımı, Maliyet Hacmi Oluşturma, Tekrarlamalı Güncelleme Modülü ve Son Disparite Tahmini bileşenlerinden oluşmaktadır. RAFTStereo'nun temel işlem adımları şunlardır:

**Özellik Çıkarımı:** Giriş stereo görüntüleri, derin özellik çıkarım ağı ile işlenerek karşılaştırılabilir temsil vektörleri oluşturulur.

**Maliyet Hacmi Oluşturma**: Özellik haritalarından maliyet hacmi oluşturularak başlangıç disparite tahmini yapılır.

**Tekrarlamalı Güncelleme Modülü**: Long Short-Term Memory (LSTM) tabanlı bir tekrar mekanizması ile iteratif olarak disparite tahmini iyileştirilir.

**Son Disparite Tahmini:** Son iterasyonun çıktısı, nihai disparite haritası olarak kullanılır.

RAFTStereo, yüksek doğruluk ve detay seviyesine sahip tahminler üretebilir. Ancak, eğitim sırasında yüksek hesaplama maliyeti nedeniyle gerçek zamanlı uygulamalar için uygun olmayabilir.

### 2.2. More Global Matching (MGM)

Semi-Global Matching (SGM) yöntemi, disparite hesaplamasında genellikle birkaç tarama hattındaki pikselleri dikkate alır. Buna karşın, More Global Matching yöntemi, önceki tarama hattında ziyaret edilen düğümlerden gelen bilgiyi entegre ederek disparite haritasındaki iz hatalarını ortadan kaldırmayı hedefleyerek disparite harita tahmininin tutarlılığını artırmak için geliştirilmiştir. MGM'nin temel adımları şunlardır:

**Yerel Maliyet Hesaplama:** Piksel bazında eşleşme maliyetleri belirlenir.

**Maliyet Yayılımı:** Sekiz farklı yönde maliyet yayılımı gerçekleştirilerek pürüzsüzlük sağlanır.

**Disparite Tahmini:** Minimum maliyet fonksiyonuna göre en uygun disparite değeri atanır.

**Son İşleme:** Gürültü azaltma ve boşluk doldurma işlemleri uygulanarak sonuç iyileştirilir.

MGM'nin avantajı, hesaplama maliyetini düşük tutarak daha doğru ve dengeli sonuçlar üretebilmesidir.

## 3. BULGULAR

Deneysel sonuçlar, MGM'nin RAFTStereo'ya göre daha doğru ve dengeli disparite haritaları ürettiğini göstermektedir. MGM, daha düşük hesaplama maliyeti ile daha kararlı ve gürültüsüz sonuçlar sağlamaktadır. RAFTStereo ise yoğun disparite haritaları üretse de, bazı durumlarda hata oranlarının arttığı ve eğitim sırasında hesaplama süresinin görece uzun olduğu belirlenmiştir. MGM'nin, yüksek doğruluk oranı ve daha dengeli tahminleriyle daha başarılı olduğu sonucuna varılmıştır. Şekil 1'de referans disparite, MGM ve RAFTStereo yöntemleriyle oluşturulmuş disparite haritaları görülmektedir.

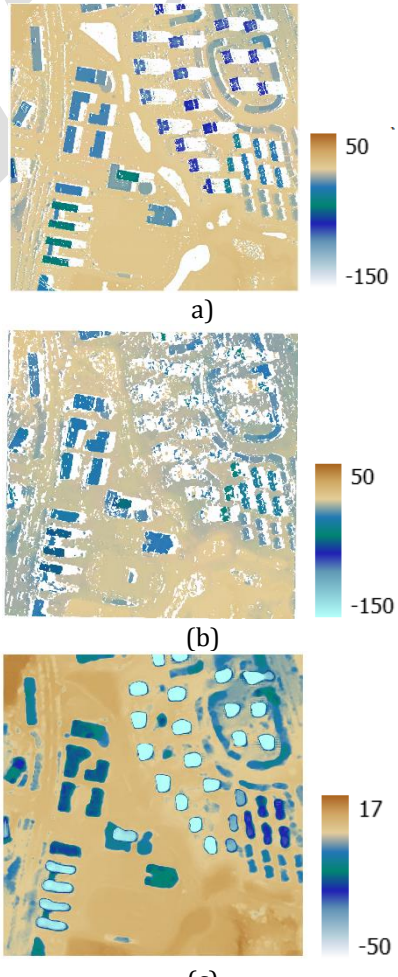


**Şekil 1.** (a) Referans disparite haritası, (b) MGM ile oluşturulmuş disparite haritası, (c) RAFTStereo ile oluşturulmuş disparite haritası.

TAŞLAK

## 4. TARTIŞMA

RAFTStereo, derin öğrenme tabanlı bir yöntem olarak yoğun tahmin yapabilme avantajına sahip olsa da, MGM'nin daha başarılı sonuçlar ürettiği görülmüştür. Özellikle, MGM'nin hesaplama maliyetini düşük tutarak hem hız hem de doğruluk açısından üstünlük sağladığı gözlemlenmiştir. RAFTStereo, yüksek GPU gereksinimi ve uzun işlem süresi nedeniyle bazı uygulamalarda verimsiz kalmaktadır. MGM ise hesaplama maliyetini optimize ederek, daha düşük donanım gücü gerektiren sistemler için halen uygun bir alternatif sunmaktadır.

## 5. SONUÇ

Bu çalışmada, RAFTStereo ve MGM yöntemleri kullanılarak stereo görüntülerden disparite haritası üretme süreci incelenmiştir. Yapılan deneyler, MGM'nin hem doğruluk hem de hesaplama verimliliği açısından RAFTStereo'ya kıyasla daha üstün olduğunu göstermektedir. MGM, düşük hesaplama maliyetiyle yüksek doğruluk sağlayarak, geniş ölçekli uygulamalar için daha uygun bir seçenek sunmaktadır. Gelecekte, bu yöntemlerin daha da geliştirilerek optimizasyon süreçlerinin iyileştirilmesi ve derin öğrenme teknikleriyle hibrit yaklaşımlar üretilmesi önerilmektedir.

## TEŞEKKÜR

Sunulan çalışma Savunma Sanayii Başkanlığı (SSB) tarafından Savunma Sanayii Yapay Zeka Yetenek Kümelenmesi (SAYZEK) projesi kapsamında desteklenmektedir. Katkılarından dolayı Dr. Gökçe Yıldırım Kalkan'a teşekkürlerimizi sunarız.

### Yazar Katkı Oranı

Bu çalışmada, Yazgı Nur Sayın araştırmaya ait veri işleme, metodoloji geliştirme, analiz ve yazım kısımlarını gerçekleştirmiştir. Prof. Dr. Ali Özgün Ok ise araştırma fikri, danışmanlık ve bildirinin gözden geçirilmesi süreçlerinde katkı sağlamıştır.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

## KAYNAKÇA

Albanwan, H., & Qin, R. (2022). A comparative study on deep-learning methods for dense image matching of multi-angle and multi-date remote sensing stereo-images. The Photogrammetric Record, 37(180), 385-409. https://doi.org/10.1111/phor.12430

Facciolo, G., De Franchis, C., & Meinhardt, E. (2015). MGM: A significantly more global matching for stereovision. In BMVC 2015. DOI : 10.5244/C.29.90

Gómez, A., Randall, G., Facciolo, G., & von Gioi, R. G. (2022). An experimental comparison of multi-view stereo approaches on satellite images. In Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision (pp. 844-853).

Lipson, L., Teed, Z., & Deng, J. (2021, December). Raft-stereo: Multilevel recurrent field transforms for stereo matching. In 2021 International Conference on 3D Vision (3DV) (pp. 218-227). IEEE. DOI: 10.1109/3DV53792.2021.00032

Patil, S., & Guo, Q. (2023). Stellar: a Large Satellite Stereo Dataset for Digital Surface Model Generation. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 48, 433-440. https://doi.org/10.5194/isprs-archives-XLVIII-M-1-2023-433-2023

Patil, S., Comandur, B., Prakash, T., & Kak, A. C. (2019). A new stereo benchmarking dataset for satellite images. arXiv preprint arXiv:1907.04404. https://doi.org/10.48550/arXiv.1907.04404

Patil, S., & Guo, Q. (2023). Stellar: A Large Satellite Stereo Dataset for Digital Surface Model Generation. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 48, 433-440. https://doi.org/10.5194/isprs-archives-XLVIII-M-1-2023-433-2023

Xia, Y., d'Angelo, P., Tian, J., & Reinartz, P. (2020). Dense matching comparison between classical and deep learning based algorithms for remote sensing data. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 43, 521-525. https://doi.org/10.5194/isprs-archives-XLIII-B2-2020-521-2020

Zhang, F., Prisacariu, V., Yang, R., & Torr, P. H. (2019). Ga-net: Guided aggregation net for end-to-end stereo matching. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 185-194).

Zhou, K., Meng, X., & Cheng, B. (2020). Review of stereo matching algorithms based on deep learning. Computational intelligence and neuroscience, 2020(1), 8562323. https://doi.org/10.1155/2020/8562323

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Makine ve Derin Öğrenme Yaklaşımları ile RGB İHA Verilerinden NDVI Haritası Üretimi ve Performans Analizi

**İlyas Aydın*[1], Umut Güneş Sefercik[1]**

[1]*Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği, Kocaeli, Türkiye*

**Anahtar Kelimeler**
İHA,
RGB,
Multispektral,
NDVI,
XGBoost,
MLP

**ÖZET**

İHA teknolojisinin kullanım alanları, gelişen sensör karakteristiklerine paralel olarak her geçen gün genişlemektedir. Özellikle multispektral (MS) kamera sistemlerinin entegrasyonu, bitki sağlığı ve fenolojik gelişim takibi, kuraklık analizi, türler arası ayrım gibi tarımsal uygulamalarda İHA'ların ön plana çıkmasına zemin hazırlamıştır. MS İHA'ların geniş spektral aralıkta veri toplayabilme kabiliyeti, yalnızca görünür bölgedeki bilgiyi sağlayabilen RGB kamera donanımlı İHA'lara kıyasla spektral bilgi temelinde gerçekleştirilen çalışmalarda onları bir adım öne çıkarmaktadır. Ancak, MS İHA'ların yüksek maliyeti ve hava fotoğraflarının radyometrik kalibrasyonu için arazide ve ofis ortamında gereken ek işlemler bu sistemlerin temel kullanıcılar tarafından yaygın kullanımını sınırlamaktadır. Bu çalışmada, Aşırı Gradyan Artırma (XGBoost) ve Çok Katmanlı Algılayıcı (MLP) makine ve derin öğrenme modelleriyle yalnızca RGB İHA hava fotoğraflarının kullanımı temelinde, MS veriye ihtiyaç duymadan, tarımsal uygulamalarda sıklıkla kullanılan Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI) haritalarının üretimi amaçlanmıştır. Üretilen NDVI haritalarının performansı, seçilen çalışma sahasında, MS görüntülerden üretilen referans NDVI haritası ile görsel ve istatistiksel kıyaslama yaklaşımları temelinde değerlendirilmiştir. XGBoost ve MLP modelleri, korelasyon göstergesi olan $R^2$ metriğinde sırasıyla 0.82 ve 0.83, karesel ortalama hata (KOH) metriğinde ise 0.095 ve 0.096 değerleriyle oldukça benzer performans sergilemiştir. Sonuçlar, RGB İHA'ların NDVI haritalandırmadaki dikkate değer potansiyelini ortaya koymuş ve uygulanan yaklaşımların MS görüntülemeye göre daha düşük maliyetli ve etkili bir alternatif sağlayabileceğini göstermiştir.

# NDVI Mapping and Performance Analysis from RGB UAV Data Using Machine and Deep Learning Approaches

**Keywords**
UAV,
RGB,
Multispectral,
NDVI,
XGBoost,
MLP

**ABSTRACT**

The applications of UAV technology continue to expand in parallel with advancements in sensor characteristics. In particular, the integration of multispectral (MS) camera systems has positioned UAVs as a valuable tool in agricultural applications such as plant health and phenological growth monitoring, drought analysis, and distinguishing between species. The ability of MS UAVs to capture data across a wide spectral range makes them superior to RGB-equipped UAVs for spectrally driven analyses. However, the high cost of MS UAVs and the additional field and office processing required for radiometric calibration limit their widespread adoption by general users. This study aims to generate Normalized Difference Vegetation Index (NDVI) maps which are widely used in agricultural applications, using only RGB UAV imagery without the need for MS data. The performance of the generated NDVI maps was evaluated by visually and statistically comparing them with reference NDVI maps derived from MS imagery within the selected study area. The Extreme Gradient Boosting (XGBoost) and Multilayer Perceptron (MLP) models were applied, achieving $R^2$ values of 0.82 and 0.83 and Root Mean Square Error (RMSE) values of 0.095 and 0.096, respectively, demonstrating highly similar performance. The results highlight the considerable potential of RGB UAVs for NDVI mapping, suggesting that the proposed approaches offer a cost-effective and efficient alternative to MS imaging.

* **Sorumlu Yazar**

*(ilyasaydin@gtu.edu.tr) ORCID ID 0000-0002-4071-8063
(sefercik@gtu.edu.tr) ORCID ID 0000-0003-2403-5956

**Kaynak Göster (APA):**

Aydın İ & Sefercik U G (2025). Makine ve Derin Öğrenme Yaklaşımları ile RGB İHA Verilerinden NDVI Haritası Üretimi ve Performans Analizi. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Günümüzde İHA'lar, uzaktan algılama çalışmalarında oldukça geniş kullanım alanına sahiptir. Düşük irtifadan yüksek çözünürlüklü görüntü sağlayabilmeleri, kullanıcı kontrolünde esnek zamansal çözünürlükte veri toplama, hızlı ve pratik çözümler sunma gibi avantajlarıyla özellikle tarımsal uygulamalarda vazgeçilmez bir teknoloji haline gelmiştir. Son yıllarda saha çalışmalarına entegre edilen teknolojik gelişmeler, hassas tarım kavramını ön plana çıkarmış ve İHA'ların bu alandaki potansiyelini artırmıştır.

Hassas tarım uygulamalarında Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI) (Tucker, 1979), bitki sağlığı (Cuaran ve Leon, 2021), tür ayrımı ve kuraklık analizi (Cheng vd., 2023) gibi birçok amaç için yaygın olarak kullanılan önemli bir gösterge niteliğindedir. NDVI haritalarının üretimi genellikle multispektral (MS) sensörlere sahip sistemler gerektirirken, bu tür donanımların yüksek maliyeti, kalibrasyon zorunluluğu ve uzmanlık gerektiren karmaşık veri işleme süreçleri, yaygın kullanımın önünde önemli engeller oluşturmaktadır. Bu nedenle, tarımsal uygulamalarda düşük maliyetli alternatif yöntemlerin geliştirilmesi ve uygulanabilirliğinin araştırılması, önemli bir çalışma alanı haline gelmiştir.

Bu çalışmada, tarımsal uygulamalarda yaygın olarak kullanılan NDVI değerinin yalnızca RGB görüntüler kullanılarak regresyon tabanlı tahmini için makine ve derin öğrenme yaklaşımları geliştirilmiş ve sonuçlar istatistiksel ve görsel analizlerle kapsamlı şekilde değerlendirilmiştir. MS hava fotoğraflarından üretilen NDVI haritası referans veri olarak değerlendirilmiş ve RGB görüntülerden elde edilen NDVI haritasının bu referans ile uyumu baz alınarak doğruluk analizi gerçekleştirilmiştir.

Uygulamada kullanılan Aşırı Gradyan Artırma (XGBoost) ve Çok Katmanlı Algılayıcı (MLP) modelleri ile elde edilen sonuçlar, bu yaklaşımların yalnızca RGB görüntülerin kullanımıyla NDVI değerlerini yüksek doğrulukta tahmin edebildiğini göstermiştir. Elde edilen bulgular, düşük maliyetli RGB İHA'ların NDVI haritalandırmada güçlü bir alternatif sunabileceğini ortaya koymaktadır.

## 2. MATERYAL ve YÖNTEM

Gebze Teknik Üniversitesi kampüsünde yer alan çalışma alanının yüksek çözünürlüklü ortomozaik görüntüsü ve NDVI haritası Şekil 1'de sunulmuştur. Çalışma alanı, zengin arazi örtüsü ve çeşitli arazi kullanımı sınıflarına sahip olması yönüyle birçok araştırma için uygun bir test ortamı sunmaktadır. Doğal ve beşeri unsurları içeren çok sınıflı yapısı, NDVI değeri bakımından geniş bir dağılım sergileyerek çeşitlilik sağlamaktadır. Bu sayede test edilen yaklaşımların performansının genelleştirilebilmesi, günlük problemlerin çözümünde uygulanabilirliği ve tutarlılığı korunmaktadır.

Çalışmada MS ve RGB görüntülerin temininde DJI Phantom 4 MS İHA kullanılmıştır. Bu cihaz, her görüntü çekim anında beş mono bant ve bir RGB kompozit algılayıcı ile eş zamanlı kayıt yaparak altı farklı hava fotoğrafı depolamaktadır. Uygulanan modellerin eğitim ve test veri setinin hazırlanması için 110 m irtifadan 0.06 m yer örnekleme aralığına sahip toplam 4208 hava fotoğrafından oluşan iki ayrı uçuş gerçekleştirilmiştir.




**Şekil 1.** Çalışma alanına ait ortomozaik (üst) ve referans NDVI haritası (alt).

Hava fotoğraflarının işlenmesi, RGB ve MS ortomozaiklerin üretilmesi amacıyla Agisoft Metashape Pro ticari yazılımı kullanılmıştır. MS görüntülerin yakın kızılötesi (YKÖ) ve kırmızı bantları referans NDVI haritasının elde edilmesinde kullanılmıştır (Eşitlik 1). Görüntülerin yöneltme işleminde uçuş öncesi tesis edilen sekiz adet mobil polikarbon malzemeli yer kontrol noktası kullanılmıştır. Bağımsız kontrol noktalarıyla denetlenen nihai fotogrametrik ürünlerin konum doğruluğunun bir piksel seviyesinde olduğu belirlenmiştir.

$$NDVI = \frac{YKÖ - KIRMIZI}{YKÖ + KIRMIZI} \quad (1)$$

Eğitim veri setinin oluşturulmasında, birinci uçuşta elde edilen RGB görüntüler ve ilgili alanların NDVI değerleri kullanılmıştır. Test veri seti ise, eğitim veri setinden bağımsız bir bölgede gerçekleştirilen ikinci uçuşta elde edilen RGB hava fotoğraflarından oluşturulmuştur.

Ağaç tabanlı çalışan XGBoost makine öğrenmesi modeli, gradyan artırma tekniğini kullanarak birden fazla karar ağacını ardışık olarak eğiten ve regresyon problemlerinde yüksek doğruluk sağlayan güçlü bir yöntemdir. Öte yandan, derin öğrenme mimarisine sahip MLP modeli, tam bağlantılı yapay sinir ağlarından oluşur

ve regresyon problemlerinde doğrusal olmayan ilişkileri modelleyerek karmaşık veri desenlerini öğrenebilmektedir. Bu çalışmada, her iki model de yalnızca RGB görüntülerden NDVI değerlerini tahmin etmek amacıyla eğitilmiş ve test veri setinde elde edilen tahmin sonuçları, MS görüntülerden üretilen referans veri ile karşılaştırılmıştır. Model performansı, $R^2$ ve KOH metrikleri kullanılarak değerlendirilmiş ve doğruluk analizi gerçekleştirilmiştir (Eşitlik 2-3). İstatistiksel analizlerin yanı sıra, model tahminlerinin referans veriye uyumunu bölgesel düzeyde inceleyebilmek için diferansiyel NDVI haritası üretilmiştir (Eşitlik 4). Bu harita, farklı alanlarda tahmin edilen NDVI değerleri ile referans NDVI arasındaki farkları görselleştirerek, modelin mekansal doğruluk dağılımını değerlendirmeye olanak tanımaktadır.

$$R^2 = 1 - \frac{\sum(y_i - \hat{y}_i)^2}{\sum(y_i - \bar{y})^2} \quad (2)$$

$$\text{KOH} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2} \quad (3)$$

$$\text{NDVI}_{\text{Differential}} = \text{NDVI}_{\text{Referans}} - \text{NVDI}_{Tahmin} \quad (4)$$

## 3. BULGULAR

Model performans analizinde XGBoost ve MLP modelleri sırasıyla 0.82 ve 0.83 $R^2$ değerleri elde ederken, KOH metrikleri 0.095 ve 0.096 olarak hesaplanmıştır. İstatistiksel analizlerde anlamlı farklar tespit edilmemesine rağmen, diferansiyel NDVI haritalarının görsel değerlendirmesi, özellikle toprak ve bina sınıflarında her iki modelin referans veri ile -0.4'e varan belirgin farklılıklar gösterdiğini ortaya koymuştur. Buna karşın, çalışma alanının genelinin yüksek doğrulukla (±0.06) tasvir edilebildiği belirlenmiştir (Şekil 2). Bu bulgular, model performansının değerlendirilmesinde yalnızca istatistiksel metriklerin yeterli olmayabileceğini ve görsel analizlerin kritik bir tamamlayıcı unsur olduğunu göstermektedir. MLP modeli, söz konusu sınıflar üzerinde daha başarılı tahminler üretmiş olsa da derin öğrenme mimarisine sahip olması nedeniyle optimizasyon ve eğitim süreci, XGBoost modeline kıyasla daha fazla zaman gerektirmektedir.

## 4. SONUÇ

Bu çalışmada, makine ve derin öğrenme yaklaşımlarının RGB veri setindeki NDVI tahmin performansı değerlendirilmiş ve iki farklı regresyon modeli kullanılarak NDVI tahmin haritaları oluşturulmuştur. Sonuç olarak, sürekli gelişen algoritmaların, RGB görüntüler gibi sınırlı spektral bilgiye sahip kaynaklara uygulanmasının tarımsal çalışmalar için umut verici sonuçlar sunabileceği belirlenmiştir. Ayrıca, kullanılan yaklaşımların, yüksek maliyetli MS kameralara erişimi sınırlı olan temel kullanıcı grupları için uygun bir alternatif olabileceği gösterilmiştir.

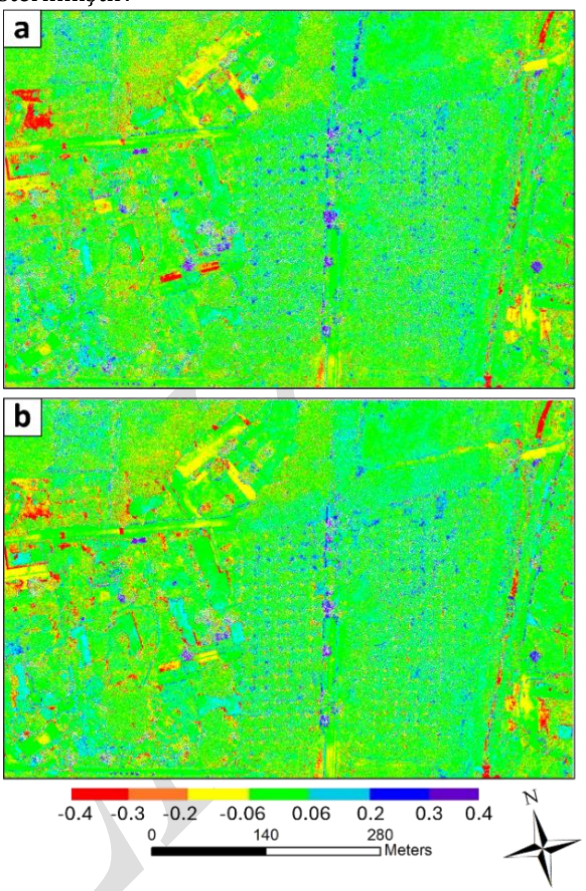


**Şekil 2.** Diferansiyel NDVI haritaları: XGBoost (a), MLP (b).

### Yazar Katkı Oranı

Tüm yazarlar çalışmanın hazırlanmasında eşit oranda katkı sağlamıştır.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

### Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

### KAYNAKÇA

Cheng, M., Sun, C., Nie, C., Liu, S., Yu, X., Bai, Y., ... & Jin, X. (2023). Evaluation of UAV-based drought indices for crop water conditions monitoring: A case study of summer maize. *Agricultural Water Management*, *287*, 108442.

Cuaran, J., & Leon, J. (2021). Crop monitoring using unmanned aerial vehicles: A review. *Agricultural Reviews*, *42*(2), 121-132.

Tucker C J (1979). Red and photographic infrared linear combinations for monitoring vegetation. Remote sensing of Environment, 8(2), 127-150.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Yersel ve Uydu Tabanlı $NO_2$ ve CO Parametrelerinin Sıcaklık ile İlişkisinin İstatistiksel Olarak Değerlendirilmesi: Kocaeli Örneği

**Rümeysa Karataş*[1], Elif Özler[1], Nur Yağmur Aydın[1]**

[1]*Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Kocaeli, Türkiye*

**Anahtar Kelimeler**
Hava Kalitesi,
Sentinel-5P,
Granger Nedensellik Testi,
Uzaktan Algılama

**ÖZET**

Hava kirliliğinin, çevre ve insan sağlığı üzerinde önemli etkileri bulunmaktadır. Kentsel büyüme ve süregelen endüstriyel faaliyetler, hava kalitesinin kötüleşmesinde rol oynamaktadır. CO ve $NO_2$ parametreleri, bu etkilerden en çok etkilenen hava kalite göstergelerindendir. Ancak, yersel hava kalite izleme sistemlerinin sayısının sınırlı olması, bu parametrelerin bölgesel düzeyde izlenmesini zorlaştırmaktadır. Bu çalışmada, yersel ve uydu kaynaklı (Sentinel-5P) verilerin birbiriyle ve sıcaklık ile ilişkisi CO ve $NO_2$ parametreleri özelinde Kocaeli İli için istatistiksel olarak değerlendirilmiştir. Sürekli Hava Kalitesi İzleme Sistemi'nde yer alan 10 istasyonun yedisi $NO_2$ verisinin, üçü ise CO verisinin temininde kullanılırken, uydu verileri Google Earth Engine (GEE) platformu kullanılarak istasyon bazında 2018-2024 yılları için elde edilmiştir. Sıcaklık verileri ise, ERA5-Land uydu verilerinden istasyon bazında GEE üzerinden temin edilmiştir. İstatistiksel analizlerde Pearson korelasyon katsayısı ve zaman serileri arasındaki nedensel ilişkiyi analiz etmek için yaygın olarak tercih edilen Granger Nedensellik Testi kullanılmıştır. Çalışmanın bulguları, iklim değişikliği ve sürdürülebilir çevre yönetimi için uzaktan algılama ve istatistiksel yöntemlerin kullanımının önemini vurgulamaktadır.

# Statistical Evaluation of the Relationship Between Ground-Based and Satellite-Derived $NO_2$ and CO Parameters with Temperature: The Case Study of Kocaeli

**Keywords**
Air Quality,
Sentinel-5P,
Granger Causality Test,
Remote Sensing

**ABSTRACT**

Air pollution significantly impacts the environment and public health, exacerbated by urban growth and industrial activities. CO and $NO_2$ are key indicators affected by these factors. However, the limited number of ground-based air quality monitoring stations poses challenges for regional monitoring. This study evaluates the statistical relationship between ground-based and Sentinel-5P satellite data, focusing on CO and $NO_2$ parameters in Kocaeli Province. Data from seven out of ten Continuous Air Quality Monitoring System stations were used for $NO_2$, and three stations for CO, complemented by satellite data from 2018 to 2024 via the Google Earth Engine (GEE) platform. Temperature data were sourced from ERA5-Land satellite records through GEE. Statistical analyses included Pearson correlation coefficients and the Granger Causality Test, widely preferred for analyzing causal relationships in time series. The findings emphasize the importance of employing remote sensing and statistical methods for climate change mitigation and sustainable environmental management.

## 1. GİRİŞ

Hava kirliliği, halk sağlığı açısından önemli bir risk faktörü olup, hastalık ve ölüm oranlarının önde gelen nedenleri arasında yer almaktadır (Manisalidis vd., 2020). Endüstriyel faaliyetler, fosil yakıtların kullanımı ve biyokimyasal süreçler sonucunda atmosferde zararlı gazların birikimi artmakta ve hava kalitesi gittikçe bozulmaktadır. Azot dioksit ($NO_2$) ve Karbon monoksit (CO) gazları, insan sağlığına etki eden hava kalite parametreleri arasında öne çıkmaktadır. $NO_2$, karayolu trafiği, enerji santralleri ve fosil yakıt veya biyokütle yanma süreçleri sonucunda atmosfere salınan önemli bir kirletici gazdır (Inness vd., 2019) ve solunum yolu hastalıklarını tetiklemektedir. CO renksiz, kokusuz ve tahriş edici olmayan toksik bir gazdır ve odun, benzin, kömür ve doğalgaz gibi karbon içeren yakıtların eksik yanması ile oluşur. CO, solumun sorunlarının yanı sıra baş ağrısı ve yorgunluğa sebep olmaktadır (EPA, 2024).

* **Sorumlu Yazar**

*(r.karatas2019@gtu.edu.tr) ORCID ID 0009-0009-5046-6208
(e-mail) ORCID ID 0009-0000-0519-9897
(nyagmur@gtu.edu.tr) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Karataş R, Özler E & Aydın N Y (2025). Yersel ve Uydu Tabanlı NO2 ve CO Parametrelerinin Sıcaklık ile İlişkisinin İstatistiksel Olarak Değerlendirilmesi: Kocaeli Örneği. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

Hava kalite parametreleri, yer izleme istasyonları ile sürekli olarak yüksek doğrulukta takip edilebilmektedir. Ancak yersel istasyonların nokta bazlı olması ve yer izleme ağının sık olmaması, alansal değerlendirmelerde kısıtlı kalmasına sebebiyet vermektedir. Uydu teknolojileri, geniş kapsama alanı ve tekrarlı veri alımı sayesinde bölgesel analizlerde elverişli olmaktadır ancak yersel veriler kadar yüksek doğruluk sağlayamamaktadır. Literatürde yersel veriler ile uzaktan algılama verilerinin birbiriyle korelasyonunun istasyonlara göre değişkenlik gösterdiğini ifade eden çalışmalar yer almaktadır (Zheng vd., 2018; Vîrghileanu vd., 2020). Ayrıca, mevsimsel hareket sergileyen hava kalite parametrelerinin meteorolojik parametrelerle ilişkisi de yapılan çalışmalarda ortaya konmuştur. Lin vd. (2019) sıcaklığın $NO_2$ ile negatif yönde güçlü bir korelasyona sahip olduğunu ortaya koyarken, Salama vd. (2022) ise $NO_2$'nin sıcaklık ile ilişkisinin zayıf olduğunu ve sıcaklığın $NO_2$ artışının temel etmenlerinden biri olmadığını ifade etmiştir.

Bu çalışmada, Kocaeli İli'nde CO ve $NO_2$ gazlarının yersel ve uydu verileri arasındaki ilişkisine ek olarak mevsimsel hareketliliğinin sıcaklık ile ilişkisi de istasyon bazında incelenmiştir. Bu amaçla, 2018-2024 yılları arasında Google Earth Engine (GEE) platformu kullanılarak elde edilen Sentinel-5P (S5P) uydu verileri ile Çevre, Şehircilik ve İklim Değişikliği Bakanlığı (ÇŞİDB) tarafından servis edilen yersel hava kalitesi istasyon verileri istatistiksel olarak analiz edilerek, uzaktan algılama ve yersel ölçümler arasındaki uyumluluk değerlendirilmiştir. Ayrıca, GEE'den elde edilen ERA5-Land sıcaklık verileri ile yersel ve uydu kaynaklı $NO_2$ ve CO parametreleri arasındaki nedensellik ilişkisi Granger Nedensellik Testi ile analiz edilmiştir.

## 2. ÇALIŞMA ALANI VE KULLANILAN VERİLER

Kocaeli İli, yoğun sanayi ve endüstriyel faaliyetleriyle öne çıkan ve Türkiye'de nüfusun en yoğun olduğu onuncu ildir. Şekil 1'de gösterildiği üzere 12 adet ilçeye sahip olan ilde, 14 adet organize sanayi bölgesi (OSB) bulunmaktadır (URL-1). OSB'ler çoğunlukla İzmit Körfezi çevresinde yer almaktadır.

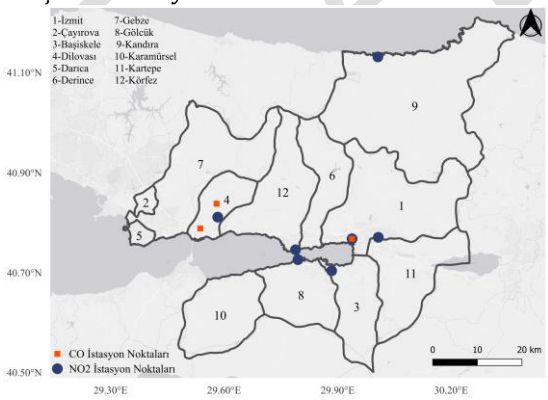


**Şekil 1.** Kocaeli İl sınırları ve hava kalite istasyonlarının konumu

Endüstri ve sanayi faaliyetlerinin yoğun olduğu ilde hava kalitesi de önem kazanmaktadır. ÇŞİDB idaresinde saatlik veri sağlayan yersel hava kalite istasyonları, özellikle faaliyetlerin yoğunlaştığı İzmit Körfezi çevresinde konumlandırılmıştır (Şekil 1). Çalışmada kullanılan $NO_2$ ve CO hava kalite parametreleri ayrıca S5P Seviye-3 uydu verilerinden ~1 km mekansal çözünürlükte temin edilerek, istasyon bazında yersel verilerle ilişkisi incelenmiştir. Ekim 2017'de atılan Sentinel-5P uydusu 2018 yılında veri sunmaya başladığından, çalışma 2018-2024 yıllarını kapsamaktadır. Yersel veriler ile uydu verilerinin beraber irdelenmesi hedefiyle, yersel verilerin uydu geçiş saatlerine karşılık gelen 13.00, 14.00 ve 15.00 saatlerindeki ölçüm değerlerinin ortalaması alınmış ve uydu geçiş tarihleri ile eşleştirilmiştir. Sıcaklık verisi ise yaklaşık olarak 11 km mekansal çözünürlüğe sahip olan ve günlük olarak servis edilen ERA5-Land verisinden temin edilmiştir.

## 3. YÖNTEM

Çalışma kapsamında, yersel istasyonlardan ve uydudan elde edilen hava kalite parametreleri arasındaki ilişki ve her iki kaynaktan elde edilen veriler ile sıcaklık verisi arasındaki ilişki pearson korelasyon katsayısı hesaplanarak ortaya konmuştur. CO ve $NO_2$ parametrelerinin sıcaklık ile ilişkisi, Granger Nedensellik Testi ile incelenmiştir. Bu test, iki zaman serisi arasındaki nedensellik ilişkisini F testi ile inceleyen istatistiksel bir yöntemdir. F testi kapsamında elde edilen p değerleri baz alınarak değişkenlerin birbiri üzerindeki nedensellik ilişkisi belirlenebilmektedir. $p<0.001$ ise çok yüksek düzeyde istatistiksel anlamlılık, $0.001\leq p<0.01$ ise yüksek düzeyde istatistiksel anlamlılık, $0.01\leq p<0.05$ istatistiksel anlamlılık, $0.05\leq p<0.10$ anlamlılık eğilimi ve $p>0.10$ istatistiksel olarak anlamlı farklılığın bulunmadığının göstergesidir.

## 4. .BULGULAR VE TARTIŞMA

Yersel istasyonlar ile S5P verilerinin istasyon bazında korelasyon değerleri Şekil 2'de verilmiştir. CO, tüm veri kaynakları arasında düşük korelasyon göstermiştir. $NO_2$ verilerinde ise yersel ve S5P uydu verileri arasındaki korelasyon değerleri çoğunlukla anlamlı bulunurken, S5P ve sıcaklık arasındaki korelasyonun ise yersel verilere göre daha yüksek olduğu gözlenmiştir.

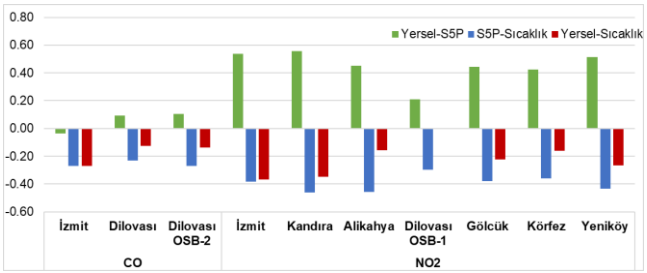


**Şekil 2.** Verilerin korelasyon katsayısı ($p< 0.05$)

İstasyon bazında üç verinin 6 günlük ortalama zaman serileri ile Granger Nedensellik Testi analizi gerçekleştirilmiş ve sonuçlar Çizelge 1'de verilmiştir. Bu doğrultuda, S5P ve yersel verilerde her iki parametrenin de sıcaklık üzerindeki etkisi çoğunlukla istatistiksel olarak anlamlı bulunmuştur. Sıcaklığın, CO parametresi üzerindeki etkisi S5P ile anlamlı bulunurken, yersel verilerde sadece İzmit istasyonunda anlamlı bulunmuştur. Sıcaklığın $NO_2$ parametresi üzerindeki etkisi ise Dilovası OSB-1 istasyonu haricinde anlamlı bulunmuştur. Bu doğrultuda, $NO_2$ ve sıcaklık arasında geri beslemeli bir ilişki olduğu söylenebilmektedir.

**Çizelge1.** Granger Nedensellik Testi sonucunda elde edilen F testi ve p değerleri.

| Par. | İstasyon | S5P-Sıcaklık (lag:1) | S5P-Sıcaklık (lag:2) | Yersel-Sıcaklık (lag:1) | Yersel-Sıcaklık (lag:2) | Sıcaklık-S5P (lag:1) | Sıcaklık-S5P (lag:2) | Sıcaklık-Yersel (lag:1) | Sıcaklık-Yersel (lag:2) |
|---|---|---|---|---|---|---|---|---|---|
| CO | İzmit | 0.7448 (0.3887) | 0.9248 (0.3976) | 10.2229 (0.0015) | 4.9544 (0.0075) | 12,4252 (0.0005) | 5.8062 (0.0033) | 14.8336 (0.0001) | 5.8052 (0.0033) |
| | Dilovası | 2.9318 (0.0877) | 2.7378 (0.0660) | 1.7084 (0.1920) | 3.0619 (0.0480) | 12.5818 (0.0004) | 7.0508 (0.0010) | 1.0990 (0.2952) | 0.2815 (0.7548) |
| | Dilovası OSB-2 | 3.1100 (0.0786) | 3.7892 (0.0235) | 12.0412 (0.0006) | 7.3564 (0.0007) | 12.2797 (0.0005) | 6.9884 (0.0011) | 0.7101 (0.3999) | 0.9780 (0.3770) |
| $NO_2$ | İzmit | 15.7106 (0.0001) | 8.9905 (0.0002) | 36.0775 (0.0000) | 21.1881 (0.0000) | 54.1221 (0.0000) | 20.1191 (0.0000) | 29.3316 (0.0000) | 11.9533 (0.0000) |
| | Kandıra | 32.3681 (0.0000) | 25.5781 (0.0000) | 18.8288 (0.0000) | 7.8908 (0.0004) | 52.7595 (0.0000) | 20.0140 (0.0000) | 38.6547 (0.0000) | 11.6562 (0.0000) |
| | Alikahya | 13.8795 (0.0002) | 8.5261 (0.0002) | 12.4223 (0.0005) | 6.0076 (0.0027) | 50.9468 (0.0000) | 17.4341 (0.0000) | 17.5583 (0.0000) | 5.8656 (0.0031) |
| | Dilovası OSB-1 | 9.2563 (0.0025) | 5.0168 (0.0071) | 2.7875 (0.0959) | 0.9887 (0.3731) | 40.5586 (0.0000) | 20.2458 (0.0000) | 2.3747 (0.1242) | 1.1411 (0.3206) |
| | Gölcük | 13.5688 (0.0003) | 7.2333 (0.0008) | 46.4796 (0.0000) | 29.5709 (0.0000) | 50.6489 (0.0000) | 23.3653 (0.0000) | 58.2520 (0.0000) | 17.6536 (0.0000) |
| | Körfez | 15.1230 (0.0001) | 7.5042 (0.0006) | 41.6660 (0.0000) | 26.1770 (0.0000) | 46.9592 (0.0000) | 19.9364 (0.0000) | 75.3122 (0.0000) | 29.8224 (0.0000) |
| | Yeniköy | 19.3711 (0.0000) | 11.5190 (0.0000) | 33.4674 (0.0000) | 26.5960 (0.0000) | 46.0430 (0.0000) | 19.0996 (0.0000) | 37.8424 (0.0000) | 11.8335 (0.0000) |

Çok yüksek düzeyde istatistiksel anlamlılık ($p<0.001$) | Yüksek düzeyde istatistiksel anlamlılık ($0.001\leq p<0.01$) | İstatistiksel anlamlılık ($0.01\leq p<0.05$) | Anlamlılık eğilimi ($0.05\leq p<0.10$)

## 5. SONUÇ

Bu çalışmada, uydu ve yersel kaynaklardan elde edilen CO ve $NO_2$ parametrelerinin birbirleriyle ve sıcaklık ile ilişki istatistiksel yöntemlerle incelenmiş ve $NO_2$ parametresinde verilerin çoğunlukla birbiriyle anlamlı bir ilişkisi olduğu belirlenmiştir. CO parametresinde ise istasyon bazında değişiklikler olduğu görülmektedir. Elde edilen sonuçlar, $NO_2$ parametresinin takibinde özellikle yersel verilerin olmadığı bölgelerde uydu verilerinin kullanımının anlamlı olduğunu ve sıcaklık ile geri beslemeli bir ilişki içerisinde olduğunu ortaya koymuştur. Yersel ve uydu tabanlı CO parametresinin sıcaklık üzerinde çoğunlukla anlamlı bir etkisi olduğu bulunurken, sıcaklığın veriler üzerindeki etkisi ise uydu verilerinde anlamlıyken yersel verilerde sadece İzmit istasyonunda anlamlı bulunmuştur. Bu doğrultuda, insan faaliyetleri ile ortaya çıkan CO ve $NO_2$ parametrelerinin iklim değişikliği ve sürdürülebilirlik açısından önemi bu çalışma kapsamında ortaya konmuştur.

### Yazar Katkı Oranı

Tüm yazarlar çalışmanın hazırlanmasında eşit oranda katkı sağlamıştır.

### Çıkar Çatışması/Çakışması

Yazarların bu çalışmanın içeriğiyle ilgili olarak beyan edecekleri hiçbir çıkar çatışması yoktur.

### KAYNAKÇA

EPA (U.S. Environmental Protection Agency), (2024). Basic Information about Carbon Monoxide (CO) Outdoor Air Pollution.

Inness, A., Ribas, R., & Engelen, R. (2019). The use of Sentinel-5P air quality data by CAMS. ECMWF Newsletter No, 25-30.

Lin, C. A., Chen, Y. C., Liu, C. Y., Chen, W. T., Seinfeld, J. H., & Chou, C. C. K. (2019). Satellite-derived correlation of $SO_2$, $NO_2$, and aerosol optical depth with meteorological conditions over East Asia from 2005 to 2015. Remote Sensing, 11(15), 1738.

Manisalidis, I., Stavropoulou, E., Stavropoulos, A. & Bezirtzoglou, E. (2020). Hava Kirliliğinin Çevresel ve Sağlık Etkileri: Bir İnceleme. Halk Sağlığı Alanındaki Sınırlar, 8, 14.

Salama, D. S., Yousif, M., Gedamy, Y., Ahmed, H. M., Ali, M. E., & Shoukry, E. M. (2022). Satellite observations for monitoring atmospheric $NO_2$ in correlation with the existing pollution sources under arid environment. Modeling Earth Systems and Environment, 8(3), 4103-4121.

Vîrghileanu, M., Săvulescu, I., Mihai, B. A., Nistor, C., & Dobre, R. (2020). Nitrogen Dioxide ($NO_2$) Pollution monitoring with Sentinel-5P satellite imagery over Europe during the coronavirus pandemic outbreak. Remote Sensing, 12(21), 3575.

Zheng, C., Zhao, C., Li, Y., Wu, X., Zhang, K., Gao, J., ... & Chai, F. (2018). Spatial and temporal distribution of $NO_2$ and $SO_2$ in Inner Mongolia urban agglomeration obtained from satellite remote sensing and ground observations. Atmospheric Environment, 188, 50-59.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Obje Tespiti Modellerinin Taşıt Sınıflarının Zenginleştirilmesine Yönelik Yeni Bir Veri Seti Oluşturulması

**Diren Yılmaz[1], Onur Can Bayrak[*2], Muzaffer Can İban[3]**

[1]*Mersin Üniversitesi, Uzaktan Algılama ve CBS ABD, 33343, Yenişehir, Mersin*
[2]*Yıldız Teknik Üniversitesi, Harita Mühendisliği Bölümü, 34220, Esenler, İstanbul*
[3]*Mersin Üniversitesi, Harita Mühendisliği Bölümü, 33343, Yenişehir, Mersin*

**Anahtar Kelimeler**
Derin Öğrenme,
Obje Tespiti,
Araç Tespiti,
Veri seti

**ÖZET**

Akıllı ulaşım sistemlerinin (AUS) bileşenlerinden olan trafik izleme sistemleri; araç tespiti, sınıflandırması ve sayım aşamalarına dayanmaktadır. Derin öğrenme yöntemleri, özellikle açık kaynaklı veri setleri ile eğitilmiş YOLOv8 gibi obje tespiti modelleri bu süreci kolaylaştırarak, görüntülerden AUS bileşenlerine yönelik çıktıları üretebilmektedir. Ancak bu modellerdeki eksiklik, araç tespitindeki türlerin Araba, Kamyon, Otobüs ve Motosiklet olmak üzere 4 sınıfa yönelik hazırlanmış olmasındandır. Bu çalışma kapsamında, AUS'ye altlık oluşturma amacıyla Araba, Kamyon, Otobüs ve Motosiklet sınıflarına ek olarak Panelvan ve Kamyonet sınıfları da olmak üzere toplam 6 araç sınıfının tespitine yönelik yeni bir veri seti oluşturulmuştur.

# Creation of a New Dataset for Enhancing Vehicle Classes in Object Detection Models

**Keywords**
Deep Learning,
Object Detection,
Vehicle Detection,
Dataset

**ABSTRACT**

Traffic monitoring systems, which are among the key components of Intelligent Transportation Systems (ITS), rely on stages such as vehicle detection, classification, and counting. Deep learning techniques, particularly object detection models like YOLOv8 trained on open-source datasets, significantly streamline this process by producing outputs relevant to ITS applications directly from visual data. However, a major limitation of these models is their restriction to only four vehicle categories—Car, Truck, Bus, and Motorcycle. In this study, to better support ITS applications, a new dataset has been developed that extends the classification to six vehicle types by incorporating Panel Van and Pickup Truck classes in addition to the existing ones.

## 1. GİRİŞ

Akıllı ulaşım sistemleri (AUS), araç tespiti, sınıflandırma ve sayım süreçlerini içeren otomatik trafik izleme sistemlerine dayanmaktadır (Akoushideh vd., 2024).

Son yıllarda, uzaktan algılama teknolojileri AUS' un önemli bir bileşeni haline gelmesiyle birlikte otonom araçlar (Ghasemieh ve Kashef, 2022), trafik izleme (Abbasi vd., 2021) gibi birçok alanda ilerlemelere yol açmıştır.

Araç tespit ve sınıflandırma süreçleri kamera, LiDAR sensörü (Ghasemieh ve Kashef, 2022) veya insansız hava aracı (Uzar vd., 2021; Yildirim vd., 2024) gibi farklı görüntüleme teknolojileriyle yapılmaktadır.

Kameraların görüntüleme açısı, kameranın yola olan uzaklığı, araçların yan yana gelmesi veya küçük boyutları gibi faktörler, araç tespit işleminin doğruluğunu ve performansını olumsuz etkileyebilmektedir.

Bununla birlikte, otomatik araç sınıflandırma çalışmalarında karşılaşılan başlıca zorluklardan biri, doğru etiketlenmiş veri setlerinin sayıca yetersizliğidir. Günümüzde, obje tespiti modelleri taşıt tespitinde yüksek doğruluk performansı gösterse de sınıf çeşitliliği açısından yeterli ve dengeli veri setlerinin oluşturulması

* **Sorumlu Yazar**

*(e-mail) ORCID ID 0009-0009-4195-0620
(onurcb@yildiz.edu.tr) ORCID ID 0000-0002-5147-747X
(caniban@mersin.edu.tr) ORCID ID 0000-0002-3341-1338

**Kaynak Göster (APA):**

Yılmaz D, Bayrak O C & İban C (2025). Obje Tespiti Modellerinin Taşıt Sınıflarının Zenginleştirilmesine Yönelik Yeni Bir Veri Seti Oluşturulması. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

halen önemini korumaktadır (Redmon vd., 2016). Her ne kadar MS-COCO (Lin vd., 2014) gibi veri setleri obje tespiti modellerinin eğitilmesinde kullanılsa da, otomatik araç tespiti için bu veri setlerindeki sınıflar Araba, Otobüs, Kamyon, Bisiklet ve Motosiklet sınıflarıyla sınırlı kalmakta olup, farklı türlerdeki araçları kapsamamaktadır.

Bu çalışmanın amacı, obje tespiti amacıyla literatürde sıklıkla kullanılan MS-COCO veri setinin ve bu veri setinden eğitilmiş olan derin öğrenme mimarilerinin daha fazla çeşitlendirilmiş araç sınıflarını da tespit edilebilmesi için altı sınıftan oluşan yeni bir veri seti oluşturmak ve araç tespiti performansını iyileştirmektir.

## 2. YÖNTEM

Bu çalışma, gece ve gündüz saatlerinde göz hizasında çekilmiş video kayıtlarında obje tespiti yöntemleri çalıştırılarak kırpılan görüntülerden yapılan sahne sınıflandırmasını kapsamaktadır. Veri setinin oluşturulması ve model eğitimine dair detaylar aşağıda belirtilmiştir.

### 2.1.Veri Setinin Oluşturulma Aşamaları

Bu çalışmada, araç sayımı için altı sınıftan oluşan bir veri seti oluşturulmuştur. Veri setinin oluşturulma sürecinde, farklı zaman dilimlerinde ve Mersin kent merkezindeki farklı bulvarlarda çekilmiş her biri ortalama 5 dakika olan, saniyede 30 kareden (30-FPS) oluşan 100 adet video kullanılmıştır. Bu videolar, Ultralytics kütüphanesi kullanılarak çeşitli obje tespiti çalışmalarında (Vargrese vd., 2024; Ilmak vd., 2024) başarısını kanıtlamış olan YOLOv8 modeli ile işlenmiş ve her Araba, Otobüs ve Kamyon sınıfları için tespit işlemleri gerçekleştirilerek bu objeler, sınırlayıcı kutularına (bounding box) göre kırpılmıştır. Kırpma işleminden sonra bu görüntüler Araba, Otobüs, Motosiklet, Kamyon, Panelvan ve Kamyonet/Açık Kasalı Araç olmak üzere 6 sınıfa ayrılmıştır (Şekil 1). Burada YOLOv8 modelinin hatalı tespit ettiği örnekler operatör tarafından düzeltilerek doğru sınıfa atanmıştır. Bu süreçte, araçların farklı açılardan ve ışık koşullarında görüntülenmesi ile birlikte perspektif ve uzaklıklarına bağlı olarak değişiklik göstermesi sayesinde veri setindeki çeşitlilik artırılmıştır. Kırpılmış görüntüler arasındaki benzerliğin azaltılarak modelin ezberleme eğiliminin engellenmesi için 30 çerçeve/saniye'lik video kayıtları 1 çerçeve/saniye şeklinde kaydedilerek veri seti oluşturulmuştur.

| Görüntü | MS-COCO Sınıfı | Oluşturulan Veri Setindeki Sınıfı |
|---|---|---|
|  | Kamyon (Truck) | Kamyonet |
|  | Araba (Car) | Panelvan |
|  | Araba (Car) | Araba |
|  | Kamyon (Truck) | Otobüs |
|  | Motosiklet (Motorcycle) | Motosiklet |
|  | Kamyon (Truck) | Kamyon |

**Şekil 1.** MS-COCO ve oluşturulan veri seti arasındaki sınıf farklılıkları

Kırpma ve sınıf düzeltmelerinden sonra elde edilen sınıf dağılımları Şekil 2' de verilmiş olup Eğitim (%), Doğrulama (%) ve Test (%) için elde edilen sınıf dağılımları her bir araç türü için sırasıyla;

Çalışmada toplam 5161 adet görüntüden oluşan bir veri seti oluşturulmuştur. Sınıf dağılımları Şekil 2'de gösterilmiştir. Sınıf dağılımları oluştururken eğitim, doğrulama ve test görüntülerinin benzer olmamasına dikkat edilmiştir.

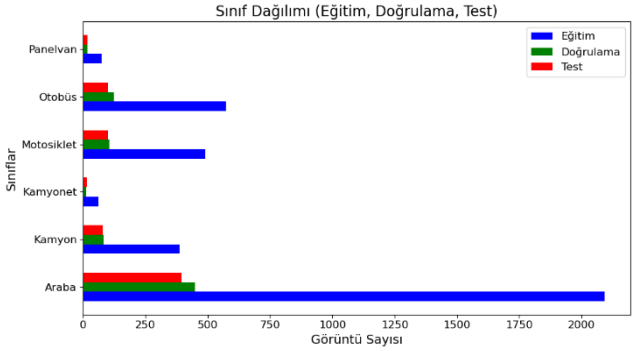


**Şekil 2.** Eğitim, doğrulama ve test sınıf dağılımı

### 2. 2. Model Eğitimi

Kırpılmış görüntülerin sınıflandırılması için eğitilen YOLOv8-n ağının hiperparametreleri YOLOv8-n ağının eğitilmesi için; epok sayısı 100, minimum parça sayısı 8, AdamW optimizasyon algoritması, 0.001 öğrenme oranı hiperparametreleri seçilmiştir. Eğitim aşamasında görüntülere 30°' lik döndürme, renk tonu değiştirme, doygunluk değiştirme, parlaklık seviyelerini değiştirme, 0.2 öteleme, 0.5 ölçekleme, eğme gibi veri arttırma işlemleri uygulanmıştır.

## 3. BULGULAR

Test sonuçlarının değerlendirilmesi için Kesinlik (Precision), Duyarlılık (Recall) ve F1-Skor metrikleri Çizelge 2' de gösterilmiştir.

**Çizelge 1.** Test sonuçlarına ait metrik değerler.

| Sınıf | Kesinlik | Duyarlılık | F1-Skor |
|---|---|---|---|
| Otobüs | 0.87 | 0.89 | 0.88 |
| Araba | 0.94 | 0.96 | 0.95 |
| Motosiklet | 0.95 | 0.92 | 0.93 |
| Kamyonet | 0.50 | 0.44 | 0.47 |
| Panelvan | 0.43 | 0.43 | 0.43 |
| Kamyon | 0.84 | 0.82 | 0.83 |

Çizelge 1' den de görülebileceği üzere; Araba sınıfı 0.95 F1-Skor ile en yüksek sınıflandırma performansına sahip olup Motosiklet (0.93), Otobüs (0.88) ve Kamyon (0.83) sınıfları göreceli olarak başarılı şekilde

sınıflandırılmıştır. Ancak Kamyonet ve Panelvan sınıfları için sırasıyla 0.47 ve 0.43 olarak elde edilen değerler, bu sınıfların belirlenmesindeki performansın zayıflığına dikkat çekmektedir.

## 4. TARTIŞMA ve SONUÇ

Çizelge1' deki sonuçlar, Şekil2' deki sınıf dağılımıyla birlikte incelendiğinde en yüksek örnek sayısına sahip olan Araba sınıfının en yüksek sınıflandırma performansına sahip olduğu, Araba sınıfını takip eden Otobüs, Motosiklet ve Kamyon sınıfının da başarılı tespit edilmesinin sınıf dağılımındaki baskınlığından kaynaklandığı konusunda bir tutarlılığa sahiptir. Ancak burada dikkat edilmesi gereken bir diğer çıkarım, en baskın sınıfların her zaman daha yüksek sınıflandırma skoruna ulaşmamasıdır. Çünkü Şekil2 incelendiğinde Motosiklet sınıfının Otobüs sınıfından daha az örnekleme sahip olduğu görülmektedir. Bu durum, Motosiklet görüntülerinden çıkarılan özniteliklerin Otobüs sınıfına göre daha ayırt edici olmasından kaynaklandığı, yani araç türleri arasında Otobüs sınıfının diğer araç türlerine göre daha fazla ortak özniteliğinin olduğundan dolayı sınıf karışıklığına sebep olabileceğini göstermektedir.

Aynı zamanda, Kamyonet ve Panelvan sınıfları en az örnekleme sahip sınıflar olduğundan ve Motosiklet haricindeki araç sınıflarıyla ortak özniteliklerinin fazla olmasından dolayı göreceli olarak zayıf sınıflandırma performansına sahip olduğu düşünülmektedir. Bu sebeple, eğitilen modelin gerçek hayatta doğrudan kullanımı konusunda bir kısıtlama söz konusudur.

Gelecek çalışmalarda, bu sınıfların belirlenmesindeki performansın artırılması için daha fazla görüntünün oluşturulan veri setine eklenmesi planlanmaktadır. Daha fazla görüntünün bulunamadığı durumların irdelenmesi için Sıfır Örnekli Öğrenme (Zero Shot Learning), Tek Örnekli Öğrenme (One Shot Learning), vb. teknikler kullanılarak model başarısının artırılabileceği öngörülmektedir. Modelin başarısının artması, taşıt türlerinin belirli bölgelerde sınıflandırılmasını ve belgelenmesini mümkün kılarak hem coğrafi bilgi sistemlerine veri altyapısı oluşturma hem de enerji ve iklim gibi alanlarda analiz kapasitesini artırma potansiyeli taşımaktadır.

### Yazar Katkı Oranı

Çalışma konsepti, D.Y. ve M.C.İ.; yöntem, D.Y. ve O.C.B., yazılım, D.Y. ve O.C.B.; veri toplama, D.Y. ve M.C.İ.; inceleme ve düzenleme, M.C.İ.; görselleştirme, O.C.B.; kaynaklar, M.C.İ.; danışmanlık, M.C.İ.;

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması yoktur.

## KAYNAKÇA

### Makale


Abbasi, M., Shahraki, A., & Taherkordi, A. (2021). Deep learning for network traffic monitoring and analysis (NTMA): A survey. *Computer communications*, *170*, 19-41.

Akoushideh, A., Sadat, S. S., & Shahbahrami, A. (2024). Counting vehicles types using deep learning algorithm in video surveillance systems. *Multimedia Tools and Applications*, 1-24.

Ghasemieh, A., & Kashef, R. (2022). 3D object detection for autonomous driving: Methods, models, sensors, data, and challenges. *Transportation Engineering*, *8*, 100115.

Uzar, M., Öztürk, Ş., Bayrak, O. C., Arda, T., & Öcalan, N. T. (2021). Performance analysis of YOLO versions for automatic vehicle detection from UAV images. *Advanced Remote Sensing*, *1*(1), 16-30.

Yildirim, E., Sefercik, U. G., & Kavzoglu, T. (2024). Automated identification of vehicles in very high-resolution UAV orthomosaics using YOLOv7 deep learning model. Turkish J. Electr. Eng. Comput. Sci., 32(1), 144-165.

Varghese, R., & Sambath, M. (2024,). Yolov8: A novel object detection algorithm with enhanced performance and robustness. In 2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS) (pp. 1-6). IEEE.


### Bildiri


Ilmak, D., Iban, M. C., & Şeker, D. Z. (2024, July). A Geospatial Dataframe of Collapsed Buildings in Antakya City after the 2023 Kahramanmaraş Earthquakes Using Object Detection Based on Yolo and VHR Satellite Images. In IGARSS 2024-2024 IEEE International Geoscience and Remote Sensing Symposium (pp. 3915-3919). IEEE.

Lin, T. Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., ... & Zitnick, C. L. (2014). Microsoft coco: Common objects in context. In Computer vision–ECCV 2014: 13th European conference, zurich, Switzerland, September 6-12, 2014, proceedings, part v 13 (pp. 740-755). Springer International Publishing.

Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 779-78


© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Lineer Dönüşüm Yöntemi İle Metrik Olmayan Dijital Kamera Kalibrasyonu

**Orhan Kurt**[1]

[1]*Kocaeli Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Kocaeli, Türkiye*

**Anahtar Kelimeler**
Dijital Fotogrametri,
Kamera Kalibrasyonu,
Lineer Dönüşüm,
En Küçük Kareler

**ÖZET**

Yardımcı değişken dönüşümü ile lineer hale getirilen lineer olmayan bir mühendislik probleminin En Küçük Kareler (EKK) kestirimi ile çözümü direkt olarak gerçekleştirilir. Bilgisayarlı Görü (BG) kullanılan 3x4 boyutlu projeksiyon matrisi ile 4B (4 Boyutlu) homojen arazi koordinatlarından 3B homojen resim koordinatlarına dönüşümü sağlayan kamera kalibrasyon elemanlarının hesaplanmasında da benzer bir yol izlenir. Bu geçişi sağlayan projeksiyon matrisi 12 adet lineer elemandan oluşur. 12 adet bilinmeyeni çözebilmek için en az 6 adet ortak noktaya ihtiyaç duyulur. Lineer hale getirilen kamera kalibrasyon işlemi, projeksiyon matrisinin doğrudan kestirilmesini sağlar. Bu yöntem Direkt Lineer Dönüşüm (DLD) yöntemi olarak adlandırılır. DLD yöntemi ile doğrudan kestirilen projeksiyon matrisinin ayrıştırılması sonucunda iç ve dış yönelme elemanlarına ulaşılır. Bu çalışmada DLD yöntemi teorik olarak incelenmiş, bütün aşamaları ayrıntılı olarak açıklanmıştır. GNU olarak yayımlanan programlama dilleri (SciLab ve Octave) kullanılarak kalibrasyon simülasyonu ve kestirimi yapan programlar geliştirilmiştir. Geliştirilen yazılımlar ile ulaşılan sonuçlar tartışılmış ve genellemelere gidilmiştir.

# Non-metric Digital Camera Calibration with Linear Transformation Method

**Keywords**
Digital Photogrammetry,
Camera Calibration ,
Linear Transformation,
Least Squares

**ABSTRACT**

The Least Squares (LS) estimation of a non-linear engineering problem that is linearized with the auxiliary variable transformation is directly performed. A similar method is preferred in calculating camera calibration elements needed for transformation from 4D (4-Dimensional) homogeneous field coordinates to 3D homogeneous image coordinates with the used 3x4 projection matrix in Computer Vision (CV). The projection matrix that provides this transition consists of 12 linear elements. At least 6 common points are needed to solve 12 unknowns. The linearized camera calibration process allows the projection matrix to be estimated directly. This method is called the Direct Linear Transformation (DLT) method. Intrinsic and extrinsic orientation elements of the camera are calculated by decomposing the projection matrix estimated by the DLT method. In this study, the DLT method is theoretically examined, and all its stages are explained in detail. Programs that perform calibration simulation and estimation have been developed using the programming languages (SciLab and Octave) distributed as GNU. The results obtained with the developed software were discussed, and generalizations were made.

## 1. GİRİŞ

Hava ve yersel fotogrametrik yöntem ile harita yapımında en önemli aşama kamera kalibrasyonudur. Kamera kalibrasyonu, alımda kullanılacak olan kameranın iç ve dış yöneltme elemanlarının hesaplanması işlemidir. Metrik kameralarda iç yöneltme elemanları genelde bilinir ya da önceden kalibre edilir. Dış yöneltme elemanları, konumları jeodezik yöntem ile ölçülmüş kontrol noktalarından yararlanarak çekim anları için hesaplanır. Metrik olmayan kameralarda çoğunlukla iç yöneltme elemanları da bilinmez. Yeterince kontrol noktası kullanılır ise iç ve dış yönelme elemanları aynı anda belirlenebilir. Direkt Lineer Dönüşüm (DLD) yöntemi, lineer olmayan iç ve dış yöneltme elemanlarını direkt olarak hesaplamaya yarayan bir yöntemdir.(Abdel-Aziz ve Karara, 1971; 2015; Bardsley ve Li, 2006; Urtasun, 2013; Barone vd., 2020; Habib,

* **Sorumlu Yazar**

*(orhnkrt@gmail.com) ORCID ID 0000-0002-2711-2024

**Kaynak Göster (APA):**

Kurt O (2025). Non-metric Digital Camera Calibration with Linear Transformation Method, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

TASDK

2020; Stachniss, 2021; Szeliski, 2022; Scaramuzza, 2024; DPRG, 2025; RPG, 2025; StachnissLab, 2025).

DLD yöntemi, iç ve dış yöneltme parametrelerinin doğrudan elde edilmesini sağlamaz. Bu yöntemde doğrudan çözüm aşamasına geçebilmek için lineer değişken dönüşümü yapılmalıdır. Bu lineer değişken dönüşümü 3x4 boyutlu projeksiyon matrisinin 12 adet elemanı ile sağlanır. Bu yardımcı parametreler ile Direkt EKK (DEKK) yöntemini uygulamak için kurulan düzeltme denklemleri Homojen Denklem Sistemi ($A \cdot p = 0$) yapısında olduğundan, lineer bilinmeyenlerin sıfırdan farklı ($p \neq 0$) çözümleri özdeğer ayrıştırma ile belirlenir. Fazla sayıda eşlenik noktanın kullanıldığı kalibrasyon işleminde bilinmeyenlerin katsayılar matrisi ($A$) dikdörtgen matris olduğundan, bu aşamada özdeğer ayrıştırma yerine Tekil Değer Ayrıştırma (TDA) tercih edilir. TDA'nın önemli avantajlılarından birisi de tekil değerlerin daima pozitif reel sayılardan oluşmasıdır. EKK amaç fonksiyonu altında en küçük tekil değere karşılık gelen öz vektör, lineer projeksiyon matrisi elemanlarının çözümüdür. Projeksiyon matrisinin elemanları belirlendikten sonra, kendisini oluşturan kalibrasyon matris bileşenlerine ayrıştırılarak kameranın iç ve dış yöneltme elemanları bulunur (Abdel-Aziz ve Karara, 1971; 2015; Bardsley ve Li, 2006; Urtasun, 2013; Barone vd., 2020; Habib, 2020; Stachniss, 2021; Szeliski, 2022; Scaramuzza, 2024; DPRG, 2025; RPG, 2025; StachnissLab, 2025).

## 2. YÖNTEM

Bu bölümde; iç ve dış yöneltme parametrelerinin tanımlandığı kalibrasyon elemanları, kalibrasyon elemanları ile görüntü simülasyonu, DLD (Direkt Lineer Dönüşüm) matematik modelin oluşturulması ve modelin EKK ile doğrudan kestirimi, simülasyon verileri ile DLD yöntemin test edilmesi üzerinde durulacaktır.

### 2.1. Kalibrasyon Elemanları

Kalibrasyon elemanları iç (IO:Intrinsic Orientation) ve dış (EO:Extrinsic Orientation) yöneltme elemanları olmak üzere iki gruba ayrılır.

### 2.2. İç yöneltme elemanları (K)

Kamera matrisini ($K$) oluşturan iç yöneltme elemanları: görüntü merkezi koordinatları ($x_0, y_0$: sağa ve aşağı), asal noktanın görüntü merkezine göre koordinatları ($\xi, \eta$), odak uzaklığı ($f$), odak uzaklığındaki pikselin metrik değerini hesaplamaya yarayan hayalet parametre (Ghost Parameter) ($\lambda$) ile tanımlanır. İç yöneltme elemanları dışında bırakılan hayalet parametre, bazı çalışmalarda da odak uzaklığı ile ile birlikte $f/\lambda$ şeklinde kullanılmaktadır (Abdel-Aziz ve Karara, 1971; 2015; Bardsley ve Li, 2006; Urtasun, 2013; Barone vd., 2020; Habib, 2020; Kurt ve Akan, 2017; Kurt ve Amirgan, 2021; Kurt, 2023a; 2023b; Stachniss, 2021; Szeliski, 2022; Scaramuzza, 2024; DPRG, 2025; RPG, 2025; StachnissLab, 2025).

Kamera matrisi (**K**) iç yöneltme elemanları ile aşağıdaki şekilde oluşturulur.

$$K = \begin{bmatrix} f/\lambda & 0 & x_0 + \xi \\ 0 & f/\lambda & y_0 + \eta \\ 0 & 0 & 1 \end{bmatrix}^{[px]} \quad (1)$$

(1) eşitliğinde mavi ile gösterilen hayalet parametrenin geometrik anlamı ve kamera matrisindeki yeri (Kurt ve Akan, 2017; Kurt ve Amirgan, 2021; Kurt, 2023a; 2023b) yayınlarında açıkça gösterilmiş ve tartışılmıştır. Son iki kaynakta özellikle bu parametrenin *geometrik* anlamı üzerinde durulmuştur. Bu çalışmada, hayalet parametrenin DLD yöntemi içerisindeki *cebrik* anlamı da irdelenmiştir.

### 2.3. Dış yöneltme elemanları (D)

İz düşüm merkezinin arazi koordinatlarını ($X_0, Y_0, Z_0$) ve iç düşüm merkezi ile asal noktayı birleştiren görüntü doğrultusunu ($\omega, \varphi, \kappa$) tanımlayan dönüklük açılarıdır. Bu parametreler yardımı ile dış yönelme matrisi ($D$) aşağıda verilen (2) eşitlikleri ile oluşturulur (Stachniss, 2021; Kurt, 2023a; 2023b).

$$D = [\, R \quad | \quad -R \cdot X_0 \,] \quad (2a)$$

$$R = R_z(\kappa) \cdot R_y(\varphi) \cdot R_x(\omega) \quad (2b)$$

$$X_0 = [X_0, Y_0, Z_0]^T \quad (2c)$$

İç ($K$) ve dış ($D$) yöneltme elemanları ile Projeksiyon ($P$) matrisi aşağıdaki (3) bağıntısı ile verilir. DLD yönteminin lineer bilinmeyenleri bu matrisin elemanlarıdır.

$$P = K \cdot D = \begin{bmatrix} p_{11} & p_{12} & p_{13} & p_{14} \\ p_{21} & p_{22} & p_{23} & p_{24} \\ p_{31} & p_{32} & p_{33} & p_{34} \end{bmatrix} \quad (3a)$$

$$x_j = P \cdot X_j \quad (3b)$$

Projeksiyon matrisi ile eşlenik noktaların homojen arazi koordinatlarından ($X_j^T = [\, X_j \; Y_j \; Z_j \; 1 \,]$), homojen görüntü koordinatlarına ($x_j^T = [\, x_j \; y_j \; 1 \,]$) dönüşümü (3b) eşitliği ile sağlanır.

### 2.4. Görüntü Simülasyonu

Aşağıda "Çizelge 1" ile verilen kalibrasyon (iç ve dış yöneltme) elemanları ile arazi koordinatları lokal bir koordinat sisteminde bilinen ve 28 noktadan oluşan bir evin resim koordinatları oluşturulmuştur (Kurt ve Akan, 2017; Kurt ve Amirgan, 2021; Kurt, 2023a; 2023b).

Arazi koordinatlarından resim koordinatlarına dönüşüm işlemi SciLab ortamında geliştirilen bir program ile yapılmıştır (SciLab, 2025). Bu programa, iç ve dış yöneltme elemanları girilerek, 2B ve 3B uzaydaki bilgilerin simülasyon hesapları yapılabilmektedir. Simülasyon programı ile elde edilen dış yöneltme elemanlarının ve evin 3B uzaydaki konumları "Şekil 1" ile, evin 2B resim görüntüsü ise "Şekil 2" ile gösterilmiştir (Çizelge 1, Şekil 1, 2).

### 2.5. DLD Yöntemi

Araziden resme geçişi sağlayan (3b) eşitliğindeki matris ve vektör çarpımları yapılır ise bir eşlenik nokta için üç adet denklem elde edilir. İlk iki denklem üçüncü denklem ile bölünürse, her bir eşlenik nokta için denklem sayısı üçten ikiye düşer. Bu iki denklemde yer alan projeksiyon matris elemanları bilinmeyen olacak şekilde düzenlenerek (4) eşitliklerine ulaşılır.

**Çizelge1.** Simülasyonda kullanılan iç ve dış yöneltme parametreleri (px:pixel) (Şekil 1,2).

| İç Yöneltme Elemanları | | Dış Yöneltme Elemanları | |
|---|---|---|---|
| $x_0$ [px] | 2000.00 | $X_0$ [m] | 1.00 |

| | | | |
|---|---|---|---|
| $y_0$ [px] | 1500.00 | $Y_0$ [m] | 3.00 |
| $\xi$ [px] | 0.00 | $Z_0$ [m] | 8.00 |
| $\eta$ [px] | 0.00 | $\omega$ [°] | -111.8014 |
| f [m] | 3 | $\varphi$ [°] | +50.3586 |
| $\lambda$ [m/px] | 0.0005 (A) | $\varkappa$ [°] | +17.1200 |
| | 0.001 (B) | | |
| | 0.002 (C) | | |
| | 0.003 (D) | | |

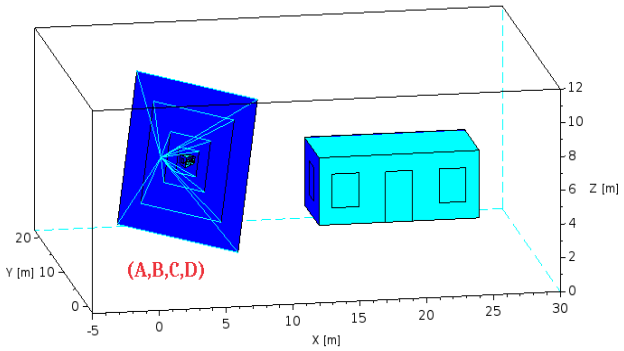


**Şekil 1.** Kalibrasyon elemanları ve evin lokal koordinat sistemindeki 3B görüntüsü (Çizelge 1).

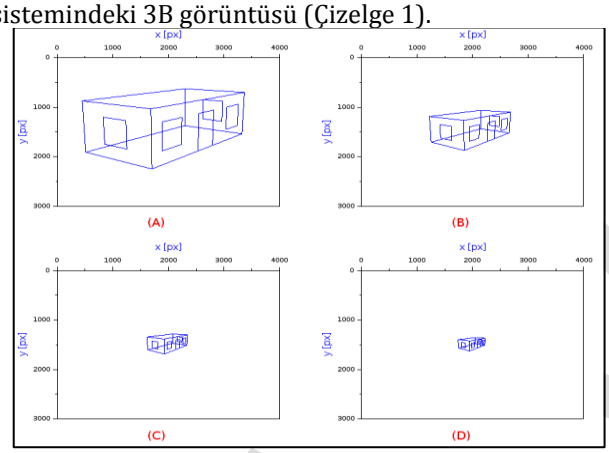


**Şekil 2.** Farklı hayalet parametre ($\lambda$) değerleri ile oluşturulan resimler (Çizelge 1).

$$\begin{bmatrix} -X_j^T & 0^T & x_j \cdot X_j^T \\ 0^T & -X_j^T & y_j \cdot X_j^T \end{bmatrix} \cdot p = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \quad (4a)$$

$$p^T = [p_{11}p_{12}p_{13}p_{14} \mid p_{21}p_{22}p_{23}p_{24} \mid p_{31}p_{32}p_{33}p_{34}] \quad (4b)$$

(4) eşitliği $n$ adet eşlenik nokta ile oluşturulur ise (5) eşitliği ile verilen Homojen Denklem sistemi elde edilir.

$$A_{2n,12} \cdot p_{12,1} = 0_{2n,1} \quad (5)$$

Yukarıdaki homojen denklem takımının $p \neq 0$ çözümü TDA yöntemi kullanılarak yapılır. Ayrıştırma işlemi sonucunda ($A = U \cdot S \cdot V^T$) elde edilen tekil değer matrisinin ($S$) en küçük tekil değeri belirlenir. Büyükten küçüğe sıralanmış tekil değerlerin en küçüğüne ($\sigma_{12} = S_{12,12}$) karşılık gelen öz-vektör ($\hat{p} = v_{12}$), bilinmeyenlerin EKK amaç fonksiyonu sağlayan çözümü olur. Kestirilen bilinmeyenler vektörü (3a) eşitliğindeki yerlerine konularak projeksiyon matrisinin EKK çözümüne ulaşılır.

$$\hat{P} = \hat{K} \cdot \hat{D} = [\, \hat{K} \cdot \hat{R} \;\mid\; -\hat{K} \cdot \hat{R} \cdot \hat{X}_0 \,] \quad (6a)$$

$$\hat{P} = [\, \hat{H} \;\mid\; \hat{h} \,] \quad (6b)$$

$$\hat{X}_0 = -\hat{H}^{-1} \cdot \hat{h} \quad (6c)$$

$\hat{H}^{-1} = (\hat{K} \cdot \hat{R})^{-1}$ matrisi QR algoritması ile bir *Ortogonal* (Q) ve bir *Üst Üçgen matris* (R) olacak şekilde ayrıştırılarak, $qr(\hat{H}^{-1}) = \hat{R}^T \cdot \hat{K}^{-1}$ bağıntısı ile rotasyon ve kalibrasyon matrislerine ulaşılır. (Bardsley & Li, 2006; Urtasun, 2013; Barone vd., 2020; Habib, 2020; Stachniss, 2021; Szeliski, 2022; Scaramuzza, 2024; DPRG, 2025; RPG, 2025; StachnissLab, 2025).

$\hat{K} = \hat{K}/\hat{K}_{3,3}$ normlandırması ile sonuç kalibrasyon matrisine elde edilir. Rotasyon matrisinden ($\hat{R}$) Euler dönüklük açılarına $(\omega, \varphi, \kappa)$ geçiş için Kurt (2018) yayınının ekinde verilen bağıntılar kullanılabilir.

## 3. BULGULAR

Yöntem bölümünde verilen DLD yönteminin test emek için simülasyon ile üretilen veriler kullanılmıştır. Octave ortamında geliştirilen DLD yöntemi yazılımı ile yapılan EKK kestirimi sonucunda soncul karesel ortalama hata $m_0 = \pm 0.30px$ (piksel) olarak elde edilmiştir (Octave 2025). Ayrıca bu yöntem ile kestirilen kalibrasyon elemanları "Çizelge 2" ile verilmiştir (Çizelge 2).

**Çizelge2.** DLD yöntemi ile kestirilen kalibrasyon elemanları (Şekil 1, 2).

| İç Yöneltme Elemanları | | Dış Yöneltme Elemanları | |
|---|---|---|---|
| $x_0$ [px] | 2000.00 | $X_0$ [m] | 0.9843 |
| $y_0$ [px] | 1500.00 | $Y_0$ [m] | 2.9892 |
| $\xi$ [px] | -1.93 | $Z_0$ [m] | 8.0063 |
| $\eta$ [px] | -4.48 | $\omega$ [°] | -111.7357 |
| f [m] | 2.9301 | $\varphi$ [°] | +50.3552 |
| $\lambda$ [m/px] | 0.000488(A) | $\varkappa$ [°] | +17.0722 |
| $m_0$ [px] | ±0.30 | | |

"Çizelge 2" de mavi ile verilen görüntü merkezi koordinatları DLD yöntemi ile (1998.07, 1495.52) olarak elde edilmiştir. Bu değerlerden "Çizelge 1 ve 2" de verilen mavi değerler çıkarılarak elde edilen asal nokta elemanlarının $(\xi,\eta)$ piksel değerlerinin gösterimi tercih edilmiştir.

DLD yöntemi ile elde edilen projeksiyon matrisi ortonormal özellikli öz vektörden elde edildiği için Frobenius (Euclidean) normu ($F = \sqrt{\Sigma p^2} = 1$) daima bire eşittir. Bu matrisin herhangi sayı ile genişletilmesi projeksiyon matrisi ile yapılan dönüşüm sonuçlarını değiştirmez. Bunun nedeni (3b) eşitliği ile verilen homojen arazi koordinatlardan $(X_j)$ resim koordinatlarına $(x_j)$ geçişte elde edilen ara koordinatların ($u_j = [u_j\ v_j\ w_j]^T = \hat{P} \cdot X_j$) üçüncü bileşen ile normlandırılmasıdır ($x_j = [x_j\ y_j\ 1]^T = u_j/w_j$). Bu geçiş, geometrik olarak ölçeklendirmeye karşılık gelen hayalet parametrenin *cebrik* anlamını göstermektedir. Bu parametrenin her bir ortak nokta için hesaplanan değerlerinin ($w_j \sim \lambda_j$) ortalaması "Çizelge 2" verilmiştir ve simülasyon aşamasında öngörülen değerine istatistiksel olarak eşit olduğu da görülmektedir (Çizelge 1).

Kullanılan TDA algoritmasına göre öz vektörlerin işaretleri farklılıklar gösterebilir. Bu durum homojen denklem takımı çözümünün bir sonucudur. Kullanılan

TDA algoritmasına göre dönüşüm sonuçları işaret bakımdan düzenleme yapmayı gerektirebilir.

## 4. SONUÇ

Bu çalışmada bilgisayarlı görü ve dijital fotogrametride yaygın olarak kullanılan DLD yöntemi irdelenmiş ve kalibrasyon değerleri bilinen bir yersel fotogrametri problemi ile test edilmiştir.

Genellikle yakın resim fotogrametrisi ve robotik işlemlerde tercih edilen DLD yöntemi, hava fotogrametrisinde de iç ve dış yöneltme elemanlarının hesaplanmasında etkin olarak kullanılabilir. Bu amaç için, yer kontrol nokta konumlarının yer merkezli jeodezik bir sistemde bilinmesi yeterlidir.

## KAYNAKÇA


Abdel-Aziz, Y.I. and H.M. Karara (1971). Direct Linear Transformation from Comparator Coordinates into Object Space Coordinates in Close-Range Photogrammetry, Proceedings of the Symposium on Close-Range Photogrammetry, 26–29 January 1971, Urbana, Illinois, pp. 1—18.

Abdel-Aziz and Y.I., Karara, H.M. (2015). Direct Linear Transformation from Comparator Coordinates into Object Space Coordinates in Close-Range Photogrammetry, Photogrammetric Engineering & Remote Sensing, Volume 81, Issue 2, Pg.103-107, ISSN 0099-1112, https://doi.org/10.14358/PERS.81.2.103.

Barone, F., Marrazzo, M., and Oton C.J. (2020). Camera Calibration with Weighted Direct Linear Transformation and Anisotropic Uncertainties of Image Control Points, Sensors 2020, 20(4), 1175; https://doi.org/10.3390/s20041175.

Bardsley D. and Li, B. (2006). 3D Reconstruction Using the Direct Linear Transform with a Gabor Wavelet Based Correspondence Measure, Technical Report, http://bardsley.org.uk/wp-content/uploads/2007/02/3d-reconstruction-using-the-direct-linear-transform.pdf: [Erişim tarihi: 21.03.2025].

DPRG, (2025). The Digital Photogrammetry Research Group, Lyles School of Civil Engneering, Purdue University, West Lafayette, Indiana / USA, [Erişim tarihi: 21.03.2025], https://engineering.purdue.edu/CCE/Academics/Groups/Geomatics/DPRG.

Habib, A.F. (2020). Direct Linear Transformation & Computer Vision Models, Chap.7-A4, Lecture Notes, https://engineering.purdue.edu/CCE/Academics/Groups/Geomatics/DPRG/Courses_Materials/Photogrammetry_2020Fall/AKAM_DLT_CV_AKAM: [Erişim tarihi: 21.03.2025].

Kurt, O. (2018). An integrated solution for reducing ill-conditioning and testing the results in non-linear 3D similarity transformations. Inverse Problems in Science and Engineering, *26*(5), 708–727. https://doi.org/10.1080/17415977.2017.1337762

Kurt, O. (2023a). On A Ghost Parameter in Central Projective Equations of Digital Photogrammetry, Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) XII. Teknik Sempozyumu, 24-26 Mayıs, Sivas/Türkiye, https://www.researchgate.net/publication/377724658.

Kurt, O. (2023b). Central Projective Equations of Digital Photogrammetry in Computer Vision, TMMOB-HKMO, 19. Türkiye Harita Bilimsel ve Teknik Kurultayı, 04-06 Ekim, Ankara/ Türkiye, https://www.researchgate.net/publication/384240509.

Kurt, O., and Amirgan, B. (2021). Geodetic Overview on Computer Vision Geometry, International Symposium of Scientific Research and Innovative Studies, 22-25 Feb 2021, pp.1601-1609, Bandırma/Balıkesir. Turkey, https://www.researchgate.net/publication/350134236.

Kurt, O., and Akan H. (2017). A Simulation Algorithm to Test Mathematical Models in Terrestrial Photogrammetry, TMMOB-HKMO, 16. Türkiye Harita Bilimsel ve Teknik Kurultayı, Ankara, https://www.researchgate.net/publication/317499101.

Octave (2025). GNU Octave, https://octave.org/, [Erişim tarihi: 21.03.2025].

RPG, (2025). Robotics and Perception Group, Department of Informatics, University of Zurich, Zurich / Switzerland, [Erişim tarihi: 21.03.2025], https://rpg.ifi.uzh.ch/.

Scaramuzza, D. (2024). Camera Calibration, Vision Algorithms for Mobile Robotics, Lecture notes https://rpg.ifi.uzh.ch/docs/teaching/2022/03_camera_calibration.pdf: [Erişim tarihi: 21.03.2025].

SciLab (2025). Open source software for numerical computation, https://www.scilab.org/, [Erişim tarihi: 21.03.2025].

Stachniss, C. (2021). Camera Calibration: Direct Linear Transform, Photogrammetry & Robotics Lab, https://www.ipb.uni-bonn.de/html/teaching/photo12-2021/2021-pho1-21-DLT.pptx.pdf: [Erişim tarihi: 21.03.2025].

StachnissLab, (2025), Photogrammetry & Robotics Lab, University of Bonn/Germany, [Erişim tarihi: 21.03.2025], https://www.ipb.uni-bonn.de/.

Szeliski, R. (2022), Computer Vision: Algorithms and Applications, Springer, https://link.springer.com/book/10.1007/978-3-030-34372-9

Urtasun, R. (2013). Computer Vision: Calibration and Reconstruction, Lecture Notes, https://home.ttic.edu/~rurtasun/courses/CV/lecture09.pdf: [Erişim tarihi: 21.03.2025].


© Yazar(lar), 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Derin Öğrenme Temelli Kara ve Buzul Sınıflarının Otomatik Segmentasyonu

**Burak Demirhan*[1], Onur Can Bayrak[1], Uğur Acar[1], Füsun Balık Şanlı[1], Ömer Gökberk Narin[2], Çağlar Bayık[3], Saygın Abdikan[4]**

[1]*Yıldız Teknik Üniversitesi, İnşaat Fakültesi, Harita Müh. Bölümü, İstanbul, Türkiye*
[2]*Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Harita Müh. Bölümü, Afyonkarahisar, Türkiye*
[3]*Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Harita Müh. Bölümü, Zonguldak, Türkiye*
[4]*Hacettepe Üniversitesi, Mühendislik Fakültesi, Harita Müh. Bölümü, Ankara, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Derin Öğrenme,
Antarktika

**ÖZET**

Buzullar ve buz tabakaları, Dünya'nın iklimini düzenlemede önemli bir rol oynamaktadır. Ancak, son yıllarda yüzen buz sahanlıklarının kalınlık ve boyutlarındaki hızlanan azalmalar, iklim üzerindeki olumsuz etkileri artırmaktadır. Bu bağlamda, buzulların izlenmesi, küresel ısınmaya karşı alınacak önlemler açısından büyük bir önem taşımaktadır. Bu çalışmada, buz tabakaları ile okyanus arasındaki kritik geçiş bölgesi olan Antarktika buz sahanlıkları (ice shelves) incelenmektedir. Çalışma kapsamında, ücretsiz olarak sağlanan uydu görüntüleri kullanılarak, Antarktika'daki Horseshoe Adası ve çevresinde buz tabakalarının (ice sheet) segmentasyonu amaçlanmıştır. Bu doğrultuda, Sentinel-2 uydu görüntülerinden yararlanılmıştır. 2019-2021 yıllarına ait bölgesel optik uydu görüntüleri, derin öğrenme mimarileri kullanılarak sınıflandırılmıştır. Sınıflandırma sürecinde, dört farklı sınıf (deniz, kara, kara-buz ve deniz-buz) için eğitim, doğrulama ve test olmak üzere bağımsız üç veri kümesi oluşturulmuştur. Sınıflandırma sonuçları F1-Skor metriği kullanılarak doğruluk analizine tabi tutulmuştur. Tüm sınıflar için en iyi performans gösteren U-Net++ modelinin ortalama F1-Skoru %75'in üzerinde hesaplanmıştır.

# Deep Learning-Based Automatic Segmentation of Land and Glacier Classes

**Keywords**
Remote sensing,
Deep Learning,
Antarctica

**ABSTRACT**

Glaciers and ice sheets play a critical role in regulating the Earth's climate system. However, the recent accelerated decline in the thickness and extent of floating ice shelves has intensified their adverse impacts on global climate. In this context, monitoring glaciers is of paramount importance for informing mitigation strategies against global warming. This study focuses on Antarctic ice shelves, which represent a crucial transitional zone between continental ice sheets and the ocean. The primary objective of this research is to segment ice sheets in and around Horseshoe Island, Antarctica, using freely available satellite imagery. To this end, Sentinel-2 optical satellite data were employed. Regional images acquired between 2019 and 2021 were classified using deep learning architectures. During the classification process, three independent datasets—training, validation, and testing—were created for four distinct classes: ocean, land, land-ice, and sea-ice. The classification performance was evaluated using the F1-score metric. Among the tested models, the U-Net++ architecture achieved the highest performance, with an average F1-score exceeding 75% across all classes.

* **Sorumlu Yazar**

*(onurcb@yildiz.edu.tr) ORCID ID 0000-0002-5147-747X
(uacar@yildiz.edu.tr) ORCID ID 0000-0003-3676-4259
(fbalik@yildiz.edu.tr) ORCID ID 0000-0003-1243-8299
(gokberknarin@aku.edu.tr) ORCID ID 0000-0002-9286-7749
(caglarbayik@beun.edu.tr) ORCID ID 0000-0001-6606-3272
(sayginabdikan@hacettepe.edu.tr) ORCID ID 0000-0002-3310-352X

**Kaynak Göster (APA):**

Bayrak O C, Acar U, Balık Şanlı F, Narin Ö G, Bayık Ç & Abdikan S (2025). Derin Öğrenme Temelli Kara ve Buzul Sınıflarının Otomatik Tespiti. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Buzullar ve buz tabakaları, küresel ölçekte Dünya'nın iklim sistemini düzenlemede önemli bir rol oynamaktadır. Yüksek yansıtıcılık özellikleri sayesinde büyük miktarda güneş enerjisini uzaya geri yansıtarak gezegenin soğuk kalmasını sağlamalarının yanı sıra, erimeleri sonucunda deniz seviyesinin yükselmesine neden olmaları gibi kritik faktörler nedeniyle izlenmeleri büyük bir önem taşımaktadır (Everest, 2022). Kar örtüsü, su buzulları, buzdağları ve kutup buzul alanlarını içeren kriyosfer bölgeleri, küresel tatlı su rezervlerinin yaklaşık %75'ini barındırdığından, iklim değişikliği bağlamında stratejik öneme sahiptir. Son yıllarda, yüzen buz sahanlıklarının kalınlık ve yüzey alanındaki azalmalar, iç buz akış dinamiklerini bozarak denize ulaşan birçok buz akıntısının geri çekilmesine ve hızlanmasına yol açmıştır (The IMBIE team, 2018).

Buz tabakalarındaki kütle değişimlerini ve akış hızlarını takip edebilmek amacıyla uydu gözlemlerine dayalı çeşitli teknikler geliştirilmiştir. Yapılan uydu bazlı analizler, Antarktika buz tabakalarının deniz seviyesinin yükselmesine olan katkısının giderek arttığını göstermektedir (Pattyn & Morlighem, 2020). Bu bağlamda, kıyı çizgisinin doğru bir şekilde belirlenmesi, değişim analizlerinde ve ileriye dönük tahminlerin yapılmasında önemli bir rol oynamaktadır.

Günümüzde derin öğrenme ağları, otomatik nesne tespiti, ses tanıma, doğal dil işleme, görüntü çözünürlüğü artırma, sınıflandırma ve segmentasyon gibi çeşitli araştırma alanlarında yaygın olarak kullanılmaktadır (Goodfellow et al., 2016).

Bu çalışmada, güncel derin öğrenme segmentasyon modelleri kullanılmış ve elde edilen sonuçlar F1-Skor metriği kullanılarak doğruluk analizine tabi tutulmuştur.

## 2. VERİ ve YÖNTEM

Çalışma alanı Türkiye'nin bilim üssünü kapsayacak şekilde İngiliz Antarktika bölgesi Marguerite Körfezi'dir (Şekil 1). Şekil 2'de görüldüğü üzere, örnek olarak seçilen iki farklı lokasyonda iki farklı tarih için okyanus yüzeyinde mevsimsel buzullar oluşmakta, deniz buzulu ve kara buzulları karışmakta ve kıyı çizgisinin doğru bir şekilde çıkarımını engellemektedir.

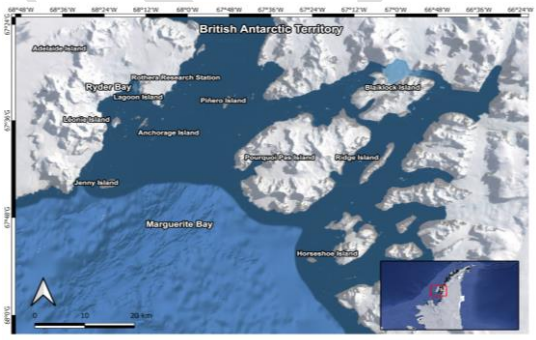


**Şekil 1.** Çalışma Alanı

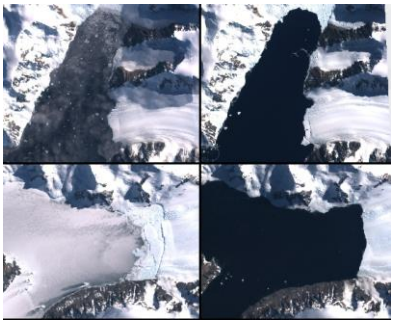

**Şekil 2.** Farklı zamanlarda alınmış uydu görüntülerinde kıyı alanlarının değişimi (I. Sütun: 2016, II. Sütun:2020)

Sunulan çalışmada toplam 9 optik görüntü (Sentinel-2) etiketlenmiştir. Sınıflandırma için U-Net, U-Net++ ve DeepLabv3+ modelleri kullanılmıştır.

## 3. BULGULAR ve TARTIŞMA

Test veri setinde gerçekleştirilen doğruluk değerlendirmesi Çizelge 1'de sunulmuştur. Test metrikleri olarak F1-Skor kullanılmıştır. Sonuçlara göre; deniz, deniz buzulu ve kara buzulu sınıflarında en başarılı model U-Net++, kara sınıfında ise U-Net olmuştur.

## 4. SONUÇ

Tüm sınıflar için en iyi sonuç veren model U-Net++ olup %79'un üzerinde F1-Skor'a ulaşmıştır. Ortalama model performanslarına bakıldığında %77,6 olarak hesaplanmıştır. Bu sonuçlar, geliştirilen modellerin sınıflandırma görevlerinde kullanılabileceğini göstermektedir.

**Çizelge1.** Farklı derin öğrenme modellerinin performans karşılaştırması (D: Deniz, DB: Deniz Buzulu, K: Kara, KB: Kara Buzulu, O: Ortalama)

| Yöntem | D | DB | K | KB | O |
|---|---|---|---|---|---|
| U-Net | 87,3 | 42,5 | 87,3 | 89,8 | 76,7 |
| U-Net++ | 89,6 | 43,3 | 86,9 | 90,7 | 77,6 |
| DeepLabv3+ | 89,2 | 38,1 | 78,4 | 89,4 | 73,8 |

**TEŞEKKÜR**

Bu çalışma 122G287 proje numaralı "Derin Öğrenme Temelli Kıyı Çizgisi Ve Buzul Sınıflarının Otomatik Tespiti: Antarktika- Marguerite Körfezi Örneği" adlı TÜBİTAK 1001 başlıklı proje kapsamında gerçekleştirilmiştir.

**Yazar Katkı Oranı**

**Burak Demirhan:** Veri Analizi, Metodoloji Geliştirme, Yazım
**Onur Can Bayrak:** Veri Analizi, Metodoloji Geliştirme, Yazım
**Uğur Acar:** Literatür Taraması, Metodoloji Geliştirme, Görselleştirme, Yazım
**Füsun Balık Şanlı**: Danışmanlık, Sonuçların Değerlendirilmesi, Revizyon
**Ömer Gökberk Narin:** Veri Analizi, Sonuçların Değerlendirilmesi, Revizyon

KABUL

**Çağlar Bayık:** Düzenleme, Sonuçların Değerlendirilmesi, Revizyon
**Saygın Abdikan:** Literatür Taraması, Metodoloji, Görselleştirme Düzenleme, Sonuçların Değerlendirilmesi, Revizyon

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

### KAYNAKÇA


Chen, L. C., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation. In *Proceedings of the European Conference on Computer Vision (ECCV)* (pp. 801–818).

Everest, J. (2022). Glacier Monitoring, https://www.bgs.ac.uk/geology-projects/glacier-monitoring/ [Erişim tarihi: 01.04.2025].

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.

Pattyn, F., & Morlighem, M. (2020). The uncertain future of the Antarctic Ice Sheet. *Science*, 367(6484), 1331–1335.

Ronneberger, O., Fischer, P., & Brox, T. (2015, October). U-Net: Convolutional networks for biomedical image segmentation. In *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015: 18th International Conference, Munich, Germany* (pp. 234–241). Springer International Publishing.

The IMBIE team. (2018). Mass balance of the Antarctic Ice Sheet from 1992 to 2017. *Nature*, 558, 219–222.

Zhou, Z., Rahman Siddiquee, M. M., Tajbakhsh, N., & Liang, J. (2018, September). UNet++: A nested U-Net architecture for medical image segmentation. In Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop, DLMIA 2018, and 8th International Workshop, ML-CDS 2018, Held in Conjunction with MICCAI 2018, Granada, Spain (pp. 3–11). Springer International Publishing.



© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Transformatör ve Evrişimsel Sinir Ağı Tabanlı Mimariler ile Yüksek Çözünürlüklü İHA Görüntülerinden Bireysel Zeytin Ağacı Tespiti

**Esra Yıldırım*[1], İsmail Çölkesen[1], Umut Güneş Sefercik[1]**

[1]*Gebze Teknik Üniversite, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Kocaeli, Türkiye*

**Anahtar Kelimeler**
İnsansız Hava Aracı,
Derin Öğrenme,
Evrişimsel Sinir Ağı,
Transformatör,
Zeytin Ağacı Tespiti

**ÖZET**

Zeytin ağacı, kuraklığa dayanıklı yapısı ve uzun ömrü sayesinde geniş coğrafyalarda yetiştirilebilmekte, sofralık ve yağlık olmak üzere farklı kullanım alanlarıyla dünya genelinde büyük bir ticari değere sahip olmaktadır. Zeytin üretiminin sürdürülebilir şekilde planlanması ve yönetilmesi için bireysel ağaç tespiti büyük önem taşımaktadır. Bu çalışmada, yüksek çözünürlüklü İHA ortofoto görüntülerinden bireysel zeytin ağacı tespiti için derin evrişimsel sinir ağı ve transformatör tabanlı mimarilerin performansı incelenmiştir. Bu amaç doğrultusunda Hatay ili Arsuz ilçesi Pirinçlik mahallesine ait RGB ortofoto görüntü üzerinde yer alan zeytin ağacı örnekleri manuel olarak etiketlenerek zeytin ağacı veriseti oluşturulmuştur. Çeşitli veri artırımı teknikleri uygulanarak veriseti yapay olarak genişletilmiş ve oluşturulan veriseti ile RF-DETR ve YOLOv12 modelleri eğitilmiş ve test edilmiştir. Deneysel sonuçlara göre RF-DETR modeli mAP@50 ve mAP@50:95 metrikleri için sırasıyla 0,98 ve 0,82 değerlerini elde ederek YOLOv12'den daha üstün performans göstermiştir. Ayrıca hesaplama maliyeti açısından her iki modelin de yaklaşık aynı sürede eğitildiği göz önüne alındığında RF-DETR modelinin yüksek doğruluğu, zeytin ağacı tespiti potansiyelini ortaya koymaktadır. Bu çalışmanın sonuçları İHA görüntüleri ve transformatör mimarilerinin bireysel zeytin ağacı tespiti için hassas ve etkili bir çıkarım sonucu sağlayarak verim tahmini, sürdürülebilir üretim ve tarımsal yönetimde yardımcı olabileceğini göstermektedir.

# Individual Olive Tree Detection from High Resolution UAV Imagery with Transformer and Convolutional Neural Network Based Architectures

**Keywords**
Unmanned Aerial Vehicle,
Deep Learning,
Convolutional Neural Network,
Transformer,
Olive Tree Detection

**ABSTRACT**

Olive trees can be grown in wide areas thanks to their drought-resistant structure and long lifespan, and they have a great commercial value worldwide with their different usage areas, such as table and oil production. Individual tree detection is of great importance for sustainable planning and management of olive production. In this study, the performance of deep convolutional neural network and transformer-based architectures for individual olive tree detection from high-resolution UAV orthophoto images was investigated. For this aim, olive tree instances on the RGB orthophoto image obtained from the Pirinçlik neighborhood of the Arsuz district of Hatay province were manually labelled to create an olive tree dataset. The dataset was artificially expanded by applying various data augmentation techniques, and RF-DETR and YOLOv12 models were trained and tested with the created dataset. According to the experimental results, the RF-DETR model outperformed YOLOv12 by obtaining values of 0.98 and 0.82 for mAP@50 and mAP@50:95 metrics, respectively. In addition, considering that both models were trained in approximately the same time in terms of computational cost, the high accuracy of the RF-DETR model demonstrates its potential for olive tree detection. The results of this study show that UAV images and transformer architectures can provide precise and effective extraction results for individual olive tree detection, helping in yield estimation, sustainable production, and agricultural management.

* **Sorumlu Yazar**

*(esrayildirim@gtu.edu.tr) ORCID 0000-0002-4951-0488
(icolkesen@gtu.edu.tr) ORCID ID 0000-0001-9670-3023
(sefercik@gtu.edu.tr) ORCID ID 0000-0003-2403-5956

**Kaynak Göster (APA):**

Yıldırım E, Çölkesen İ & Sefercik U G (2025). Transformatör ve Evrişimsel Sinir Ağı Tabanlı Mimariler ile Yüksek Çözünürlüklü İHA Görüntülerinden Bireysel Zeytin Ağacı Tespiti, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Zeytin ağacı, Akdeniz iklimine sahip bölgelerde uzun yıllardır yetiştirilen, kuraklığa dayanıklı ve uzun ömürlü bir bitki olarak ekonomik, ekolojik ve kültürel anlamda büyük bir öneme sahiptir. Zeytin yetiştiriciliği, Akdeniz'e komşu ülkelerde yapılmakta olup ülkemiz dünyanın önde gelen zeytin üreticilerinden biridir. Yağlık ve sofralık olarak değerlendirilebilen zeytin meyvesi, işlenmesi sırasında ortaya çıkan yan ürünlerin taşıdığı ekonomik değer ve sağlık açısından sunduğu yararlar nedeniyle her geçen gün artan bir talebe sahiptir (TEPGE, 2023). Böyle büyük bir talebin karşılanması noktasında bireysel zeytin ağacı tespiti; rekolte tahmini, hastalık-zarar takibi ve sürdürülebilir üretim planlaması açısından büyük önem taşımaktadır.

Uzaktan algılama teknolojileri, geniş tarımsal alanların yüksek çözünürlükte ve kapsamlı bir şekilde görüntülenmesine olanak sağladığı için çeşitli ağaç türlerinin haritalanması noktasında önemli bir kaynak durumundadır. Özellikle yüksek konumsal, spektral ve zamansal veri sağlayabilen İnsansız Hava Araçları (İHA); ağaç tespiti, sayımı ve haritalaması gibi birçok hassas tarım uygulamasında etkili bir şekilde uygulanmaktadır. Son yıllarda derin öğrenme mimarileri, görüntülerdeki karmaşık özellikleri derin bir sinir ağı oluşturarak otomatik öğrenme yetenekleri sayesinde nesne tespiti ve sayımı uygulamalarında büyük başarılar elde edebilmiştir. Bu bağlamda İHA görüntüleri ve derin öğrenme kombinasyonunun palmiye, zeytin, elma, fıstık çamı ve kavak dahil olmak üzere çeşitli ağaç türlerinin tespitindeki başarısı literatürdeki çalışmalar tarafından kanıtlanmıştır (Yildirim vd., 2025; Wu vd., 2020). Örneğin, Yildirim vd. (2022) RGB İHA görüntülerinden fıstık çamlarını tespit etmek için YOLOv4 modelini kullanmıştır. Bireysel kavak ağaçlarının multispektral İHA görüntülerinden tespiti ve sayımı için Colkesen vd. (2023) YOLOv7 algoritmasının performansını araştırmıştır. Palmiye ağaçlarının İHA görüntülerinden tespiti ve sayımı için Gibril vd. (2022) evrişimsel sinir ağı ve transformatör mimarilerinin etkinliği incelemiştir.

Bu çalışmada yüksek çözünürlüklü İHA görüntülerinden zeytin ağaçlarının otomatik tespiti için derin evrişimsel sinir ağı ve transformatör tabanlı mimarilerin performansı araştırılmıştır. Bu amaç doğrultusunda Hatay ili Arsuz ilçesine ait ortofoto görüntü kullanılarak zeytin ağacı veriseti oluşturulmuş ve veriseti ile RF-DETR ve YOLOv12 modelleri eğitilmiş ve test edilmiştir. Modellerin performansı doğruluk metrikleri göz önüne alınarak karşılaştırılmıştır.

## 2. ÇALIŞMA ALANI VE VERİ SETİ

Araştırmada kullanılan çalışma alanı Hatay ili Arsuz ilçesi Pirinçlik mahallesinde yer alan bir zeytin ağacı tarlasını kapsamaktadır (Şekil 1). Çalışma alanına ait temin edilen yaklaşık 4 cm konumsal çözünürlüğünde RGB bantlara sahip ortofoto üzerinde sınırları Şekil 1'de kırmızı ile belirtilen deney sahası içerisindeki zeytin ağaçları ArcGIS Pro yazılımında manuel olarak etiketlenerek toplamda 902 zeytin ağacı örneği elde edilmiştir. Ardından ortofoto görüntü 256×256 piksel boyutunda görüntü parçalarına bölünmüştür. Oluşturulan verisetine yatay çevirme, 90° döndürme ve gürültü ekleme dahil olmak üzere çeşitli veri artırımı teknikleri uygulanarak veriseti genişletilmiştir. Toplamda 708 görüntü ve 1344 zeytin ağacı örneğinden oluşan veriseti modelin eğitimi, doğrulaması ve testi için %70, %20 ve %10 oranlarında rastgele olarak eğitim, doğrulama ve test verisetlerine bölünmüştür.

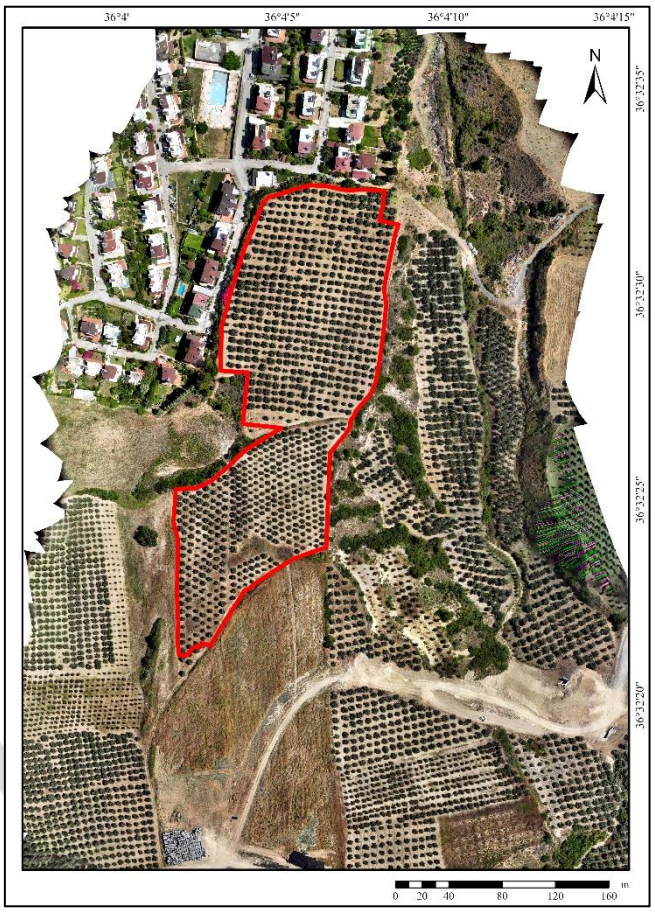


**Şekil 1.** Çalışma alanı ve deney sahası.

## METODOLOJİ

Çalışmada zeytin ağacı tespiti için derin öğrenme tabanlı güncel RF-DETR ve YOLOv12 obje tespit yöntemleri kullanılmıştır. RF-DETR, DETR modelinin geliştirilmiş yeni bir versiyonu olup kodlayıcı-kod çözücü tabanlı bir transformatör mimarisidir. YOLOv12, YOLO ailesinin en yeni versiyonu olarak tanıtılan dikkat merkezli bir evrişimsel sinir ağı modelidir. Çalışmada modellerin eğitimi ve testine ilişkin tüm deneyler NVIDIA A100 GPU erişimi sağlayan bulut tabanlı Google Colab Pro ortamında Python programlama dili kullanılarak gerçekleştirilmiştir. Her iki model oluşturulan zeytin veriseti kullanılarak 4 yığın boyutu ile 50 epok boyunca yaklaşık 30 dakika eğitilmiştir.

## 3. BULGULAR

Eğitilen modellerin performansı farklı Birleşim üzerinde Kesişim (IoU) eşik değerlerinde ve nesne boyutlarında hesaplanan mAP (mean Average Precision) metrikleri kullanılarak karşılaştırılmıştır. IoU, ilgili nesneye ait model tarafından tahmin edilen sınırlandırıcı kutu ile gerçek zemin değeri sınırlandırıcı kutu arasındaki örtüşmeyi ölçer. Dolayısıyla artan eşik değeri modeli konumsal olarak daha hassas bir tespit yapmaya

zorlar. Buna göre %50 IoU eşiğinde (mAP@50) ve %50 ile %95 arasındaki %5'lik artışla 10 IoU eşiğinin ortalaması alınarak hesaplanan (mAP@50:95) iki farklı mAP değeri ve bunların orta ve büyük boyutlu nesneler için hesaplanan türevleri Tablo 1'de verilmiştir. Elde edilen sonuçlara göre RF-DETR modeli tüm doğruluk metrikleri açısından YOLOv12 modelinden daha üstün performans göstermiştir. Özellikle artan IoU eşik değerlerinde RF-DETR modelinin doğruluğunda mAP@50:95, $mAP@50:95_{medium}$ ve $mAP@50:95_{large}$ metrikleri için sırasıyla %3, %4 ve %5'lik önemli artışlar gözlemlenmiştir. Bu durum özellikle RF-DETR modelinin YOLOv12'ye göre konumsal olarak daha doğru ve hassas sınırlandırıcı kutular üretebildiğini göstermektedir.

**Tablo 1.** RF-DETR ve YOLOv12 modellerinin performans karşılaştırması.

| Metrikler | RF-DETR | YOLOv12 |
|---|---|---|
| mAP@50:95 | 0,82 | 0,79 |
| mAP@50 | 0,98 | 0,97 |
| $mAP@50:95_{medium}$ | 0,79 | 0,75 |
| $mAP@50_{medium}$ | 0,99 | 0,95 |
| $mAP@50:95_{large}$ | 0,91 | 0,86 |
| $mAP@50_{large}$ | 0,96 | 0,95 |

Modellerin test veriseti üzerindeki tahmin sonuçları görsel olarak incelendiğinde RF-DETR modelinin zemin gerçeğine uygun olarak tüm zeytin ağaçlarını tespit edebildiği görülmektedir (Şekil 2). Öte yandan YOLOv12 modelinin görüntünün sol alt kenarına çok küçük bir kısmı veya gölgesi denk düşen zeytin ağacını da düşük skorla algıladığı görülmektedir. Zemin gerçeğine uygun olarak modellerin tahmin ettiği nesnelerin tahmin skorları incelendiğinde ise RF-DETR modelinin daha yüksek güven skorları elde ettiği görülmektedir. Ayrıca görüntünün sağına yarısı denk düşen zeytin ağacı örneğinde ise YOLOv12'nin nesne sınırları ile tam olarak örtüşmeyen sınırlandırıcı kutu ürettiği görülmektedir.

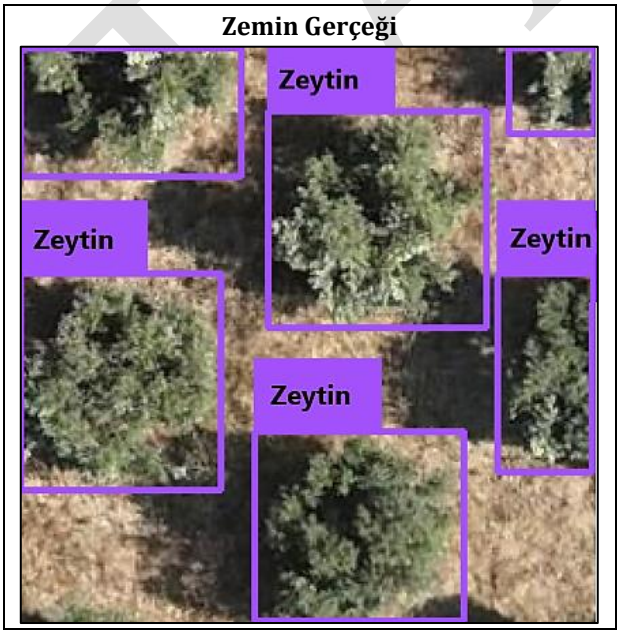


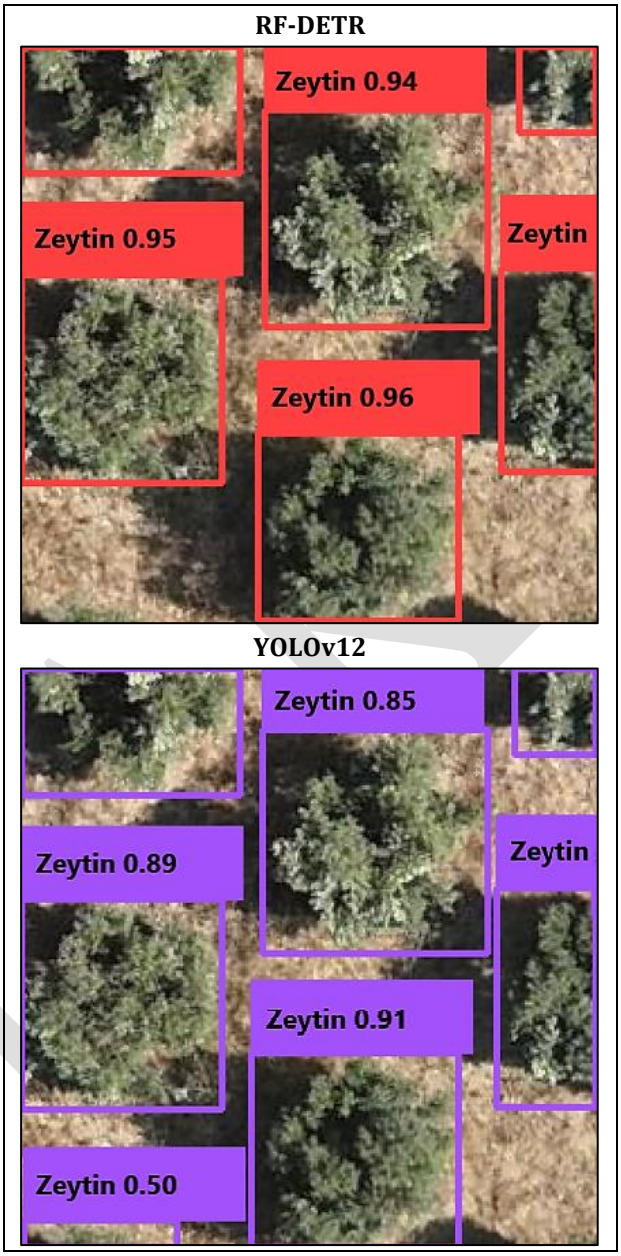


**Şekil 2.** RF-DETR ve YOLOv12 modellerinin test veri seti üzerindeki zeytin ağacı tahmin sonuçları.

## 4. SONUÇLAR

Bu çalışmada İHA görüntülerinden zeytin ağaçlarının otomatik tespiti için derin öğrenme tabanlı güncel obje tespit yöntemleri RF-DETR ve YOLOv12 modellerinin performansı incelenmiştir. Deneysel sonuçlar transformatör tabanlı RF-DETR modelinin evrişimsel sinir ağı tabanlı YOLOv12 modelinden daha üstün performans göstererek zeytin ağacı tespitinde daha etkili olduğunu göstermiştir. Bir bütün olarak çalışma bulguları, İHA verileri ve derin öğrenme yöntemlerinin entegrasyonunun sürdürülebilir üretim, rekolte tahmini ve tarımsal yönetim açısından bireysel zeytin ağacı tespitinde etkin bir araç olarak kullanılabileceğini ortaya koymaktadır. Bu bağlamda gelecek çalışmalar İHA yükseklik verileri ve vejetasyon indekslerinin modellerin performansı üzerindeki etkilerinin incelenmesine odaklanacaktır. Ek olarak açıklanabilir yapay zekâ teknikleri kullanılarak model performansları ve tespit sonuçları detaylı olarak analiz edilecektir.

**TEŞEKKÜR**

Araştırma kapsamında kullanılan İHA verilerinin sağlanmasında ESİS Harita Planlama Müşavirlik İnşaat Gayrimenkul Sanayi ve Ticaret Limited Şirketi'ne katkılarından dolayı teşekkürlerimizi sunarız.

**KAYNAKÇA**

Colkesen, I., Kavzoglu, T., Sefercik, U. G., Altuntas, O. Y., Nazar, M., Ozturk, M. Y., & Saygı, M. (2023). Deep learning based poplar tree detection and counting using multispectral UAV images. Advanced Engineering Days (AED), 64-67.

Gibril, M. B. A., Shafri, H. Z. M., Shanableh, A., Al-Ruzouq, R., Wayayok, A., Hashim, S. J. B., & Sachit, M. S. (2022). Deep convolutional neural networks and Swin transformer-based frameworks for individual date palm tree detection and mapping from large-scale UAV images. Geocarto International, 37(27), 18569-18599. https://doi.org/10.3390/rs13142787

Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü Müdürlüğü (TEPGE) (2023). Zeytinyağı ve Sofralık Zeytin Ürün Raporu. https://arastirma.tarimorman.gov.tr/tepge/Menu/37/Urun-Raporlari [Erişim tarihi: 27.03.2025].

Wu, J., Yang, G., Yang, H., Zhu, Y., Li, Z., Lei, L., & Zhao, C. (2020). Extracting apple tree crown information from remote imagery using deep learning. Computers and Electronics in Agriculture, 174, 105504. https://doi.org/10.1016/j.compag.2020.105504

Yıldırım, E., Çölkesen, İ., & Sefercik, U. G. (2025). Ayçiçeği çiçek tablalarının Mask R-CNN derin sinir ağı ile RGB ve multispektral İHA ortomozaiklerinden örnek segmentasyonu. Türk Uzaktan Algılama ve CBS Dergisi, 6(1), 57-72. https://doi.org/10.48123/rsgis.1602369

Yildirim, E., Nazar, M., Sefercik, U. G., & Kavzoglu, T. (2022). Stone pine (*pinus pinea* l.) detection from high-resolution UAV imagery using deep learning model. IGARSS 2022- IEEE International Geoscience and Remote Sensing Symposium, 441-444. https://doi.org/10.1109/IGARSS46834.2022.9883964

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# SAR Uydu Görüntüleri ve InSAR Tekniği ile Deformasyon Analizi

**İrem BAKIR*[1], Veysel Okan ATAK[1]**

[1]*IMPRO Uydu Görüntü İşleme ve Telekomünikasyon A.Ş., Görüntü Ticaret Direktörlüğü, Ankara, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Deformasyon Analizi,
SAR Uydu Görüntüleri,
InSAR,
PSI

**ÖZET**

İstanbul, jeolojik ve yapısal özellikleri nedeniyle sürekli izlenmesi gereken kritik bir metropoldür. Şehrin aktif fay hatlarına yakınlığı, yüksek nüfus yoğunluğu ve düzensiz kentleşme dinamikleri, bina ve altyapı deformasyonlarının artmasına neden olmaktadır. Bu çalışmada, yapısal deformasyonların yüksek doğrulukla belirlenmesi amacıyla, Sentetik Açıklıklı Radar İnterferometrisi (InSAR) tabanlı Kalıcı Saçılma İnterferometrisi (PSI) yöntemi kullanılarak detaylı bir analiz gerçekleştirilmiştir. PSI yöntemi, özellikle uzun vadeli ve milimetre hassasiyetinde deformasyon izleme imkânı sunmasıyla öne çıkmaktadır. Çalışmada, COSMO-SkyMed yüksek çözünürlüklü SAR görüntüleri kullanılarak bina ve kritik tesis ölçeğinde hassas yer değişim analizleri gerçekleştirilmiştir. Görüntü işleme aşamalarında ENVI SARscape yazılımı kullanılmış, interferogram üretimi, faz dengeleme, PSI noktalarının belirlenmesi ve zaman serisi analizleri uygulanmıştır. Çalışmadan elde edilen analizler, altyapı projeleri ve kentsel planlama süreçlerinde karar vericilere yol gösterici olabileceği gibi, uzun vadeli deformasyon trendlerinin belirlenmesi ve büyük ölçekli yıkıcı olaylar öncesinde erken uyarı sistemlerinin geliştirilmesi süreçlerine de katkı sağlayabilir.

# Deformation Analysis Using SAR Satellite Images and InSAR Technique

**Keywords**
Remote sensing,
Deformation Analysis,
SAR Satellite Imagery,
InSAR,
PSI

**ABSTRACT**

Istanbul is a critical metropolis that requires continuous monitoring due to its geological and structural characteristics. The city's proximity to active fault lines, high population density, and unregulated urbanization dynamics contribute to increasing building and infrastructure deformations. In this study, a detailed analysis was conducted using the Persistent Scatterer Interferometry (PSI) method based on Interferometric Syntetic Aperture Radar (InSAR) to accurately determine structural deformations. The PSI method stands out for its ability to monitor long-term deformations with millimeter-level precision. In this study, high-resolution SAR images from the COSMO-SkyMed (CSG) satellite were utilized to conduct precise displacement analyses at the building and critical facility scale. The image processing stages involved the use of ENVI SARscape software, interferogram generation, phase unwrapping, PSI identification, and time-series analyses were performed. The analyses derived from the study can guide decision-makers in infrastructure projects and urban planning processes, as well as contribute to the identification of long-term deformation trends and the development of early warning systems before large-scale destructive events occur.

## 1. GİRİŞ

Depremler, yer altı hareketleri, zemin oturmaları ve yapı malzemelerinin zamanla yıpranması gibi nedenlerle ortaya çıkabilecek deformasyonlar, büyük yapısal hasarlara ve hatta can kayıplarına yol açabilir. Bu yüzden küçük ölçekli hareketlerin bile büyük hasarlara dönüşmeden önce izlenmesi ve tespit edilmesi, insan güvenliği açısından kritik öneme sahiptir.

Bu projenin amacı, bina deformasyonlarını yüksek hassasiyetle tespit ederek zamansal değişimlerini analiz etmektir. Bu çalışmada, küçük ölçekli deformasyonları uzun vadeli ve yüksek hassasiyetle izlemek amacıyla InSAR yönteminin gelişmiş bir formu olan PSI tekniği kullanılmıştır. PSI, yapısal deformasyonları analiz

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Bakır İ & Atak V O (2025). SAR Uydu Görüntüleri ve InSAR Tekniği ile Deformasyon Analizi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

TASLAK

ederken kalıcı yansıtıcılar üzerinden milimetre doğruluğunda veriler sağladığından, özellikle bina güvenliği ve altyapı risk analizlerinde güçlü bir inceleme ve analiz aracıdır.

## 2. YÖNTEM

Bu çalışmada kullanılan yöntem, InSAR analizinin bir türü olan PSI tekniğine dayanmaktadır. Bu yöntem, farklı zamanlarda ve uygun periyodik aralıklarla elde edilen SAR görüntülerindeki faz farklarını analiz ederek milimetre düzeyinde deformasyonları hassas bir şekilde tespit etmeye olanak tanır. Çalışmada, İstanbul'daki yapılar ve kritik altyapıların deformasyonlarını izlemek amacıyla ikinci nesil İtalyan Cosmo SkyMed (CSG) uydularından elde edilmiş 3m çözünürlüklü SAR görüntüleri kullanılmıştır. Veri işleme süreci, ENVI SARscape yazılımı kullanılarak gerçekleştirilmiş; interferogram üretimi, faz dengeleme, PS noktalarının belirlenmesi ve zaman serisi analizleri aşamaları ile deformasyon modelleri oluşturulmuştur. Bu yöntem, binaların ve altyapıların yapısal sağlığına dair önemli veriler sağlayarak, elde mevcut diğer veriler (fay haritaları, GPS ölçümleri, bina kayıtları, karot analizleri vb.) ile birlikte değerlendirilerek sismik etkinlik ya da kentleşme ile ilgili olası riskleri tespit etmeye yardımcı olabilir.

### 2.1. Bina Deformasyonu

Depremler, yer altı hareketleri, iklim koşulları gibi çevresel faktörler; yetersiz tasarım, kalitesiz malzeme kullanımı gibi inşaat hataları ve malzeme yorgunluğu gibi nedenler deformasyona yol açabilir. Bu deformasyonlar, küçük ölçekli çatlaklardan büyük yapısal hasarlara kadar geniş bir yelpazede ortaya çıkabilir ve yapının dayanıklılığını tehdit edebilir (Milillo vd., 2016; Sousa vd., 2013). Özellikle büyük yapılarda veya yüksek nüfuslu kentlerde, bu tür deformasyonların izlenmesi güvenlik açısından kritik önem taşır.

### 2.2. Uzaktan Algılama ve Sentetik Açıklıklı Radar

Uzaktan algılama, yer yüzeyindeki fiziksel özellikleri ölçmek ve izlemek amacıyla hava veya uzay tabanlı sensörlerin kullanılmasıdır. Bu teknoloji, coğrafi ve çevresel değişimlerin izlenmesi, doğal afetlerin tahmin edilmesi ve yönetilmesi gibi birçok alanda geniş bir kullanım alanına sahiptir. Özellikle SAR sistemleri, bulut örtüsü, yağış gibi atmosfer koşullarından bağımsız olarak gece gündüz her türlü hava koşulunda veri toplama kapasitesine sahip olup, zemindeki deformasyonları, yapısal bozulmaları, su seviyelerini vb. değişiklikleri milimetre hassasiyetle izleme yeteneği sunarlar (Ferretti vd., 2001; Bürgmann vd., 2000).

### 2.3. Yapay açıklıklı radar interferometrisi (InSAR)

InSAR teknolojisi, yüzey deformasyonlarının hassas bir şekilde izlenmesini sağlayan güçlü bir uzaktan algılama tekniğidir. İki farklı SAR görüntüsü arasında faz farklarını analiz ederek yüzeyde meydana gelen değişiklikleri tespit edebilir (Massonnet ve Feigl, 1998). Bu teknoloji, özellikle yeryüzündeki küçük deformasyonları gözlemlemek için kullanılır ve büyük alanları kapsayan verileri kısa sürede elde edebilme avantajına sahiptir (Bürgmann vd., 2000). InSAR'ın doğruluğu ve geniş kapsamı, deformasyon analizlerinde kapsamlı veri sağlamasını mümkün kılmaktadır.

### 2.4. Kalıcı saçılma interferometrisi (PSI)

InSAR yönteminin gelişmiş bir formu olan PSI tekniği, deformasyon ölçümlerinde çok daha yüksek doğruluk ve güvenilirlik sağlamaktadır. PSI, zaman içinde sabit kalan ve PS olarak bilinen yüzey noktalarını hedef alır, bu sayede zaman serisi analizinde daha kararlı ölçümler yapılabilir. PSI, özellikle deformasyon hızının düşük olduğu, yavaş ve küçük ölçekli yer hareketlerinin hassas bir şekilde izlenmesinde kullanılır (Ferretti vd., 2001). Standart InSAR yönteminde atmosferik etkiler ve yüzey yansımalarındaki değişimler nedeniyle ölçüm doğruluğu azalabilirken, PSI teknikleri sabit saçıcı noktaların kullanımı sayesinde atmosferik etkileri büyük ölçüde ortadan kaldırır (Gabriel vd., 1989; Hanssen, 2001). PSI ayrıca deformasyon tespitinde santimetre-altı, hatta mm seviyesinde hassasiyet sağlaması nedeniyle bina deformasyonları gibi kritik yapı analizlerinde tercih edilmektedir (Crosetto vd., 2016). PSI tekniğinin sunduğu bu avantajlar, özellikle şehirleşmiş alanlarda veya karmaşık yapısal özelliklere sahip bölgelerde deformasyon takibinin yüksek doğrulukla yapılmasına olanak tanır (Ferretti vd., 2007).

### 2.5. Çalışma Alanı

Proje kapsamında, elde mevcut CSG SAR arşiv görüntüleri incelenmiş, deprem araştırmalarının yoğunlaştığı ve Şekil 1'de görüntülenen İstanbul bölgesi çalışma alanı olarak seçilmiştir.




**Şekil 1.** Çalışma alanı- İstanbul ili

### 2.6. Kullanılan Veriler

CSG SAR arşivinde yapılan incelemeler sonucunda, tarihsel olarak yakın zamanda ve uygun aralıklarla alınmış aynı özelliklere sahip 32 adet 3 m çözünürlüklü StripMap SAR görüntüsü seçilmiştir. Görüntüler 07 Ocak 2023 ile 18 Haziran 2024 tarihleri arasında yükselen yörüngede (Ascending) alınmış olup, HH (yatay-yatay) polarizasyona ve sağ yönlü bakış açısına sahiptirler.

## 3. BULGULAR

İstanbul, yoğun yapılaşması ve fay hattına yakın konumu nedeniyle bina deformasyonu risklerinin yüksek olduğu bir bölge olarak dikkat çekmektedir. PSI analizi sonucu elde edilen vektör veriler deformasyonları

TASLAK

milimetre hassasiyetinde belirleyerek kritik yapıların tespitine olanak sağlamaktadır.

Özellikle, bina yoğunluğunun fazla olduğu alanlarda yansıtıcıların sayısının artması, analiz sonuçlarının doğruluğunu artırmaktadır. Bu veriler, hem zaman içinde meydana gelen yer değiştirmeleri hem de doğrusal ve doğrusal olmayan deformasyon trendlerini haritalandırarak kentsel alanlardaki yapısal risklerin daha doğru bir şekilde değerlendirilmesine yardımcı olmaktadır. Ayrıca, PSI analizlerinde farklı parametrelerin (eşik değeri, yer kontrol nokta-YKN seçimi, zamansal çözünürlük vb.) kullanımının konumsal doğruluk ve PS nokta sayısına etki ettiği görülmüştür. Şekil 2'de yer alan İstanbul analizinde; kıyı kesimlerde, kazı-dolgu yapılan bölgelerde ve inşaat çalışması olan bölgelerde farklı zemin hareketleri görüntülenmiştir.

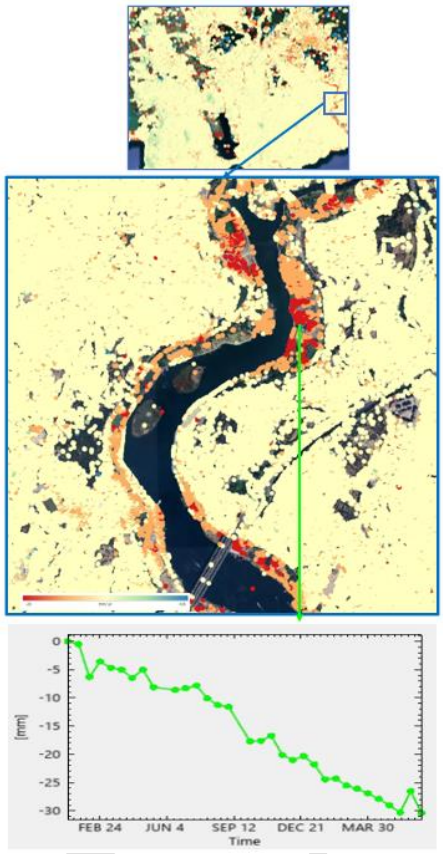


**Şekil 2.** İstanbul ili analiz sonucu

## 4. TARTIŞMA

Çalışma, kentsel dönüşüm, risk yönetimi ve yapı güvenliği gibi alanlarda karar vericilere destek sağlayabilecek nitelikte veriler sunmuştur. Tartışma kapsamında, daha hassas yükseklik modelleri kullanılarak elde edilecek sonuçların doğruluğunun artırılabileceği tespit edilmiştir. Ayrıca, yerde reflektörler hazırlanarak kullanılabilecek hassas YKN entegrasyonu ile analizlerin doğruluğu ve kapsamı genişletilebilir. Bu gelişmeler, ileride yapılacak çalışmalarda şehir izleme ve afet yönetimi için daha güvenilir sonuçların elde edilmesine katkı sunacaktır.

## 5. SONUÇ

Bu çalışmada, İstanbul'daki yapı deformasyonlarını tespit etmek amacıyla PSI yöntemi kullanılmış ve CSG uydu görüntüleri ENVI SARscape yazılımıyla analiz edilmiştir. İstanbul'un yapı ve nüfus yoğunluğu ile aktif fay hattına yakınlığı, çalışmayı daha da önemli hale getirmiştir. Elde edilen deformasyon haritaları ve zaman serisi analizleri, şehirdeki yer değişimlerinin mekânsal dağılımını detaylı biçimde ortaya koymuştur.

**TEŞEKKÜR**

Yazarlar olarak, görüntü ve yazılım konularındaki destekleri nedeniyle IMPRO Uydu Görüntü İşleme ve Telekomünikasyon A.Ş.'ye teşekkürlerimizi sunuyoruz.

**Yazar Katkı Oranı**

Çalışmaya yazarlar eşit oranda katkı sağlamıştır.

## KAYNAKÇA

Bürgmann, R., Rosen, P. A., and Fielding, E. J. (2000). Synthetic aperture radar interferometry to measure Earth's surface topography and its deformation. Annual Review of Earth and Planetary Sciences, 28, 169-209.

Crosetto, M., Monserrat, O., and Luzi, G. (2005). Persistent Scatterer Interferometry for Ground Deformation Monitoring: State of the Art and Applications. Proceedings of the 2005 European Conference on Synthetic Aperture Radar (EUSAR), 1347-1350.

Ferretti, A., Prati, C., and Rocca, F. (2001). Permanent scatterers in SAR interferometry. IEEE Transactions on Geoscience and Remote Sensing, 39(1), 8-20.

Ferretti, A., Fumagalli, A., Novali, F., Prati, C., and Rocca, F. (2007). A New Algorithm for Processing Interferometric Data-Stacks: SqueeSAR. IEEE Transactions on Geoscience and Remote Sensing, 45(5), 1260-1270.

Gabriel, A. K., Goldstein, R. M., and Zebker, H. A. (1989). Mapping small elevation changes over large areas: Differential radar interferometry. Journal of Geophysical Research: Solid Earth, 94(B7), 9183-9191.

Hanssen, R. F. (2001). Radar Interferometry: Data Interpretation and Error Analysis. Kluwer Academic Publishers.

Massonnet, D., and Feigl, K. L. (1998). Radar interferometry and its application to changes in the Earth's surface. Reviews of Geophysics, 36(4), 441-500.

Milillo, P., Berardino, P., and Pepe, A. (2016). Use of Persistent Scatterer Interferometry to detect and monitor ground deformation: Case studies in urban areas. Remote Sensing of Environment, 175, 13-28.

Sousa, J., Crosetto, M., and Luzi, G. (2013). Ground deformation monitoring using Persistent Scatterer Interferometry. International Journal of Applied Earth Observation and Geoinformation, 21, 1-9.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Patates Verimi ile Sentinel-2 Uydu Görüntüleriyle Üretilen Bitki indeksleri Arasındaki Korelasyonun İncelenmesi

**Barış Sucu*[1], Ömer Gökberk Narin[1]**

[1] *Kocatepe Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği, Afyonkarahisar, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Sentinel-2,
Google Earth Engine,
Patates,
NDVI

**ÖZET**

Patates bitkisi en önemli tüketim ürünlerinden birisidir. Bununla birlikte günümüzde tarımsal üretimin sürdürülebilirliği, gıda güvenliği ve doğal kaynakların etkin kullanımı, küresel ölçekte önemini giderek artırmaktadır. Uzaktan algılama verileri bitki tarımsal üretim faaliyetlerinin izlenmesi için oldukça önemli bir veri kaynağıdır. Bu çalışma Sentinel-2 uydu görüntülerinden üretilmiş dört farklı bitki indeksi ile patates verimi arasındaki ilişkiyi araştırmıştır. Bu amaçla, Türkiye'de patates ekiminin yoğun olduğu Afyonkarahisar ili seçilmiştir. Bu kapsamda 32 farklı patates parseli seçilmiştir ve ekim zamanlarına göre erken ekim ve geç ekim zamanlarına göre iki gruba ayrılmıştır. Sonuç olarak erken ekim döneminde NDVI indeksi 2 Temmuz tarihinde en yüksek korelasyonu r=0.9 olarak elde edilmiştir.

# Correlation between Potato Yield with Sentinel-2 Satellite-Derived Vegetation Indices

**Keywords**
Remote sensing,
Sentinel-2,
Google Earth Engine,
Potato,
NDVI

**ABSTRACT**

Potato plant is one of the most important consumer crops. However, today, the sustainability of agricultural production, food safety and efficient use of natural resources are becoming increasingly important on a global scale. Remote sensing data is a very important data source for monitoring agricultural production activities. The study investigates the relationship between four different vegetation indices produced from Sentinel-2 satellite images and potato yield. To this aim, Afyonkarahisar province, where potato cultivation is intensive in Turkey, was selected. 32 different potato plots were selected and divided into two groups according to planting times: early planting and late planting. As a result, the highest correlation of NDVI index in the early planting period was obtained as r=0.9 on 2 July.

## 1. GİRİŞ

Patates (Solanum tuberosum L.) Dünya'da insani tüketim açısından buğday ve pirinç ile birlikte en önemli 3 üründen bir tanesidir. Patates 2024 yılında Türkiye'de de buğday, mısır, arpa ve şeker pancarından sonra en çok ekimi yapılan bitkidir (TÜİK 2024). Dünya'da artan nüfus, kıyılardan gerçekleşen toprak erozyonunun artması ve iklim değişikliğine bağlı olan hava koşullarının değişmesi birçok ürünü etkilediği gibi patates üretimini için riskler barındırmaktadır. Bu sebeple patates ekili arazilerinin takibi önemlidir.

Uzaktan algılama bitki alanı, sağlığı ve verimini izleme ve tahmini konusunda önemli bir kaynaktır (Kasampalis vd., 2018; Narin ve Abdikan, 2022). Bala ve Islam (2009) Bangladeş'te gerçekleştirdikleri çalışmada 50 adet patates tarlasını ait verim bilgisi ile TERRA MODIS'den üretilmiş bitki indeksleri arasında ilişkiye bakmış ve verim tahmini yapmışlardır. Normalize Edilmiş Fark Bitki Örtüsü İndeksi (Normalized Difference Vegetation Index — (NDVI)) ile patates verimi arasında r=0.65 ile r=0.88 arasında korelasyon bulmuşlardır. Al-Gaadi vd., (2016) Suudi Arabistan'ın güneyinde gerçekleştirdikleri çalışmada, Landsat-8 ve Sentinel-2 uydularından üretilen NDVI ve Toprak Ayarlı Bitki Örtüsü İndeksi (Soil Adjusted Vegetation Index — (SAVI) ile patates verimi arasında ilişkiyi incelemiş ve verim tahmini yapmışlardır. Sentinel-2 ile patates veriminin ilişkisini r=0.48 ile r=0.7 değerleri arasında ilişki

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Sucu B & Narin Ö G (2025). Patates Verimi ile Sentinel-2 Uydu Görüntüleriyle Üretilen Bitki indeksleri Arasındaki Korelasyonun İncelenmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

TASLAK

bulmuşlardır. Landsat-8 ile patates veriminin ilişkisini r=0.1 ile r=0.7 değerleri arasında bulmuşlardır.

Bu çalışmada, Sentinel-2 uydu görüntülerinden üretilen NDVI, NDVIred, SAVI ve Patates Verimlilik İndeksi (Potato Productivity Index — (PPI)) kullanılarak patates verimi ile bitki indeksleri arasındaki ilişkilere bakılmıştır.

## 2. YÖNTEM

### 2.1. Çalışma Alanı ve Arazi Çalışmaları

Çalışma alanı Afyonkarahisar ili Sinanpaşa ilçe sınırları içerisinde bulunan Taşoluk Beldesi patates ekili tarım arazileridir (Şekil 1). Afyonkarahisar, Nevşehir ilinden sonra en çok patates ekili arazi'ye sahiptir. Ayrıca Türkiye'nin toplam üretiminin yaklaşık %10'ununu karşılamaktadır (TÜİK 2024). Bölgede karasal iklim hakim olup kışlar soğuk ve kar yağışlı, yazlar ise sıcak ve kuraktır. İlkbahar aylarında yağmur yağışlarının arttığı görülmektedir. Arazi çalışmaları kapsamında 32 adet patates ekili parsel takip edilmiştir. Bu parsellerden 15 tanesi 1-10 Nisan tarihlerinde ekilmiştir. Çalışma'nın diğer kısımlarında bu parsellere erken ekim'li parseller olarak bahsedilmiştir. Geriye kalan 17 adet parsel 20-30 Nisan tarihlerinde ekilmiştir. Çalışma'nın diğer kısımlarında bu parsellere geç ekim'li parseller olarak bahsedilmiştir.

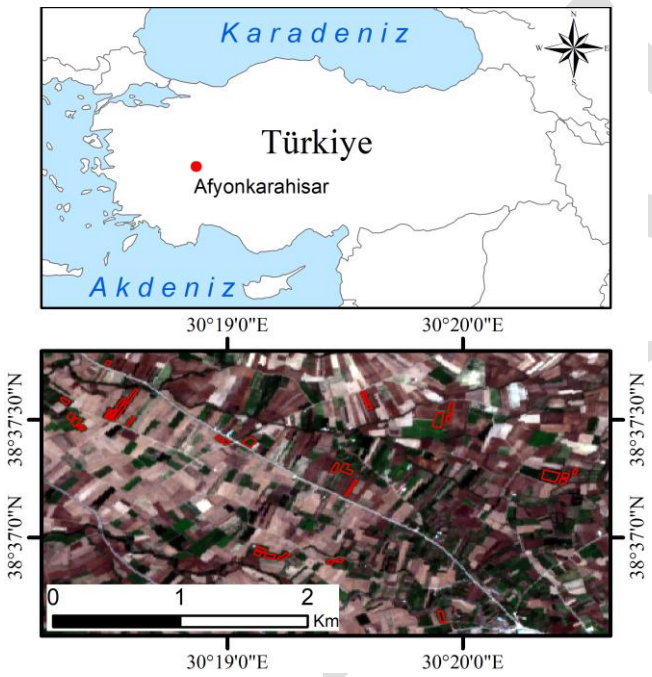


**Şekil 1.** Çalışma alanını gösterir harita, kırmızı alanlar patates ekili arazileri göstermektedir.

### 2.2. Uydu Verileri ve Bitki Örtüsü İndeksleri

Çalışmada Sentinel-2 uydu verileri kullanılmıştır. Ücretsiz ve Açık erişimli olan Sentinel-2 uyduları, 13 farklı spektral banta sahiptir ve Sentinel-2A/B uydularının birlikte kullanımıyla yaklaşık 5 günlük zamansal çözünürlüğe sahiptir (ESA 2025). Sentinel-2 görüntüleri Google tarafından geliştirilen Google Earth Engine platformu kullanılarak indirilmiştir (Gorelick vd., 2017). Analizlerde kullanılmak üzere Nisan-Ekim 2024 tarihleri arasında bulutsuz 37 adet Level-2A (Yüzey Yansıması) görüntüsü bulunmuştur. Çalışma kapsamında 4 farklı bitki örtüsü indeksi üretilmiştir. Bunlar sırasıyla NDVI (Rouse vd., 1974) (Eşitlik-1), NDVIred (Gitelson ve Merzlyak 1994) (Eşitlik-1), SAVI (Huate, 1988) (Eşitlik-3), PPI (Gómez vd., 2021) (Eşitlik-4).

$$NDVI = \frac{B8 - B4}{B8 + B4} \quad (1)$$

$$NDVIred = \frac{B8 - B5}{B8 + B5} \quad (2)$$

$$SAVI = \frac{B8 - B4}{B8 + B4 + L} * (1 + L) \quad (3)$$

$$\mathrm{PPI} = \left(\frac{\mathrm{B3}}{B2 + B4}\right) + \left(\frac{\mathrm{B9}}{B8A}\right) * \left(\frac{\mathrm{B3}}{B5}\right) \quad (5)$$

Formüllerde bulunan bant numaraları Sentinel-2 uydu görüntüsüne göre uyarlanmıştır. SAVI indeksinde bulunan L sabiti 0.5 alınmıştır.

Dekardaki patates verimi ile uydu görüntülerinden elde edilen indeks değerleri arasında bir ilişki olup olmadığının incelenmesi için Pearson'ın Korelasyon katsayısı (r) kullanılmıştır (Eşitlik-6).

$$r = \frac{\sum(p - \overline{p})(v - \overline{v})}{\sqrt{\sum(p - \overline{p})^2 \sum(v - \overline{v})^2}} \quad (6)$$

## 3. BULGULAR

Çalışmada tüm parseller için Sentinel-2 uydu görüntüsünün olduğu her tarihte NDVI, NDVIred, SAVI ve PPI indeksleri üretilmiştir. Ardından her bir parsel için indeks değerleri hesaplanmıştır. Şekil-2'de tüm parsellerin ortalaması hesaplanarak hazırlanmış zaman grafiği verilmiştir. Erken ekilen patates parsellerinin NDVI'a göre en yüksek ulaştığı ortalama değer 2 Temmuz tarihinde 0.81'dir. Geç ekilen patates parsellerinin NDVI'a göre en yüksek ulaştığı ortalama değer 22 Temmuz tarihinde 0.81'dir.

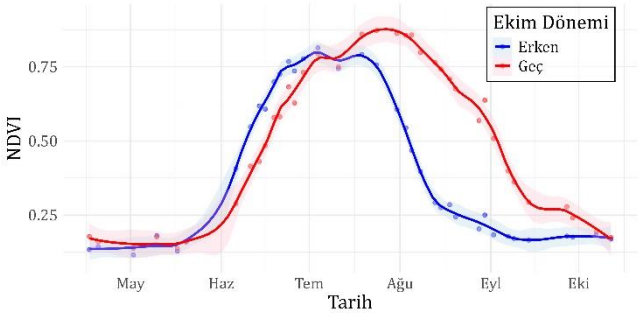


**Şekil 2.** Tüm parsellerin ortalama NDVI değerlerinin yumuşatılmış çizgi grafiğidir. Noktalar parsellere ait gerçek ortalama NDVI değerlerini göstermektedir.

Çalışmada en yüksek korelasyon verilen tarihlerin haziran ve ağustos ayı olduğu görülmüştür. Erken ekim zamanının sonuçlarına bakıldığında en yüksek korelasyon 2 Temmuz tarihinde verim ile NDVI arasında r=0.9 olarak tespit edilmiştir (Çizelge 1). Geç ekim zamanının sonuçlarına bakıldığında en yüksek korelasyon 14 Haziran tarihinde verim ile PPI arasında

r=0.6 olarak tespit edilmiştir. Ayrıca erken ekim döneminde en yüksek korelasyonlar NDVIred için r=0.78, SAVI için r= 0.66 PPI için r=0.64 olarak elde edilmiştir (Çizelge 1).

**Çizelge1.** İndeksler ile verim arasındaki korelasyon katsayıları. Tablodaki renklendirme erken ekim zamanı ve geç ekim zamanı olarak ayrı ayrı yapılmıştır.

| Ekim Zamanı | İndeksler | 9 Haz | 12 Haz | 14 Haz | 17 Haz | 19 Haz | 22 Haz | 24 Haz | 27 Haz | 2 Tem | 9 Tem | 17 Tem |
|---|---|---|---|---|---|---|---|---|---|---|---|---|
| Erken | NDVI | 0.70 | 0.42 | 0.76 | 0.77 | 0.49 | 0.72 | 0.87 | 0.87 | 0.90 | 0.82 | 0.72 |
| | NDVIred | 0.63 | 0.41 | 0.78 | 0.61 | 0.39 | 0.53 | 0.62 | 0.59 | 0.41 | 0.22 | 0.04 |
| | SAVI | 0.64 | 0.52 | 0.66 | 0.61 | 0.52 | 0.58 | 0.65 | 0.60 | 0.40 | 0.34 | 0.10 |
| | PPI | 0.58 | 0.38 | 0.51 | 0.62 | 0.53 | 0.64 | 0.60 | 0.62 | 0.61 | 0.59 | 0.64 |
| Geç | NDVI | 0.14 | 0.34 | 0.33 | 0.07 | 0.33 | 0.18 | 0.30 | 0.35 | 0.21 | 0.25 | 0.34 |
| | NDVIred | 0.08 | 0.21 | 0.24 | 0.06 | 0.27 | 0.12 | 0.26 | 0.21 | 0.08 | 0.16 | 0.15 |
| | SAVI | 0.20 | 0.24 | 0.27 | 0.21 | 0.29 | 0.27 | 0.29 | 0.33 | 0.30 | 0.32 | 0.41 |
| | PPI | 0.12 | 0.43 | 0.60 | 0.35 | 0.53 | 0.43 | 0.46 | 0.51 | 0.42 | 0.48 | 0.46 |

## 4. SONUÇ

Bu çalışmada 4 farklı bitki indeks değeri ile patates parsellerinin verim tahminlerinin korelasyonları incelenmiştir. Patates parselleri erken ekim ve geç ekim zamanı olarak iki farklı grupta değerlendirilmiştir. Bu kapsamda erken ekim zamanında en yüksek korelasyon değerlerini veren indeks NDVI olmuştur. Bununla birlikte dört indeks için tüm tarihlerde olmasa da korelasyon katsayısı r=0.6 ve üstündedir. Geç ekim zamanında ise PPI indeksinin diğer indekslerden daha iyi olduğu görülmektedir. İlerleyen çalışmalarda farklı indekslerle korelasyonlar incelenip, verim tahmini çalışması yapılması planlanmaktadır.

### Yazar Katkı Oranı

Yazarların bildiri metnine eşit oranda katkısı bulunmaktadır.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması yoktur.

### KAYNAKÇA


Al-Gaadi, K. A., Hassaballa, A. A., Tola, E., Kayad, A. G., Madugundu, R., Alblewi, B., & Assiri, F. (2016). Prediction of potato crop yield using precision agriculture techniques. *PloS one*, *11*(9), e0162219. https://doi.org/10.1371/journal.pone.0162219

Bala, S. K., & Islam, A. S. (2009). Correlation between potato yield and MODIS-derived vegetation indices. *International Journal of Remote Sensing*, *30*(10), 2491-2507. https://doi.org/10.1080/01431160802552744

ESA., (2024). Sentinel-2 https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-2: [Erişim tarihi: 25.03.2025]

Gitelson, A., & Merzlyak, M. N. (1994). Spectral reflectance changes associated with autumn senescence of Aesculus hippocastanum L. and Acer platanoides L. leaves. Spectral features and relation to chlorophyll estimation. *Journal of plant physiology*, *143*(3), 286-292. https://doi.org/10.1016/S0176-1617(11)81633-0

Gómez, D., Salvador, P., Sanz, J., & Casanova, J. L. (2021). New spectral indicator Potato Productivity Index based on Sentinel-2 data to improve potato yield prediction: A machine learning approach. *International Journal of Remote Sensing*, *42*(9), 3426-3444. https://doi.org/10.1080/01431161.2020.1871102

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote sensing of Environment*, *202*, 18-27. https://doi.org/10.1016/j.rse.2017.06.031

Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote sensing of environment*, *25*(3), 295-309. https://doi.org/10.1016/0034-4257(88)90106-X

Kasampalis, D. A., Alexandridis, T. K., Deva, C., Challinor, A., Moshou, D., & Zalidis, G. (2018). Contribution of remote sensing on crop models: a review. *Journal of Imaging*, *4*(4), 52. https://doi.org/10.3390/jimaging4040052

Narin, O. G., & Abdikan, S. (2022). Monitoring of phenological stage and yield estimation of sunflower plant using Sentinel-2 satellite images. *Geocarto international*, *37*(5), 1378-1392. https://doi.org/10.1080/10106049.2020.1765886

Rouse J, Haas R, Schell J, Deering D. 1974. Monitoring vegetation systems in the great plains with ERTS.In: Third ERTS Symposium, 10–14 December 1974, Washington, USA, Vol. 1; p. 48–62

TÜİK., (2024). Bitkisel Üretim İstatistikleri, https://data.tuik.gov.tr/Bulten/Index?p=Bitkisel-Uretim-Istatistikleri-2024-53447: [Erişim tarihi: 24.03.2025]


© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Afet Senaryolarında Parsel Bazlı Erişilebilirlik, Yol Genişliği ve Eğim Analizi: İstanbul Fikirtepe Örneği

**Veysel AKATAY*[1], Aycan Murat MARANGOZ[2]**

[1]*Bülent Ecevit Üniversitesi, FBE, Geomatik Mühendisliği Anabilim Dalı, Zonguldak, Türkiye*
[2]*Bülent Ecevit Üniversitesi, Geomatik Mühendisliği Bölümü, Zonguldak, Türkiye*

**Anahtar Kelimeler**
Erişilebilirlik,
Yol Eğim,
Yol Genişliği,
Afet,
SAM

**ÖZET**

Büyük ve kalabalık şehirlerde erişilebilirlik analizleri, kentsel yönetim, planlama ve afet durumlarında kritik bir öneme sahiptir. Özellikle İstanbul gibi yoğun nüfus ve trafik hareketine sahip şehirlerde, bu analizler yöneticilere stratejik kararlar alırken rehberlik ederken, vatandaşlar için daha sürdürülebilir bir yaşam sağlamaktadır. Bu çalışma, İstanbul ili Fikirtepe bölgesine odaklanmakta ve itfaiye istasyonlarından tüm parsellere erişilebilirlik sürelerinin hesaplanmasını ve görselleştirilmesini içermektedir. Analiz kapsamında, İstanbul Büyükşehir Belediyesi'nin güncel SAM verisi, yol verileri, parsel verileri, yol hız verileri ve itfaiye istasyonlarına ait Poi'ler kullanılmıştır. Yol genişliği analizinde, ağır tonajlı araçlar ve acil müdahale ekiplerinin güzergâh planlamaları için belirleyici bir veri sağlanmıştır. Bunun yanı sıra, şerit düzenlemeleri, kavşak tasarımları ve yol bakım planlamalarına yönelik öngörüler sunulmuştur. Yol eğim analizi ise, dik yokuşların acil müdahale araçlarının hareketliliği üzerindeki etkilerini değerlendirmek için gerçekleştirilmiştir. FME ve ArcGIS programları kullanılarak yapılan analizler, parsel bazlı erişim sürelerini ve yol verilerini görselleştirerek kentsel yönetim süreçlerine dair önemli çıktılar sunmuştur. Sonuç olarak, bu çalışma, erişilebilirlik, yol genişliği ve eğim analizlerini bütünleştirerek afet yönetimi, trafik düzenlemeleri ve kentsel planlama için etkili bir rehber niteliği taşımaktadır.

# Parcel-Based Accessibility, Road Width and Slope Analysis in Disaster Scenarios: A Case Study of Istanbul Fikirtepe

**Keywords**
Accessibility,
Road Slope
Road Width,
Disaster
SAM

**ABSTRACT**

In large and crowded cities, accessibility analysis is critical for urban management, planning and disaster response. Especially in cities with dense population and traffic movement such as Istanbul, these analyses guide managers in making strategic decisions and provide a more sustainable life for citizens. This study focuses on the Fikirtepe region of Istanbul and includes the calculation and visualization of accessibility times from fire stations to all parcels. Within the scope of the analysis, current DEM data of Istanbul Metropolitan Municipality, road data, parcel data, road speed data and Pois of fire stations were used. The road width analysis provides decisive data for route planning of heavy tonnage vehicles and emergency response teams. In addition, predictions for lane arrangements, intersection designs and road maintenance plans are presented. Road slope analysis was performed to assess the effects of steep gradients on the mobility of emergency response vehicles. Analyses using FME and ArcGIS programs visualized parcel-based access times and road data, providing important outputs for urban management processes. As a result, this study integrates accessibility, road width and slope analysis to provide an effective guide for disaster management, traffic regulation and urban planning.

* **Sorumlu Yazar**

*(veyselakatay@gmail.com) ORCID ID 0000-0001-8682-4745
(aycanmarangoz@hotmail.com) ORCID ID 0000-0003-4409-6000

**Kaynak Göster (APA):**

Akatay V & Marangoz A (2025). Afet Senaryolarında İtfaiye Araçları İçin Parsel Bazlı Erişilebilirlik Analizi ve Yol Genişliği Üzerine Bir Çalışma: İstanbul Örneği 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Kentsel alanlarda artan nüfus yoğunluğu ve karmaşık trafik yapısı, şehirlerin erişilebilirlik, altyapı planlaması ve afet yönetimi gibi kritik konularda daha analitik ve veri odaklı yaklaşımlar geliştirilmesini zorunlu kılmaktadır. Özellikle İstanbul gibi anakent şehirlerde, erişilebilirlik analizleri, acil müdahale kapasitelerinin değerlendirilmesinden trafik yönetimine kadar geniş bir yelpazede stratejik karar alma süreçlerine katkı sağlamaktadır. Bunun yanı sıra, yol genişliği ve eğim parametreleri, güzergâhların en uygun seviyeye getirilmesinden, altyapı iyileştirme süreçlerine kadar çok yönlü kullanım alanları sunmaktadır.

Bu çalışmada, İstanbul'un Fikirtepe Kentsel Dönüşüm alanı bölge olarak seçilmiş ve bu bölgede eldeki veriler ışığıyla parsel bazlı erişim süreleri hesaplanmış, yol genişliği ve eğim verileriyle zenginleştirilmiş sonuçlar elde edilmiştir. Çalışma, yol ağı, hız bilgisi ve yükseklik verisi gibi farklı veri kaynaklarının bütünleşik bir yaklaşımla işlenmesi ve görselleştirilmesi yoluyla sadece mevcut durumu anlamaya yönelik değil, aynı zamanda gelecekteki planlama süreçlerine rehberlik edecek bir analiz modeli sunmaktadır.

## 2. YÖNTEM

Bu çalışmada, Fikirtepe bölgesinde erişilebilirlik, yol genişliği ve eğimi analiz edilerek kentsel planlama sürecine katkı sağlanmıştır. SAM (Sayısal Arazi Modeli) verileri kullanılarak yol eğimleri hesaplanmış, trafik hız verileri Safe Software tarafından geliştirilen FME (Feature Manipulation Engine) programıyla incelenmiş ve yol genişlikleri belirlenmiştir.

İstanbul Büyükşehir Belediyesi'nin açık veri kaynak sitesinde yayınladığı 2022 yılı hız verileri birleştirmesiyle mesai saatlerindeki hız değişimleri değerlendirilmiş, hız verisi eksik yollar için Ulaşım Koordinasyon Merkezinin (UKOME) belirlediği hız limitleri referans alınmıştır.

Yol eğim analizinde, yollar 40 metrelik parçalara bölünerek kırılım noktalarına Z değerleri atanmış, maksimum ve minimum eğim değerleri hesaplanmıştır. Yol genişlikleri, en yakın komşuluk analizi ve kesit alma yöntemleriyle belirlenmiş, istatistiksel hesaplamalarla yol verisi ile birleştirilmiştir.

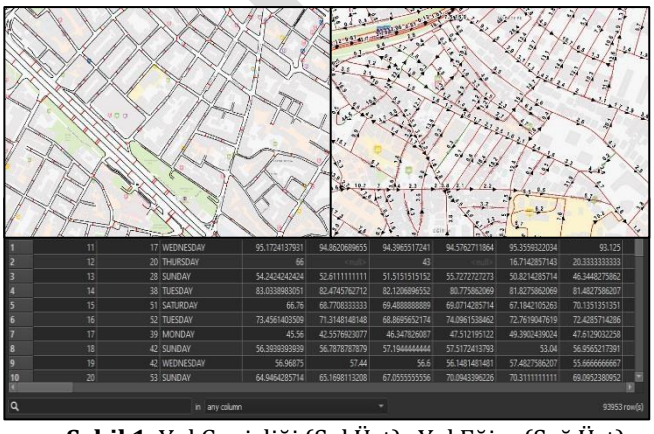

| | | | | | | | | |
|---|---|---|---|---|---|---|---|---|
| 1 | 11 | 17 | WEDNESDAY | 95.1724137931 | 94.8620689655 | 94.3965517241 | 94.5762711864 | 95.3559322034 | 93.125 |
| 2 | 12 | 20 | THURSDAY | 66 | null | 43 | null | 16.7142857143 | 20.3333333333 |
| 3 | 13 | 28 | SUNDAY | 54.2424242424 | 52.6111111111 | 51.5151515152 | 55.7272727273 | 50.8214285714 | 46.3448275862 |
| 4 | 14 | 38 | TUESDAY | 83.0338983051 | 82.4745762712 | 82.1206896552 | 80.7758620069 | 81.8275862069 | 81.4827586207 |
| 5 | 15 | 51 | SATURDAY | 66.76 | 68.7708333333 | 69.4888888889 | 69.0714285714 | 67.1842105263 | 70.1351351351 |
| 6 | 16 | 52 | TUESDAY | 73.4561403509 | 71.3148148148 | 68.8695652174 | 74.0961538462 | 72.7619047619 | 72.4285714286 |
| 7 | 17 | 39 | MONDAY | 45.56 | 42.5576923077 | 46.347826087 | 47.5121951122 | 49.3902439024 | 47.6129032258 |
| 8 | 18 | 42 | SUNDAY | 56.3939393939 | 56.7878787879 | 57.1944444444 | 57.5172413793 | 53.04 | 56.9565217391 |
| 9 | 19 | 42 | WEDNESDAY | 56.96875 | 57.44 | 56.6 | 56.1481481481 | 57.4827586207 | 55.6666666667 |
| 10 | 20 | 53 | SUNDAY | 64.9464285714 | 65.1698113208 | 67.0555555556 | 70.0943396226 | 70.3111111111 | 69.0952380952 |

in any column — 93953 row(s)

**Şekil 1.** Yol Genişliği (Sol Üst) , Yol Eğim (Sağ Üst) Trafik Hız Verileri (Alt)

Parsel erişilebilirlik analizinde, her parselin en yakın yol bağlantısı üzerinden ulaşım süresi hesaplanmış ve ağ analizi yapılmıştır. Tüm veriler puanlama sistemine tabi tutularak afet senaryolarına göre kullanılabilir ve kullanılamaz yollar tespit edilerek görselleştirilmiştir.

## 3. BULGULAR

Yapılan analizler, yol genişlikleri, erişilebilirlik ve acil durum senaryoları açısından önemli bulgular ortaya koymuştur. İtfaiye istasyonlarının bazı parsellere erişiminde dar yollar, yoğun trafik ve dik eğimler nedeniyle kritik gecikmeler tespit edilmiştir.

Ana ulaşım yollarının bazı bölümlerde yetersiz genişliğe sahip olduğu belirlenmiş ve alternatif yollar önerilmiştir. SAM verileri, eğimli yolların acil müdahale araçlarının hareketini kısıtladığını göstermiştir.

2022 trafik verileri, mesai saatlerinde hız düşüşleri yaşandığını ve trafik yönetimi ile sinyalizasyon sisteminin en uygun hale getirilmesinin önemini ortaya koymuştur. Tüm veriler değerlendirilerek, bazı yolların yüksek eğim, dar genişlik veya yoğun trafik nedeniyle acil durum erişimine uygun olmadığı saptanmıştır.

## 4. TARTIŞMA

Fikirtepe bölgesinde yol erişilebilirliğinin dar yollar, eğim ve trafik yoğunluğundan etkilendiğini göstermektedir. Yol genişliği analizleri bazı ana ulaşım yollarının yetersiz olduğunu ortaya koyarken, eğim hesaplamaları ise ulaşımı kısmen zorlaştıran bölgeleri belirlemiştir. Trafik verileri, mesai saatlerinde hız düşüşlerinin yaşandığını ve şehir içi trafik yönetiminin iyileştirilmesi gerektiğini göstermektedir. Elde edilen bulgular, afet ve acil durum planlamalarında yol altyapısının kritik önem taşıdığını ortaya koymaktadır.

## 5. SONUÇ

Elde edilen bulgular doğrultusunda, şehir içi ulaşım planlamasında alternatif yolların geliştirilmesi, trafik akışının en uygun hale getirilmesi ve acil durum senaryoları kapsamında yol altyapısının güçlendirilmesi önerilmektedir.

Ayrıca, puanlama sistemi ile belirlenen kullanılamaz yolların iyileştirilmesi veya alternatif güzergâhların oluşturulması, afet durumlarında erişilebilirliği artırmak açısından büyük önem taşımaktadır. Bu analizler, kent içi ulaşım planlaması ve kentsel dönüşüm projelerine veri temelli bir bakış açısı kazandırarak, daha güvenli ve erişilebilir bir ulaşım ağı oluşturulmasına katkı sağlayacaktır.

### Yazar Katkı Oranı

Veysel AKATAY: Kavramsallaştırma, Metodoloji, Yazılım. Yazma-Orijinal taslak hazırlama, Yazılım, Doğrulama.

Aycan Murat MARANGOZ: Görselleştirme, İnceleme, Yazma-İnceleme ve Düzenleme.

TASLAK

**Çıkar Çatışması Beyanı**

Yazar/lar arasında herhangi bir çıkar çatışması bulunmamaktadır.

**Araştırma ve Yayın Etiği Beyanı**

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur**.**

**KAYNAKÇA**


Aydın, S. (2017). Yol eğimi ve erişilebilirlik analizlerinin şehir içi ulaşım planlamasında uygulanabilirliği. Yüksek Lisans Tezi, Hacettepe Üniversitesi Mühendislik Fakültesi.

Berkes, F., & Turner, N. J. (2018). Road safety and accessibility in rural and urban areas: Lessons from comparative studies. Transportation Research Part A, 110, 174-183.

Chien, S. (2019). Dynamic traffic congestion and road safety measures in metropolitan areas. PhD Thesis, University of Michigan, USA

Çelik M. (2015). Afet yönetiminde ulaşım altyapısının rolü: İstanbul örneği. Yüksek Lisans Tezi, Boğaziçi Üniversitesi Sosyal Bilimler Enstitüsü

Duran, M., & Arslan, G. (2015). Trafik yoğunluğunun şehir içi ulaşım üzerindeki etkileri. Ulaşım Dergisi, 19(2), 112-130.

Günay, G., & Çelik, A. (2012). Şehir içi yol eğim analizi ve erişilebilirlik çalışmaları: Ankara örneği. Coğrafya ve Ulaşım Dergisi, 8(3), 1-14.

Kara, M. (2016). Ulaşılabilirlik kavramı ve şehir içi ulaşımda erişilebilirliğin değerlendirilmesi. Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü

Torrens, , P. M. (2017). Spatial analysis of road networks and urban accessibility. PhD Thesis, University of California, Berkeley

Özdemir, G., & Topçu, D. (2013). Ulaşılabilirlik analizi için bir yöntem: İstanbul örneği. İstanbul Teknik Üniversitesi Dergisi, 12(1), 45-59.

Yılmaz, M. (2019). Afet anında ulaşım yönetimi ve yol güvenliği: İstanbul örneği. Afet ve Acil Durum Yönetimi Dergisi, 3(2), 123-137.

Yılmaz, A., & Öztürk, S. (2018). Trafik yönetiminde yeni teknolojilerin kullanımı ve çözüm önerileri. 5. Uluslararası Ulaşım ve Lojistik Sempozyumu, 24-25 Eylül 2018, İstanbul, Türkiye.

Zhang, R., & Li, Y. (2016). A study on road safety improvements using smart technologies. International Transportation and Infrastructure Conference, 2016, Beijing, China

Zhang, W., & Xie, Y. (2016). Road accessibility and traffic safety analysis in urban areas: A case study in Beijing. Journal of Urban Planning, 18(3), 245-257.


© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# CBS Yöntemleriyle Açık Kaynak Kodlu Yazılımlar Kullanılarak Afet Bilgi Sistemi Oluşturulması: Şişli İlçesi Örneği

**Süleyman Yılmaz*[1], Aycan Murat Marangoz[2]**

[1]*Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Geomatik Mühendisliği ABD., Zonguldak, Türkiye*
[2]*Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Zonguldak, Türkiye*

**Anahtar Kelimeler**
CBS,
Afet,
Deprem,
Açık Kaynak Kodlu Yazılım

**ÖZET**

Ülkemiz son yıllarda deprem, yangın ve sel gibi birçok afetten derinden etkilenmiştir. İstanbul, coğrafi konumu ve yoğun nüfusuyla deprem, yangın, sel ve su taşkınları gibi doğal afetler konusunda yüksek risk taşıyan bir metropol olarak öne çıkmaktadır. İstanbul'un Şişli ilçesindeki yapıların çoğunluğu 2000 yılı öncesinde eski yönetmeliklere göre yapılmıştır. Özellikle depreme karşı yüksek risk barındırmaktadır. Yangın ve su taşkınları gibi diğer doğal afetler de İstanbul için önemli tehditler arasında yer almaktadır. Artan kent nüfusu ve yapılaşması, yangın riskini artırırken, iklim değişikliğinin etkileri ve altyapı eksiklikleri sel ve su taşkınlarına karşı savunmasızlığı artırmaktadır. Özellikle yoğun yağışlar sonrası meydana gelen su baskınları, ulaşımı aksatmakta, altyapı sistemlerine zarar vermekte ve günlük yaşamı olumsuz etkilemektedir. Bu tür afetlere karşı hazırlıklı olmak için konumsal verilerden faydalanılan bir afet bilgi sisteminin geliştirilmesi büyük önem taşımaktadır. Bu çalışmada Şişli ilçesi hakkında afetlere yönelik veri araştırması ve veri sayısallaştırılması yapılarak bir Postgresql veritabanı oluşturulmuştur. Bu veritabanındaki katmanlar OGC (Open Geospatial Consortium) standartlarında WMS (Web Map Service) ve WFS (Web Feature Service) olarak Geoserver üzerinden yayınlanmıştır. Açık kaynak kodlu yazılımlar (QGIS ve Qgis2web eklentisi) ile uygulamanın kodları oluşturularak web tabanlı bir afet bilgi sistemi hazırlanmıştır. Qfield eklentisi ile ise mobil uygulama üzerinden de verilerin yayınlanıp kullanımı sağlanmıştır. Çalışmada istenilen her bölgenin verisinin kullanılabilir olmasıyla tüm dünyada afetlere karşı insanlığın direncinin artmasına katkı sağlaması hedeflenmiştir.

# Creating a Disaster Information System Using Open-Source Software with GIS Methods: A Case Study of Şişli District

**Keywords**
GIS,
Disaster,
Earthquake,
Open Source Software

**ABSTRACT**

In recent years, our country has been deeply affected by numerous disasters, including earthquakes, wildfires, and floods. Due to its geographical location and dense population, Istanbul stands out as a metropolitan area with a high risk of natural disasters such as earthquakes, fires, floods, and water inundations. The majority of the buildings in the Şişli district of Istanbul were constructed before the year 2000 under outdated regulations, making them particularly vulnerable to earthquakes. Additionally, other natural disasters, such as fires and floods, pose significant threats to Istanbul. To enhance preparedness for such disasters, the development of a disaster information system utilizing spatial data is of great importance. In this study, a PostgreSQL database was created by conducting data research and digitization related to disasters in the Şişli district. The layers in this database were published via GeoServer as WMS (Web Map Service) and WFS (Web Feature Service) in compliance with OGC (Open Geospatial Consortium) standards. To develop a web-based disaster information system without requiring programming knowledge, open-source software (QGIS and the Qgis2web plugin) was used to generate the application's code, resulting in the creation of a disaster information system. Furthermore, with the integration of the QField plugin, data was also published and made accessible via a mobile application. By enabling the use of data from any desired region, this study aims to contribute to enhancing humanity's resilience against disasters on a global scale.

* **Sorumlu Yazar**

*(suleymanyilmaz99@gmail.com) ORCID ID 0000–0002–1331–6659
(aycanmarangoz@hotmail.com) ORCID ID 0000–0003–4409–6000

**Kaynak Göster (APA):**

Yılmaz S & Marangoz A M (2025). CBS Yöntemleriyle Açık Kaynak Kodlu Yazılımlar Kullanılarak Afet Bilgi Sistemi Oluşturulması: Şişli İlçesi Örneği, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Açık kaynak kodlu yazılımlarla Şişli ilçesi için afet konulu bir CBS (Coğrafi Bilgi Sistemi) yazılımı oluşturarak afet öncesi ve sonrası yapılan veya yapılacak çalışmalara konumsal verilerle hazırlıklı olmak, ilçeye üst ölçekten bakabilmeyi sağlamak bu çalışmanın amacını oluşturmaktadır. Eğitim, çevre, mülkiyet, bayındırlık, ulaşım, sağlık, turizm, orman, tarım, ticaret, sanayi, belediye ve savunma gibi birçok başlıkta açık kaynak kodlu CBS uygulamaları kullanılmaktadır (Karataş & Kırbaş, 2015). Fu (2018) yılında yazmış olduğu "Getting to Know WEB GIS" adlı kitabında şu şekilde bir tanımlama yapmaktadır; Web CBS, web ve CBS'nin birleşimidir. Web, siber uzaydaki mesafe kısıtlamasını ortadan kaldırmıştır. Böylece insanlara küresel olarak CBS uygulamalarıyla etkileşimde bulunma ve bilgiye neredeyse anında erişme özgürlüğü sağlamaktadır.

Açık kaynak kodlu yazılımlar, eğitim ve öğrenme, maliyet tasarrufu, özelleştirilebilirlik ve topluluk desteği gibi avantajlardan yararlanılmasını sağlamaktadır (Yektek, 2024). Çağımızın bilgi ve iletişim kaynağı olan internet ortamında bilgiyi sunulabilir hale getirmektedir. Böylece, acil ulaşım yolları, toplanma alanları, dere yatakları ve eğimli araziler gibi verilere insanların daha kolay ulaşmasına; afet öncesi bilgilenmesine, afet anında ve sonrasında ise bilinçli hareket etmesine katkı sağlanır (Arca, 2012). Özellikle afet sonrası dönemde hasar tespiti gibi saha çalışmalarında, mobil olarak da veri üretimi ve güncelleştirmesi; farklı etmenleri bir arada bütün olarak görüp eksiklerin fark edilmesi ve farklı bakış açıları edinilmesi de hedeflenmektedir. Çalışma alanı olarak özellikle eski yapı stoğuyla dikkat çeken İstanbul'un Şişli ilçesi seçilmiştir (İBB, 2022). Kamu yararı için hazırlanan bu çalışma, diğer bölgeler için de uygulanabilir ve geniş bir kullanıcı kitlesine erişilebilir.

## 2. YÖNTEM

Açık kaynaklı veri araştırmaları internet üzerinden yapılmış, ayrıca kamu kuruluşlarından gerekli izinler alınarak vektör veriler temin edilmiştir.

Afet sonrası gerekli olacak acil ulaşım yolları, toplanma alanları, sağlık kuruluşları, emniyet merkezleri, okul, otel, kamu kuruluşlarının konumları projeye eklenmiş ve QGIS kullanılarak düzenlenmiştir. Toplanma alanlarına yakınlıklara göre bölgeler oluşturulmuş ve bu bölgelere göre tahliye koridorları planlanmıştır. Coğrafi veriler projeye eklenmiş, coğrafi veri formatında olmayan veya sayısal olmayan veriler ise QGIS aracılığıyla sayısallaştırılmıştır. Projenin veritabanı, veri servisi, mobil erişim aşamalarında da açık kaynak kodlu yazılımlar kullanılmıştır.

### 2.1. Veritabanı Oluşturulması

Postgresql veritabanının Postgis eklentisi kullanılarak konumsal verinin veritabanına eklenebilmesi sağlanmaktadır (Ikechukwu & Okeke, 2018). Geoserver web servisi kullanılarak da bu veriler web ortamında sunulabilir hale gelmektedir.

### 2.2. Web Tabanlı Uygulama Oluşturulması

QGIS'in Qgis2web eklentisiyle bir Javascript kütüphanesi olan Leaflet kullanılarak CBS yazılımı oluşturulmasını sağlanmıştır. Böylece, herhangi bir kod yazma bilgisi gerekmeksizin ".css", ".js" ve ".html" formatlarında kod çıktıları elde edilmiştir. Bu işlemle elimizdeki coğrafi veriler geojson formatına dönüşmüştür.

Şekil 1'de göründüğü gibi, uygulama katman yönetim penceresinin yanı sıra yakınlaşma-uzaklaşma, ölçüm araçları, konumuma git ve arama özelliği gibi bazı özellikler eklenmiştir.




**Şekil 1.** Qgis2web ile kodları hazırlanan uygulama görünümü

### 2.3. Projenin Mobil Uygulamaya Aktarılması

Opengis.ch firmasının QFieldCloud bulut ürünü, QField mobil uygulaması ve QField Sync eklentileri, QGIS'de hazırlanan verilerin mobil uygulamalar üzerinden kullanılabilmesine olanak sağlamaktadır (OPENGIS.ch, 2025b). QField Sync eklentisi kullanılarak, QGIS'te hazırlanan veri ve proje QFieldCloud bulut sistemine yüklenmiştir. QField mobil uygulamasında ilgili QField hesabına giriş yapılmış, ardından buluta yüklenen projeye ulaşılabilir hale gelmiştir.

Bu sayede, çalışma kapsamında Android ya da iOS işletim sistemli mobil cihazlarda veriler görüntülenmiş, düzenlenmiş ve yeni veriler eklenebilmiştir. Bulut altyapısı sayesinde çift taraflı senkronizasyon gerçekleştirilmiştir (OPENGIS.ch, 2025a).

## 3. BULGULAR

CBS tabanlı afet bilgi sisteminin Şişli ilçesi özelinde uygulanabilir olduğu görülmüştür. Açık kaynaklı yazılımların sağladığı esneklik sayesinde, kurumların ve bireylerin afet yönetimine katılımı kolaylaştırılmıştır. Mobil uygulamalar sayesinde, afet anında ve sonrasında anlık veri güncelleme imkanı sağlanmıştır. Qgis2web kullanıldığında veriler geojson olarak saklanıp Postgresql veritabanı olmadan ve Geoserver kullanılmadan da uygulama çalıştığı anlaşılmıştır. QGIS'te hazırlanan proje dosyası koda dönüştürülürken bazı hatalarla karşılaşılmıştır. Hatanın temel kaynağının veri kaynaklı olduğu anlaşılmıştır. Katmanların sembolojisi ve tanımlı koordinat sistemleri hataya sebep olabilmektedir.

Mobil uygulamaya aktarılan projede web tabanlı projeden farklı olarak görüntüleme ve düzenleme aynı anda yapılabilmektedir. Web tabanlı uygulamada

tarayıcı üzerinden görüntüleme yapılırken veri düzenleme QGIS üzerinden yapılabilmektedir.

## 4. TARTIŞMA

Kod oluşturma aşamasında kullanılan katmanların özelliklerinin çıkarabileceği sorunlar tam kestirilememekle birlikte, semboloji ve koordinat sistemlerinden kaynaklı bazı hatalar tespit edilmiştir. Uygulama oluşturma aşamasında sorun çıkmaması için daha detaysız basit semboloji kullanılmalıdır. Katmanların tanımlı koordinat sistemleri da aynı olması hataların önüne geçmektedir. Sorunun neden kaynaklandığını çözmek için araştırma yapılması ve bütün katmanların kontrol edilmesi gerekmektedir. Qgis2web eklentisinin yetenekleri sınırlıdır fakat temel olarak işlevini yerine getirmektedir. Postresql veritabanı ve Geoserver işlemleri olmadan da uygulama çalışmakta ancak belli sınırlar içinde kalınmasına sebep olmaktadır. Bu yüzden kodlara müdahale edilip Geoserver üzerinden yayınlanan servisler ve farklı özelikler eklenerek uygulama geliştirilebilir.

## 5. SONUÇ

Bu çalışmanın sonuçları, Şişli ilçesi için geliştirilecek CBS tabanlı afet bilgi sisteminin, afetlere hazırlıklı olmada büyük bir katkı sağlayabileceğini ve afet yönetimi alanındaki potansiyelini göstermektedir. Sistemin sadece Şişli ile sınırlı kalmayıp, diğer bölgelerde de uygulanabilir olması hedeflenmelidir.

CBS tabanlı verilerin web ve mobil uygulamalar aracılığıyla kullanıcı dostu hale getirilmesi, afet yönetiminde etkinliği artıracaktır. Kamu kurumlarının CBS projelerinde açık kaynak kodlu yazılımları benimsemeleri, maliyetleri azaltacak ve sürekli güncellenebilen sistemlerin oluşmasını sağlayacaktır.

Kod oluşumu sırasında oluşan hatalar katmanların koordinat sistemi, etiket ve semboloji gibi özellikleri kontrol edilip değiştirildiğinde; daha basit seçenekler tercih edildiğinde kullanımı uygulamanın temel işlev ve amacının yerine getirilmesinde başarıya ulaşmasına engel olmamaktadır. Oluşturulan temel kodun üzerine istenilen ekstra geliştirmeler de sağlanabilmesiyle uzun yıllar kullanılabilecektir.

**TEŞEKKÜR**

Projeye veri paylaşımı sağlayan Şişli Belediyesi'ne teşekkür ederim.

**Yazar Katkı Oranı**

Süleyman YILMAZ: Kavramsallaştırma, Veri Toplama, Metodoloji, Yazma-Orijinal taslak hazırlama, Yazılım, Doğrulama.

Aycan Murat MARANGOZ: Görselleştirme, İnceleme, Yazma-İnceleme ve Düzenleme.

**Çıkar Çatışması/Çakışması**

Yazarlar arasında herhangi bir çıkar çatışması/çakışması yoktur.

**Araştırma ve Yayın Etiği Beyanı**

Çalışmanın araştırma ve yayın etiği hakkında açıklanması gereken herhangi bir bilgi yoktur.

## KAYNAKÇA

Arca, D. (2012). Afet Yönetiminde Coğrafi Bilgi Sistemi ve Uzaktan Algılama. Karaelmas Fen ve Mühendislik Dergisi, 53-61

Fu, P. (2018). Getting to Know WEB GIS, Thirth Edition.

Ikechukwu, M. N., & Okeke, F. I. (2018). Towards realisation of heterogeneous Earth-observation sensor database framework for the sensor observation service based on PostGIS. arXiv preprint. doi: 10.48550/arXiv.1802.06183

İstanbul Büyükşehir Belediyesi [İBB], (2022). Şişli İlçesi 1/5000 Ölçekli Nazım İmar Planı Raporu. İstanbul Büyükşehir Belediyesi, Şehir Planlama Müdürlüğü. [Erişim tarihi: 12.03.2025], https://sehirplanlama.ibb.istanbul/wp-content/uploads/2022/12/PR_94151.pdf

Karataş İ. & Kırbaş İ. (2015). Açık Kaynak Kodlu Coğrafi Bilgi Sistemi Yazılımların Karşılaştırmalı Değerlendirilmesi. XVII. Akademik Bilişim Konferansı Bildirileri, Anadolu Üniversitesi. doi: 10.13140/RG.2.1.3113.2241

OPENGIS.ch, (2025a). QFieldCloud Başlangıç Rehberi, OPENGIS.ch, [Erişim tarihi: 12.03.2025], https://support.qfield.cloud/portal/en/kb/articles/get-started-tutorials-get-started-qfc

OPENGIS.ch, (2025b). QField Ekosistemi Dokümantasyonu, OPENGIS.ch, [Erişim tarihi: 12.03.2025], https://docs.qfield.org/get-started/tutorials/get-started-qfc/

Yektek, K. (2024). Açık Kaynak Kodlu Yazılım Nedir?, https://www.patika.dev/blog/acik-kaynak-kodlu-yazilim-nedir: [Erişim tarihi: 15.02.2025].

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Uzaktan Algılama Verilerini Kullanarak Türkiye'deki Sıcaklık, Yağış ve Bitki Örtüsü Değişimlerinin İklim Sınıflandırması ve Analizi

**Nehir Uyar, Azize Uyar**

**Anahtar Kelimeler**
Uzaktan Algılama,
İklim sınıflandırma,
K-Ortalamalar Kümelemesi,
Görüntü İşleme

**ÖZET**

Bu çalışma, Türkiye'nin iklim sınıflandırmasını ve her bir iklim sınıfı için sıcaklık, yağış ve bitki örtüsü değişimlerini analiz etmeyi amaçlamaktadır. Çalışmada, ECMWF ERA5-Land iklim verileri (2000-2020) ve MODIS NDVI verileri kullanılarak, 4 farklı iklim sınıfı oluşturmak için K-Means kümeleme algoritması uygulanmıştır. Sonuç olarak, 4 farklı iklim sınıfı belirlenmiş ve her bir sınıf için toplam alan hesaplanmıştır. Sınıf 0'ın alanı 37,512.74 km$^2$, Sınıf 1'in alanı 210,171.11 km$^2$, Sınıf 2'nin alanı 157,518.91 km$^2$ ve Sınıf 3'ün alanı ise 365,654.11 km$^2$ olarak belirlenmiştir. İklim sınıflarına ait sıcaklık istatistikleri de hesaplanmış, her sınıfın minimum ve maksimum sıcaklıkları belirlenmiştir. Sınıf 0 için minimum sıcaklık 0.10°C, maksimum sıcaklık ise 13.12°C olarak hesaplanmıştır; Sınıf 1'de minimum 0.63°C, maksimum ise 10.67°C; Sınıf 2'de minimum 10.71°C, maksimum 19.87°C; ve Sınıf 3'te minimum 8.46°C, maksimum ise 15.22°C olarak bulunmuştur. Ayrıca, MODIS NDVI verileriyle Sınıf 0 için 2002-2020 yılları arasında bir zaman serisi analizi yapılmış, bu analiz bitki örtüsündeki yıllık değişimleri incelemeye yöneliktir ve sınıf 0 için belirgin bir mevsimsel değişim göstermektedir. Bu çalışma, Türkiye'deki farklı iklim sınıflarını belirlemek ve bu sınıfların sıcaklık ve bitki örtüsü özelliklerini analiz etmek için ECMWF ERA5-Land iklim verilerinin ve MODIS NDVI verilerinin birleşik kullanımını sunmaktadır. Bu tür analizler, iklim değişikliği araştırmalarına katkı sağlamak ve yerel düzeydeki iklim etkilerini daha iyi anlamak için önemli bir temel oluşturmaktadır.

## Climate Classification and Analysis of Temperature, Precipitation, and Vegetation Changes in Turkey Using Remote Sensing Data

**Keywords**
Remote sensing,
Climate Classification,
K-Means Clustering,
Image Processing

**ABSTRACT**

This study aims to classify Turkey's climate and analyze the changes in temperature, precipitation, and vegetation for each climate class. The study applies the K-Means clustering algorithm to create four distinct climate classes using ECMWF ERA5-Land climate data (2000-2020) and MODIS NDVI data. As a result, four different climate classes were identified, and the total area for each class was calculated. The area of Class 0 is 37,512.74 km$^2$, Class 1 covers 210,171.11 km$^2$, Class 2 covers 157,518.91 km$^2$, and Class 3 covers 365,654.11 km$^2$. Temperature statistics for the climate classes were also calculated, with minimum and maximum temperatures determined for each class. For Class 0, the minimum temperature is 0.10°C and the maximum is 13.12°C; for Class 1, the minimum is 0.63°C and the maximum is 10.67°C; for Class 2, the minimum is 10.71°C and the maximum is 19.87°C; and for Class 3, the minimum is 8.46°C and the maximum is 15.22°C. Furthermore, a time series analysis of MODIS NDVI data for Class 0 was conducted for the period 2002-2020, focusing on vegetation changes and showing a significant seasonal variation for Class 0. This study presents the combined use of ECMWF ERA5-Land climate data and MODIS NDVI data to classify Turkey's different climate regions and analyze the temperature and vegetation characteristics of these classes. Such analyses contribute to climate change research and serve as an essential foundation for understanding local climate impacts.

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Uyar N & Uyar A (2025). Uzaktan Algılama Verilerini Kullanarak Türkiye'deki Sıcaklık, Yağış ve Bitki Örtüsü Değişimlerinin İklim Sınıflandırması ve Analizi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Farklı Yoğunluklardaki Zararlı Alg Patlamalarının Sentinel-2 Görüntüleriyle Tespitinde Alg Özgü Spektral İndeksler ve Derin Öğrenme Modellerinin Entegrasyonu

**Mustafacan Saygı*[1], İsmail Çölkesen[2], Meltem Çelen[1]**

[1]*Gebze Teknik Üniversitesi, Yer ve Deniz Bilimleri Enstitüsü, Kocaeli, Türkiye*
[2]*Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği, Kocaeli, Türkiye*

**Anahtar Kelimeler**
Alg Patlaması,
Derin Öğrenme,
Sentinel-2,
Spektral İndeks,
Uzaktan Algılama

**ÖZET**

Hızla artan iklim değişikliğine bağlı olumsuz etkiler, insan kaynaklı etkiler ve bunlara bağlı artan besin yükleri nedeniyle su kütlelerinde gözlemlenen alg patlamaları, ekosistemin devamlılığı açısından büyük öneme sahip su kütleleri için tehditler oluşturmaktadır. Bu çalışmada, Sentinel-2 uydu görüntüleri kullanılarak farklı yoğunluktaki alg patlaması oluşumlarının tespitine yönelik geliştirilen güncel Sentinel-2 Yüzen Alg Patlaması İndeksi'nin (SFABI) hem eşik değer tayinine bağlı olarak sınıflandırılmasında hem de derin öğrenme modellerinin eğitim aşamasında etiket veri seti olarak kullanıldığında farklı yoğunluktaki alg patlamalarının tespitindeki performansı incelenmiştir. Farklı yoğunlukta alg patlamalarının gözlemlendiği Burdur Gölü çalışma alanı olarak seçilmiş olup Sentinel-2 Seviye-2A uydu görüntüleri temel veri seti olarak kullanılmıştır. SFABI'nin performansını karşılaştırabilmek adına Yüzen Alg İndeksi (FAI) ve Normalize Fark Klorofil İndeksi (NDCI) kullanılmıştır. Eşikleme algoritmasıyla oluşturulan iki sınıflı tematik haritalar, derin öğrenme modellerinin eğitiminde etiket veri seti olarak kullanılması ve düşük yoğunluklu alg patlamalarının tespitinde elde edilen sonuçlar birlikte değerlendirildiğinde; SFABI indeksinin sırasıyla %89.34, %92.77 ve %84.54 F-skor değerleriyle, NDCI ve FAI indekslerine kıyasla daha yüksek bir başarı sergilediği görülmüştür. Sonuçlar, hem eşik değer tayinine dayalı sınıflandırılmasında hem de alg patlaması gibi dinamik yapılara yönelik gerçekleştirilen uygulamalarda derin öğrenme modellerinin hassas ve yüksek doğrulukta gerçekleştirilmesi gereken eğitim süreçlerine ilişkin etiket veri setinin oluşturulması gibi problemlerde SFABI'nın büyük avantaj sağladığını göstermektedir.

# Integration of Algae-Specific Spectral Indices and Deep Learning Models for the Detection of Harmful Algal Blooms of Varying Densities Using Sentinel-2 Imagery

**Keywords**
Algal Bloom,
Deep Learning,
Remote Sensing,
Sentinel-2,
Spectral Index

**ABSTRACT**

The adverse effects associated with rapidly increasing climate change, anthropogenic activities, and the consequent rise in nutrient loads pose significant threats to water bodies that are vital for the continuity of aquatic ecosystems. In this study, the effectiveness of the Sentinel-2 Floating Algal Bloom Index (SFABI), developed for detecting algal blooms of varying intensities using Sentinel-2 satellite imagery, was evaluated both in threshold based classification and as a labeled dataset for training deep learning models. Lake Burdur, where algal blooms of different densities have been frequently observed, was selected as the study area, and Sentinel-2 Level-2A satellite imagery was used as the primary dataset. For performance comparison, two widely used spectral indices, the Floating Algae Index (FAI) and the Normalized Difference Chlorophyll Index (NDCI), were also utilized. The results of the binary thematic maps created using a thresholding algorithm, the performance of deep learning models trained using these indices as labeled datasets, and the detection of low-density algal blooms were assessed. SFABI demonstrated superior performance with F-score values of 89.34%, 92.77%, and 84.54%, respectively, surpassing both NDCI and FAI. These findings indicate that SFABI not only provides high accuracy in threshold-based classifications but also offers substantial advantages in generating reliable training labels for deep learning models, particularly in applications targeting dynamic phenomena such as algal blooms.

* **Sorumlu Yazar**

*(msaygi@gtu.edu.tr) ORCID ID 0009-0003-6015-1273
(icolkesen@gtu.edu.tr) ORCID ID 0000-0001-9670-3023
(mkocal@gtu.edu.tr) ORCID ID 0000-0001-9487-497X

**Kaynak Göster (APA):**

Saygı M, Çölkesen İ & Çelen M (2025). Farklı Yoğunluklardaki Zararlı Alg Patlamalarının Sentinel-2 Görüntüleriyle Tespitinde Alg Özgü Spektral İndeksler ve Derin Öğrenme Modellerinin Entegrasyonu, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Hızla artan nüfusun ihtiyaçlarının karşılanabilmesi amacıyla artan sanayileşme ve buna bağlı artan antropojenik faaliyetler, iklim değişikliği ve tarımsal aktiviteler su kütlelerinde alg patlaması oluşumlarının meydana gelmesine neden olmaktadır. Küresel ısınmanın ve iklim değişikliğindeki olumsuz artışla birlikte bu oluşumların Dünya genelinde artması beklenmektedir (Beusen vd., 2016). Dünya genelinde su kütleleri için tehdit oluşturan alg patlamalarının olumsuz etkilerinin en aza indirgenmesi için hassas ve yüksek doğrulukta takip sistemlerinin geliştirilmesi gerekmektedir. Ancak yersel ölçümlere dayalı geleneksel yöntemler maaliyet ve zamansal olarak bu sistemlerin oluşturulmasında yetersiz kalmaktadır. Bu noktada geniş kapsama alanına sahip uzaktan algılama teknolojilerinin, çevresel değişim analizlerinde kullanımı artmaktadır. Literatürde, özellikle alg patlaması oluşumlarının tespitine ve haritalandırılmasına yönelik birçok uygulama gerçekleştirilmektedir. Örneğin Hu (2009) tarafından yüzen alg patlamalarının tespiti için Yüzen Alg İndeksi (FAI), Mishra ve Mishra (2012) tarafından Normalize Fark Klorofil İndeksi (NDCI) ve Saygi vd. (2025) tarafından Sentinel-2 Yüzen Alg Patlaması İndeksi (SFABI) geliştirilmiştir. Spektral indekslerin yetersiz kalması ve özellikle çok zamanlı veri alımına bağlı olarak artan veri seti boyutlarıyla daha yüksek doğrulukta sonuçların elde edilmesine olan sağlayan derin öğrenme yöntemlerinin kullanımı da gün geçtikçe artmaktadır. Bu noktada Çölkesen vd. (2025) farklı yoğunluktaki alg patlaması oluşumlarının tespitinde U şekline sahip derin öğrenme modellerinin transfer edilebilirliğini incelemiş olup sonuçlar Dikkat Mekanizmalı ve Artık Bağlantılı U-Net (ARU-Net) modelinin en yüksek transfer edilebilirliğe sahip model olduğunu göstermiştir.

Bu çalışmada, farklı spektral indekslerin hem eşik değer tayinine dayalı bireysel kullanımında hem de derin öğrenme modellerinin eğitim aşamasında etiket veri seti olarak kullanımında farklı yoğunluktaki alg patlamalarının tespitindeki etkinliklerinin incelenmesi amaçlanmıştır.

## 2. ÇALIŞMA ALANI VE VERİ SETİ

Çalışma kapsamında, ülkemizde yoğun alg patlaması oluşumlarının gözlemlendiği Burdur Gölü, çalışma alanı olarak belirlenmiştir (Şekil 1). Son yıllarda kuraklık riskiyle de karşı karşıya kalan Burdur Gölü'nde başta evsel atık sular olmak üzere tarımsal aktivitelerden kaynaklanan azot ve fosfor gibi besin yükleri göldeki alg patlamalarına neden olmaktadır.




**Şekil 1.** Çalışma alanı.

Gerçekleştirilen çalışmada kullanılmak üzere Sen2Cor kullanılarak atmosferik olarak düzeltilmiş, bulut içermeyen Sentinel-2 Seviye-2A uydu görüntüleri ESA tarafından sağlanan Copernicus Data Space platformundan (https://dataspace.copernicus.eu) temin edilmiştir. Temin edilen uydu görüntülerinin 20m çözünürlüğe sahip 6 spektral bandı, SNAP yazılımında En Yakın Komşuluk enterpolasyon tekniğinden yararlanılarak 10m mekânsal çözünürlüğe yeniden örneklenmiştir. Spektral indekslerin göl yüzey alanına ait histogramlarının daha hassas bir şekilde bölünebilmesi ve derin öğrenme modellerinin alakasız nesnelere odaklanmasını önlemek amacıyla kara alanları, Değiştirilmiş Fark Su İndeksi (MNDWI) kullanılarak maskelenmiştir.

## 3. YÖNTEM

### 3.1. Alg Patlamasına Yönelik Spektral İndeksler

Alg patlaması oluşumlarının eşik değer tayinine dayalı olarak hem derin öğrenme modellerinin eğitim aşamasında kullanılacak etiket veri setlerinin oluşturulması amacıyla çalışma kapsamında SFABI, NDCI ve FAI spektral indeksleri kullanılmıştır. Belirtilen spektral indekslere yönelik gri düzey spektral indeks haritaları, göl alanının maskelenmesinin ardından oluşturulmuştur. Spektral indekslerin eşik değer tayinine dayalı ve derin öğrenme modellerinin performanslarının karşılaştırılabilmesi amacıyla Çizelge 1'de ifade edilen test görüntüsü, derin öğrenme modellerinin eğitim ve doğrulama aşamasında kullanılmak üzere ise derin öğrenme modellerinin eğitimi amacıyla kullanılacağı belirtilen 6 görüntü Jenks Natural Breaks (JNB) eşik değer algoritması kullanılarak 2 sınıfa (su ve alg patlaması) ayrılmıştır (Jenks, 1967).

### 3.2. Derin Öğrenme Modellerinin Kurulması

Çalışma kapsamında alg patlamasına yönelik spektral indekslerin, etiket veri seti olarak kullanıldığında derin öğrenme modellerinin performansını karşılaştırmak amacıyla yama (patch) tabanlı ARU-Net derin öğrenme modeli kurulmuştur. U şeklinde tam bağlantılı evrişimsel sinir ağlarına dayalı mimariye sahip U-Net derin öğrenme modeli, alg patlamasına yönelik çalışmalarda sıklıkla kullanılmaktadır (Zhu vd., 2023; Çölkesen vd., 2025). Ronneberger vd. (2015) tarafından geliştirilen U-Net, semantik segmentasyon uygulamaları için uçtan uca bağlı bir kodlayıcı ve kod çözücü yapısından meydana gelmektedir. Çalışma kapsamında kullanılan ARU-Net modeli ise dikkat mekanizmalarının ve artık bağlantıların klasik U-Net mimarisine entegrasyonuyla oluşturulmuştur.

## 4. SONUÇLAR VE TARTIŞMA

### 4.1. Spektral İndekslerin JNB Eşik Değer Algoritmasıyla Sınıflandırılmasında Doğruluk Analizi

Alg patlamasına özgü spektral indekslerin, farklı yoğunluktaki alg patlaması (yoğun ve düşük yoğun) oluşumlarını tespitindeki performanslarını

karşılaştırabilmek amacıyla, farklı yoğunlukta alg patlaması oluşumlarının gözlemlendiği 27.08.2021 tarihli Sentinel-2 test görüntüsü kullanılmıştır. Gri-düzey indeks haritaları JNB eşik değer algoritması kullanılarak 2 sınıfa (su ve alg) kategorize edilmiş olup ardından f-skor metriğine göre her sınıfa (su, yoğun ve düşük yoğun alg patlaması) ait 1000'er örnek piksel kullanılarak doğruluk analizi gerçekleştirilmiştir (Çizelge 1). Elde edilen sonuçlarda SFABI'nin alg patlaması sınıfına ait %89.34 F-skor değeriyle NDCI ve FAI indekslerine kıyasla daha üstün bir performans sergilediği görülmüştür.

**Çizelge 1.** Spektral indekslerin sınıflandırma sonuçları.

| F-skor (%) | SFABI | NDCI | FAI |
|---|---|---|---|
| Su | 84.13 | 80.17 | 67.02 |
| Alg Patlaması | 89.34 | 85.59 | 66.42 |

**Farklı Etiket Veri Setleri ile Eğitilen Derin Öğrenme Modellerinin Performans Analizi**

Derin öğrenme modelinin kurulması amacıyla, alg patlaması oluşumlarının gözlemlendiği 6 farklı Sentinel-2 uydu görüntüsü kullanılmıştır. ARU-Net modelinin girdi boyutuna uygun hale getirmek amacıyla görüntüler 64x64 piksel boyutlarında parçalara ayrılmış olup görüntülerin %40'ı eğitim ve %60'ı doğrulama veri seti olacak şekilde rastgele bölünmüştür. Objektif bir karşılaştırma yapabilmek adına tüm modeller için eğitim tur sayısı, yığın boyutu ve öğrenme oranı parametreleri sırasıyla 100, 64 ve 0.001 olacak şekilde belirlenmiştir.

Derin öğrenme modellerinin eğitim aşamasında aşırı öğrenme ve yetersiz öğrenme durumları meydana gelmemiş olup SFABI, NDCI ve FAI için doğrulama veri setine ait ortalama f-skor değerleri sırasıyla %97.59, %97.00 ve %96.86 olarak hesaplanmıştır. Derin öğrenme modellerinin objektif bir şekilde karşılaştırılabilmesi amacıyla eğitim ve doğrulama aşamasında kullanılmayan test görüntüsünde modellerin tespit sonuçları, piksel tabanlı test veri seti kullanılarak karşılaştırılmıştır (Şekil 2). Elde edilen sonuçlar, eşik değer tayinine ilişkin yöntemde olduğu gibi SFABI'nın %92.77 F-skor değeriyle alg patlaması oluşumlarının tespitinde NDCI ve FAI indekslerine göre daha başarılı olduğunu göstermektedir.

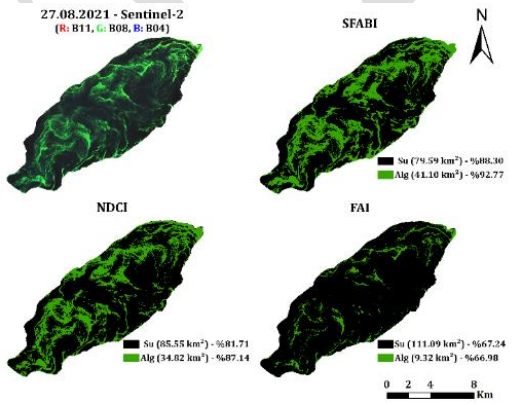


**Şekil 2.** Derin öğrenme modellerinin tespiti sonuçları.

**Düşük Yoğunluktaki Alg Patlamalarının Tespiti için Derin Öğrenme Modellerinin Duyarlılık Analizi**

Derin öğrenme modellerinin düşük yoğunluktaki alg patlamalarının tespitindeki duyarlılığının analiz edilebilmesi amacıyla test veri setinde yer alan düşük yoğunluklu alg patlaması sınıfa ait pikseller kullanılarak karşılaştırma gerçekleştirilmiştir (Şekil 3). Hesaplanan hassasiyet metriği uyarınca gerçekleştirilen doğruluk analizinde SFABI, NDCI ve FAI için sırasıyla %73.22, %55.04 ve %2.27 değerleri elde edilmiş olup SFABI ile eğitilen derin öğrenme modelinin düşük yoğunluktaki alg patlaması oluşumlarının tespitine daha duyarlı olduğu görülmüştür.

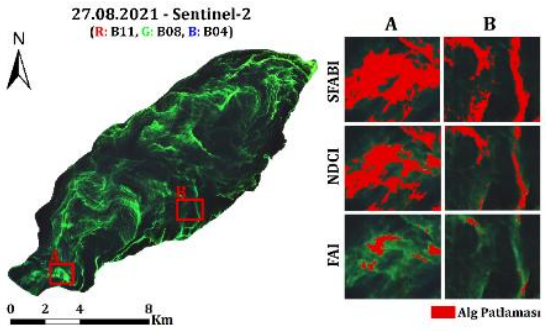


**Şekil 3.** Derin öğrenme modellerinin düşük yoğunluktaki alg patlamalarının tespitindeki performansı.

Sonuçlar, SFABI'nın alg patlaması oluşumları tespitinde etkinliğini doğrularken, farklı çalışma alanlarında, çeşitli derin öğrenme modelleriyle, farklı eşik değer algoritmalarıyla ve farklı spektral indekslerle karşılaştırmalı çalışmalara ihtiyaç duyulmaktadır.

**TEŞEKKÜR**

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 124Y295 no'lu proje kapsamında desteklenmiştir.

**Yazar Katkı Oranı**

**Mustafacan Saygı:** Yazım – orijinal taslak, yazılım, yöntem, araştırma, veri düzenleme, görselleştirme. **İsmail Çölkesen:** Yazım – inceleme ve düzenleme, yazım – orijinal taslak, yazılım, süpervizyon, yöntem, kavramsallaştırma. **Meltem Çelen:** Yazım – inceleme ve düzenleme, yazım – orijinal taslak, süpervizyon, yöntem.

**Çıkar Çatışması/Çakışması**

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

**Araştırma ve Yayın Etiği Beyanı**

Bu çalışma kapsamında etik kurul onayı gerektiren herhangi bir durum bulunmamaktadır.

**KAYNAKÇA**

Beusen, A. H., Bouwman, A. F., Van Beek, L. P., Mogollón, J. M., & Middelburg, J. J. (2016). Global riverine N and P transport to ocean increased during the 20th century despite increased retention along the aquatic continuum. Biogeosciences, 13(8), 2441-2451.doi: 10.5194/bg-13-2441-2016

Colkesen, I., Saygi, M., Ozturk, M. Y., & Altuntas, O. Y. (2025). U-shaped deep learning networks for algal

bloom detection using Sentinel-2 imagery: Exploring model performance and transferability. Journal of Environmental Management, 381, 125152. doi: 10.1016/j.jenvman.2025.125152

Hu, C. (2009). A novel ocean color index to detect floating algae in the global oceans. Remote Sensing of Environment, 113(10), 2118-2129. doi: 10.1016/j.rse.2009.05.012

Jenks, G. F. (1967). The data model concept in statistical mapping. International yearbook of cartography, 7, 186-190.

Mishra, S., & Mishra, D. R. (2012). Normalized difference chlorophyll index: A novel model for remote estimation of chlorophyll-a concentration in turbid productive waters. Remote Sensing of Environment, 117, 394-406. doi: 10.1016/j.rse.2011.10.016

Oyama, Y., Fukushima, T., Matsushita, B., Matsuzaki, H., Kamiya, K., & Kobinata, H. (2015). Monitoring levels of cyanobacterial blooms using the visual cyanobacteria index (VCI) and floating algae index (FAI). International Journal of Applied Earth Observation and Geoinformation, 38, 335-348. doi: 10.1016/j.jag.2015.02.002

Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In Medical image computing and computer-assisted intervention–MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18 (pp. 234-241). Springer international publishing. doi: 10.1007/978-3-319-24574-4_28.

Saygi, M., Colkesen, I., Celen, M. (2024) Efficient Detection of Floating Algal Blooms using Sentinel-2 Imagery: The Introduction of the SFABI Index. ISPRS, EARSeL DGPF Joint Istanbul Workshop, 29-31 January, Istanbul, Türkiye.

Zhu, S., Wu, Y., & Ma, X. (2023). Deep learning-based algal bloom identification method from remote sensing images—Take China's Chaohu Lake as an example. Sustainability, 15(5), 4545. doi: 10.3390/su1505

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Google Earth Engine Tabanlı Spektral İndeksler ve Rastgele Orman Algoritması ile Yanmış Alanların Belirlenmesi: 2022 Yılı Muğla-Marmaris Orman Yangını Örneği

**Başak Gürdal*[1], Damlanur Alkan[1], Lütfiye Karasaka[1]**

[1] *Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Harita Mühendisliği, Konya, Türkiye*

**Anahtar Kelimeler**
Google Earth Engine,
Rastgele Orman,
Spektral İndeksler,
Uzaktan Algılama,
Yangın

**ÖZET**

Yangınlar, doğrudan ve dolaylı etkileriyle doğal ekosistemleri, insan yaşamını ve çevresel dengeyi tehdit eden ciddi olaylardır. Yanmış alanlarını tespit etmek mevcut durumun analiz edilmesi, hasar tespiti ve alana yapılacak müdahaleler açısından önemlidir. Bu doğrultuda orta çözünürlüklü ve kısa zaman aralıklarında yayımlanan uydu görüntüleri yanmış alanlarının haritalanmasında önemli avantajlar sunmaktadır. Tüm bunlarla birlikte Yanmış alanların haritalanmasında uzaktan algılama yöntemlerinden sınıflandırma yaklaşımları, değişim saptama ve bant indekslerine bağlı haritalama sıklıkla tercih edilen yöntemlerdendir. Bu çalışmada 21 Haziran 2022 tarihinde Muğla Marmaris ilçesinde meydana gelen orman yangını, Sentinel-2 uydu görüntüleri kullanılarak Normalize Edilmiş Yanma Şiddeti (Normalized Burned Ratio-NBR), Fark Normalize Edilmiş Yanma Şiddeti (Difference Normalized Burned Ratio-dNBR), Normalleştirilmiş Fark Bitki İndeksi (Normalized Difference Vegetation Index-NDVI), Orta Kızılötesi Yanma İndeksi (Mid-infrared burn index-MIRBI) , Yanmış Alan İndeksi (Burned Area Index-BAI), Göreli Yanma Oranı (Relativized Burn Ratio-RBR) indeksleri ve rastgele orman sınıflandırması kullanılarak analiz edilmiştir. Doğruluk değerlendirmesi için genel doğruluk ve Kappa istatistiği hesaplanmıştır.

# Detection of Burned Areas Using Spectral Indices and Random Forest Algorithm Based on Google Earth Engine: A Case Study of the 2022 Muğla-Marmaris Wildfire

**Keywords**
Google Earth Engine,
Random Forest,
Spectral Index,
Remote Sensing,
Wildfire

**ABSTRACT**

Wildfires are significant events that threaten natural ecosystems, human life, and environmental balance through both direct and indirect effects. Detecting burned areas is crucial for analyzing the current situation, assessing damage, and planning interventions. In this regard, medium-resolution satellite imagery with frequent revisit intervals provides significant advantages for mapping burned areas. Remote sensing methods, including classification approaches, change detection, and spectral index-based mapping, are frequently preferred techniques for mapping burned areas. In this study, the forest fire that occurred in the Marmaris district of Muğla on June 21, 2022 was analyzed using Sentinel-2 satellite imagery. The analysis utilized by the Normalized Burned Ratio (NBR), Difference Normalized Burned Ratio (dNBR), Normalized Difference Vegetation Index (NDVI), Mid-infrared Burn Index (MIRBI), Burned Area Index (BAI), and Relativized Burn Ratio (RBR) indices, Random Forest classification method. Accuracy was evaluated using by overall accuracy and the Kappa statistic.

## 1. GİRİŞ

Yangınlar sonucunda dünya genelinde her yıl milyonlarca hektar orman alanı zarar görmektedir. Yangının, ekosistem üzerindeki etkisini tahmin etmek için güvenilir, etkili izleme ve analiz teknikleri uygulanmalıdır (Li ve ark., 2003). Yanmış alanların tespitinde uydu görüntülerinin kullanılması ile geleneksel yöntemlere kıyasla zaman ve maliyet tasarruf

* **Sorumlu Yazar**

*(basakgurdal03@gmail.com) ORCID ID 0009-0004-3755-2025
(dalkan@ktun.edu.tr) ORCID ID 0000-0002-2013-0262
(lkarasaka@ktun.edu.tr) ORCID ID 0000-0002-2804-3219

**Kaynak Göster (APA):**

Gürdal B, Alkan D & Karasaka L (2025). Google Earth Engine Tabanlı Spektral İndeksler ve Rastgele Orman Algoritması ile Yanmış Alanların Belirlenmesi: 2022 Yılı Muğla-Marmaris Orman Yangını Örneği, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

sağlanabilmektedir. Yanmış alanları belirlemek için Sınıflandırma yaklaşımları (Palandjian vd., 2009; Petropoulos vd., 2011; Ramo ve Chuvieco, 2017) ve spektral indekse dayalı yöntemler yaygın olarak kullanılmaktadır (Liu vd. 2020). Bu çalışmada 21 Haziran 2022 tarihinde Muğla Marmaris ilçesinde meydana gelen yanmış alanları belirlemek için Google Earth Engine (GEE) platformunda yangın öncesi ve yangın sonrası Sentinel-2 görüntüleri kullanılmıştır. Yanmış alanların belirlenmesinde Normalize Edilmiş Yanma Şiddeti (Normalized Burned Ratio-NBR), Fark Normalize Edilmiş Yanma Şiddeti (Difference Normalized Burned Ratio-dNBR), Normalleştirilmiş Fark Bitki İndeksi (Normalized Difference Vegetation Index-NDVI), Orta Kızılötesi Yanma İndeksi (Mid-infrared burn index-MIRBI), Yanmış Alan İndeksi (Burned Area Index-BAI), Göreli Yanma Oranı (Relativized Burn Ratio-RBR) indeksi ve Rastgele Orman (Random Forest) sınıflandırması kullanılmıştır.

## 2. YÖNTEM

Bu çalışmada Sentinel-2 görüntüleri ile NBR, dNBR, NDVI, MIRBI, BAI, RBR indeksleri ve rastgele orman sınıflandırması kullanılmıştır.

### 2.1. Sentinel-2

Sentinel uyduları Avrupa Uzay Ajansının Kopernik program kapsamında uzaya gönderilmiştir. 13 multispektral banttan oluşur. Dalga boyuna bağlı olarak 10 m, 20 m ve 60 m mekânsal çözünürlüğe sahip ücretsiz veri sağlar (Suhet, 2013).

### 2.2. Spektral İndeksler

Çalışmada NBR, dNBR, NDVI, MIRBI, BAI, RBR indeksleri kullanılmış ve hesaplanışları Çizelge 1'de gösterilmiştir. NBR ve NDVI [-1 ile +1] aralığında, dNBR ise [-2 ile +2] aralığında değişmektedir (Tonbul, 2015).

**Çizelge1.** Kullanılan Spektral İndeksler

| İndeks | Hesaplanışı |
|---|---|
| NBR | $\frac{B8 - B12}{B8 + B12}$ |
| dNBR | $NBR_{Yangın\ Öncesi} - NBR_{Yangın\ Sonrası}$ |
| NDVI | $\frac{B8 - B4}{B8 + B4}$ |
| $MIRBI$ | $10 \times \mathrm{B12} - 0.98 \times \mathrm{B11} + 2$ |
| BAI | $\frac{1}{((0.1 + B4)^2 + (0.06 + B8)^2)}$ |
| RBR | $\frac{dNBR}{NBR\text{yangın öncesi} + 1.001}$ |

Burada *B4 Kırmızı (Red), B8 Yakın Kızılötesi (NIR), B11 ve B12 Kısa Dalga Kızılötesi (SWIR)* bantlarını temsil etmektedir.

### 2.3.Rastgele Orman Algoritması

Rastgele orman algoritması, fazla ağaç üretmek için tekrar tekrar bölünerek parçalanan bir toplu öğrenme metodudur. Rastgele orman algoritması ile sınıflandırma işlemini gerçekleştirmek için rastgele ağaç sayısı ve oluşturulacak her bir ağaçta sınıflandırma için kullanılacak değişken sayısı belirlenmelidir. (Taşcı, 2018).

## 3. BULGULAR

Bu çalışmada, 2022 yılı Marmaris yangını sonucunda meydana gelen yanmış alanın tespit edilmesi amaçlanmıştır. Yanmış alanlar NBR-dNBR ile 4051 ha, NDVI ile 4282 ha, MIRBI ile 3703 ha, BAI ile 4689 ha, RBR ile 4188 ha, rastgele orman kontrollü sınıflandırma yöntemi ile 4239 ha bulunmuştur. Aynı zamanda yapılan doğruluk değerlendirme metrikleri sonucunda rastgele orman sınıflandırmasının genel doğruluk oranı %99,9 Kappa istatistiği 0.9983, F1-skoru (F1-score) 0.9984, duyarlılık (recall) 1 olarak bulunmuştur. Karmaşıklık matrisi [[36056,2], [0,612]] olarak bulunmuştur. Karmaşıklık matrisi tahmin edilen değerler ile gerçek değerleri karşılaştırarak modelin performansının yüksek bir doğruluk sağladığını gösterir. (Alkan,2023). Muğla Büyükşehir Belediyesinin yangın sonrası bölgede yapmış olduğu hasar tespit çalışmaları sonucu yaklaşık 4208 ha alanın tahrip olduğu belirtilmiştir (URL-1). Bu sonuç ve yapılan çalışmada elde edilen sonuçların tutarlılık sağladığı görülmektedir.



**Şekil 1.** Yanmış Alanların Kullanılan Yöntemlere Göre Dağılımı a) Rastgele Orman b) dNBR c) RBR d) BAI e) NDVI f) MIRBI

## 4. TARTIŞMA

Çalışma, uzaktan algılama yöntemlerinin yangın sonrası hasar tespitinde etkinliğini vurgulamaktadır. Kullanılan spektral indeksler ve Rastgele Orman algoritması ile yangının etkileri hassas bir şekilde haritalanmış ve sonuçlar, yerel yönetimlerin hasar tespit

verileri ile tutarlılık göstermiştir. Karmaşıklık matrisi ve doğruluk metrikleri, sınıflandırma modelinin yüksek doğruluk oranı sağladığını ortaya koymuştur. Bu sonuçlar, uzaktan algılama tekniklerinin afet sonrası değerlendirmelerde güvenilir ve etkili bir araç olarak kullanılabileceğini göstermektedir.

## SONUÇ

Bu çalışmada, Muğla Marmaris'teki 2022 orman yangınının haritalanmasında Sentinel-2 uydu görüntüleri kullanılarak farklı spektral indeksler (NBR, dNBR, NDVI, MIRBI, BAI, RBR) ve Rastgele Orman algoritması ile analiz yapılmıştır. Elde edilen genel doğruluk oranı %99,9, Kappa istatistiği 0.9983, F1 skoru 0.9984 ve duyarlılık (recall) 1 olarak bulunmuştur. Bunlar modelin yüksek performansını ve güvenilirliğini ortaya koymaktadır. Spektral indeksler ise yangın sonrası bitki örtüsü değişimini belirlemede etkili sonuçlar vermiştir. Yerel yönetim sonuçlarına en yakın sonucu NDVI indeksi vermiş olup bunu RBR ve NBR indekslerinin takip ettiği gözlemlenmiştir. Bu indeksler yanmış alanların tespitinde önemli bir rol oynamıştır. Sonuç olarak, spektral indekslerin ve rastgele orman sınıflandırma yönteminin yangın sonrası hasar tespitinde yüksek doğruluk sağladığı ve afet yönetimi süreçlerinde etkin bir şekilde kullanılabileceği görülmektedir.

## TEŞEKKÜR

Bu çalışma, birinci yazarın (Başak Gürdal) lisans bitirme tezinden geliştirilmiştir.

### Yazar Katkı Oranı

**Başak Gürdal:** Kavramsallaştırma, Metodoloji, Yazılım, Yazma.
**Damlanur Alkan:** Metodoloji, İnceleme ve Düzenleme.
**Lütfiye Karasaka:** Metodoloji, İnceleme ve Düzenleme.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

### Araştırma ve Yayın Etiği Beyanı

Bu çalışmada bilimsel araştırma ve yayın etiğine uyulmuştur. İntihal, sahtecilik, çarpıtma, haksız yazarlık gibi etik dışı hiçbir eylemde bulunulmamıştır. Çalışma, özgünleştirilmiş bir araştırma olup yazar(lar)ın kendi emeğiyle hazırlanmıştır.

## KAYNAKÇA

Alkan, D. (2023). U-Net Derin Öğrenme Mimarisi Kullanılarak Yanmış Alanların Uydu Görüntülerinden Tespiti. (Yüksek Lisans Tezi). Lisansüstü Eğitim Enstitüsü, Konya Teknik Üniversitesi, Konya.

Li, Z., Fraser, R., Jin, J., Abuelgasim, A. A., Csiszar, I., Gong, P., Pu, R. & Hao, W. (2003). Evaluation of algorithms for fire detection and mapping across North America from satellite. Journal of Geophysical Research: Atmospheres, 108(D2).

Liu S., Zheng Y., Dalponte M., Tong X., (2020). A novel fire index-based burned area change detection approach using Landsat-8 OLI data, European Journal of Remote Sensing, 53(1), 104-112.

Muğla Büyükşehir Belediyesi, (2022). Büyükşehir'den Marmaris yangını raporu, https://www.mugla.bel.tr/haber/buyuksehirden-marmaris-yangini-raporu : [Erişim tarihi: 14.04.2025].

Palandjian, D., Gitas, I. Z., & Wright, R. (2009). Burned area mapping and post-fire impact assessment in the Kassandra peninsula (Greece) using Landsat TM and Quickbird data. Geocarto International, 24(3), 193–205.

Petropoulos, G., Charalabos, K. & Keramitsoglou, I. (2011). Burnt area delineation from a uni-temporal perspective based on Landsat TM imagery classification using support vector machines. International Journal of Applied Earth Observation and Geoinformation, 13(1), 70-80.

Ramo, R. & Chuvieco, E. (2017). Developing a Random Forest Algorithm for MODIS Global Burned Area Classification. Remote Sensing, 9(11), 1193.

Suhet, (2013). Sentinel-2 User Handbook 1: 9.

Taşcı, I. (2018). Orta çözünürlüklü uydu görüntüleri kullanarak yanmış orman alanlarının farklı sınıflandırma yöntemleri ile haritalanması. (Yüksek Lisans Tezi). Fen Bilimleri Enstitüsü, Anadolu Üniversitesi, Eskişehir.

Tonbul, H. (2015). Uydu Görüntü Verileri Kullanılarak Orman Yangın Şiddeti ve Yangın Sonrası Durumun Zamansal Olarak İncelenmesi: Akdeniz Bölgesi Örneği (Yüksek Lisans Tezi). Fen Bilimleri Enstitüsü, İstanbul Teknik Üniversitesi, İstanbul.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Mekânsal Yapay Zeka Uygulamaları ve Düşündürdükleri

**Arda Günay*[1], Bilal Erkek[2], Ekrem Ayyıldız[3]**

**Anahtar Kelimeler**
Coğrafi Veri, Yapay Zeka, İmar Kirliliği, İmar Suçları, Yapı var/yok Analizi

**ÖZET**

Harita ve harita bilgileri diğer bir ifade ile coğrafi veriler; kadastro yapımı ve yaşatılması, şehirsel ve kırsal düzenleme, toprağa yönelik projelerin planlama, etüt ve uygulamalarında temel altlık olarak kullanılmakta, yatırım ve istihdam imkanları yaratmaya yönelik kamu alt yapı hizmetleri kapsamında değerlendirilmektedir.

Harita kadastro sektörünün önünü açan ve yeni hizmetleri ile vatandaşın yaşamını kolaylaştıran Tapu ve Kadastro Genel Müdürlüğümüz dijitalleşme ve dijital dönüşümde önemli çalışmalar yürütmektedir. TAKBİS, MEGSİS, Web TAPU, e-HACİZ, TUSAGA-Aktif, HBB ve 3 boyutlu şehir modelleri üretimi ve 3 boyutlu kadastro altlığı oluşturma projeleri en önemli projeler arasındadır.

Tapu ve Kadastro Genel Müdürlüğü (TKGM), yapay zekâ uygulamalarıyla süreçlerini daha etkin hale getirme potansiyeline sahiptir. Yapay zekâ destekli sistemler; veri doğruluğunu artırmak, işlem sürelerini kısaltmak ve sahtecilik riskini azaltmak gibi avantajlar sağlayabilir. Özellikle veri madenciliği, görüntü işleme ve doğal dil işleme teknikleriyle taşınmazların dijitalleşmesi, kayıtların otomatik analizi ve tapu işlemlerinde hızlı ve doğru karar verme imkânı ortaya çıkmaktadır.

Bu çalışmada yapay zekanın pozitif kullanımından ziyade olumsuz/kötü niyetli kullanımına odaklanılmıştır. Kamu kaynakları ile üretilen ve paylaşılan coğrafi verilerin yapay zekâ teknikleri ile deforme edilmesi, değiştirilmesi, yok edilmesi ya da kamufle edilmesi mümkündür. Açık yapay zekâ kullanım olanakları ile bir video, fotoğraf veya hava fotoğrafı üzerinde yapılan değişiklikler öne çıkarılarak bazı önerilere yer verilmiştir.

## 1. GİRİŞ

Yapay zekâ, bilgisayar sistemlerinin insan zekasını taklit ederek öğrenme, analiz yapma, karar verme ve problem çözme gibi işlemleri gerçekleştirmesini sağlayan teknolojilerdir. Özellikle makine öğrenimi ve derin öğrenme gibi alt dalları sayesinde, günlük yaşamdan endüstriyel süreçlere kadar geniş bir kullanım alanına sahiptir. Yapay zekanın gelişimi, büyük veri analitiği ve yüksek işlem gücüyle birleşerek pek çok sektörde devrim niteliğinde yenilikler yaratmaktadır.

Harita ve harita bilgileri yani coğrafi veriler; kadastro yapımı ve yaşatılması, şehirsel ve kırsal düzenleme, toprağa yönelik projelerin planlama, etüt ve uygulamalarında temel altlık olarak kullanılmakta, yatırım ve istihdam imkanları yaratmaya yönelik kamu alt yapı hizmetleri kapsamında değerlendirilmektedir.

Ülkemizde harita hizmetleri, kalkınma ve savunma amaçlarına yönelik tüm yatırım ve mühendislik hizmetlerinin alt yapısını oluşturmaktadır. Buna göre, konu sadece sosyoekonomik açıdan değil, ülke kalkınması ve savunması ile yatırım ve mühendislik hizmetlerinin gerçekleştirilmesi açısından da önem taşımaktadır.

Genel müdürlüğümüz, kamu kurumları, üniversiteler ve özel sektörümüzle yapılan iş birliği sonucunda ulusal düzeyde harita ve harita bilgisi üretimi ve güncelleştirilme konularında önemli çalışmalar yapmıştır. Ülkemiz kadastrosunun tamamlanmış olması ve harita-kadastro çalışmalarında coğrafi konum bilgisinin gerçek zamanda, hassas, güvenilir ve ekonomik biçimde toplanması ile e-devlet hizmetlerinin konumsal altyapısı oluşturulmuştur.

Harita kadastro sektörünün, sektörde dijitalleşme yönünde çalışmalar yürüten genel müdürlüğümüz dijitalleşme ve dijital dönüşümde önemli çalışmalar yürütmektedir. TAKBİS, MEGSİS, web TAPU, e-HACİZ, TUSAGA-Aktif, HBB ve 3 boyutlu şehir modelleri üretimi ve 3 boyutlu kadastro altlığı oluşturma projeleri en önemli projeler arasındadır. Dijitalleşme yolunda Genel müdürlüğümüz; 3 boyutlu şehir modelleri ile ilgili İstanbul özelinde yapılacak çalışma ile İstanbul'daki 3b

* **Sorumlu Yazar**

*(ardagunay@tkgm.gov.tr) ORCID ID:0009-0006-5018-4030
(berkek@tkgm.gov.tr) ORCID ID:0000-0002-4918-2779
(tk43237@tkgm.gov.tr) ORCID ID:0000-0002-0805-1529

**Kaynak Göster (APA):**

Günay A, Erkek B & Ayyıldız A. (2025). Mekansal Yapay Zeka Uygulamaları ve Düşündürdükleri, Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

üretimlerinin doğruluk, tamlık ve bilgi sistemleri (TAKBİS, MEGSİS, MAKS) ile uyum oranını %90 seviyelerine çıkarmak ve değer verileri ile de bütünleştirerek 2025 yılı sonunda taşınmaz yönetim bilgi sistemi kurulması, tapu kütüğüne fiziksel tescil ve terkin usulünün kaldırılması, ekonomik, sosyal ve çevresel etkiler dikkate alınarak web tapu uygulamasının (API, Mobil, vb.) iyileştirilmesi, tapu işlemlerinin gerçekleştirilmesinde yapay zeka ve robot teknolojisinin kullanılması, e-arşiv uygulamaları geliştirilerek sürdürülebilir arşiv yönetiminin oluşturulması, KKTC'de dijital ikiz üretimi ve tapu kadastro altyapısının oluşturulması, kadastro paftalarının fiziksel olarak hazırlanması usulünün kaldırılarak ve kadastro arşivleri taranarak dijitalleştirilmesi gibi eni adımlar atmaktadır.

Tapu ve Kadastro Genel Müdürlüğü (TKGM), yapay zekâ uygulamalarıyla süreçlerini daha etkin hale getirme potansiyeline sahiptir. Yapay zekâ destekli sistemler; veri doğruluğunu artırmak, işlem sürelerini kısaltmak ve sahtecilik riskini azaltmak gibi avantajlar sağlayabilir. Özellikle veri madenciliği, görüntü işleme ve doğal dil işleme teknikleriyle taşınmazların dijitalleşmesi, kayıtların otomatik analizi ve tapu işlemlerinde hızlı ve doğru karar verme imkânı ortaya çıkmaktadır.

Bu çalışmada yapay zekanın yalnızca pozitif değil, olası kötü niyetli kullanım senaryoları da incelenmiştir. Kamu kaynakları ile üretilen ve paylaşılan coğrafi verilerin yapay zekâ teknikleri ile deforme edilmesi, değiştirilmesi, yok edilmesi ya da kamufle edilmesi mümkündür. Açık yapay zekâ kullanım olanakları ile bir video, fotoğraf veya hava fotoğrafı üzerinde yapılan değişiklikler öne çıkarılarak bazı önerilere yer verilmiştir.

## 2. AVRUPA YAPAY ZEKA DÜZENLEMELERİ

Avrupa Birliği, yapay zekanın gelişimini desteklerken güvenlik ve etik standartlarının korunmasını sağlamak üzere kapsamlı yasal düzenlemeler getirmiştir. AB Komisyonu'nun hazırladığı "AI Act" (Yapay Zekâ Yasası), risk tabanlı bir yaklaşımla yapay zekâ sistemlerinin şeffaflığını, hesap verilebilirliğini ve insan merkezli kullanımını zorunlu kılmaktadır. Ayrıca, Horizon Europe gibi finansal destek programlarıyla da yenilikçi yapay zekâ projelerine fon sağlanmakta ve Ar-Ge faaliyetleri teşvik edilmektedir.

Avrupa Birliği Konseyi onayından geçen tasarının, Avrupa Parlamentosu'nun sitesinde yayınlanan en son sürümünde, Avrupa Komisyonu bağımsız Yapay Zekâ uzman grubu tarafından hazırlanan ve 2019 senesinde yayımlanan "Güvenilir Yapay Zekâ İçin Etik Kurallara (Kılavuz) atıfta bulunulduğu ve tanımlara yer verildiği görülmektedir.

Yapay zekanın güvenilir ve etik olmasına yardımcı olacak, bağlayıcı olmayan ancak uygulamada özellikle dikkate alınması önerilen yedi etik ilke geliştirilmiştir. Bu ilkeler 1.İnsan kontrolü ve gözetimi, 2.Teknik sağlamlık ve güvenlik, 3.Gizlilik ve veri yönetişimi, 4.Şeffaflık, 5.Çeşitlilik, ayrımcılık yapmama ve adalet, 6.Toplumsal ve çevresel refah ve 7.Hesap verebilirliktir.

## 3. TÜRKİYE YAPAY ZEKA DÜZENLEMELERİ

Türkiye, yapay zekâ teknolojilerinin geliştirilmesi ve uygulamaya alınması konusunda son yıllarda önemli adımlar atmıştır. Cumhurbaşkanlığı Dijital Dönüşüm Ofisi koordinasyonunda hazırlanan "Ulusal Yapay Zekâ Stratejisi" bu alanda en önemli düzenleyici belgedir. Yapay Zekâ Enstitüleri, Teknoparklar ve çeşitli üniversiteler aracılığıyla yürütülen projeler ile yapay zekâ alanındaki yetkinliklerin artırılması amaçlanmaktadır. Ayrıca, kişisel verilerin korunması ve etik uygulamalar konularında da gerekli yasal altyapılar oluşturulmaktadır.

2024 yılında TBMM'ne sunulan Yapay Zeka Kanun Teklifi ile yapay Zekâ teknolojilerinin güvenli, etik ve adil bir şekilde kullanılmasının sağlanması, kişisel verilerin korunmasının temin edilmesi, gizlilik haklarının ihlal edilmesinin önlemesi ile yapay zeka sistemlerinin geliştirilmesi ve kullanımına yönelik düzenleyici bir çerçevenin oluşturulması amaçlanmaktadır.

2025 yılında yapay zekânın kazanımlarına yönelik atılacak adımların belirlenmesi, bu alanda hukuki altyapının oluşturulması ve yapay zekâ kullanımının barındırdığı risklerin önlenmesine ilişkin tedbirlerin belirlenmesi amacıyla meclis araştırması komisyonu kurulmuştur.

2025 yılında Ankara'da Savunma Sanayii Yapay Zekâ Yetenek Kümelenmesi (SAYapay ZekaEK) faaliyetleri kapsamında yapay zekâ alanındaki gelişmelerle birlikte hızla ilerleyen sektörlerin başında gelen "Coğrafi Bilgi Sistemlerinde Yapay Zekâ" temalı çalıştay gerçekleştirilmiştir.

## 4. TKGM'DE YAPAY ZEKA KULLANIM POTANSİYELİ

Tapu ve Kadastro Genel Müdürlüğü (TKGM), yapay zekâ uygulamalarıyla süreçlerini daha etkin hale getirme potansiyeline sahiptir. Yapay zekâ destekli sistemler; veri doğruluğunu artırmak, işlem sürelerini kısaltmak ve sahtecilik riskini azaltmak gibi avantajlar sağlayabilir. Özellikle veri madenciliği, görüntü işleme ve doğal dil işleme teknikleriyle taşınmazların dijitalleşmesi, kayıtların otomatik analizi ve tapu işlemlerinde hızlı ve doğru karar verme imkânı ortaya çıkmaktadır.

Haritacılık alanında yapay zekanın kullanımı gün geçtikçe artmakta ve sektör için kritik bir önem kazanmaktadır. Yapay zekâ, uydu görüntüleri ve dron verilerinin otomatik analiziyle, daha hızlı ve hassas haritalar üretilmesine olanak tanır. Böylece, şehir planlaması, afet yönetimi, çevre koruma ve tarımsal faaliyetler gibi pek çok alanda daha verimli çalışmalar yürütülebilir. Gelecekte, yapay zekanın haritacılık süreçlerine daha fazla entegre olması beklenmektedir. Özellikle akıllı şehirler, artırılmış gerçeklik (AR) ve sanal gerçeklik (VR) gibi teknolojilerle birleşerek, mekânsal bilginin kullanım şekli tamamen değişecektir.

Yapay zekâ, hava fotoğrafları ve videoların analizinde etkin bir rol oynamaktadır. TKGM'nin hava fotoğraflarının işlenmesi ve arazi üzerindeki değişimlerin tespiti için kullanılan algoritmalar, arazi yönetiminde önemli kolaylıklar sağlar. Ayrıca, video görüntülerinin yapay zekâ tabanlı analizleri ile imar denetimleri, kaçak yapıların otomatik tespiti ve mekânsal veri tabanlarının güncel tutulması mümkün hale gelmektedir. Bu uygulamalar sayesinde kaynakların etkin kullanımı ve veri kalitesinin artırılması sağlanır.

TKGM'de resmî web sayasında yer alan mevzuat bölümünde, TAKBIS iş ve işlemlerinde yapay zeka

destekli yaklaşık 40 robot, üç boyutlu modellerin kaplanmasında en uygun hava fotoğrafların seçimi gibi yapay zekâ uygulamalar kullanılmaktadır.

Kamu kaynakları ile üretilen ve paylaşılan coğrafi verilerin yapay zekâ teknikleri ile deforme edilmesi, değiştirilmesi, yok edilmesi ya da kamufle edilmesi mümkündür. Açık yapay zekâ kullanım olanakları ile bir video, fotoğraf veya hava fotoğrafı üzerinde yapılan değişikliklere örnek olması bakımından iki önemli çalışmaya aşağıda yer verilmiştir.

### 1.1. Basit Bir Fotoğraf/Video Uygulaması

- ChatGPT uygulamasında; kadın, üzerinde takım elbise, göz rengi, saç rengi, ten rengi şu olsun bir seyirci karşısında olduğu varsayılarak seyirciye bakması, duruşunun nasıl olacağı gibi komutlar verilerek bir sunucu görseli tasarımı yapması istenmiştir. Gelen tasarım incelenmiş ve komutlarla düzeltmeler/iyileştirmeler yapılarak göze hitap eden bir sunucu görseli hazırlanmıştır.




Şekil 1:

- Sunucu için bir konuşma metni hazırlanmıştır. Hazırlanan metin ttsmaker.com adlı web sitesinden Türkçe, kadın sesi ve ses tonu gibi seçenekler kullanılarak seslendirme dosyası oluşturmuştur.
- D-ID- AI video platform adlı siteye görseli ve ses dosyasını yükleyerek ilgi görüntünün yüklediğim ses dosyasına uyumlu olarak konuşan bir video haline getirilmesi sağlanmıştır.
- Elbette ChatGPT ve Canva gibi uygulamaların ücretli versiyonları bu tarz içerikler daha detaylı ve daha profesyonel içerikler hazırlamak mümkündür.



**Şekil 2:**



**Şekil 3:**



**Şekil 4:**

### 4.2.Hava Fotoğrafları Uygulaması

Hava fotoğrafları; kadastro haritalarının yenilenmesi ve güncellenmesi, zilyetlik süresinin belirlenmesi, belirli tarihlere göre imar ve ihya uygulamalarının analizi, taşınmaz üzerinde yapı var/yok tespiti, yapı değişikliklerinin takibi, imar kirliliği ve imar suçlarının ortaya çıkarılması gibi birçok teknik ve hukuki alanda delil niteliği taşıyan kritik bir veri kaynağıdır. Ancak, bu kadar yüksek bir doğruluk ve güvenirlik atfedilen hava fotoğraflarının, yapay zekâ teknikleriyle dijital olarak değiştirilmesi ya da manipüle edilmesi mümkündür. Bu bağlamda, çalışmanın temel amacı; kamu kurumlarının karar alma süreçlerinde başvurduğu görsel verilerin, kötü niyetli yapay zekâ uygulamalarıyla nasıl yanıltıcı hale getirilebileceğini göstermek ve bu riske karşı farkındalık oluşturmaktır.



**Şekil 5:**



**Şekil 6:**



**Şekil 7:**



**Şekil 8:**



**Şekil 9:**

## 5. SONUÇ VE DEĞERLENDİRME

Yapay zekâ, dünya genelinde hızla gelişmekte olan ve düzenleyici çerçevelerle desteklenen önemli bir teknolojidir. TKGM gibi kamu kurumlarında yapay zekâ kullanımının artması, işlemlerde doğruluğu ve hızı artırırken, hizmet kalitesini de yükseltecektir. Ancak, yapay zekanın potansiyel risklerinin yönetilmesi, etik ve hukuki standartların titizlikle uygulanması gerekmektedir. Yapay zekâ uygulamalarının sürdürülebilir başarısı için, sürekli eğitim, yatırım ve mevzuat güncellemelerinin sağlanması önemlidir.

Kurumsal verilerin paylaşımı ile paylaşılan verilerden katma değerli yeni ürünlerin üretilmesi, paylaşım amacı dışında kullanımların önlenmesi, telif ve iktibas haklarının korunması amacıyla;

- Coğrafi verilerin korunması,
- Paylaşılan coğrafi verilerin izlenmesi,
- Veri de değişim/oynama denetimi,
- Veri orijinal mi veya yapay zekayla mı üretilmiş,

gibi fonksiyonları içerecek mekanizma kurulması ve mevzuat düzenlemesine ihtiyaç bulunmaktadır.

© Günay Arda 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Şeker Pancarı'nın NDVI ile Fenolojik Evreleri ve Anomali Paternlerinin Analizi

**Osman Salih YILMAZ*[1], Ceren Akgül[2], Füsun Balık Şanlı[3], Ramazan Güngör[4], Birol Kuru[5]**

[1]*Manisa Celal Bayar Üniversitesi, Demirci Meslek Yüksekokulu, Mimarlık ve Şehir Planlama, Manisa, Türkiye*
[2]*Yıldız Teknik Üniversitesi, İnşaat Fakültesi, Harita Mühendisliği, İstanbul, Türkiye*
[3]*Yıldız Teknik Üniversitesi, İnşaat Fakültesi, Harita Mühendisliği, İstanbul, Türkiye*
[4]*Manisa Celal Bayar Üniversitesi, Demirci Meslek Yüksekokulu, Mimarlık ve Şehir Planlama, Manisa, Türkiye*
[5]*Manisa Celal Bayar Üniversitesi, Köprübaşı Meslek Yüksekokulu, Mimarlık ve Şehir Planlama, Manisa, Türkiye*

**Anahtar Kelimeler**
Şeker Pancarı,
Google Earth Engine,
NDVI,
Uzaktan Algılama

**ÖZET**

Bu çalışmada şeker pancarı (*Beta vulgaris* L.) gelişiminin fenolojik evreleri, uzaktan algılama teknikleri kullanılarak Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI) ile analiz edilmiştir. Sentinel-2 uydu verilerinden üretilen NDVI zaman serisi, çimlenme, vejetatif gelişim, rozet gelişimi, kök gelişimi ve hasat dönemlerindeki değişimleri izlemek için kullanılmıştır. Savitzky-Golay filtreleme yöntemiyle zaman serisi verilerindeki gürültüler azaltılarak fenolojik evreler daha hassas şekilde belirlenmiştir. Daha sonra her evredeki son beş yılın (2018-2022) NDVI referans değerleri kullanılarak fenolojik evrelerdeki anomaliler belirlenmiştir. Orijinal ve filtrelenmiş NDVI değerleri arasında yüksek düzeyde bir korelasyonu belirlenmiş olup, korelasyon katsayısı R = 0,98 olarak hesaplanmıştır. 2023 yılı büyüme sezonunda şeker pancarının gelişimi, Nisan ayında çimlenme evresinde minimum NDVI değeri olan 0,13 ile başlamıştır. Şeker pancarı, temmuz ayı sonlarında rozet büyümesi evresinde maksimum NDVI değeri olan 0,83'e ulaşarak en yoğun vejetatif gelişimini göstermiştir. Sezon sonunda, Ekim ayındaki hasat döneminde NDVI değeri yeniden 0,32'e gerilemiştir. Anomali analizi, şeker pancarının gelişim sürecinin genel olarak olumlu seyrettiğini göstermektedir. Çimlenme evresinde Z-skoru-1,01 ile "orta negatif" anomali kaydedilmiştir. Vejatatif gelişim evresinde Z-skoru 0,29 değeri ile "normal" anomali tespit etmiştir. Rozet gelişim evresinde ve kök gelişim evresinde sırasıyla Z-skoru 1,24 ve 1,14 değerleri ile "orta pozitif" bir anomali göstermiştir. Hasat döneminde ise Z-skoru 0,69 ile "hafif pozitif" bir anomali göstermiştir. Bu çalışma, şeker pancarı üretiminde fenolojik evrelerin izlenmesi ve anomalilerin belirlenmesi açısından NDVI indeksinin etkin bir araç olduğunu ortaya koymaktadır.

# Analysis of Phenological Stages and Anomaly Patterns of Sugar Beet Using the NDVI

**Keywords**
Sugar beet,
Google Earth Engine,
NDVI,
Remote sensing

**ABSTRACT**

In this study, the phenological stages of sugar beet (Beta vulgaris L.) development were analysed using remote sensing techniques through the Normalized Difference Vegetation Index (NDVI). The NDVI time series derived from Sentinel-2 satellite data was used to monitor changes during the germination, vegetative growth, rosette development, root development, and harvest periods. Noise in the time series data was reduced using the Savitzky-Golay filtering method, allowing for more precise identification of phenological stages. Subsequently, anomalies in these stages were detected by using the NDVI reference values from the past five years (2018–2022) for each stage. A strong correlation was found between the original and filtered NDVI values, with a correlation coefficient of R = 0.98. During the 2023 growing season, sugar beet development began in April with the germination stage, showing a minimum NDVI value of 0.13. By the end of July, the crop reached its peak vegetative growth during the rosette stage, with a maximum NDVI value of 0.83. At the end of the season, during

* **Sorumlu Yazar**

* (osmansalih.yilmaz@cbu.edu.tr) ORCID ID 0000-0003-4632-9349
(crnakgl12@gmail.com) ORCID ID 0009-0004-4196-4751
(fbalik@yildiz.edu.tr) ORCID ID 0000-0003-1243-8299
(ramazan.gungor@cbu.edu.tr) ORCID ID 0000-0002-6338-8554
(birol.kurur@cbu.edu.tr) ORCID ID 0000-0002-2203-301X

**Kaynak Göster (APA):**

Yılmaz O S, Akgül C, Balık Şanlı F, Güngör R, & Kuru B (2025). Şeker Pancarı'nın NDVI ile Fenolojik Evreleri ve Anomali Paternlerinin Analizi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

the harvest period in October, the NDVI value decreased again to 0.32. The anomaly analysis indicated that the overall growth process of sugar beet was favourable. In the germination stage, a "moderate negative" anomaly was recorded with a Z-score of -1.01. During the vegetative growth stage, a "normal" anomaly was observed with a Z-score of 0.29. The rosette and root development stages showed "moderate positive" anomalies with Z-scores of 1.24 and 1.14, respectively. In the harvest period, a "slight positive" anomaly was observed with a Z-score of 0.69. This study demonstrates that the NDVI index is an effective tool for monitoring phenological stages and detecting anomalies in sugar beet production.

## 1. GİRİŞ

Artan küresel nüfus ve iklim değişikliği, tarımsal üretimde sürdürülebilir ve verimli yöntemlerin benimsenmesini zorunlu kılmaktadır. Bitki fenolojisi, tarımsal verimlilik ve ekosistem dinamikleri açısından kritik bir parametre olup, özellikle şeker pancarı gibi stratejik ürünlerin izlenmesinde önem taşımaktadır. Şeker pancarının gelişim süreci; sıcaklık, toprak nemi, besin elementleri ve güneş ışığı gibi çevresel faktörlerden etkilenmektedir. Bu çevresel değişkenler, bitkide anormal büyüme paternlerine ve dolayısıyla verim kayıplarına yol açabilmektedir(Gungula vd., 2003).

Bu çalışma, şeker pancarının fenolojik gelişimini yalnızca NDVI (Normalize Edilmiş Fark Bitki Örtüsü İndeksi) kullanarak incelemeyi amaçlamaktadır. Sentinel-2 uydu verilerinden elde edilen NDVI verileri, şeker pancarının beş ana fenolojik evresinin (çimlenme, vejetatif gelişim, rozet gelişimi, kök gelişimi ve hasat) tespitinde etkin bir şekilde kullanılacaktır. Çalışmanın yenilikçi yönü, Savitzky-Golay filtreleme tekniğiyle zaman serisi verilerinden fenolojik evrelerin tam otomatik olarak tespit edilmesidir. 2018-2022 yıllarındaki tarihsel verilerle karşılaştırmalar yapılarak, 2023 yılı için fenolojik gelişim anomalileri z-skor metoduyla nicelleştirilmiştir. Bu yöntem, tarımsal üretimin izlenmesi ve verim tahminlerinin doğruluğunu artırmak için yeni bir bakış açısı sunmakta, aynı zamanda sürdürülebilir tarım uygulamalarının geliştirilmesine katkı sağlamaktadır.

## 2. YÖNTEM

Şeker pancarının fenolojik evrelerini analiz etmek amacıyla, Sentinel-2 uydu görüntüleri (13 spektral bant, 10–60 m çözünürlük) ve NDVI indeksi ((NIR − RED)/(NIR + RED)) kullanılmıştır (Rouse vd., 1974). NDVI zaman serisi analizlerinde, veri gürültüsünü azaltmak için Savitzky-Golay filtresi (pencere boyutu: 7, polinom derecesi: 2) uygulanmıştır.

Şeker pancarının beş fenolojik evresi —çimlenme, vejetatif gelişim, rozet gelişimi, kök gelişimi ve hasat— BBCH ölçeği doğrultusunda belirlenmiştir (Gasparic vd., 2021). 2023 yılı verileri, 2018-2022 referans dönemiyle karşılaştırılarak Z-skorları hesaplanmış ve anomaliler yedi kategoride (şiddetli negatif, orta negatif, hafif negatif, normal, hafif pozitif, orta pozitif ve şiddetli) sınıflandırılmıştır.

## 3. BULGULAR

Bu çalışmada, Küresel Konumlama Uydu Sistemi (Global Navigation Satellite System-GNSS) ile sınırları belirlenen şeker pancarı tarlalarına ait veriler Google Earth Engine (GEE) ortamına aktarılmış ve bu alanlardan rastgele 250 nokta seçilmiştir. Seçilen noktaların ortalama NDVI değerleri, şeker pancarının çimlenme başlangıcından hasat dönemine kadar olan süreçte hesaplanmıştır. Bulutların etkisini ortadan kaldırmak için %10 bulut filtresi uygulanmış ve QA60 bandı ile bulut maskesi oluşturulmuştur. Bu işlemlerle elde edilen uydu görüntüleri üzerinden NDVI bitki indeksi hesaplanmış ve sonuçlar zaman serisi grafiği oluşturulmuştur. Daha sonra bu zaman serisi grafiğine Savitzky-Golay filtresi uygulanmıştır (Şekil 1).

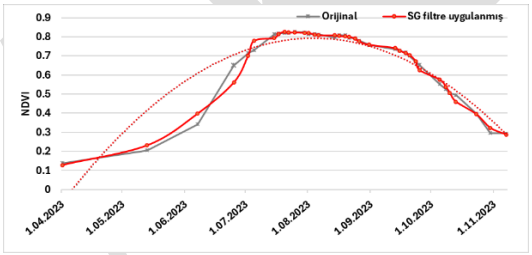


**Şekil 1.** Filtre uygulanmış NDVI zaman serisi analizi

Zaman serisi grafikleri incelendiğinde, şeker pancarı bitkisinin 2023 vejetasyon dönemindeki gelişim paterni net bir şekilde görülmektedir. Nisan ayındaki düşük indeks değerleri, vejetasyonun başlangıç aşamasını temsil etmektedir. Haziran ayı itibariyle tüm indekslerde hızlı bir artış gözlenmiş ve temmuz ortasında maksimum değerlere ulaşılmıştır. NDVI değerleri 0,13-0,83 aralığında değişirken, maksimum değer 0,83 olarak filtrelenmiş veride gözlenmiştir.

Savitzky-Golay algoritması uygulanarak gürültüden arındırılan zaman serisi grafiklerine ait fenolojik evrelere ait bilgiler Çizelge 1'de verilmiştir.

**Çizelge 1.** Fenolojik evreler

| İndeks | Periot | Değer | Tarih |
|---|---|---|---|
| NDVI | Çimlenme | 0,13 | 01.04.2023 |
| NDVI | Vejetatif | 0,23 | 13.05.2023 |
| NDVI | Rozet | 0,83 | 20.07.2023 |
| NDVI | Kök | 0,47 | 05.10.2023 |
| NDVI | Hasat | 0,32 | 30.10.2023 |

Şeker pancarının fenolojik gelişimi, NDVI değerlerindeki karakteristik değişimlerle takip edilebilmektedir. Çimlenme evresinde NDVI (0,13) düşük olup, vejetatif gelişim sürecinde artış (0,23) göstermektedir. Rozet gelişimi evresinde maksimum değere (0,83) ulaşan NDVI, kök gelişimi evresinde azalmaya başlamakta (0,47) ve hasat döneminde bu azalış devam etmektedir. Bu spektral değişimler, bitkinin yeşil kütle gelişimi, fotosentetik aktivitesi ve fizyolojik olgunlaşma süreçlerini yansıtmaktadır. Fenolojik evrelere ait harita Şekil 2'de gösterilmiştir.

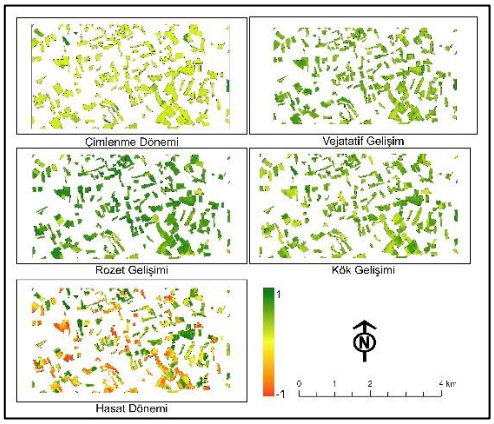


**Şekil 2.** Fenolojik evrelere ait harita

2023 yılına ait Z-skor analizine göre şeker pancarının fenolojik evrelerinde farklı düzeylerde anomaliler gözlemlenmiştir. Çimlenme döneminde Z-skorunun-1,81 olarak hesaplanması, bu evrede geçmiş beş yıl ortalamasına kıyasla belirgin bir düşüş yaşandığını ve "orta negatif" bir anomali olduğunu göstermektedir. Vejetatif gelişim evresinde ise Z-skoru 0,29 ile "normal" seviyede bulunmuş, bu da bu dönemdeki gelişimin geçmiş yıllarla tutarlı seyrettiğini ortaya koymuştur. Rozet gelişimi ve kök gelişimi evrelerinde sırasıyla 1,24 ve 1,14 Z-skorlarıyla "orta pozitif" anomaliler tespit edilmiştir. Bu pozitif sapmalar, bu evrelerde bitkinin gelişiminin ortalamanın üzerinde gerçekleştiğini ve muhtemelen elverişli iklim koşullarının etkili olduğunu göstermektedir. Son olarak, hasat döneminde Z-skoru 0,69 ile "hafif pozitif" bir anomali belirlenmiş, bu da sezon sonunda gelişimin genel olarak olumlu seyrettiğini desteklemektedir. Genel olarak değerlendirildiğinde, çimlenme evresi dışında şeker pancarının gelişiminin büyük ölçüde olumlu koşullar altında gerçekleştiği anlaşılmaktadır.

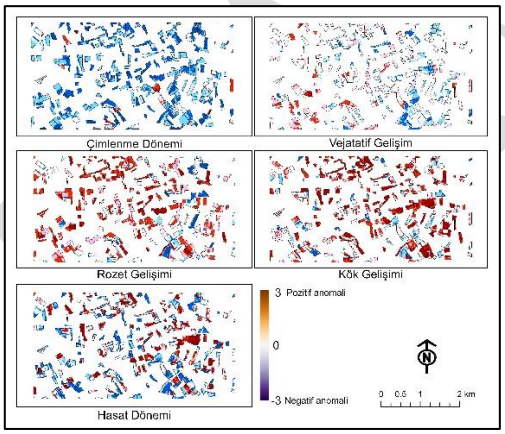


**Şekil 3.** Anomali haritaları

## 4. TARTIŞMA

NDVI, şeker pancarının fenolojik evrelerini izlemede etkili bir gösterge olarak tespit edilmiştir. Çalışmada, NDVI değerlerinin Nisan'da düşük seviyeden başlayıp Haziran'da hızla yükseldiği ve temmuz ortasında maksimum seviyeye ulaştığı gözlemlenmiştir. Savitzky-Golay filtresi, zaman serisindeki dalgalanmaları azaltarak fenolojik evrelerin daha net belirlenmesini sağlamıştır. Yüksek korelasyon katsayıları, filtreleme işleminin veri bütünlüğünü koruduğunu doğrulamıştır. Bu bulgular, daha önceki araştırmalarla uyumlu olup, NDVI'nın hassas tarım uygulamalarında fenolojik haritalama ve anomali tespiti için değerli bir araç olduğunu göstermektedir (Pettorelli vd., 2005).

## 5. SONUÇ

Çalışma, NDVI'nın şeker pancarının fenolojik evrelerini izlemede kritik önemini ortaya koymuştur. 2023 vejetasyon döneminde NDVI değerleri Nisan'da düşük başlayıp, Haziran'da hızla yükselmiş ve temmuz ortasında maksimuma ulaşmıştır. Savitzky-Golay filtresi sayesinde gürültüden arındırılan zaman serileri, çimlenmeden hasat dönemine kadar olan evrelerin spektral olarak ayrışmasını sağlamıştır. NDVI değerleri ve Z-skor analizine göre, 2023 yılında çimlenme evresi dışında tüm gelişim dönemleri normalin üzerinde seyretmiş ve özellikle rozet ile kök gelişimi evrelerinde "orta pozitif" anomaliler tespit edilmiştir. Bu bulgular, şeker pancarının 2023 sezonunda genel olarak uygun çevresel koşullarda geliştiğini ve NDVI ile fenolojik izleme ile anomali tespitinin hassas tarım uygulamalarında etkili bir yaklaşım sunduğunu ortaya koymuştur.

### Yazar Katkı Oranı

Tüm yazarlar eşit oranda katkı sağlamıştır

### Çıkar Çatışması/Çakışması

Yazarların herhangi bir çıkar çatışması yoktur.

### KAYNAKÇA

Gasparic, H. V., Lemic, D., Drmic, Z., Cacija, M., & Bazok, R. (2021). The efficacy of seed treatments on major sugar beet pests: Possible consequences of the recent neonicotinoid ban. *Agronomy*, *11*(7). doi:10.3390/agronomy11071277

Gungula, D. T., Kling, J. G., & Togun, A. O. (2003). CERES-Maize Predictions of Maize Phenology under Nitrogen-Stressed Conditions in Nigeria. *Agronomy Journal*, *95*(4), 892–899. doi:10.2134/AGRONJ2003.8920

Pettorelli, N., Vik, J. O., Mysterud, A., Gaillard, J. M., Tucker, C. J., & Stenseth, N. C. (2005). Using the satellite-derived NDVI to assess ecological responses to environmental change. *Trends in Ecology & Evolution*, *20*(9), 503–510. doi:10.1016/J.TREE.2005.05.011

Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). *Monitoring vegetation systems in the Great Plains with ERTS. 1974*. In *Proceeding Of Erts-1 Symposium*.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# 3B Şehir Modellerinin İyileştirilmesi İçin Metodoloji Önerisi

**Gülay Karabaş*[1], Bilal Erkek[1], Ekrem Ayyıldız[1]**

[1]*Tapu ve Kadastro Genel Müdürlüğü, Harita Dairesi Başkanlığı, Ankara*

**Anahtar Kelimeler**
Uzaktan Algılama,
3B Modelleme,
Google Earth Engine

**ÖZET**

Bu çalışmada, 2019–2024 yılları arasında meydana gelen kentsel yapı değişimlerinin uzaktan algılama ve coğrafi bilgi sistemleri (CBS) tabanlı yöntemlerle analiz edilmesi amaçlanmıştır. Bu analiz sonucunda sadece değişime uğrayan bölgelerde uçuş yapılarak büyük oranda ekonomik tasarruf sağlanacağı düşünülmüştür. Çalışma iki aşamadan oluşmaktadır. Birinci aşamada, Ankara İl merkezinde Sentinel-2 uydu görüntüleri kullanılarak Google Earth Engine (GEE) platformunda Dynamic World arazi örtüsü sınıflandırma modeli ile analizler gerçekleştirilmiştir. Bu sayede belirtilen yıllar arasında yıkılan ve yeni inşa edilen binaların tespiti yapılmış ve yaklaşık bina sayıları hesaplanmıştır. İkinci aşamada ise, Kahramanmaraş ili sınırları içerisinde yer alan 1/1000 ölçekli 6(altı) adet paftada, 2019(deprem öncesi) ve 2024 (deprem sonrası) yıllarına ait Sayısal Yüzey Modeli (DSM), ortofoto ve nokta bulutu verileri kullanılmıştır. Bu veriler QGIS, Global Mapper gibi yazılımlar aracılığıyla analiz edilerek yıkılan ve bu yıllar arasında inşa edilen binalar tespit edilmiştir. Aynı zamanda, çalışma alanındaki yapıların eğim haritaları çıkartılarak, çatı geometrilerinin vektörel olarak çıkarılması hedeflenmiştir. Çatı geometrilerinden yararlanılarak 3D şehir modellerinin iyileştirilmesi hedeflenmiştir.

# Methodology Proposal for Improving 3D City Models

**Keywords**
Remote sensing,
3D Modelling,
Google Earth Engine

**ABSTRACT**

This study aims to analyze the urban structure changes that occurred between 2019 and 2024 using remote sensing and geographic information systems (GIS) based methods. As a result of this analysis, it was thought that a large amount of economic savings could be achieved by taking images only in the areas where were changed. The study consists of two objectives. In the first objective, analyzes were performed using Sentinel-2 satellite images in the city center of Ankara with the Dynamic World land cover classification model on the Google Earth Engine (GEE) platform. In this way, the demolished and new constructed buildings were detected between the specified years and the approximate number of buildings was calculated. In the second objective, Digital Surface Model (DSM), orthophoto and point cloud data for the years 2019 (before the earthquake) and 2024 (after the earthquake) were used in 6 (six) plots at a scale of 1/1000 within Kahramanmaraş province. These data were analyzed using software such as QGIS and Global Mapper to identify demolished and new constructed buildings. At the same time, it was aimed to extract the roof geometries vectorially by extracting the slope maps of the structures in the study area. It was aimed to improve 3D city models by utilizing the roof geometries.

## 1. GİRİŞ

Arazi örtüsü sınıflandırması, sürdürülebilir arazi yönetimi için kritik öneme sahiptir çünkü bölgedeki arazi örtüsü türleri ve dağılımını anlamaya yardımcı olur. [1] Bu bilgiler, bozulmaya uğramış veya koruma gerektiren alanların tespit edilmesine ve sürdürülebilir kullanım fırsatlarının belirlenmesine olanak sağlar. Uzaktan algılama teknolojisi, bu tür verilerin doğruluğunu artırarak, farklı arazi örtüsü tiplerinin yansıma özelliklerini yakalamayı mümkün kılar. Landsat, Aster, Sentinel ve MODIS gibi uydu verileri, arazi örtüsü

* **Sorumlu Yazar**

*(tk48603@tkgm.gov.tr) ORCID ID 0009-0002-4707-5897
(berkek@tkgm.gov.tr) ORCID ID 0000-0002-4918-2779
(eayyildiz@tkgm.gov.tr) ORCID ID 0000-0002-9151-364x

**Kaynak Göster (APA):**

Karabaş G, Erkek B & Ayyıldız E (2025). 3B Şehir Modellerinin İyileştirilmesi İçin Metodoloji Önerisi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

sınıflandırması ve değişim izleme için kullanılırken, Tapu ve Kadastro Genel Müdürlüğü tarafından üretilen yüksek çözünürlüklü veriler de mevcuttur. Arazi örtüsü sınıflandırması için kullanılan yazılımlar arasında ERDAS, ArcMap, QGIS ve Google Earth Engine yer almaktadır. Raporun hazırlık sürecinde, Sentinel-2 uydu görüntülerinden elde edilen verilerle iyileştirilmesi gereken bölgeler tespit edilmiştir. Bu veriler, QGIS, Google Earth Engine ve diğer yazılımlar kullanılarak incelenmiştir. İkinci ve üçüncü aşamalarda, Tapu ve Kadastro Genel Müdürlüğü'nün ürettiği sayısal yükseklik modelleri, çatı vektör verileri ve diğer verilerle analiz yapılmıştır. Çalışmanın amacı, farklı tarihlerde üretilen verilerle arazi kullanım değişimlerini belirlemek ve yapıların iyileştirilmesi için bir model önerisi geliştirmektir. Bu analizler sonucunda, iyileştirilmesi gereken alanlar için daha ayrıntılı çözümler önerilmiştir.

## 2. YÖNTEM

İlk aşamada, şehir merkezlerinde ortofotolara göre nispeten daha düşük çözünürlükte olduğundan uydu görüntüleri ile yıkılan ve yeni yapılan yapıların tespit edilip edilmeyeceğini test edebilmek için Sentinel-2 uydu görüntüleri kullanılarak Google Earth Engine ortamında Dynamic World kullanılarak 2019 ve 2024 yıllarında Ankara İl merkezinde sınıflandırılmış verilerden bina sınıfı seçilip diğer sınıflardan ayrıştırılmıştır. Sadece bina verileri üzerinden bu zaman aralığında yıkılan ve yeni inşa edilen binaların piksel alanları hesaplanmış buradan bina sayıları hesaplanmaya çalışılmıştır. Veri üretimi sürecinde, 3b modelleme ve çatı çıkarımları yapılması hedeflendiği için daha yüksek çözünürlüklü veriler ve depremden etkilenmesinden dolayı değişikliğin yoğun olduğu Kahraman Maraş ili tercih edilmiştir. Ortofoto görüntüler, sayısal yükseklik modelleri ve çatı verileri kullanılarak Kahramanmaraş İlinde 1/1000 lik 6 pafta üzerinde 2019-2024 yılları arasında DSM verileri üzerinden yıkılan ve yeni yapılan binalar DSM Raster formatında karşılaştırılmıştır. Yükseklik farkları 5 sınıfa ayrılıp daha sonra vektörleştirilip QGIS, Global Mapper ve CloudCompare gibi yazılımlarla analiz edilmiştir.

## 3. BULGULAR

GEE platformunda Dynamic World veri kümesi kullanılarak 2019 ve 2024 Temmuz aylarındaki Ankara'daki bina değişimleri analiz edilmiştir.

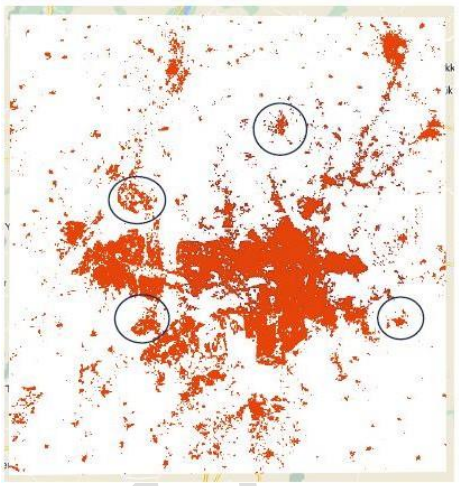

**Şekil 1**. 2019 yılı sadece binalar

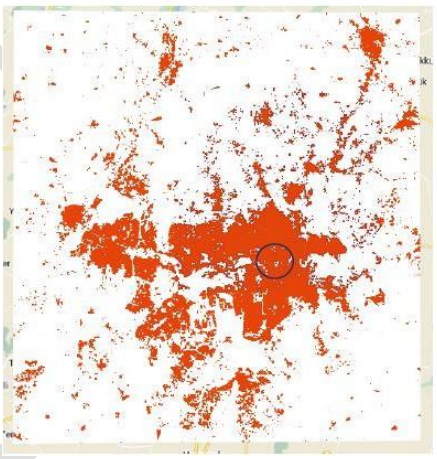

**Şekil 2.** 2024 yılı sadece binalar

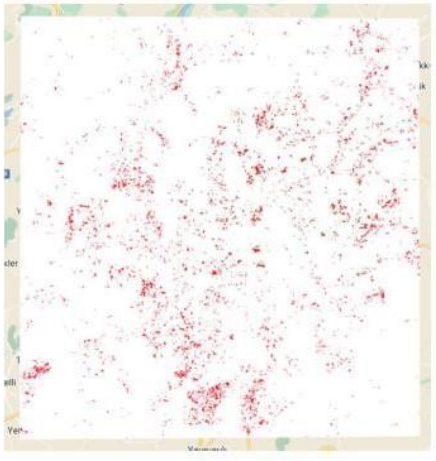

**Şekil 3.** 2019-2024 yılları arasında yeni yapılan binalar

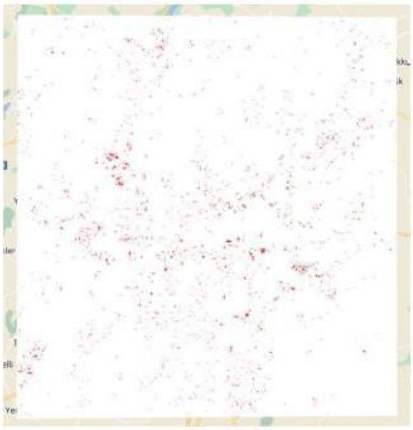

**Şekil 4.** 2019-2024 yılları arasında yıkılan binalar

- 2019- Temmuz'dan 2024 yılına kadar yıkılan ve yeni yapılan binalar birlikte değerlendirilmiştir.
- Değişim, Ankara'nın çeper bölgelerinde yoğunlaşmaktadır.
- Gölbaşı, Oran, Saray, Kahramankazan, Pursaklar, Akyurt ve Karapürçek mahalleleri değişimin yoğun olduğu bölgelerdir.

**Çizelge 1.** Çalışma alanında bina sayıları öngörüsü

| Analiz Bilgisi | Alan [m²] | Öngörülen Bina Sayısı |
|---|---|---|
| Çalışma Bölgesi | 3,657,159,185 | 365,716 |
| 2024 Yapılaşma | 677,722,013 | 33,886 |
| 2019 Yapılaşma | 605,179,970 | 30,259 |
| 2019-2024 Arası Yeni Yapılaşma | 113,999,743 | 5,700 |
| 2019-2024 Arası Yapılaşması Yok Olan | 41,457,700 | 2,073 |

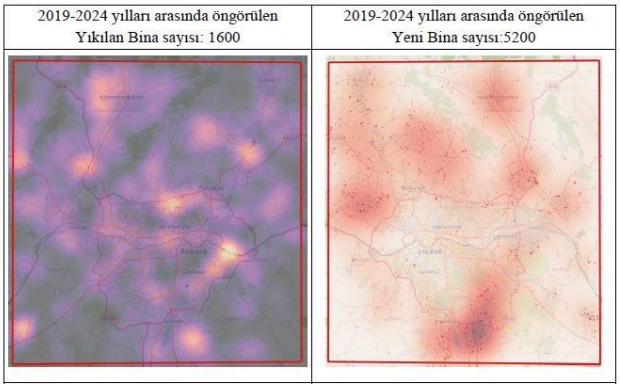


**Şekil 5.** Öngörülen yeni ve yıkılan bina sayıları

## 4. TARTIŞMA

Bu çalışmada, bina çatı çizgilerinin belirlenmesine yönelik olarak eğim verileri ve kompaktlık analizleri kullanılmış; bu yöntemlerin, özellikle karmaşık kentsel dokularda çatı kenarlarının ayrıştırılması açısından önemli katkılar sunduğu gözlemlenmiştir. Ancak elde edilen bulgular, bitişik nizam yapıların yoğun olduğu bölgelerde, ağaç örtüsü ya da diğer düzensiz şekillerin varlığı nedeniyle bu yöntemlerin sınırlı başarıyla çalıştığını ortaya koymuştur. Özellikle bu tür çevresel ve yapısal karmaşıklıklar, çatı çizgilerinin doğru şekilde sınıflandırılmasını ve ayrıştırılmasını zorlaştırmıştır.

Bu durum, çatı çizgilerinden üç boyutlu bina modellerinin doğrudan otomatik olarak üretimini engellemiş, manuel müdahale gereksinimini artırmıştır. Bu bağlamda, mevcut koşullar altında çatı çizimlerinin 3B stereo modeller üzerinden operatör destekli olarak gerçekleştirilmesi gerektiği değerlendirilmiştir. Bu yaklaşım, doğruluğu artırmakla birlikte zaman ve maliyet açısından dezavantaj oluşturmaktadır.

## 5. SONUÇ

Yapılan çalışma ile 2019- 2024 yılına kadar yıkılan ve yeni yapılan binalar birlikte değerlendirilmiştir ve değişimlerin yoğun olduğu bölgeler tespit edilmiştir.

Deprem sonrası Kahramanmaraş ilinde güncellenmesi gereken veya yıkılan binaların tespiti mevcut imkân ve kabiliyetler ile yapılabileceği ortaya konulmuştur. Söz konusu tespit çalışmalarının büyük alanlarda ve kısa sürede yapılabilmesi için işlem süreçlerinin otomasyonu sağlanması gerektiği değerlendirilmektedir.

Yüksek eğimli (%70-90) bölgelerde bina çatı çizgilerinin belirginliği doğrulandı. Kompaktlık analiziyle daha düzgün geometrilere odaklanıldı, ancak bitişik/düzensiz şekiller süreçte sınır ü oluşturmuştur.

## TEŞEKKÜR

### Yazar Katkı Oranı

%45 Gülay KARABAŞ, %45 Bilal ERKEK, %10 Ekrem
Ayyıldız

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

## KAYNAKÇA

Song, X. P., Hansen, M. C., Stehman, S. V., Potapov, P. V., Tyukavina, A., Vermote, E. F., & Townshend, J. R. (2018). Global land change from 1982 to 2016. Nature, 560(7720), 639-643.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Yüksek Çözünürlüklü Hava Görüntülerinden U-Net Tabanlı Otomatik Çatı Tespiti

**Ebru KAYA*[1], Ekrem AYYILDIZ [1]**

[1]*Tapu ve Kadastro Genel Müdürlüğü, Ankara, Türkiye*

**Anahtar Kelimeler**
Derin Öğrenme,
Hava Fotoğrafları,
Çatı Tespiti,
Görüntü Segmentasyonu

**ÖZET**

Bu çalışma, yüksek çözünürlüklü hava fotoğrafından bina çatılarının derin öğrenme tabanlı yöntem ile otomatik olarak çıkarılmasını amaçlamaktadır. Leeds (Birleşik Krallık) kentinde yer alan yaklaşık 1 km²'lik kentsel alan için, 25 cm çözünürlüğe sahip hava fotoğrafı kullanılmıştır. Görüntü verileri Digimap platformu aracılığıyla temin edilmiş olup, bina çatı sınırlarının etiketlenmesi süreci QGIS yazılımı kullanılarak manuel olarak yürütülmüştür. Eğitim sürecinde U-Net mimarisi tercih edilmiş ve veri eğitim, doğrulama ve test gruplarına ayrılmıştır. Modelin başarımı, test seti üzerinde yapılan değerlendirmelerde genel olarak yüksek doğrulukla sonuçlanmıştır. Görsel analizlere ek olarak, modelin çıktıları mekânsal doğruluk açısından da QGIS ortamında karşılaştırmalı olarak incelenmiştir. Değerlendirme metrikleri modelin, özellikle belirgin yapı geometrilerinde başarılı sonuçlar verdiğini, ancak gölge ve sınıf dengesizliği gibi çevresel etmenlerde performans düşüşü yaşadığını göstermektedir. Elde edilen bulgular, bina çatı segmentasyonuna yönelik derin öğrenme tabanlı çözümlerin, uzaktan algılama verilerinden anlamlı mekânsal bilgi üretimi sürecine katkı sağlayabileceğini ortaya koymaktadır. Ayrıca, kentsel planlama ve enerji uygulamaları gibi alanlarda bu tür yöntemlerin etkin biçimde kullanılabileceği öngörülmektedir.

# U-Net Based Automatic Roof Detection in High Resolution Aerial Images

**Keywords**
Deep Learning,
Aerial Imagery,
Roof Detection,
Image Segmentation

**ABSTRACT**

This study aims to automatically extract building roofs from high-resolution aerial image using a deep learning-based method. Aerial image with a resolution of 25 cm were used for an urban area of approximately 1 km² in Leeds (United Kingdom). Image data was obtained via the Digimap platform, and the process of labelling building roof boundaries was carried out manually using the QGIS software. U-Net architecture was preferred in the training process and the data were divided into training, validation and test groups. The performance of the model generally resulted in high accuracy in the evaluations made on the test set. In addition to visual analyses, the outputs of the model were also comparatively examined in terms of spatial accuracy in the QGIS environment. The evaluation metrics show that the model gives successful results especially for distinct building geometries, but it experiences performance degradation in environmental factors such as shadow and class imbalance. The findings show that deep learning-based solutions for building roof segmentation can contribute to the process of generating meaningful spatial information from remote sensing data. In addition, it is envisaged that such methods can be used effectively in areas such as urban planning and energy applications.

## 1. GİRİŞ

Bina çatı sınırlarının otomatik çıkarımı; kentsel planlama, afet yönetimi, güneş paneli yerleşimi ve çevresel izleme gibi birçok alanda, mekânsal analiz süreçlerini kolaylaştırma potansiyeli taşımaktadır. Özellikle yüksek çözünürlüklü görüntülerle çalışırken, geleneksel manuel etiketleme yöntemleri zaman alıcı ve hata riskine açıktır (Maggiori vd., 2017). Bu durum, derin öğrenme tabanlı yöntemlerin coğrafi veri işleme süreçlerinde daha sık tercih edilmesine yol açmıştır.

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(eayyildiz@tkgm.gov.tr) ORCID ID 0000-0002-9151-364x

**Kaynak Göster (APA):**

Kaya E & Ayyıldız E (2025). Yüksek Çözünürlüklü Hava Görüntülerinden U-Net Tabanlı Otomatik Çatı Tespiti, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

U-Net, başlangıçta tıbbi görüntü segmentasyonu için geliştirilmiş olup, günümüzde farklı görüntü işleme alanlarında başarıyla uygulanmaktadır (Ronneberger vd., 2015). Bu çalışmada, Birleşik Krallık'ın Leeds şehri yakınlarında yer alan 1 km²'lik bir kentsel alan için, 25 cm çözünürlüklü dikey hava fotoğrafları kullanılarak bina çatılarının otomatik olarak çıkarılması amaçlanmıştır.

Model eğitimi için veri kümesi eğitim, doğrulama ve test olarak ayrılmış; değerlendirme metrikleri olarak IoU (Intersection over Union), Dice Katsayısı, kesinlik (Precision), geri çağırma (Recall) ve F1-Skoru kullanılmıştır. Sonuçlar, modelin yüksek doğruluk sunduğunu ancak çevresel koşullardan etkilendiğini göstermektedir. Bu çalışma, derin öğrenme ile elde edilen bina çatı sınırlarının, yüksek çözünürlüklü hava görüntüleri üzerinde ne derece doğru bir şekilde çıkarılabildiğini ve bu sürecin kentsel analizlerde nasıl fayda sağlayabileceğini göstermektedir.

## 2. YÖNTEM

### 2.1. Çalışma Alanı ve Veri Hazırlama Süreci

Çalışma, Birleşik Krallık'ın Leeds kenti yakınlarında yer alan yaklaşık 1 km²'lik bir kentsel alanda gerçekleştirilmiştir. Bu bölge, farklı çatı tiplerini (tekil, bitişik nizam, endüstriyel vb.) içermesi nedeniyle modelin genelleme kabiliyetini değerlendirmek açısından tercih edilmiştir. Kullanılan 25 cm mekânsal çözünürlüklü dikey hava görüntüleri, Birleşik Krallık'taki araştırmacılara açık erişim sağlayan Digimap platformu aracılığıyla temin edilmiştir. Veriler, coğrafi koordinat bilgisi içeren ortorektifiye formatta sağlandığından ek bir geometrik düzeltmeye gerek duyulmamıştır. Etiketleme işlemleri QGIS yazılımı yapılmış ve raster maskelere dönüştürülen vektör çatı sınırları, model eğitiminde "ground truth" olarak kullanılmıştır (Maggiori vd., 2017).

### 2.2. Veri Bölme ve Görüntü Kesitleri

Yüksek çözünürlüklü görüntülerin doğrudan işlenmesi yerine, veri 256×256 piksel boyutlarında yamalara bölünerek, veri seti %70 eğitim, %15 doğrulama ve %15 test olarak ayrılmıştır. Her bir yama için .wld uzantılı konum dosyaları oluşturularak QGIS ortamında konumsal doğruluk sağlanmıştır.

### 2.3. Model Mimarisinin Tanımı ve Eğitim Süreci

Görüntü segmentasyonu için U-Net mimarisi tercih edilmiştir(Ronneberger vd., 2015). Modelde, öğrenmeyi iyileştirmek amacıyla veri artırma (döndürme, yansıma, ölçekleme), Batch Normalization (Ioffe ve Szegedy, 2015) ve Dropout gibi teknikler kullanılmış; optimizasyon için ADAM algoritması uygulanmıştır (Kingma ve Ba, 2015). Model, Binary Cross-Entropy kayıp fonksiyonu ile eğitilmiş, hiperparametreler eğitim sürecinde deneme-yanılma yöntemiyle belirlenmiştir. Öğrenme oranı, epoch sayısı ve erken durdurma stratejileri, overfitting'i engelleyecek şekilde yapılandırılmıştır.

### 2.4. Performans Değerlendirmesi ve Mekânsal Analiz

Modelin performansı; test veri setinde IoU, Dice katsayısı, kesinlik, geri çağırma ve F1-Skoru gibi metriklerle değerlendirilmiştir. Ayrıca, QGIS ortamında modelin tahmin ettiği çatı maskeleri ile gerçek çatı sınırları üst üste bindirilerek görsel analiz yapılmıştır. Sayısal analizde, vektöre dönüştürülen maskelerle gerçek çatı alanları karşılaştırılmış, "Vektör Birleştirme (Union)" yöntemi ile alan farkları hesaplanmıştır.

## 4. BULGULAR

U-Net modeli, bina çatılarının segmentasyonu için iki aşamalı bir eğitim süreciyle uygulanmıştır. İlk aşamada model genel segmentasyon yeteneğini kazanmış, ikinci aşamada ise ince ayar (fine-tuning) ile daha karmaşık çatı yapılarında doğruluk artırılmaya çalışılmıştır. Eğitim sürecinde doğruluk oranı %95'in, doğrulama doğruluğu ise %92'nin üzerine çıkmıştır. Erken durdurma stratejisi ile modelin aşırı öğrenmesi engellenmiştir. Test verisi üzerinde yapılan değerlendirmelerde modelin başarımı, IoU, Dice, Kesinlik (Precision), Geri Çağırma (Recall) ve F1-Skoru gibi metriklerle analiz edilmiştir. **Çizelge 1**'de bu metriklerin test seti üzerindeki ortalama sonuçları özetlenmektedir. Elde edilen sonuçlar, modelin genel olarak başarılı bir segmentasyon gerçekleştirdiğini göstermektedir.

**Çizelge 1.** Modelin test verisinde elde edilen ortalama performans metrikleri

| Metric | Average (%) |
|---|---|
| **IoU** | 81.0 |
| **Dice** | 89.0 |
| **Precision** | 86.0 |
| **Recall** | 89.0 |
| **F1-Score** | 87.0 |

QGIS ortamında yapılan görsel karşılaştırmalar ve alan hesaplamaları, modelin segmentasyon çıktılarının gerçek çatı sınırlarıyla büyük ölçüde örtüştüğünü göstermektedir. Özellikle Patch 12 örneğinde, modelin uzun ve karmaşık çatı yapılarını yüksek doğrulukla tespit ettiği görülmektedir (Şekil 1). Bu yamada elde edilen Intersection over Union (IoU) değeri %89, Dice katsayısı ise %94'tür. Bu sonuçlar, modelin özellikle belirgin çatı geometrilerinde etkili bir performans sunduğunu ortaya koymaktadır. Ancak, çatı kenarlarında ve gölge alanlarında sınırlı sapmalar tespit edilmiştir. Genel olarak, alan bazlı analizlerde modelin tahmin ettiği çatı alanı ile gerçek alan arasında ortalama %10 sapma bulunmuş; bazı örneklerde bu farkın %50'yi aştığı gözlemlenmiştir. Bu durum, çevresel koşulların ve sınıf dengesizliğinin modelin hassasiyetini etkileyebileceğini göstermektedir.




**Şekil 1**. Yama 12 – Orijinal görüntü, gerçek çatı maskesi ve model tarafından tahmin edilen maske karşılaştırması

## 4. TARTIŞMA

Elde edilen bulgular, U-Net mimarisinin yüksek çözünürlüklü hava görüntülerinde bina çatılarının çıkarımında etkili bir yöntem olduğunu göstermektedir. Model, özellikle büyük ve belirgin çatı yapılarında yüksek doğruluk sağlamış; ancak gölge, ağaç örtüsü ve yol-çatı benzerliği gibi çevresel etmenlerin yoğun olduğu alanlarda performans düşüşü gözlemlenmiştir.

Düşük performans gösteren yama örnekleri incelendiğinde, eğitilen veri setinin sınırlı çeşitliliğe sahip olması ve sınıf dengesizliği gibi faktörlerin modelin başarımını olumsuz etkilediği anlaşılmaktadır. Özellikle küçük çatı alanlarında veya çatısız bölgelerde modelin kararsız tahminler ürettiği gözlemlenmiştir.

Ayrıca, elde edilen performans değerleri (örneğin %81 IoU ve %89 Dice), literatürde U-Net mimarisiyle yüksek çözünürlüklü hava görüntülerinde yapılan benzer çalışmalarla genel olarak tutarlıdır (Ronneberger vd., 2015; Maggiori vd., 2017). Örneğin, Cheng vd. (2021) çalışmalarında DeepLabv3+ modeliyle %65.4 IoU başarımı elde edildiğini rapor etmiş; Ramalingam vd. (2024) ise donanım sınırlı ortamlarda çalışabilen, düşük karmaşıklıkta bir U-Net türevi geliştirerek pratik bir yaklaşım sunmuştur. Bu bağlamda, mevcut çalışmada ulaşılan sonuçlar, literatürdeki farklı yöntemlerle elde edilen bulgularla karşılaştırıldığında benzer düzeyde sonuçlar sunmaktadır.

Modelin yalnızca CPU tabanlı bir sistemde eğitilmesi de sınırlayıcı olmuştur. Diakogiannis vd. (2020), büyük ölçekli uydu görüntülerinde GPU kullanımının eğitim sürecini önemli ölçüde hızlandırdığını ve doğruluğu artırdığını vurgulamaktadır. Öte yandan, farklı çatı tiplerini içeren daha çeşitli veri kümeleriyle yapılacak eğitimlerin, modelin genelleme yeteneğini artırması beklenmektedir.

## 5. SONUÇ

Bu çalışma, yüksek çözünürlüklü hava görüntülerinden bina çatı sınırlarının otomatik olarak çıkarılması için U-Net mimarisinin etkinliğini değerlendirmeyi amaçlamıştır. Model, test verisi üzerinde ortalama %81 IoU ve %89 Dice başarımları ile genel olarak yüksek doğruluk göstermiştir.

Bununla birlikte, gölge, ağaç örtüsü, köprü ve yapı karmaşıklığı gibi çevresel faktörler model başarımını sınırlayabilmektedir. Ayrıca, sınıf dengesizliği ve donanım kısıtları gibi unsurların model performansı üzerinde etkili olduğu gözlemlenmiştir.

Modelin performansını artırmak adına daha güçlü donanım, çeşitlendirilmiş veri kümeleri ve gelişmiş kayıp fonksiyonlarının kullanılması önerilmektedir. Sonuç olarak, U-Net tabanlı derin öğrenme yaklaşımı, bina çatı sınırlarının çıkarımı konusunda umut verici sonuçlar sunmakta ve özellikle kentsel analizlerde, enerji planlamasında ve mekânsal karar destek süreçlerinde kullanılabilir potansiyele sahiptir.

## KAYNAKLAR


Cheng, Y., Tang, X., & Guo, L. (2024). Attention-enhanced U-Net for building extraction from aerial images. *ISPRS Journal of Photogrammetry and Remote Sensing, 203*, 89–104. https://doi.org/10.1016/j.isprsjprs.2024.01.005

Diakogiannis, F. I., Waldner, F., Caccetta, P., & Wu, C. (2020). ResUNet-a: A deep learning framework for semantic segmentation of remotely sensed data. *Remote Sensing of Environment, 237*, 111465. https://doi.org/10.1016/j.rse.2019.111465

Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. In *Proceedings of the 32nd International Conference on Machine Learning (ICML-15)* (pp. 448–456).

Kingma, D. P., & Ba, J. L. (2015). Adam: A method for stochastic optimization. *International Conference on Learning Representations (ICLR)*. https://doi.org/10.48550/arXiv.1412.6980

Maggiori, E., Tarabalka, Y., Charpiat, G., & Alliez, P. (2017). Dataset creation workflows for semantic segmentation of remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing, 122*, 6878.https://doi.org/10.1016/j.isprsjprs.2016.10.012

Ramalingam, A., Srivastava, V., George, S.V., Alagala, S. and Manickam, M.L. 2024. Building rooftop extraction from aerial imagery using low complexity UNet variant models. Journal of spatial science. 69(3), pp.773–800.

Ronneberger, O., Fischer, P. and Brox, T. 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation In: Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics). Cham: Springer International Publishing, pp.234–241


## TEŞEKKÜR

Bildiri, yazarın University of Leeds'te tamamladığı yüksek lisans tezine (2024) dayanmaktadır.

## YAZAR KATKI ORANI

Yazar, çalışmanın tamamından sorumludur.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Derin Öğrenme Modelleri ile Kentsel Alanlarda Çok Sınıflı Bina Çatı Segmentasyonu

**Gurbet Budak[1], Elif Özlem Yılmaz*[1], Taşkın Kavzoğlu[1]**

[1]*Gebze Teknik Üniversite, Mühendislik Fakültesi, Harita Mühendisliği, Kocaeli, Türkiye*

**Anahtar Kelimeler**
Derin Öğrenme,
Semantik Segmentasyon,
Çatı Tipi,
U-Net,
Çok Sınıflı Segmentasyon

**ÖZET**

Bina çatı tiplerinin belirlenmesi, kentleşme uygulamaları ve afet yönetimi gibi alanlarda yaygın olarak kullanılan önemli bir araştırma konusudur. Kentleşme dinamiklerinin sürekli olarak gözlemlenmesinin zor olduğu bölgelerde, bina çatı tiplerinin doğru bir şekilde tanımlanması, bu süreçlerin etkili bir şekilde izlenmesi için çok önemlidir. Bu çalışma, Türkiye'nin başkenti Ankara'nın yüksek çözünürlüklü SPOT uydu görüntüsü üzerinde çok sınıflı bina çatı segmentasyonu gerçekleştirmeyi amaçlamaktadır. Çalışma alanı; konut ve kamu binalarını kapsayan kırmızı çatı sınıfı, endüstriyel yapıları içeren beyaz çatı sınıfı ve şekil ile renk açısından bu iki sınıftan farklılık gösteren diğer çatı sınıfı olmak üzere üç farklı çatı tipi ile karakterize edilmiştir. Bu çatı türlerini tespit etmek için U-Net ve U-Net++ modelleri kullanılmış ve performanslarını değerlendirmek için Birlik üzerine Kesişim (IoU), hassasiyet, geri çağırma, F-skor ve doğruluk ölçütleri kullanılmıştır. Bulgular U-Net++ modelinin, U-Net modelini %6 oranında aşan ortalama IoU değeri ile üstün performans sergilediğini ortaya koymuştur. Ayrıca, U-Net++ modelinin sınıf bazlı IoU değerlerinin analizi ise her bir çatı tipi sınıfı için IoU değerlerinin %10 ila %5 arasında daha yüksek olduğunu ortaya koymaktadır. Bulgular, derin öğrenme modellerinin, özellikle büyük ölçekli alanlar kapsamında, kentsel çatı tiplerinin otomatik segmentasyonunda uygulama için önemli bir etkinliğe ve potansiyele sahip olduğunu göstermektedir.

# Multi-Class Building Roof Segmentation in Urban Areas with Deep Learning Models

**Keywords**
Deep learning,
Semantic Segmentation,
Roof Type,
U-Net,
Multi-Class Segmentation

**ABSTRACT**

The identification of building roof types represents a major research topic that is widely used in areas such as urbanization applications and disaster management. In regions where continuous observation of urbanization dynamics is challenging, the accurate identification of building roof types becomes paramount for effective monitoring of these processes. The present study aims to perform multi-class building roof segmentation on a high-resolution SPOT satellite image of Ankara, the capital of Turkey. The study area is characterized by the presence of three distinct roof classes: red roof class, which encompasses residential and public buildings; white roof class, which includes industrial buildings; and other roof class that deviate in shape and color from the other categories. To detect these roof types, the U-Net and U-Net++ deep learning models were employed, with IoU, precision, recall, F-score and accuracy metrics to assess their performance. The findings revealed that the U-Net++ model exhibited superior performance, with an average IoU value that surpassed the U-Net model by 6%. Furthermore, an analysis of the class-based IoU values of the U-Net++ model reveals that its IoU values for each roof type class were between 10% and 5% higher. The findings indicate that deep learning models possess considerable efficacy and potential for application in the automated segmentation of urban roof types, particularly for large-scale areas.

## 1. GİRİŞ

Son zamanlarda kentleşmenin artması nedeniyle kentsel alanlar hakkında güncel bilgilere olan ihtiyaç artmaktadır. Uzaktan algılama teknolojileri, detaylı kentsel analizlere olanak sağlayarak bu talebin karşılanmasında önemli bir rol oynamaktadır (Kavzoglu & Bilucan). Bu teknolojiler sayesinde bina çatısı tespiti uygulamalarında önemli başarılar elde etmektedir. Otomatik bina çatı tespiti işlemi, afet izleme, şehir planlama ve 3b şehir modelleme gibi birçok kentsel uygulamalarda sağlam bir alt yapı oluşturmaktadır (Amirgan & Erener, 2024). Bununla birlikte, uydu

* **Sorumlu Yazar**
(g.budak2022@gtu.edu.tr) ORCID ID 0009-0006-6230-5899
* (eoyilmaz@gtu.edu.tr) ORCID ID 0000-0002-6853-2148
(kavzoglu@gtu.edu.tr) ORCID ID 0000-0002-9779-3443

**Kaynak Göster (APA):**
Budak G, Yılmaz E Ö & Kavzoglu T (2025). Derin Öğrenme Modeller ile Kentsel Alanlarda Çok Sınıflı Bina Çatı Segmentasyonu. 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

görüntülerinin doğasından kaynaklı ve binaların karmaşık kentsel alanlarda yer alması ve bina çatılarının şekilsel/dokusal olarak farklılık göstermesi nedeniyle birçok zorlukla karşılaşılmaktadır.

Son yıllarda popüler olarak kullanılan derin öğrenme (DÖ) modelleri birçok problemin çözümü için yüksek doğruluk ve genelleme yeteneği sunarak etkili yaklaşımlar sağlamaktadır (Yilmaz & Kavzoglu, 2024). Özellikle, uzaktan algılanmış görüntülerin kullanıldığı semantik segmentasyon içeren çalışmalarda DÖ yaklaşımları önemli bir araç haline gelmiştir. Geleneksel yöntemlerin aksine, veri setinden otomatik özellik öğrenme yeteneği sayesinde, birçok çalışmada güçlü bir performans sergilemektedir (Yang vd., 2019).

Çalışmada kapsamında, Türkiye'nin başkenti olan Ankara'nın yüksek çözünürlüklü SPOT uydu görüntüsü üzerinde U-Net ve U-Net++ modelleri kullanılarak çok sınıflı bina çatı segmentasyonu gerçekleştirilmiştir. Ayrıca, bu modellerin performanslarının analiz edilmesi için Birlik üzerinden Kesişim (IoU), hassasiyet, geri çağırma, F-skor ve doğruluk ölçütleri kullanılmıştır.

## 2. YÖNTEM

### 2.1. Çalışma Alanı ve Veri Seti

Ankara, Türkiye'nin planlı gelişmiş şehirlerinden biri olup farklı bina türlerini içerdiği için çalışma alanı olarak seçilmiştir. Çalışma alanında konut, endüstri ve kamuya ait birçok farklı bina türü yer almaktadır. Bu analiz için Airbus tarafından ücretsiz olarak sağlanan ve yüksek mekânsal çözünürlüğe sahip SPOT-6 optik görüntüsü kullanılmıştır. Görüntü, 1,5 m mekânsal çözünürlüğe sahip bir pankromatik bant ve 6 m mekânsal çözünürlüğe sahip dört spektral banttan (kırmızı, yeşil, mavi ve yakın kızılötesi) oluşmaktadır. Pankromatik bant ile dört spektral bandın mekânsal çözünürlüğünü 1,5 metreye düşürülmüştür. Çalışma alanındaki bina çatı tiplerinin analiz edilmesi için OpenStreetMap (OSM) platformundan bina ayak izlerine ait vektör veriler elde edilmiştir. Kullanım amacına ve yapısal özelliklerine göre her bir bina türü etiketlemiştir. Kırmızı çatıya sahip binalar (konutlar, gecekondular, kamu binaları), endüstriyel amaçlı kullanılan binaları ve diğer binalar (şekilsel olarak diğer iki bina türünden farklı olan yapılar) olarak üç farklı bina tipi tespit edilmiştir.

### 2.2. Derin Öğrenme Modelleri

Çalışmada kapsamında yaygın olarak tercih edilen U-Net ve U-Net++ modelleri kullanılmıştır. U-Net, kodlacı ve kod çözücü bölümleri içeren simetrik bir modeldir. Kodlayıcı kısmı girdi görüntüsünden problemi çözmeye uygun özellikleri çıkarırken, kod çözücü kısmı ise çıkartılan özelliklerin girdi görüntüsü boyutuna dönüştürmekle görevlidir. Ayrıca, kodlayıcı kısmı özellik çıkartmak için evrişimsel katmanlar kullanır; kod çözücü kısmı ise yukarı örnekleme işlemlerini gerçekleştirir. Bu bölümler arasındaki bağlantılar sayesinde düşük seviyeli özellikler yüksek seviyeli özelliklere entegre edilir (Ronneberger vd., 2015). U-Net++ ise U-Net mimarisinin bir üst versiyonu olup daha sık derin bağlantılar içeren bir mimaridir. Bu bağlantılar sadece kodlayıcı ve kod çözücü arasında olmayıp ara katmanlar arasında da yer almaktadır. Böylelikle, daha çok özellik birleşimi sağlanırken karmaşık nesne sınırı belirlemede daha başarılı performans gösterirler (Zhou vd., 2018).

## 3. BULGULAR VE TARTIŞMA

OSM'den elde edilen vektör veriler düzenlenip etiketlendikten sonra semantik segmentasyon uygulaması için ön işlem aşamalarına tabii tutulmuştur. İlk olarak, maske-görüntü çiftlerini oluşturmak için %50 örtüşme oranı ile 256x256 boyutlarında görüntüler kesilmiştir. Bu işlem sonrası, 1734 adet görüntü-maske çifti oluşturulmuştur. Elde edilen bu verilerin %70'i eğitim, %15'i test ve %15'i ise validasyon amaçlı rastgele olacak şekilde gruplandırılmıştır.

DÖ modellerinde aynı hiper parametreler kullanılmıştır. Önceden eğitilmiş ağırlıklar kullanılarak eğitim işleminin tamamlanması için kodlayıcı olarak 'ResNet34' mimarisi ve ağırlıklar için ise 'ImageNet' seçilmiştir. Ayrıca, eğitim aşamasından önce yatay-dikey döndürme gibi veri çoğaltma teknikleri kullanılarak aşırı öğrenme probleminin önüne geçilmiştir. Eğitim aşamasında epok sayısı 30 olarak seçilmiş ve batch boyutu ise 16 olarak kullanılmıştır. Optimizasyon için 'Adam' kullanılırken, öğrenme hızı da '0.0005' olarak tercih edilmiştir. Ayrıca, modellerin kayıp fonksiyonlarını ölçmek için 'CrossEntropyLoss' algoritmasından faydalanılmıştır.

DÖ modellerinin eğitimi tamamlandıktan sonra performans analizi için IoU, hassasiyet, geri çağırma, F-skor gibi metrikler kullanılmıştır (Çizelge 1). Genel olarak, U-Net++'ın U-Net modeline göre üstün bir performans sergilediği tespit edilmiştir. U-Net++ modelinin ortalama IoU değeri 0,9094 iken U-Net modelinin ise 0.8463 olarak hesaplanmıştır.

Her iki modelde de arka plan sınıfı en yüksek değerlere sahip olduğu söylenebilir, bunun temel nedeni, arka plan piksellerinin diğer çatı sınıflarına göre daha fazla piksel içermesinden kaynaklanmaktadır. Çatı sınıfları arasında da en yüksek doğruluk değerlerine sahip sınıf beyaz çatı yani endüstri alanlarına ait yapılardır; çünkü spektral açıdan diğer çatı tiplerine göre kolaylıkla ayırt edilebilir.

**Çizelge1.** Derin öğrenme modellerine ait performans analizi.

| Bina Çatı Sınıfları | U-Net++ | | | | U-Net | | | |
|---|---|---|---|---|---|---|---|---|
| | IoU | Hassasiyet | Geri Çağırma | F-skor | IoU | Hassasiyet | Geri Çağırma | F-skor |
| **Arka Plan** | 0,9740 | 0,9851 | 0,9886 | 0,9868 | 0,9536 | 0,9736 | 0,9736 | 0,9763 |
| **Kırmızı Çatı** | 0,8913 | 0,9504 | 0,9348 | 0,9425 | 0,8113 | 0,9036 | 0,8881 | 0,8958 |
| **Beyaz Çatı** | 0,9071 | 0,9535 | 0,9490 | 0,9513 | 0,8505 | 0,9357 | 0,9033 | 0,9192 |
| **Diğer Çatı** | 0,8650 | 0,9374 | 0,9180 | 0,9276 | 0,7697 | 0,8777 | 0,8622 | 0,8699 |
| **Doğruluk** | 0,9779 (0,9476 - Dengelenmiş) | | | | 0,9605 (0,9081- Dengelenmiş) | | | |
| **Ortalama IoU** | 0,9094 | | | | 0,8463 | | | |

Ardından, IoU doğrulukları açısından, U-Net++ için 0,8913 ile U-Net için 0,8113 ile kırmızı çatı sınıfı gelmektedir. En düşük doğruluk değerlerine sahip sınıf ise diğer çatı grubuna aittir. Bu gruptaki binaları şekilsel ve yapısal olarak diğer binalardan ayrışmaktadır. Özellik çıkarımında, ortak özelliklerin tespit edilmesi işlemi diğer sınıflara göre daha zorlu olması nedeniyle doğruluk değerlerinin düşük olduğu söylenebilir.

Her iki modelin görsel açıdan performans karşılaştırmasının yapılması için model tahmin çıktıları Şekil 1'de verilmiştir. Görselde, 3 farklı çatı tipi ve arka plan sınıfları yer almaktadır. U-Net++ modeli, U-Net modeline göre daha doğru tahminlerde bulunmuştur. U-Net modelinin bazı çatı türlerinde eksik veya yanlış sınıflandırma yaptığı söylenebilir. Ayrıca, U-Net++ modelinin büyük yapıları daha iyi tespit ettiği, küçük yapıların tespitinde ise iki modelin de benzer sonuçlar verdiği görülmektedir. Ancak, bu durumda U-Net++'ın daha az hatalı olduğu tespit edilmiştir. U-Net++ modeli kırmızı ve diğer çatıları daha iyi ayırabilirken, U-Net modeli bu çatı sınıflarını karıştırabilmektedir. Sonuç olarak, U-Net++ modelinin karmaşık şehir alanında daha güvenilir sonuçlar verirken, U-Net modeli bu alanların detaylı ayrımı konusunda yetersiz kaldığı izlenmiştir.

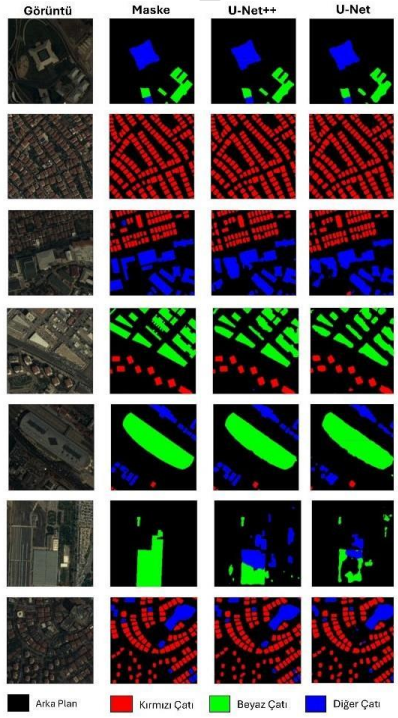


**Şekil 1.** Derin öğrenme modellerinin çatı tiplerine göre semantik segmentasyon sonuçları.

## 4. SONUÇ

Bu çalışmada, derin öğrenme tabanlı U-Net ve U-Net++ modelleri, kentsel alanlardaki farklı bina çatıtiplerinin tespiti için uygulanmıştır. Bu modellerin farklı çatı tiplerini yüksek doğrulukla ayırt edebildiği görülmüştür. Ayrıca, çatı sınıfları arasındaki ayrım da başarıyla gerçekleştirilmiştir. Özellikle U-Net++ modeli, gelişmiş mimarisi sayesinde U-Net mimarisinden daha iyi performans gösterdiği söylenebilir. Elde edilen bulgular, kentsel uygulamalar gibi alanlarda kullanılabilecek güvenilir bir altyapı sağlamaktadır. Gelecek çalışmalarda DÖ modellerinin genelleme kabiliyetinin artırılması için farklı çözünürlük ve özelliklere sahip bina çatı tiplerini içeren veri kümeleri ile eğitilmesi önerilmektedir.

## TEŞEKKÜR

Bu çalışma, 124Y240 nolu TÜBİTAK 1002 projesi tarafından desteklenmektedir.

**Yazar Katkı Oranı:** Tüm yazarlar eşit miktarda katkı sağlamıştır.

## KAYNAKÇA

Amirgan, B., & Erener, A. (2024). Semantic Segmentation of Satellite Images with Different Building Types Using Deep Learning Methods. Remote Sensing Applications: Society and Environment, 34, 101176. Doi: 10.1016/j.rsase.2024.101176

Kavzoglu, T., & Bilucan, F. (2023). Effects of Auxiliary and Ancillary Data on LULC Classification in aHeterogeneous Environment Using Optimized Random Forest Algorithm. Earth Science Informatics, 16(1), 415-435. Doi: 10.1007/s12145-022-00874-9

Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In Medical Image Computing and Computer-Assisted Intervention. Münih, Almanya. Doi:10.1007/978-3-319-24574-4_28

Yang, L., Wang, H., Yan, K., Yu, X., Li, J., & Man, D. (2019). Building Extraction of Multi-source Data Based on Deep Learning. 4th International Conference on Image, Vision and Computing. Xiamen, Çin. Doi: 10.1109/ICIVC47709.2019.8980990

Yilmaz, E. O., & Kavzoglu, T. (2024). Burned Area Detection with Sentinel-2A Data: Using Deep Learning Techniques with eXplainable Artificial Intelligence. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences,

10, 251-257. Doi: 10.5194/isprs-annals-X-5-2024-251-2024.

Zhou, Z., Siddiquee, M. M. R., Tajbakhsh, N., & Liang, J. (2018). UNet++: A nested U-Net architecture for medical image segmentation. Stoyanov, D., vd. (Eds.) Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. Doi: 10.1007/978-3-030-00889-5_1



© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Heyelan Olmayan Örneklemlerin Seçimi için Kullanılan Yöntemlerin Heyelan Duyarlılık Haritalarının Doğruluğuna Etkisinin Araştırılması

**Süeda Kaş*[1], Buse Dallı[1], Elif Nur Yıldız[1], Alihan Teke[1], Taşkın Kavzoğlu[1]**

[1]*Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Gebze, Kocaeli, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Yapay Zeka,
Makine Öğrenmesi,
Heyelan Duyarlılık Haritalama

**ÖZET**

Heyelan duyarlılık haritaları, potansiyel heyelan risklerinin önceden belirlenmesini sağlayan ve alternatif yöntemlere kıyasla daha düşük maliyetli olmaları nedeniyle literatürde yaygın olarak tercih edilen araçlardır. Özellikle, heyelan oluşumuna neden olan faktörler arasındaki karmaşık ilişkileri modelleme yeteneği nedeniyle makine öğrenmesi algoritmaları son yıllarda heyelan duyarlılık haritalarının üretiminde ön plana çıkmıştır. Bu modellerin başarısı, çalışmaya özgü çevresel değişkenler, geçmiş heyelan kayıtları ve heyelan olmayan örneklem alanlarının doğruluğuna bağlıdır. Her ne kadar heyelana sebep olan faktörler ve heyelanlı örneklemler mevcut uzaktan algılama verileri ve tarihsel envanterler aracılığıyla güvenilir bir şekilde üretilebilse de heyelan olmayan örneklemlerin seçimi konusunda literatürde halen evrensel bir görüş birliği bulunmamaktadır. Çalışma kapsamında, bu araştırma boşluğunun literatürde heyelan olmayan örneklemlerin belirlenmesinde kullanılan farklı yaklaşımlar (rastgele seçim, tampon mesafesi, eğimi 5 dereceden küçük alanlar ve frekans oranı yöntemleri) ve farklı topluluk tabanlı makine öğrenmesi algoritmaları (Rastgele Orman, GBM, XGBoost ve NGBoost) kullanılarak üretilecek heyelan duyarlılık haritalarının kaliteleri üzerindeki etkileri araştırılarak doldurulması hedeflenmektedir. Sonuçlar, frekans oranı yönteminin tüm örneklem stratejileri arasında en yüksek başarıyı sağladığını ve özellikle GBM algoritması ile birlikte kullanıldığında %97,51 AUC ve %91,91 genel doğruluk performans değerlerine ulaştığını ortaya koymuştur. Buna karşın, rastgele örneklem yaklaşımı, tüm algoritmalar için en düşük doğruluk sonuçlarını vermiştir.

# Exploring the Influence of Non-Landslide Sample Selection Methods on Landslide Susceptibility Map Accuracy

**Keywords**
Remote Sensing,
Artificial Intelligence,
Machine Learning,
Landslide Susceptibility Mapping

**ABSTRACT**

Landslide susceptibility maps are widely favoured in the literature as they enable the identification of potential landslide risks in advance and are more cost-effective compared to alternative methods. In recent years, machine learning algorithms have come to the forefront in the production of landslide susceptibility maps due to their ability to model complex relationships among the factors that cause landslides. The success of these models depends on study-specific environmental variables, historical landslide records, and the accuracy of non-landslide sample areas. While landslide causative factors and landslide-prone samples can be reliably derived from existing remote sensing data and historical inventories, a universally accepted approach is still lacking in the literature regarding the selection of non-landslide samples. Within the scope of this study, it is aimed to fill the research gap by investigating the effects of different approaches used to identify non-landslide samples in the literature (random selection, buffer distance, areas with slopes less than 5 degrees, and frequency ratio methods) and different ensemble-based machine learning algorithms (Random Forest, GBM, XGBoost, and NGBoost) on the quality of landslide susceptibility maps. The findings revealed that the frequency ratio method achieved the highest accuracy among all sampling strategies, reaching remarkable performance metrics such as 97.51% AUC and 91.91% overall accuracy, especially when used in combination with the GBM algorithm. In contrast, the random sampling approach produced the lowest accuracy results across all algorithms.

* **Sorumlu Yazar**

*(s.kas2022@gtu.edu.tr) ORCID ID 0009-0006-0806-1475
(b.dalli2022@gtu.edu.tr) ORCID ID 0009-0007-6071-5736
(e.yildiz@gtu.edu.tr) ORCID ID 0009-0002-8261-6361
(a.teke2020@gtu.edu.tr) ORCID ID 0000-0003-4048-329X
(kavzoglu@gtu.edu.tr) ORCID ID 0000-0002-9779-3443

**Kaynak Göster (APA):**

Kaş S , Dallı B, Yıldız E N, Teke A & Kavzoğlu T (2025). Heyelan Olmayan Örneklemlerin Seçimi için Kullanılan Yöntemlerin Heyelan Duyarlılık Haritalarının Doğruluğuna Etkisinin Araştırılması, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Heyelanlar, yerçekimi etkisiyle yüzey malzemelerinin kayma düzlemi boyunca kütlesel hareketi sonucu meydana gelen jeolojik afetlerden birisidir (Schuster & Fleming 1986). Bu afetler ciddi can kaybına, maddi zararlara ve doğal kaynakların tahribatına neden olmaktadır. Heyelan duyarlılık haritalarının üretimi, riskin önceden değerlendirilmesine olanak tanıması ve alternatiflerine göre genellikle daha düşük maliyete sahip olması nedeniyle literatürde en fazla tercih edilen yöntemlerden birisi haline gelmiştir (Merghadi vd. 2020).

1970'lerden bu yana fiziksel modelleme teknikleri, uzman görüşüne dayalı yaklaşımlar ve çok kriterli karar destek sistemleri gibi birçok yöntem kullanılmış olsa da heyelan oluşumlarına sebebiyet veren çeşitli faktörler arasındaki karmaşık ve doğrusal olmayan ilişkileri modelleme becerileri nedeniyle makine öğrenmesi algoritmaları heyelan duyarlılık haritalarının üretimi için son zamanlarda literatürde sıklıkla tercih edilmektedir (Kavzoğlu & Teke, 2022). Makine öğrenmesi algoritmaları ile duyarlılık haritalarının üretiminde temel olarak (i) ilgili çalışma alanının karakteristiğini doğru bir biçimde temsil eden ve heyelan aktivitelerinin oluşmasına sebebiyet veren faktörler, (ii) çalışma sahasında tarihsel olarak kaydedilmiş heyelanlar ve (iii) yine çalışma alanında heyelan olma ihtimalinin çok düşük veya hiç olmadığı alanlar (heyelan olmayan örneklemler) olmak üzere üç temel girdi (veri bileşeni) kullanılmaktadır. Öte yandan, makine öğrenmesi algoritmaları ile üretilen duyarlılık haritalarının doğruluğu büyük ölçüde eğitim aşamasında modele sağlanan bu bileşenlerin kalitesi ile ilişkilidir. Heyelana sebebiyet veren faktörlerin ve heyelanlı örneklemlerin uydu görüntüleri, sayısal yükseklik modelleri ve tarihsel heyelan envanterleri gibi mevcut veri kümeleri ve geçmiş kayıtlar aracılığıyla üretimleri mümkün olsa da heyelanlı olmayan örneklemlerin seçimi konusunda önerilen çeşitli yaklaşımlara rağmen hangi yöntemin model doğruluğunu en üst düzeye çıkardığı konusunda literatürde açık bir fikir birliği bulunmamaktadır.

Bu çalışma kapsamında, yukarıda tanımlanan araştırma boşluğunun literatürde heyelan olmayan örneklemlerin belirlenmesinde kullanılan rastgele seçim, tampon mesafesi, eğimi 5 dereceden küçük alanlar ve frekans oranı yöntemleri ve farklı topluluk tabanlı makine öğrenmesi algoritmaları (Rastgele Orman, GBM, XGBoost ve NGBoost) kullanılarak üretilecek heyelan duyarlılık haritalarının kaliteleri üzerindeki etkileri araştırılarak doldurulması hedeflenmektedir. Bu kapsamda, makine öğrenmesi modelleri kullanılmadan önce heyelana sebebiyet veren faktörler arasındaki olası bir ilişki, çoklu doğrusal ilişki (multicollinearity) testi kullanılarak incelenmiştir.

## 2. ÇALIŞMA ALANI VE VERİ SETİ

Coğrafi olarak 41°8′ ve 40°30′K enlemleri ve 39°15′ ve 40°15′D boylamları arasında bulunan Trabzon ili, Türkiye'nin kuzeydoğu bölümünde yer almaktadır (Şekil 1). Çalışma alanının topografik olarak yükseltileri 0 ile
3.354 metre arasında değişmekte olup, arazi eğimi 70°'ye kadar ulaşabilmektedir. Bölgenin morfolojik, iklimsel ve fizyografik özellikleri, heyelan faaliyetlerinin meydana gelmesini tetikleyen faktörler arasında yer almaktadır. Bölgenin yüksek yağış almasının yanında, eğimli topoğrafyası ve zemin yapısı, yüzeyin kütle hareketlerine karşı dayanıklılığını ciddi şekilde zayıflatmaktadır. Çalışma alanının karakteristiğine bağlı olarak heyelana sebebiyet veren faktörlerin belirlenmesinde, Trabzon ilinde heyelana sebep olan jeolojik, topografik, meteorolojik ve hidrolojik özellikler ve daha önce bu bölgede yapılan çalışmalar dikkate alınmıştır. Bu sebeple, litoloji, yükseklik, eğrilik, bakı, eğim, eğim uzunluğu, vadi derinliği, topoğrafik ıslaklık indeksi, nehirlere olan mesafe ve yollara olan mesafe olmak üzere toplamda 10 faktör temin edilerek kullanılmıştır.

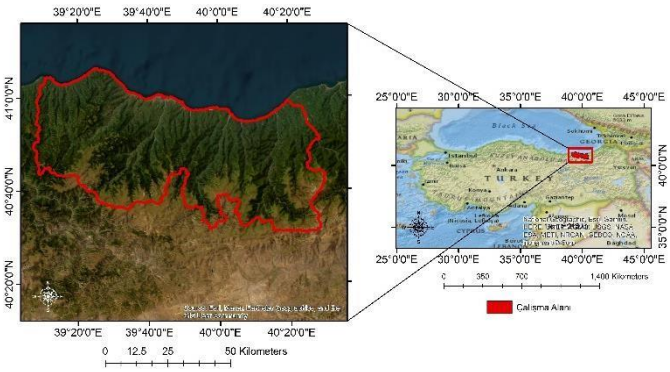


**Şekil 1.** Çalışma alanının coğrafi konumu

## 3. YÖNTEM

Çalışma kapsamında, heyelan örneklemlerinin üretimi için Türkiye Maden Tetkik ve Arama (MTA) Genel Müdürlüğü tarafından sağlanan 1:25.000 ölçekli topoğrafik haritalar üzerinde ayrıntılı hava görüntüleri ve arazi araştırmalarının yorumlanmasıyla oluşturulan envanter haritası kullanılmıştır. Heyelan olmayan örneklemlerin seçimi için ise rastgele seçim yöntemi, tampon mesafesi, eğimi 5°'den düşük alanların seçimi ve frekans oranı yaklaşımı olmak üzere 4 farklı yaklaşım uygulanmıştır. Bu çalışmada, topluluk tabanlı makine öğrenme algoritmalarından, çok sayıda karar ağacını bir araya getiren ve her bir ağacın bağımsız olarak tahminlerini yapan Rastgele Orman, belirsizlik tahmini ve olasılıksal modelleme ihtiyaçlarını karşılayan NGBoost, hatalı tahminleri düzeltmeye yönelik her bir ağaç modeli için önceki ağaçlardan gelen hataları minimalize eden XGBoost ve her seferinde bir önceki ağaç üzerinden yeni bir ağaç üreten GBM algoritması kullanılmıştır (Teke & Kavzoğlu, 2024). Performans analizleri için doğruluk, keskinlik, duyarlılık, F1-Skor ve AUC kriterleri kullanılmıştır.

## 4. UYGULAMA

Çalışma kapsamında ilk olarak heyelan olan ve

heyelan olmayan örneklemlerden oluşan veri seti %70 eğitim ve %30 test olmak üzere iki gruba ayrılmış ve dört topluluk tabanlı makine öğrenme algoritması (XGBoost, NGBoost, GBM, Rastgele Orman) kullanılarak Trabzon iline ait heyelan duyarlılık haritaları üretilmiştir. Bu kapsamda öncelikle çoklu doğrusallık testi uygulanarak tolerans ve varyans artırıcı faktör metrikleri incelenerek faktörler arasında çoklu doğrusallık problemine rastlanılmamıştır.Öncelikle, frekans oranı yönteminin, tüm örneklem stratejileri arasında en yüksek genel doğruluk, F1 skoru ve özellikle AUC değerlerini sağladığı belirlenmiştir (Şekil 2). GBM algoritması ile frekans oranı yönteminin kullanıldığı senaryoda %97,51'lik AUC değeri ve %91,91'lik genel doğruluk ile en başarılı heyelan duyarlılık modeli elde edilmiştir. Buna karşın, rastgele örneklem seçim yönteminin en düşük performans değerlerine sahip olduğu görülmüştür. RF algoritması ile sadece %54,24 genel doğruluk ve %67,13 AUC değeri elde edilmiş olup, bu yöntemle üretilen modellerin, sınıflar arasında yüksek bir ayrıştırma başarısı gösteremediği ve yüksek varyans ürettiği anlaşılmaktadır. Tampon bölge yönteminde ise, özellikle 2000 metrelik mesafe ile oluşturulan senaryoda XGBoost algoritması %79,25 AUC ile oldukça başarılı bir sonuç üretmiştir. Bu bulgu, tampon mesafe stratejisinin dikkatli parametrizasyonla oldukça etkili olabileceğini göstermektedir. Ancak daha küçük tampon mesafelerinde (örneğin 500 m), model performansında belirgin düşüşler gözlenmiştir. Düşük eğim (<5°) kriterine dayalı örneklem stratejisi, genel olarak yüksek doğruluk sağlamış, ancak frekans oranı kadar tutarlı bir başarı göstermemiştir. Bu yöntemde özellikle XGBoost algoritması %95,34 AUC ve %86,14 genel doğruluk ile öne çıkmıştır. Ancak NGBoost ile elde edilen yüksek F1 skoru (%88.77) ve Kappa değeri (%85.57), bu yöntemin modelin genel performansını artırma potansiyeline sahip olduğunu göstermektedir.

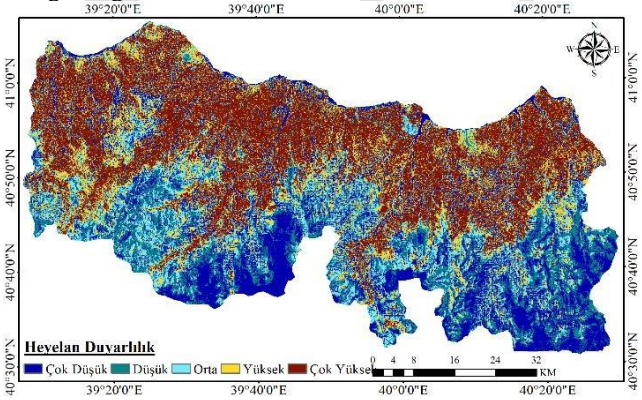


**Şekil 2.** Heyelan olmayan noktaların seçiminde frekans oranı yaklaşımı ve GBM algoritması kullanılarak üretilen heyelan duyarlılık haritası

## 5. SONUÇ

Bu çalışmada, Trabzon ili için heyelan duyarlılık haritalarının üretiminde kullanılan farklı heyelan olmayan örneklem seçim yaklaşımlarının model performansına etkisi incelenmiştir. Bu kapsamda, 10 farklı faktörden oluşan veri seti kullanılarak Random Forest, XGBoost, NGBoost ve GBM algoritmaları ile modellemeler gerçekleştirilmiştir. Çalışma kapsamında heyelan olmayan örneklemlerin seçiminde kullanılan yöntemlerin, model performansını doğrudan ve belirgin şekilde etkilediği belirlenmiştir. Frekans oranı yöntemi, kullanılan dört farklı örneklem stratejisi arasında en yüksek performansı sağlayan yöntem olmuştur. Bu yöntem, dört algoritmanın tamamında yüksek AUC ve genel doğruluk değerleri üretmiş; özellikle GBM ile birlikte kullanıldığında %97,51 AUC ve %91,91 OA değerine ulaşarak en başarılı kombinasyonu sunmuştur. GBM algoritması, farklı örneklem seçim stratejileriyle en istikrarlı ve yüksek doğrulukta sonuçlar üreten modelleme tekniği olmuştur. Bu durum, GBM'in hem örneklem dengesizliğine karşı dayanıklı yapısı hem de açıklanabilirlik açısından avantajlı oluşu ile açıklanabilir. Rastgele örneklem seçimi, hem algoritmalar arasında hem de performans ölçütleri açısından en düşük başarıyı sergileyerek bu yöntemin güvenilir olmayan sonuçlar doğurabileceğini ortaya koymuştur. Tampon bölge yönteminde, özellikle 2000 m'lik mesafede makul düzeyde doğruluk elde edilirken, daha dar tampon mesafelerinde model başarısının düştüğü tespit edilmiştir. Eğim kriterine dayalı örneklem yöntemi (<5°) bazı algoritmalarda özellikle XGBoost ve NGBoost ile iyi sonuçlar üretmiş olsa da frekans oranı kadar tutarlı bir performans sergileyememiştir. Bu bulgular ışığında, heyelan duyarlılık haritalarının üretiminde örneklem seçim stratejisinin en az algoritma seçimi kadar kritik olduğu, hatta bazı durumlarda daha belirleyici hale gelebildiği sonucuna varılmıştır. Gelecek çalışmalarda, özellikle SHAP veya LIME gibi açıklanabilir yapay zekâ teknikleriyle örneklem seçimi stratejilerinin entegrasyonu sağlanarak, hangi örneklem türünün hangi faktörleri daha fazla etkilediği daha ayrıntılı şekilde analiz edilerek daha güvenilir ve genellenebilir modellerin geliştirilmesi önerilmektedir.


## TEŞEKKÜR

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 2209-A Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı kapsamında desteklenmektedir. Sağladıkları değerli katkılardan dolayı TÜBİTAK'a teşekkür ederiz.


## Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

**Yazar Katkı Oranı:** Tüm yazarlar eşit miktarda katkı sağlamıştır.

## KAYNAKÇA


Kavzoglu, T., & Teke, A. (2022). Advanced Hyperparameter Optimization for Improved Spatial Prediction of Shallow Landslides Using Extreme Gradient Boosting (XGBoost). Bulletin of Engineering Geology and

the Environment, 81, 201.

Merghadi, A., Yunus, A. P., Dou, J., Whiteley, J., ThaiPham, B., Bui, D. T., Avtar, R., & Abderrahmane, B. (2020). Machine Learning Methods for Landslide Susceptibility Studies: A Comparative Overview of Algorithm Performance. Earth-Science Reviews, 207, 103225.

Schuster, R. L., & Fleming, R. W. (1986). Economic Losses and Fatalities Due to Landslides. Bulletin of the Association of Engineering Geologists, 23(1), 11–28.

Teke, A., & Kavzoglu, T. (2024). Exploring the Decision- Making Process of Ensemble Learning Algorithms in Landslide Susceptibility Mapping: Insights from Local and Global Explainable AI Analyses. Advances in Space Research, 74, 3765–3785.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# ESA WorldCover ve ESRI Land Cover 2021 Arazi Örtü Veri Setlerinin Doğruluk Değerlendirilmesi

**Fidan Şevval Bulut*[1], Ayhan Ateşoğlu[2], Emrah Acar[3]**

[1]*Bartın Üniversitesi, Orman Fakültesi, Orman Mühendisliği Bölümü, Bartın, Türkiye*

**Anahtar Kelimeler**
Arazi Kullanımı ve Arazi Örtüsü (LULC),
ESA Worldcover,
ESRI Land Cover
Doğruluk Değerlendirmesi

**ÖZET**

Bu çalışmada, 2021 yılına ait 10 m çözünürlüklü ESA WorldCover ve ESRI Land Cover veri setlerinin Türkiye'de Karadeniz (H1), Güney Doğu Anadolu (H2) ve Doğu Anadolu bölgelerinde(H3) olmak üzere üç farklı coğrafi havzada sınıflandırma doğrulukları karşılaştırılmıştır. Her iki veri seti için raster haritalar üzerinde sınıflandırma doğruluğunu belirlemek amacıyla tabakalı rastgele örnekleme yöntemi kullanılmıştır. Minimum örnek sayıları, binom olasılık dağılımına dayalı hesaplama yöntemiyle belirlenmiştir. Örnek noktalarının referans sınıfları yüksek çözünürlüklü Google Earth görüntüleri üzerinden görsel yorumlama ile oluşturulmuştur. Analiz sonuçlarına göre, ESA WorldCover veri seti, H1 havzasında %86,32, H2 havzasında %93,00 ve H3 havzasında %90,25 genel doğruluk oranı ile ESRI Land Cover veri setine kıyasla daha yüksek performans sergilemiştir. Buna karşılık, ESRI Land Cover verisinin aynı havzalardaki genel doğruluk oranları sırasıyla %65,15 (H1), %77,20 (H2) ve %87,74 (H3) olarak hesaplanmıştır. Elde edilen bulgular, farklı veri setlerinin sınıflandırma performanslarının arazi örtüsüne ve bölgesel heterojenliğe bağlı olarak değişkenlik gösterdiğini ortaya koyarak karar vericilere önemli katkılar sağlamaktadır.

# Accuracy assessment of ESA WorldCover and ESRI Land Cover 2021 Land Cover Datasets

**Keywords**
Land Use and Land Cover (LULC),
ESA Worldcover,
ESRI Land Cover
Accuracy Assessment

**ABSTRACT**

In this study, the classification accuracies of the 10-meter resolution ESA WorldCover 2021 and ESRI Land Cover 2021 datasets were compared across three geographically distinct basins in Turkey: the Black Sea (H1), Southeastern Anatolia (H2), and Eastern Anatolia (H3) regions. A stratified random sampling method was employed to assess the classification accuracy of both raster datasets. Minimum sample numbers were determined by the calculation method based on binomial probability distribution. Reference classes for sample points were created through visual interpretation of high-resolution Google Earth imagery. According to the analysis results, ESA WorldCover outperformed ESRI Land Cover in all three basins, with overall accuracies of 86.32% (H1), 93.00% (H2), and 90.25% (H3). In contrast, ESRI Land Cover achieved lower accuracies in the same basins, with 65.15% (H1), 77.20% (H2), and 87.74% (H3), respectively. These findings demonstrate that the classification performance of global LULC datasets can vary depending on land cover type and regional heterogeneity, providing valuable insights for decision-makers involved in environmental assessment and land management.

## 1. GİRİŞ

Günümüzde doğal kaynakların sürdürülebilir yönetimi, çevresel değişimlerin izlenmesi ve planlama süreçlerinin desteklenmesi açısından arazi kullanımı ve arazi örtüsü (LULC) verileri önemli rol oynamaktadır (Wang, Bretz, Dewan, & Delavar, 2022). Uzaktan algılama teknolojileri sayesinde elde edilen yüksek çözünürlüklü uydu görüntüleri, geniş alanlara yönelik zamansal ve mekânsal analizlerin gerçekleştirilmesini mümkün kılmaktadır (Rogan & Chen, 2004). Küresel ölçekte yayımlanan LULC veri setleri, farklı bölgelerdeki arazi örtüsü yapısını analiz etme ve karşılaştırma açısından temel veri kaynakları arasında yer almaktadır. ESA WorldCover 2021 ve ESRI Land Cover 2021 veri setleri, 10 metre mekânsal çözünürlüğe sahip olmalarıyla hem bilimsel araştırmalarda hem de karar destek sistemlerinde yaygın olarak kullanılmaktadır (Chaaban,

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Bulut F Ş, Ateşoğlu A & Acar E (2025). ESA WorldCover ve ESRI Land Cover 2021 Arazi Örtü Veri Setlerinin Doğruluk Değerlendirilmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

El Khattabi, & Darwishe, 2022). Bu çalışmada, Türkiye'nin üç farklı bölgesinde yer alan H1 (Karadeniz), H2 (Güneydoğu Anadolu) ve H3 (Doğu Anadolu) havzalarında ESA WorldCover 2021 ve ESRI Land Cover 2021 veri setlerinin doğruluk değerlendirmesi gerçekleştirilmiştir.

## 2. YÖNTEM

### 2.1. Çalışma Alanı

Bu çalışma kapsamında, Türkiye'nin üç farklı coğrafi bölgesinde yer alan ve farklı ekolojik özellikler gösteren üç örnek havza seçilmiştir: H1 (Karadeniz Bölgesi), H2 (Güneydoğu Anadolu Bölgesi) ve H3 (Doğu Anadolu Bölgesi). Havzaların seçiminde, ekolojik çeşitliliğin ve arazi örtüsü karakteristiklerinin farklılık göstermesi, doğruluk analizlerinin farklı coğrafi ve yapısal koşullarda nasıl değiştiğini değerlendirmek açısından temel kriter olmuştur.

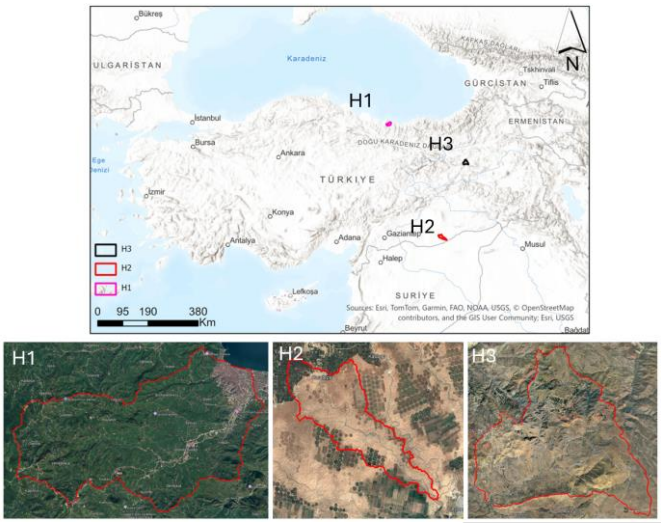


**Şekil 1.** Çalışma alanları

Seçilen havzaların arazi örtüsü dağılımları ESA ve ESRI veri setlerine göre karşılaştırmalı olarak incelenmiştir. Seçilen bu üç havza, farklı iklimsel, topografik ve arazi kullanım dinamiklerine sahip bölgeleri temsil etmesi bakımından, ESA WorldCover ve ESRI Land Cover veri setlerinin coğrafi bağlama bağlı doğruluk performanslarını karşılaştırmak açısından uygun örnekler sunmaktadır.

### 2.2. Veri Seti

ESA WorldCover 2021 verisi, Avrupa Uzay Ajansı (ESA) tarafından geliştirilmiş olup, hem Sentinel-1 radar hem de Sentinel-2 optik uydu görüntülerinin birlikte kullanıldığı bir sınıflandırma algoritmasıyla üretilmiştir. Veri seti, rastgele orman algoritmasıyla işlenmiş ve tarım alanları, sürekli ormanlar, otlaklar, sulak alanlar, yapılı alanlar, çıplak toprak ve diğer doğal alanlar, buz ve karla kaplı alanlar, açık su yüzeyleri, mangrovlar ve orman dışı doğal alanları içerecek şekilde 11 temel arazi örtüsü sınıfı olarak tanımlanmıştır (Zanaga et al., 2022). ESRI Land Cover 2021 verisi ise, yalnızca Sentinel-2 optik görüntülerine dayanmakta ve büyük çapta etiketlenmiş örnek veriyle eğitilmiş bir derin öğrenme modeli kullanılarak oluşturulmuştur. Su, ağaçlar, sulu bitki örtüsü, tarım, yapılı alan, çıplak alan, kar ve buz, bulutlar ve mera alanları olmak üzere 9 ana LULC sınıfını kapsayan yıllık haritalar üretmektedir (Karra et al., 2021).

### 2.3. Metodoloji

Analiz süreci üç ana aşamadan oluşmaktadır: veri hazırlığı, örnekleme ve doğruluk değerlendirmesi. İlk olarak, ESA ve ESRI veri setleri, GeoTIFF formatında indirildikten sonra çalışma alanlarına göre kesilerek analiz için uygun hale getirilmiştir. Harita verileri raster biçiminde işlendiği için, her bir havza için ayrı raster katmanlar hazırlanmış ve sınıflandırma kodları standardize edilmiştir. Alanlar iki veride de ortak yıl olan 2021'e göre seçilmiştir.

Doğruluk analizinde tabakalı rastgele örnekleme yöntemi (stratified random sampling) uygulanmıştır. Bu yöntem, her bir arazi örtüsü sınıfının yeterli sayıda temsil edilmesini sağlamaya yönelik olup, küçük alan kaplayan sınıfların analizde göz ardı edilmesini engellemiştir. Bu çalışmada kullanılan veri setlerinin küresel ölçekte bağımsız doğrulaması gerçekleştirilmiş olup, her iki veri seti için genel doğruluk oranının %75'in üzerinde olduğu rapor edilmiştir. Bu nedenle, örnek noktaların sayısı, genel doğruluk oranının %75 olarak varsayıldığı binom olasılık teorisi temelli hesaplama ile belirlenmiştir (Maingi, Marsh, Kepner, & Edmonds, 2002).

$$N = \frac{Z^2 pq}{E^2} \quad (1)$$

Bu denklemde, **N** minimum örneklem sayısını; **p**, beklenen doğruluk oranını; **q**, hata oranını (1–p); **E**, kabul edilebilir hata payını; **Z** ise %95 güven düzeyi için kullanılan standart normal dağılım katsayısını (1.96) temsil etmektedir (Maingi et al., 2002). Çalışmada, küçük alan kaplayan sınıfların doğruluk değerlendirmesinde yeterince temsil edilmesini sağlamak amacıyla her sınıf için en az 20 örnek noktasının atanması gerektiği dikkate alınmıştır (Maingi et al., 2002; Van Genderen & Lock, 1977). Her örnek noktanın gerçek arazi örtüsü sınıfı, yüksek çözünürlüklü Google Earth Pro görüntüleri üzerinden manuel olarak görsel yorumlama yöntemi ile belirlenmiştir. Yorumlama sırasında, referans sınıflar ESA ve ESRI veri setlerindeki sınıf tanımları dikkate alınarak; örtü tipi, ton, doku, desen ve nesne biçimi gibi görsel ipuçlarına dayalı bir değerlendirme gerçekleştirilmiştir. Ayrıca, "mera", "otlak" ve "sulu bitki örtüsü" gibi sınıflar, mevsimsellik koşulları göz önünde bulundurularak ayrıştırılmıştır. Değerlendirme sürecinde en az iki uzman tarafından çapraz kontrol yapılmış; çelişkili durumlarda ise kararlar ortak uzlaşı yoluyla verilmiştir.

## 3. BULGULAR VE TARTIŞMA

Doğruluk analizi sonuçlarına göre, ESA WorldCover 2021 veri seti, incelenen üç havzada da ESRI Land Cover 2021 veri setine kıyasla daha yüksek genel doğruluk (OA) ve Kappa katsayısı değerleri sunmuştur. ESA verisinin genel doğruluğu H1 havzasında %86,32, H2 havzasında %93,00 ve H3 havzasında %90,25 olarak hesaplanmıştır. Buna karşın ESRI verisinin doğruluk

değerleri sırasıyla H1 için %65,15, H2 için %77,20 ve H3 için %87,74 seviyelerinde kalmıştır (Çizelge 1). Kappa katsayısı açısından da ESA WorldCover, H2 havzasında %88,48 ile en yüksek uyumu göstermiştir. ESRI veri seti ise aynı havzada yalnızca %58,20 Kappa değerine ulaşabilmiştir. Bu durum, ESA veri setinin hem genel sınıflandırma başarısını hem de rastgele sınıflandırmaya kıyasla güvenilirliğini ortaya koymaktadır.

**Çizelge1.** Genel doğruluk ve Kappa karşılaştırması

| Havza | ESA WorldCover | | ESRI Land Cover | |
|---|---|---|---|---|
| | OA | Kappa | OA | Kappa |
| H1 | %86,32 | 0,651 | %65,15 | 0,491 |
| H2 | %93,00 | 0,885 | %77,20 | 0,582 |
| H3 | %90,25 | 0,732 | %87,74 | 0,531 |

Sonuç olarak, elde edilen bulgular, her iki veri setinin sınıf bazlı performansının arazi örtüsünün türüne ve bölgesel heterojenliğe bağlı olarak değişkenlik gösterdiğini ortaya koymakta; ESA veri setinin radar-optik bütünleşik yapısı sayesinde daha kararlı ve güvenilir sınıflandırma sunduğunu işaret etmektedir.

## 4. SONUÇ

Bu çalışmada, ESA WorldCover 2021 ve ESRI Land Cover 2021 veri setlerinin H1, H2 ve H3 havzalarında karşılaştırmalı doğruluk analizleri gerçekleştirilmiştir. Elde edilen bulgular, ESA veri setinin her üç havzada da daha yüksek genel doğruluk ve Kappa katsayısı sunduğunu ortaya koymuştur. Özellikle su yüzeyleri, ağaç örtüsü ve tarım sınıflarında ESA WorldCover, radar ve optik veriyi entegre etmesinin sağladığı avantajla daha başarılı sonuçlar vermiştir. Öte yandan, ESRI veri seti, homojen mera alanlarında daha tutarlı performans sergilemiştir. Bu bağlamda, karar vericiler ve araştırmacılar için uygun veri seti seçiminin, bölgesel koşullar göz önünde bulundurularak yapılması gerektiği önerilmektedir.

**TEŞEKKÜR**

Bu çalışmada Tübitak–2209-A Üniversite Öğrencileri Araştırma Projeleri Desteği Programı tarafından desteklenen "Global 10 m Arazi Kullanımı Arazi Örtüsü Veri Setlerinin Doğruluk Değerlendirilmesi; ESA World Cover ve Esri Land Cover" isimli proje kapsamındaki verilerden yararlanılmıştır.

**Yazar Katkı Oranı**

Fidan Şevval Bulut: Çalışmanın analizlerini yapmış ve bildiriyi yazmıştır. Ayhan Ateşoğlu: Çalışmanın analizlerini yapmış ve bildiriyi yazmıştır. Emrah Acar: Çalışma verilerini toplamıştır.

**Çıkar Çatışması/Çakışması**

Yazarlar çıkar çatışması bildirmemişlerdir.

**Araştırma ve Yayın Etiği Beyanı**

Çalışmanın araştırma ve yayın etiği hakkında varsa açıklanması gereken bilgiler bu bölümde verilmelidir.

## KAYNAKÇA

Chaaban, F., El Khattabi, J., & Darwishe, H. (2022). Accuracy assessment of ESA WorldCover 2020 and ESRI 2020 land cover maps for a Region in Syria. *Journal of Geovisualization and Spatial Analysis*, 6(2), 31.

Karra, K., Kontgis, C., Statman-Weil, Z., Mazzariello, J. C., Mathis, M., & Brumby, S. P. (2021). Global land use/land cover with Sentinel 2 and deep learning. In *2021 IEEE international geoscience and remote sensing symposium IGARSS* (pp. 4704–4707). IEEE.

Maingi, J. K., Marsh, S. E., Kepner, W. G., & Edmonds, C. M. (2002). *An Accuracy Assessment of 1992 Landsat-MSS Derived Land Cover for the Upper San Pedro Watershed (US/Mexico). US Environmental Protection Agency, Washington DC*. Retrieved from EPA/600/R-02/040:

Rogan, J., & Chen, D. (2004). Remote sensing technology for mapping and monitoring land-cover and land-use change. *Progress in Planning*, 61(4), 301–325.

Van Genderen, J. L., & Lock, B. F. (1977). Testing land-use map accuracy. *Photogrammetric Engineering and Remote Sensing*, 43(9).

Wang, J., Bretz, M., Dewan, M. A. A., & Delavar, M. A. (2022). Machine learning in modelling land-use and land cover-change (LULCC): Current status, challenges and prospects. *Science of the Total Environment*, 822, 153559.

Zanaga, D., Van De Kerchove, R., Daems, D., De Keersmaecker, W., Brockmann, C., Kirches, G., … Fritz, S. (2022). ESA WorldCover 10 m 2021 v200.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

**TUFUAB XIII. TEKNİK SEMPOZYUMU**
https://tufuab2025.beun.edu.tr

# Depremlerde Bina Yıkılmasına Bağlı Kapanacak Yolların Monte Carlo Simülasyonu ve Coğrafi Bilgi Sistemleri ile Tespit Edilmesi

**Sefanur Doğan*[1], Resul Çömert[2], Onur Kaplan[2]**

[1]*Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri, Eskişehir, Türkiye*
[2]*Eskişehir Teknik Üniversitesi, Yer ve Uzay Bilimleri Enstitüsü, Eskişehir, Türkiye*

**Anahtar Kelimeler**
Afet Yönetimi
CBS,
Monte Carlo Simülasyonu,
Servis Alanı Analizi

**ÖZET**

Depremler, yerleşim alanlarında büyük yıkımlara yol açarak yapıların çökmesine ve buna bağlı olarak ulaşım ağlarında ciddi aksaklıkların meydana gelmesine neden olmaktadır. Bu tür aksaklıklar, afet yönetimi açısından önemli ulaşım problemleri oluşturmaktadır. Bu çalışmada, Coğrafi Bilgi Sistemleri (CBS) teknikleri ve Monte Carlo simülasyonu kullanılarak deprem sonrası yol kapanmalarının belirlenmesi ve acil durum müdahalesi üzerindeki etkilerinin analiz edilmesi amaçlanmıştır. Çalışma sahası olarak 6 Şubat 2023 tarihli depremlerden etkilenen Kahramanmaraş ilinin Elbistan ilçesi seçilmiştir. Bu kapsamda, farklı senaryolar altında kapanacak ve kapanma riski taşıyan yollar farklı yaklaşımlarla tespit edilmiş ve bu yollar dikkate alınarak hastanelerden 5, 10 ve 15 dakikalık servis alanı analizi gerçekleştirilmiştir. Binaların yol kapatma durumları tamamen kapanan yollar + Monte Carlo Simülasyonu (Birinci yaklaşım), tamamen kapanan yollar + açık yol genişliği <3.5 m + Monte Carlo Simülasyonu (ikinci yaklaşım), tamamen kapanan yollar + açık yol genişliği <3.5 m (Üçüncü yaklaşım) olmak üzere üç farklı şekilde değerlendirilmiştir. Yapılan doğruluk analizinde gerçekte kapanan yolların tespiti birinci, ikinci ve üçüncü yaklaşımda sırasıyla %89, %82 ve %84 kesinlik değeri tespit edilirken, uygulanan yaklaşımların F1-Skor değerleri sırasıyla, 0.55, 0.62 ve 0.61 olarak elde edilmiştir. Elde edilen F1-Skor sonuçlarına göre ikinci yaklaşım modele yol kapatma modeline uygulanmıştır. Ardından yapılan servis analiz sonuçları, bazı bölgelerde erişim süresinin uzadığını ve bazı noktalara hiç ulaşılamadığını göstermektedir. Çalışma, afet ve kriz yönetimini iyileştirmek amacıyla, afet sonrası ulaşım ağlarının etkinliğini artırmaya yönelik öneriler sunmaktadır. Elde edilen bulgular, afet yönetimi planlarına entegre edilerek acil durum müdahalelerinin daha hızlı ve etkili bir şekilde gerçekleştirilmesine katkı sağlayacaktır.

# Determination of Road Closures Due to Building Collapse in Earthquakes Using Monte Carlo Simulation and Geographic Information Systems

**Keywords**
Disaster Management,
GIS,
Monte Carlo Simulation,
Service Area Analysis

**ABSTRACT**

Earthquakes cause major destruction in residential areas, leading to the collapse of structures and consequently serious disruptions in transportation networks. Such disruptions pose significant transportation problems in terms of disaster management. In this study, Geographic Information Systems (GIS) techniques and Monte Carlo simulation were used to identify post-earthquake road closures and analyze their impact on emergency response. Elbistan district of Kahramanmaraş province, which was affected by the earthquakes on February 6, 2023, was selected as the study area. In this context, the roads that will be closed and at risk of closure under different scenarios were identified with different approaches and the 5, 10 and 15 minute service area analysis from hospitals was performed considering these

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Doğan S, Çömert R & Kaplan O (2025). Depremlerde Bina Yıkılmasına Bağlı Kapanacak Yolların Monte Carlo Simülasyonu ve Coğrafi Bilgi Sistemleri ile Tespit Edilmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

roads. The road closures of the buildings were evaluated in three different ways: completely closed roads + Monte Carlo Simulation (first approach), completely closed roads + open road width <3.5 m + Monte Carlo Simulation (second approach), completely closed roads + open road width <3.5 m (3 approaches). In the accuracy analysis, while the detection of actually closed roads was detected with 89%, 82% and 84% precision in the first, second and third approaches, respectively, the F1-Score values of the applied approaches were obtained as 0.55, 0.62 and 0.61, respectively. According to the F1-Score results, the second approach was applied to the road closure model. Subsequent service analysis results show that access time is prolonged in some areas and some points cannot be reached at all. The study provides recommendations to improve the efficiency of post-disaster transportation networks in order to improve disaster and crisis management. The findings will be integrated into disaster management plans and contribute to faster and more effective emergency response.

## 1. GİRİŞ

Depremler, meydana geldikleri bölgelerde ciddi can ve mal kayıplarına neden olan, doğrudan ve dolaylı etkileri uzun yıllar sürebilen doğal afetlerdir. Özellikle aktif tektonik kuşaklar üzerinde yer alan ülkelerde, depremler sadece anlık yıkımlara değil, bununla birlikte altyapı sistemleri üzerinde de uzun vadeli olumsuz etkilere yol açmaktadır. Türkiye, yüksek sismik tehlike barındıran bölgelerden biri olup, tarih boyunca büyük depremlerle karşı karşıya kalmıştır. En son 6 Şubat 2023 tarihinde merkez üssü Kahramanmaraş'ın Pazarcık ve Elbistan ilçeleri olan Mw 7.7 ve Mw 7.6 büyüklüğündeki iki deprem meydana gelmiş, bu depremler geniş bir coğrafyada büyük yıkıma sebep olmuştur. İlk deprem, 8.6 km derinlikte, ikinci deprem ise 7 km derinlikte gerçekleşmiş ve özellikle şehir merkezlerindeki yapısal hasar ve altyapı sistemlerindeki bozulmalar nedeniyle arama-kurtarma faaliyetlerinde büyük aksaklıklar yaşanmıştır. (AFAD, 2023)

Bu tür büyük ölçekli afetlerde, can kayıplarının ve ekonomik zararların en aza indirilmesi için afet öncesi hazırlık ve risk değerlendirmesi, afet yönetimi için büyük bir önem taşımaktadır. Deprem sonrası ulaşım ağlarının kullanabilirliği, acil müdahale ekiplerinin etkinliği önemlidir. Yıkılan veya ağır hasar gören binalardan dolayı yolların kapanması, arama-kurtarma çalışmalarını geciktirmekte ve hayati önem taşıyan lojistik destek süreçlerini olumsuz etkilemektedir. Bu bağlamda, binaların yıkılma durumlarını ve yol kapanmalarını önceden tahmin eden simülasyon tabanlı modeller, afet yönetimi süreçlerine önemli katkılar sunmaktadır.

Literatürde, farklı ülkelerde depremlerin yol ağları üzerindeki etkilerini analiz eden çeşitli çalışmalar bulunmaktadır. Örneğin, (Anastasiadis, 2005)Yunanistan'ın Selanik şehrine yönelik bir çalışma gerçekleştirerek bina stokunun ve kritik altyapı unsurlarının kırılganlık değerlendirmesine dayalı bir metodoloji geliştirmiştir. Bu çalışmada, şiddetli yer hareketlerinin dikkate alınarak, bina yıkımlarının yol kapanmalarına etkisi analiz edilmiştir. Çalışmada ayrıca, GIS teknolojisinin tehlike haritalarının hazırlanması ve deprem risk değerlendirmesinde kullanımı vurgulanmaktadır. Bir diğer çalışma olan (Zanini et al., 2017)ise, tarihi şehir merkezlerinde deprem sonrası acil durum yönetimi için kentsel yol ağlarının işlevselliğini değerlendirmiş ve binaların sismik hasarının yol kullanılabilirliği üzerindeki etkilerini analiz etmek amacıyla bulanık mantık ve olasılık teorisi temelli bir yöntem önerilmiştir.

(D. Toma-Danila, Tiganescu, D'Ayala, Armas, & Sun, 2022a; Dragos Toma-Danila, 2018a; Dragos Toma-Danila, Armas, & Tiganescu, 2020a) tarafından yapılan çalışmalarda ise, Bükreş'teki kentsel yol ağlarının depremlerden nasıl etkileneceği Monte Carlo simülasyonları kullanılarak incelenmiş, kritik yolların kapanmasının acil müdahale süreçlerine etkileri değerlendirilmiştir. Özellikle 2020 yılında geliştirilen "Network-risk" adlı GIS aracı, doğal afetlerin ulaşım sistemleri üzerindeki etkilerini analiz ederek trafik sıkışıklığı ve yol kapanmalarının acil müdahale operasyonlarına olan etkisini ortaya koymuştur. 2022 yılında yapılan devam niteliğindeki çalışmada ise önceki araştırmalardan farklı olarak zaman bağımlı bir model kullanılarak deprem sonrası acil müdahale süreleri detaylı bir şekilde analiz edilmiştir. Çalışmada, kritik yolların ve sağlık tesislerinin erişilebilirliği değerlendirilmiş, risk azaltma stratejileri kapsamında yeni hastanelerin inşası ve trafik yönetiminde iyileştirmeler önerilmiştir.

Bu çalışmada, literatürde sunulan metodolojilerden yola çıkılarak Kahramanmaraş'ın Elbistan ilçesine yönelik kapsamlı bir analiz gerçekleştirilmiştir. Özellikle (D. Toma-Danila, Tiganescu, D'Ayala, Armas, & Sun, 2022b; Dragos Toma-Danila, 2018b; Dragos Toma-Danila, Armas, & Tiganescu, 2020b)tarafından geliştirilen yöntemler otomatize edilerek bölgeye uyarlanmış, olası bir deprem senaryosu altında yol kapanmaları tahmin edilerek ulaşım ağlarının durumu değerlendirilmiştir. Çalışma kapsamında, deprem sonrası kapanacak ve kapanma riski taşıyan yollar belirlenmiştir. Ayrıca, servis alanı analizi gerçekleştirilerek, acil müdahale ekiplerinin hastanelerden 5, 10 ve 15 dakikalık zaman dilimleri içerisinde ulaşabileceği bölgeler belirlenmiştir. Bu analizler, deprem sonrası müdahale süreçlerinin etkinliğini artırmak, kritik bölgelerdeki erişilebilirliği değerlendirmek ve afet yönetimi kapsamında stratejik karar alma süreçlerine bilimsel bir temel sağlamak amacıyla gerçekleştirilmiştir. Böylece, risk azaltma

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Doğan S, Çömert R & Kaplan O (2025). Depremlerde Bina Yıkılmasına Bağlı Kapanacak Yolların Monte Carlo Simülasyonu ve Coğrafi Bilgi Sistemleri ile Tespit Edilmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

stratejilerinin geliştirilmesine katkıda bulunulması ve acil durum planlamalarının optimize edilmesi hedeflenmektedir

## 2. YÖNTEM

Bu çalışma, Coğrafi Bilgi Sistemleri (CBS) teknikleri kullanılarak gerçekleştirilmiş olup, deprem sonrası ulaşım ağında meydana gelebilecek yol kapanmalarının belirlenmesini amaçlamaktadır. Bu kapsamda, binaların çökmesi sonucu etkilenecek yol kesimlerini tespit etmek için aşağıdaki formül uygulanmıştır(Milutinovic & Trendafiloski, 2003).

Etkilenen Alan = (2/3) × Kat Sayısı

Etkilenen alan formülüne bağlı kalarak, binaların yol kapamalarında farklı yaklaşımlar denenmiştir. Bu yaklaşımlar tamamen kapanan yollar + Monte Carlo Similasyonu (Birinci yaklaşım), tamamen kapanan yollar + açık yol genişliği <3.5 m + Monte Carlo Simülasyonu (ikinci yaklaşım), tamamen kapanan yollar + açık yol genişliği <3.5 m (Üçüncü yaklaşım) şeklindedir. Bu 3,5 metreden küçük alanlar minimum ambulans geçebileceği alanlar olarak belirlenmiştir(Anelli, Mori, & Vona, 2020).Depremlerin yol ağları üzerindeki etkilerini daha kapsamlı bir şekilde değerlendirmek amacıyla, Monte Carlo simülasyonu kullanılmıştır. Bu yöntem, farklı deprem senaryoları altında yol kapanma olasılıklarını modelleyerek, acil müdahale süreçlerinde yaşanabilecek riskleri ve belirsizlikleri analiz etmeye olanak tanımaktadır(Dragos Toma-Danila, 2018b). Monte Carlo simülasyonu ile kentsel yol ağlarının sismik olaylara karşı kırılganlığı belirlenmiş ve elde edilen sonuçlar doğrultusunda, daha etkili afet yönetimi stratejilerinin geliştirilmesine katkı sağlanmıştır.

Acil durum yönetimi açısından kritik bir diğer analiz ise servis alanı analizidir. Bu analiz, ulaşım ağında belirli noktaların çevrelerine sunabilecekleri hizmet alanlarını belirlemek için kullanılmaktadır(Erkal et al., n.d.). Özellikle hastaneler, 112 acil yardım istasyonları ve itfaiye istasyonları gibi kritik ünitelerin erişilebilirliği servis alanı analizi ile değerlendirilmiştir. Deprem sonrası yol kapanmaları göz önünde bulundurularak, acil müdahale ekiplerinin belirlenen sağlık tesislerinden 5, 10 ve 15 dakikalık süreler içinde ulaşabileceği bölgeler belirlenmiştir.

Elde edilen analiz sonuçları, afet sonrası müdahale süreçlerinin daha etkin planlanmasına katkı sağlamakta ve risk azaltma stratejilerinin oluşturulmasına yönelik bilimsel bir altyapı sunmaktadır. Böylece, deprem sonrası ulaşım ağındaki aksaklıkların önceden öngörülmesi, acil durum ekiplerinin müdahale sürelerinin optimize edilmesine ve afet yönetimi kapasitesinin artırılmasına olanak tanımaktadır.

## 3. BULGULAR

Bu çalışmada farklı senaryolar altında kapanacak ve kapanma riski taşıyan yollar farklı yaklaşımlarla tespit edilmiş ve bu yollar dikkate alınarak hastanelerden 5, 10 ve 15 dakikalık servis alanı analizi gerçekleştirilmiştir. Binaların yol kapatma durumları tamamen kapanan yollar + Monte Carlo Simülasyonu (Birinci yaklaşım), tamamen kapanan yollar + açık yol genişliği <3.5 m + Monte Carlo Simülasyonu (ikinci yaklaşım), tamamen kapanan yollar + açık yol genişliği <3.5 m (Üçüncü yaklaşım) olmak üzere üç farklı şekilde değerlendirilmiştir.

| Yöntem | Doğruluk | Kesinlik | Duyarlılık | F1 Skor |
|---|---|---|---|---|
| Birinci Yaklaşım | 0.7865 | 0.8929 | 0.3968 | 0.5495 |
| İkinci Yaklaşım | 0.7969 | 0.8158 | 0.4921 | 0.6139 |
| Üçüncü Yaklaşım | 0.8021 | 0.8378 | 0.4921 | 0.62 |

**Çizelge1.** Doğruluk analizi sonuçları.

Çizelge1.'e göre, en yüksek doğruluk değeri %80,21 ile üçüncü yaklaşımda elde edilmiştir. Kesinlik değeri açısından en yüksek performans birinci yaklaşıma (%89,29) aitken, duyarlılık değeri ikinci ve üçüncü yaklaşımlarda eşit çıkmış (%49,21) ve birinci yaklaşıma kıyasla daha başarılı sonuçlar vermiştir. F1 skoru açısından değerlendirildiğinde ise, üçüncü yaklaşım %62 ile en dengeli ve tatmin edici sonuçları sunmuştur.

Elbistan depremi sonrası elde edilen veriler doğrultusunda, tamamen ve kısmen yıkılmış binalar temel alınarak bir analiz gerçekleştirilmiştir. Monte Carlo simülasyonu kullanılarak, deprem nedeniyle kapanabilecek yollar tespit edilmiş ve bu durumun ulaşım ağındaki etkileri değerlendirilmiştir. Ardından, hastaneler için 5, 10 ve 15 dakikalık servis alanları oluşturularak, deprem sonrası ulaşılabilirlik analiz gerçekleştirilmiştir (Şekil 1.).

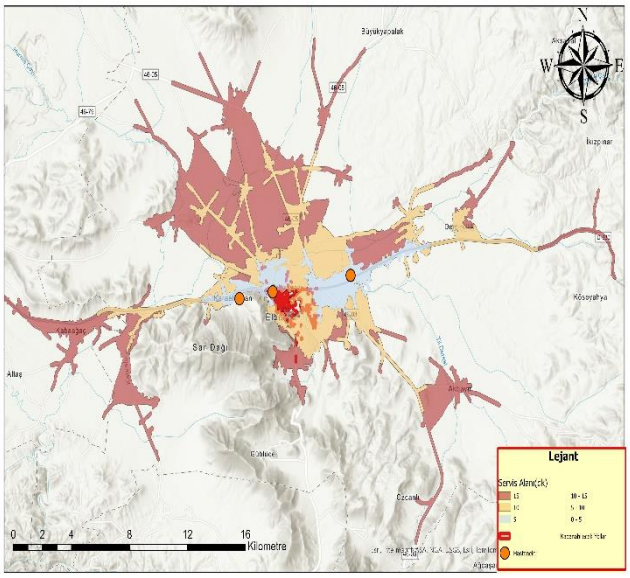


**Şekil 1.** 5,10,15 dakikalık servis alanı analizi

Şekil 2'de göründüğü üzere normal koşullarda 5 dakikada erişilebilen bölgelerin, yolların kapanması

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Doğan S, Çömert R & Kaplan O (2025). Depremlerde Bina Yıkılmasına Bağlı Kapanacak Yolların Monte Carlo Simülasyonu ve Coğrafi Bilgi Sistemleri ile Tespit Edilmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

sonucunda 10 dakikaya kadar ulaşım süresine maruz kaldığı belirlenmiştir. Ayrıca, yolların özellikle merkez bölgelerde yoğun şekilde kapanması nedeniyle bazı alanlara ulaşım tamamen sağlanamamıştır.



**Şekil 2.** Ulaşılamayan alanlar

Bu artış, özellikle afet sonrası acil müdahale ve kurtarma operasyonlarının zamanında gerçekleştirilmesinin güçleşmesine yol açmıştır. Ayrıca, ulaşılabilirlikteki bu bozulma, belirli bölgelere erişimi zorlaştırmış ve özellikle hastaneler gibi kritik altyapılara ulaşımın sağlanmasında ciddi sıkıntılar yaratmıştır.

## 4. TARTIŞMA

Çalışmada elde edilen bulgular, deprem nedeniyle kapanan yolların özellikle şehir merkezinde yoğunlaştığını ve kritik altyapı noktalarına erişimi ciddi şekilde engellediğini göstermektedir. Yapılan servis alanı analizleri, hastaneler gibi hayati öneme sahip tesislere ulaşım süresinin belirli bölgelerde önemli ölçüde arttığını ortaya koymuştur. Normal şartlar altında 5 dakikada erişilebilen bazı bölgelerin, yolların kapanması nedeniyle 10 dakikaya kadar uzayan erişim sürelerine maruz kaldığı görülmüştür. Bu durum, acil müdahale ekiplerinin etkinliğini azaltmakta ve deprem sonrası hayati önem taşıyan kurtarma faaliyetlerini olumsuz yönde etkilemektedir.

Literatürde yer alan (D. Toma-Danila et al., 2022b; Dragos Toma-Danila, 2018b; Dragos Toma-Danila et al., 2020b)tarafından gerçekleştirilen çalışmalar otomatikleştirilerek, Monte Carlo simülasyonları kullanımıyla benzer yol kapanma senaryoları üretilmiş ve kritik ulaşım ağlarındaki kesintilerin afet müdahalesi üzerindeki etkileri detaylı bir şekilde incelenmiştir. Bu bağlamda, mevcut çalışmamız literatürdeki yöntemleri bölgeye özgü şekilde uyarlayarak Elbistan ilçesi özelinde kapsamlı bir değerlendirme sunmaktadır.

Çalışmanın bazı kısıtlılıkları bulunmaktadır. Öncelikle, yol kapanmalarının tahmininde bina yıkımlarına dayalı istatistiksel yöntemler kullanılmıştır. Ancak, yerel zemin koşulları, altyapı dayanıklılığı gibi faktörler de ulaşım ağının durumunu etkileyebilmektedir. Ayrıca, simülasyon sonuçları belirli belirsizlikleri içerebilir ancak çalışma doğrudan deprem etkileri üzerine yapılmış olup, teorik bir varsayımdan ziyade gerçek olaylara dayanmaktadır. Bu nedenle, gelecekteki çalışmalar, daha karmaşık fiziksel modellemeler ve gerçek zamanlı veri entegrasyonu ile desteklenmelidir. Farklı formül ve yıkılama türleri incelenerek Monte Carlo simülasyonunu başka çalışma alanlara uyarlanmalıdır.

## 5. SONUÇ

Bu çalışma, deprem sonrası ulaşım ağında meydana gelebilecek yol kapanmalarını öngörmek ve afet müdahale süreçlerini iyileştirmek amacıyla gerçekleştirilmiştir. Monte Carlo simülasyonları kullanılarak oluşturulan senaryolar, yolların kapanma olasılıklarını belirlemiş ve bu kapanmaların acil durum ekiplerinin erişilebilirliğine olan etkisini değerlendirilmiştir. Servis alanı analizleri sonucunda, özellikle şehir merkezlerinde acil müdahale süresinin uzadığı ve bazı kritik bölgelerde tamamen erişilemez hale geldiği tespit edilmiştir.

Elde edilen bulgular doğrultusunda, afet yönetimi süreçlerinin iyileştirilmesine yönelik bazı öneriler sunulabilir. Öncelikle, kritik yolların deprem sonrası hızlı bir şekilde açılabilmesi için önceden belirlenmiş alternatif güzergahların planlanması gerekmektedir. Ayrıca, yol kapanma risklerini minimize etmek adına yapı güvenliği artırılmalı ve afet anında kullanılabilecek geçici ulaşım çözümleri geliştirilmelidir. Bunun yanı sıra, acil durum ekiplerinin ve hastanelerin konumlandırılması, afet senaryoları göz önünde bulundurularak yeniden değerlendirilmelidir.

Bu çalışmada, deprem sonrası ulaşım ağlarında meydana gelebilecek yol kapanmaları üç farklı yaklaşımla analiz edilmiştir. Elde edilen sonuçlara göre, yalnızca olasılıksal yaklaşımların yeterli olmadığı; fiziksel yol özelliklerinin de dikkate alınmasının model doğruluğunu artırdığı görülmüştür. Özellikle üçüncü yaklaşım, en yüksek doğruluk ve F1 skoru ile en başarılı sonuçları sunmuştur. Bu bulgular, afet yönetiminde ulaşım erişilebilirliğinin değerlendirilmesinde çok kriterli yaklaşımların önemini ortaya koymaktadır.

Sonuç olarak, bu çalışma, Elbistan ilçesi özelinde yapılan kapsamlı bir analiz ile deprem sonrası ulaşım sistemlerinin nasıl etkileneceğini ortaya koymuştur. Bu tür analizler, afet öncesi planlamalar ve müdahale stratejileri için önemli bilimsel temeller sağlamaktadır. Gelecekte, bu modellemelerin daha geniş alanlarda uygulanması ve gerçek zamanlı veri kaynaklarıyla entegrasyonu, afet yönetiminde daha etkin ve sürdürülebilir çözümler geliştirilmesine katkı sağlayacaktır.

## KAYNAKÇA

AFAD. (2023). *06 Şubat 2023 PAZARCIK (KAHRAMANMARAŞ) MW 7.7 ELBİSTAN (KAHRAMANMARAŞ) MW 7.6 DEPREMLERİNE İLİŞKİN ÖN DEĞERLENDİRME RAPORU DEPREM DAİRESİ BAŞKANLIĞI 9 Şubat*.

Anastasiadis, A. (2005). *Roadway Network Seismic Risk Analysis in Urban Areas: The case of Thessaloniki-Greece*. Retrieved from https://www.researchgate.net/publication/267405507

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Doğan S, Çömert R & Kaplan O (2025). Depremlerde Bina Yıkılmasına Bağlı Kapanacak Yolların Monte Carlo Simülasyonu ve Coğrafi Bilgi Sistemleri ile Tespit Edilmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

Anelli, A., Mori, F., & Vona, M. (2020). Fragility curves of the urban road network based on the debris distributions of interfering buildings. *Applied Sciences (Switzerland)*, 10(4). Retrieved from https://doi.org/10.3390/app10041289

Erkal, T., Değerliyurt, M., Üniversitesi, A. K., Fakültesi, F.-E., Coğrafya, B., & Üniversitesi, M. K. (n.d.). Türk Coğrafya Dergisi Eskişehir'de Acil Durum Yönetiminde Ağ (Network) Analizlerinin Kullanılması The Use of Network Analysis for Emergency Management in the City of Eskişehir, Turkey. Retrieved from http://www.tcd.org.tr

Milutinovic, Z. V, & Trendafiloski, G. S. (2003). *RISK-UE An advanced approach to earthquake risk scenarios with applications to different European towns WP4: Vulnerability of current buildings*.

Toma-Danila, D., Tiganescu, A., D'Ayala, D., Armas, I., & Sun, L. (2022a). Time-Dependent Framework for Analyzing Emergency Intervention Travel Times and Risk Implications due to Earthquakes. Bucharest Case Study. *Frontiers in Earth Science*, 10. Retrieved from https://doi.org/10.3389/feart.2022.834052

Toma-Danila, D., Tiganescu, A., D'Ayala, D., Armas, I., & Sun, L. (2022b). Time-Dependent Framework for Analyzing Emergency Intervention Travel Times and Risk Implications due to Earthquakes. Bucharest Case Study. *Frontiers in Earth Science*, 10. Retrieved from https://doi.org/10.3389/feart.2022.834052

Toma-Danila, Dragos. (2018a). A GIS framework for evaluating the implications of urban road network failure due to earthquakes: Bucharest (Romania) case study. *Natural Hazards*, 93, 97–111. Retrieved from https://doi.org/10.1007/s11069-017-3069-y

Toma-Danila, Dragos. (2018b). A GIS framework for evaluating the implications of urban road network failure due to earthquakes: Bucharest (Romania) case study. *Natural Hazards*, 93, 97–111. Retrieved from https://doi.org/10.1007/s11069-017-3069-y

Toma-Danila, Dragos, Armas, I., & Tiganescu, A. (2020a). Network-risk: An open GIS toolbox for estimating the implications of transportation network damage due to natural hazards, tested for Bucharest, Romania. *Natural Hazards and Earth System Sciences*, 20(5), 1421–1439. Retrieved from https://doi.org/10.5194/nhess-20-1421-2020

Toma-Danila, Dragos, Armas, I., & Tiganescu, A. (2020b). Network-risk: An open GIS toolbox for estimating the implications of transportation network damage due to natural hazards, tested for Bucharest, Romania. *Natural Hazards and Earth System Sciences*, 20(5), 1421–1439. Retrieved from https://doi.org/10.5194/nhess-20-1421-2020

Zanini, M. A., Faleschini, F., Zampieri, P., Pellegrino, C., Gecchele, G., Gastaldi, M., & Rossi, R. (2017). Post-quake urban road network functionality assessment for seismic emergency management in historical centres. *Structure and Infrastructure Engineering*, 13(9), 1117–1129. Retrieved from https://doi.org/10.1080/15732479.2016.1244211

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Doğan S, Çömert R & Kaplan O (2025). Depremlerde Bina Yıkılmasına Bağlı Kapanacak Yolların Monte Carlo Simülasyonu ve Coğrafi Bilgi Sistemleri ile Tespit Edilmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Derin Öğrenme Kullanılarak Yüksek Çözünürlüklü Görüntülerden Bina Segmentasyonu

**İrem Kavas[1], Bahadır Kulavuz*[1], Tolga Bakırman[1], Bülent Bayram[1]**

[1]*Yıldız Teknik Üniversitesi, İnşaat Fakültesi, Harita Mühendisliği Bölümü, İstanbul, Türkiye, irem.kavas@std.yildiz.edu.tr*

**Anahtar Kelimeler**
Uzaktan Algılama,
Derin Öğrenme,
Bina Segmentasyonu,
ISPRS

**ÖZET**

Uzaktan algılama verileri derin öğrenme yaklaşımları ile bina segmentasyonu gibi mekânsal analiz görevlerinde etkin biçimde kullanılmaktadır. Bu çalışmada, yüksek çözünürlüklü uydu görüntüleri kullanılarak binaların çıkarımını gerçekleştirmek amacıyla farklı bant kombinasyonlarının ve farklı yapay zeka mimarilerin performanslarını karşılaştırmalı olarak analiz etmektedir. Çalışma Kapsamında kullanılan ISPRS Potsdam veri kümesine ait RGB, IRRG ve RGBIR bant bileşimleri ile U-Net mimarisi kullanılarak yapılan ilk deneylerde, RGBIR görüntülerin segmentasyon doğruluğu açısından belirgin üstünlük sağladığı gözlemlenmiştir. Bu nedenle çalışmanın ileri aşamalarında yalnızca RGBIR görüntüler ile eğitim gerçekleştirilmiş; modern mimarilerden SegFormer ve DeepLabv3+ modelleri kullanılarak ek deneyler uygulanmıştır. Her iki model benzer doğruluk seviyeleri üretmiş olsa da, eğitim süresi ve yapısal verimlilik bakımından SegFormer daha avantajlı bir profil sergilemiştir. Ayrıca her iki modele sınırlı sayıda epok uygulanmasına rağmen, SegFormer düşük eğitim süresine karşın rekabetçi sonuçlar vermiş ve daha uzun eğitimlerle performansını artırmaya açık bir mimari olarak öne çıkmıştır.

# Deep Learning Based Bilding Segmentation Using High Resolution Images

**Keywords**
Remote sensing,
Deep Learning,
Building Segmentation,
ISPRS

**ABSTRACT**

Remote sensing data is effectively used in spatial analysis tasks such as building segmentation with deep learning approaches. This study comparatively analyzes the performances of different band combinations and different artificial intelligence architectures to perform building extraction using high-resolution satellite images. In the initial experiments conducted within the scope of the study using the ISPRS Potsdam dataset with RGB, IRRG, and RGBIR band combinations and the U-Net architecture, it was observed that RGBIR images provided a significant advantage in terms of segmentation accuracy. Therefore, in the subsequent stages of the study, training was performed only with RGBIR images; additional experiments were conducted using modern architectures SegFormer and DeepLabv3+. Although both models produced similar accuracy levels, SegFormer exhibited a more advantageous profile in terms of training time and structural efficiency. Furthermore, despite applying a limited number of epochs to both models, SegFormer yielded competitive results despite its shorter training time and stood out as an architecture open to performance improvement with longer training durations.

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Kavas İ, Kılavuz B, Bakırman T & Bayram B. (2025). Derin Öğrenme Kullanılarak Yüksek Çözünürlüklü Görüntülerden Bina Segmentasyonu, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Binalar, insanların günlük yaşamı ve üretimi için temel mekânlar olarak, kentsel kültürün, tarihin ve modernleşme düzeylerinin sergilenmesinde önemli taşıyıcılardır. Aynı zamanda, kentsel temel coğrafi bilgi altyapısının ayrılmaz bir bileşenidir. Binaların makul bir şekilde konumlandırılması, kent gelişimi, çevresel yapılaşma ve insanların yaşamları üzerinde önemli etkilere sahiptir. Yapıların inşası, yıkımı, yenilenmesi, genişletilmesi gibi faaliyetler ise belirli bir bölgedeki büyüme potansiyelini yansıtır (Pang vd., 2024). Bu nedenle, uzaktan algılama (RS) görüntülerinden bina segmentasyonu ve çıkarımı, birçok kritik uygulama için zemin hazırlar. Bu uygulamalar arasında otomatik bina tespiti, kentsel planlama, çevresel izleme, nüfus tahmini ve yönetimi, afet ve risk yönetimi, değişim tespiti ve bina veri tabanı oluşturma yer alır (Bakirman vd., 2022).

Günümüzde araştırmacılar, uzaktan algılama görüntülerinden bina bilgilerini otomatik olarak çıkarmaya yönelik çalışmalara odaklanmıştır. Bu amaçla çeşitli çıkarım algoritmaları önerilmiştir ve bu algoritmalar genel olarak geleneksel yöntemler ile derin öğrenme tabanlı yaklaşımlar olmak üzere iki ana gruba ayrılmaktadır (Xu vd., 2023). Derin öğrenme tabanlı yöntemler, yüksek çözünürlüklü görüntüler üzerinde daha hassas segmentasyon sağlamanın yanı sıra, karmaşık kentsel yapılar içinde bina sınırlarını daha net şekilde ayırt edebilme avantajı sunmaktadır. Bu nedenle, özellikle büyük veri kümelerinde otomatik bina çıkarımı için tercih edilmektedir.

## 2. YÖNTEM

Bu bölümde, bina segmentasyonu amacıyla kullanılan veri seti, görüntü işleme ve ön hazırlık ve derin öğrenme mimarisi ele alınmıştır.

### 2.1. ISPRS Potsdam Veriseti

Bu veri seti, yüksek çözünürlüklü hava görüntülerinden oluşturulmuş 38 yama içermektedir. Her bir yama, hem gerçek ortofoto (TOP) hem de sayısal yüzey modeli (DSM) verisini içermektedir. 5 cm yer örnekleme aralığına sahip bu veriler, Trimble INPHO yazılım araçlarıyla üretilmiş ve boşluksuz olacak şekilde mozaiğin merkezi kısımlarından seçilmiştir. TOP görüntüleri, 8 bit çözünürlüklü IRRG (Kızılötesi - Kırmızı - Yeşil), RGB (Kırmızı - Yeşil - Mavi) ve RGBIR (Kırmızı - Yeşil - Mavi - Kızılötesi) olmak üzere farklı kanal bileşimlerinde sunulmaktadır. Çalışma kapsamında, veri setinde bulunan RGB, IRRG ve RGBIR ortofoto görüntülerden faydalanılmıştır.

### 2.2. Görüntü İşleme ve Ön Hazırlık

Bu çalışma kapsamında, Potsdam veri setinde yer alan RGB, IRRG ve RGBIR görüntüleri kullanılmıştır. Tüm görüntüler 6000x6000 piksel boyutundan 512x512 piksel boyutuna yeniden boyutlandırılmıştır.

Veri setinde yer alan segmentasyon maskeleri; yol, bina, ağaç, bitki örtüsü, araç ve karmaşık yapılar gibi sınıfları içermektedir (Şekil 1a). Ancak bu çalışma kapsamında sınıflar, "bina" ve "arka plan" olmak üzere iki kategoriye indirgenmiştir. Bu doğrultuda maskeler tek bantlı hale getirilmiş; bina pikselleri 1, arka plan pikselleri ise 0 olarak yeniden etiketlenmiştir (Şekil 1b).

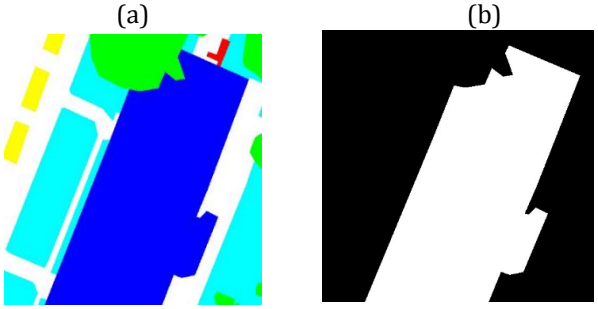


**Şekil 1.** 512x512 olarak boyutlandırılmış Potsdam veri setine ait görüntünün orijinal maskesi (a) ve sadece bina ve arka plan olarak ayrılmış maske(b).

### 2.3. Model

Bu çalışmada, derin öğrenme tabanlı üç farklı mimari kullanılmıştır: U-Net, SegFormer ve DeepLabv3+.

İlk olarak U-Net, kodlayıcı (encoder) ve çözücü (decoder) alt-ağları arasında aynı çözünürlükteki öznitelik haritalarını doğrudan birleştiren atlamlı bağlantı mekanizması sayesinde, segmentasyon doğruluğunu artırmakta ve ayrıntılı uzamsal bilgilerin korunmasına olanak tanımaktadır (Li vd., 2021).Diğer yandan, DeepLabv3+ mimarisi, atrous konvolüsyonları ve encoder-decoder yapısıyla çok ölçekli bağlamsal bilgi çıkarımı sağlayan bir başka etkili segmentasyon modelidir. "DeepLabv3+, derin konvolüsyonel sinir ağları ile atrous (dilated) konvolüsyonları birleştirerek çok ölçekli bağlamsal bilgiyi yakalamayı amaçlayan bir segmentasyon modelidir (Chen vd., 2018). SegFormer, Transformer temelli encoder yapısını, hafif ve verimli bir MLP tabanlı decoder ile birleştiren modern bir segmentasyon mimarisidir. "SegFormer, Transformers ile hafif çok katmanlı algılayıcı (MLP) çözücüleri birleştiren basit, verimli ve güçlü bir anlamsal segmentasyon çerçevesidir (Xie vd., 2021). Bu çalışmada, SegFormer mimarisi uygulanırken orijinal yapıda yer alan Transformer tabanlı encoder yerine bütünlüğü bozmamak adına daha hafif olan "MobileNetv2" kullanılmıştır.

## 3. BULGULAR

Bu çalışmada, farklı bant kombinasyonlarının segmentasyon başarısı üzerinde olan etkisi incelenmek istenmiştir. Bunun için ilk olarak RGB, IRRG ve RGBIR olmak üzere üç farklı bant kombinasyonu, başlangıçta U-Net mimarisiyle değerlendirilmiştir. Elde edilen sonuçlar Çizelge 1'de gösterilmiştir.

**Çizelge 1.** Farklı bant kombinasyonları kullanılarak yapılan segmentasyon sonuçları.

| Bant Kombinasyonları | Piksel Doğruluk | IoU |
|---|---|---|
| RGB | 0.93 | 0.81 |
| IRRG | 0.72 | 0.58 |
| RGBIR | 0.96 | **0.87** |

Bu sonuçlar doğrultusunda, en yüksek segmentasyon başarımını gösteren RGBIR bant kombinasyonu ile çalışmanın sonraki aşamaları yürütülmüştür. RGBIR görüntüler üzerinde yenilikçi ve

farklı öğrenme mimarilerine sahip SegFormer ve DeepLabv3+ mimarileriyle ek deneyler yapılmıştır. Bu iki model, literatürde yüksek doğruluk ve verimlilikleriyle öne çıktıkları için seçilmiş ve farklı derin öğrenme yaklaşımlarının aynı veri üzerinde karşılaştırılması hedeflenmiştir.

## 4. TARTIŞMA

Çalışma kapsamında spektral bantların ve mimari yapıların karşılaştırmalı analizi gerçekleştirilmiştir. İlk aşamada RGB, IRRG ve RGBIR bant bileşimlerinin etkisi değerlendirilmiş ve RGBIR, 0.87 mIoU değeri ile en yüksek segmentasyon performansını göstermiştir. IRRG kombinasyonu ise, 0.58 mIoU ile en düşük performansı sergilemiştir. Bu durum, yakın kızılötesi bandın bazı çatı yüzeylerini bitki örtüsüne benzer şekilde göstermesi nedeniyle sınıflar arası spektral çakışma yaşanmasından kaynaklanmaktadır. Özellikle kırmızı tonlara sahip çatılar, IR kanalında bitki örtüsüyle benzer spektral tepkiler verdiğinden model, bina sınıfını doğru şekilde ayırt etmekte zorlanmıştır.

Bulgular doğrultusunda, sonraki aşamada yalnızca RGBIR görüntüler kullanılarak daha gelişmiş mimariler olan SegFormer ve DeepLabv3+ ile ek deneyler gerçekleştirilmiştir. Her iki model de yüksek doğrulukta sonuçlar üretmiş olup, DeepLabv3+ 0.871 mIoU ve 0.955 piksel doğruluğu, SegFormer ise 0.870 mIoU ve 0.956 piksel doğruluğu elde etmiştir. Her iki mimari benzer doğruluk düzeyinde sonuç üretmiş olsa da, SegFormer'ın daha kısa eğitim süresi ve daha düşük model karmaşıklığı, sınırlı donanıma sahip ortamlarda daha uygulanabilir ve verimli bir alternatif olarak kullanılabilir olduğu belirlenmiştir. Bununla birlikte, her iki modelin de eğitiminde donanım yetersizliğinden dolayı sınırlı sayıda epok uygulanmıştır. Bu durum, modellerin tam performans potansiyellerine ulaşmalarını kısıtlamış olabilir. Özellikle SegFormer'ın daha düşük epok sayısına rağmen rekabetçi sonuçlar vermesi, mimarinin daha uzun süreli eğitimlerle daha yüksek doğruluk elde edebileceğini göstermektedir. DeepLabv3+ ise erken epoklarda hızlı bir doğruluk artışı göstermiş ancak sonrasında doğrulama eğrisinin durağan ve düşüşe eğilim göstermeye başladığı gözlemlenmiştir.

## 5. SONUÇ

Bu çalışmada, derin öğrenme algoritmaları kullanılarak, uydu görüntülerinden kentsel alanlarda otomatik bina segmentasyonu gerçekleştirilmiştir. Bu amaçla derin öğrenmeye dayalı UNet, Segformer ve DeepLabv3+ mimarileri kullanılmıştır. Segmentasyon işlemleri için ISPRS Potsdam veri kümesindeki RGB, IRRG ve RGBIR görüntüler değerlendirilmiştir.

Çalışmanın ilk aşamasında RGB, IRRG ve RGBIR bant bileşimlerinin segmentasyon üzerindeki etkisi değerlendirilmiş, RGBIR bileşiminin daha başarılı olduğu gözlemlenmiştir (Çizelge 1). Bant kombinasyonlarının karşılaştırılmasının ardından, RGBIR verisi kullanılarak SegFormer ve DeepLabv3+ modelleri ile yeniden eğitim yapılmıştır. Her iki modelin de yüksek doğrulukta segmentasyon sonuçları ürettiği görülmüştür. SegFormer'ın düşük epok sayısıyla dahi rekabetçi performans sergilediğini ve daha fazla eğitime açık bir mimari olduğunu ortaya koymaktadır. Bu nedenle, yapısal hafifliği ile birlikte düşünüldüğünde, pratik uygulamalarda daha uygun bir alternatif olarak değerlendirilebileceği belirlenmiştir.

### Yazar Katkı Oranı

İK: Uygulama, Analiz, Yazma; BK: Analiz, Yazma; BB: Danışmanlık, Eleştirel İnceleme; TB: Fikir, Tasarım, Danışmanlık, Eleştirel İnceleme

### Çıkar Çatışması/Çakışması

Yazarlar arasında beyan edilecek herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

### KAYNAKÇA


Bakirman, T., Komurcu, I., & Sertel, E. (2022). Comparative analysis of deep learning based building extraction methods with the new VHR Istanbul dataset. Expert Systems with Applications, 202, 117346 https://doi.org/10.1016/j.eswa.2022.117346

Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation. In Proceedings of the European Conference on Computer Vision (ECCV) (pp. 801–818). https://doi.org/10.1007/978-3-030-01234-2_49

Li, C., Fu, L., Zhu, Q., Zhu, J., Fang, Z., Xie, Y., Guo, Y., & Gong, Y. (2021). Attention enhanced U-Net for building extraction from farmland based on Google and WorldView-2 remote sensing images.Remote Sensing, 13(21), 4411. https://doi.org/10.3390/rs13214411

Pang, Z., Hu, R., Zhu, W., Zhu, R., Liao, Y., & Han, X. (2024). A building extraction method for high-resolution remote sensing images with multiple attentions and parallel encoders combining enhanced spectral information.Sensors, 24(3), 1006. https://doi.org/10.3390/s24031006

Xie, E., Wang, W., Yu, Z., Anandkumar, A., Alvarez, J. M., & Luo, P. (2021). SegFormer: Simple and efficient design for semantic segmentation with transformers. *Advances in neural information processing systems*, *34*, 12077-12090 https://doi.org/10.48550/arXiv.2105.15203

Xu, X., Zhang, H., Ran, Y., & Tan, Z. (2023). High-precision segmentation of buildings with small sample sizes based on transfer learning and multi-scale fusion. Remote Sensing, 15(9), 2436. https://doi.org/10.3390/rs15092436

TUFUAB, (2024). Tarihçe, Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB), Ankara, [Erişim tarihi: 05.12.2024], https://www.tufuab.org.tr/tarihce/sayfa/3


© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Derin Öğrenme ile Yüksek Çözünürlüklü Uydu Görüntülerinden Çok Sınıflı Askeri Uçak Tespiti

**Melih Karamustafa[1] Bahadır Kulavuz[*1], Bülent Bayram[1], Tolga Bakırman[1]**

*[1]Yıldız Teknik Üniversitesi, İnşaat Fakültesi, Harita Mühendisliği Bölümü, İstanbul, Türkiye, melih.karamustafa@std.yildiz.edu.tr*

**Anahtar Kelimeler**
Obje Tespiti,
Uydu Görüntüleri,
Derin Öğrenme,
YOLOv12,
QGIS

**ÖZET**

Bu çalışmada, yüksek çözünürlüklü uydu görüntülerinden askeri uçakların tespiti amacıyla derin öğrenme tabanlı mimari olan YOLOv12 modeli eğitilmiştir. Savunma ve istihbarat alanındaki kritik ihtiyaçlar doğrultusunda, uzaktan algılama verilerinden askeri teçhizatın doğru ve hızlı bir şekilde belirlenmesi amaçlanmıştır. Modelin eğitimi için, çeşitli açılardan ve koşullarda çekilmiş askeri uçak görüntülerini içeren açık kaynaklı "MAR:20" veri kümesi kullanılmıştır. Yüksek performanslı Kaggle platformunda gerçekleştirilen eğitim sonucunda, YOLOv12 modeli %76,6 mAP (50:95) başarımı elde etmiştir. Modelin farklı platformlarda kullanılabilirliğini artırmak amacıyla ONNX formatına dönüştürülmüş ve coğrafi bilgi sistemlerine entegrasyonu "Deepness" adlı özel bir QGIS eklentisi ile sağlanmıştır. Bu entegrasyon, eğitilmiş modelin doğrudan QGIS ortamında çalıştırılarak uydu görüntüleri üzerindeki askeri nesnelerin konumsal analizlerinin etkin bir şekilde yapılabilmesine olanak tanımaktadır. Bu durum, askeri nesnelerin konumlarının belirlenmesi, dağılımlarının analizi ve zaman içindeki değişimlerinin izlenmesi gibi savunma ve istihbarat uygulamaları için önemli katkılar sunmaktadır. Geliştirilen bu sistem, karar destek mekanizmalarını güçlendirerek operasyonel verimliliği artırmayı amaçlamaktadır.

# Multi-Class Military Aircraft Detection from High-Resolution Satellite Images with Deep Learning

**Keywords**
Object Detection,
Satellite Images,
Deep Learning,
YOLOv12,
QGIS

**ABSTRACT**

In this study, the deep learning-based architecture YOLOv12 model was trained for the detection of military aircraft from high-resolution satellite images. Driven by the critical needs in the defense and intelligence sectors, the aim was to accurately and rapidly identify military equipment from remote sensing data. For the model training, the open-source "MAR:20" dataset, which includes military aircraft images captured from various angles and under different conditions, was used. As a result of the training conducted on the high-performance Kaggle platform, the YOLOv12 model achieved a mean Average Precision (mAP) of 76.6% (at IoU thresholds 0.50 to 0.95). To enhance the model's usability across different platforms, it was converted to the ONNX format, and its integration into geographic information systems was achieved through a custom QGIS plugin named "Deepness". This integration enables the effective spatial analysis of military objects on satellite images by directly running the trained model within the QGIS environment. This capability offers significant contributions to defense and intelligence applications such as determining the locations of military objects, analyzing their distribution, and monitoring their changes over time. The developed system aims to enhance operational efficiency by strengthening decision support mechanisms.

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Karamustafa M, Kılavuz B, Bayram B & Bakırman T (2025). Derin Öğrenme ile Yüksek Çözünürlüklü Uydu Görüntülerinden Çok Sınıflı Askeri Uçak Tespiti, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

TASLAK

## 1. GİRİŞ

Günümüzde, uzaktan algılama teknolojilerindeki hızlı gelişmeler, uydu görüntülerinden elde edilen verilerin analizini kritik bir hale getirmiştir (Zhang et al., 2016; Ma et al., 2019). Bu görüntüler, askeri stratejilerin belirlenmesi, sınır güvenliği, istihbarat faaliyetleri ve afet yönetimi gibi hayati uygulamalarda kullanılabilmektedir. Ayrıca, geniş alanları kapsayabilme, erişilmesi güç bölgelerin izlenebilmesi ve çevresel değişimlerin düzenli olarak takip edilebilmesi gibi avantajlar da uzaktan algılamanın sivil ve askeri alanda vazgeçilmez bir araç olmasını sağlamaktadır (Lillesand vd., 2015; Toth & Jóźków, 2016).

Yüksek çözünürlüklü uydu görüntülerinin stratejik nesnelerin, özellikle hava araçlarının tespitinde sunduğu avantajlar da göz önünde bulundurulduğunda (Cheng & Han, 2016), görüntülerin manuel analizi sürecinin zaman alıcı ve hataya açık olduğu anlaşılmaktadır (Li et al., 2020). Bu noktada, derin öğrenme tabanlı yaklaşımlar, daha yüksek doğruluk ve hız ile bu sürecin iyileştirilmesine olanak tanımaktadır (Ren et al., 2017).

Literatürde, askeri ve sivil uçakların uzaktan algılama görüntülerinden tespitine yönelik çeşitli çalışmalar dikkat çekmektedir. Örneğin, Bakırman (2023) tarafından oluşturulan HRPlanes veri seti, derin öğrenme modellerinin bu alandaki başarımını değerlendirmek için önemli bir kaynak sunmaktadır (Bakırman, 2023). Benzer şekilde, Li vd., (2021) tarafından sunulan MAR20 çalışmasında, uzaktan algılama görüntüleri üzerinden askeri uçak tespiti için derin öğrenme teknikleri kullanılmıştır. Ardından Zhang vd., (2022), çok ölçekli dikkat mekanizmaları kullanarak savaş uçaklarının yüksek doğrulukla tespit edilebildiğini ve gerçek zamanlı analiz yeteneklerinin geliştirilebildiğini göstermiştir (Zhang et al., 2022).

Bu çalışmada, yüksek çözünürlüklü uydu görüntülerinden askeri uçak tespiti için Wang et al. (2023) tarafından geliştirilen YOLOv12 modeli kullanılmıştır (Wang et al., 2023). Model eğitim sürecinde veri artırma ve hiperparametre optimizasyonu gibi yöntemler uygulanmıştır. YOLO tabanlı modellerin gerçek zamanlı nesne tespitindeki başarısı ise Redmon ve Farhadi (2018) tarafından ortaya konulan YOLOv3 mimarisiyle desteklenmektedir (Redmon & Farhadi, 2018). Son olarak, tespit edilen uçakların koordinatlarının Coğrafi Bilgi Sistemleri (CBS) ortamında görselleştirilmesi için Longley et al. (2015) tarafından tanımlanan yöntemler temel alınarak QGIS platformu kullanılmıştır (Longley et al., 2015; QGIS Development Team, 2023).

## 2. YÖNTEM

Çalışmada kullanılan uydu görüntüsü veri seti, Dr. Gong Cheng'in GitHub adresinden alınmış yüksek çözünürlüklü MAR:20 adlı uydu görüntülerinde çeşitli tiplerde askeri hava araçlarını içermektedir. 640x640 görüntü boyutlu, 3842 adet uydu görüntüsü mevcuttur. Çalışmanın ilk aşamasında, uydu görüntülerine ait verisetinin Roboflow platformuna aktarılması gerçekleştirilmiştir. modelin eğitim sürecinde veri setine özel veri artırma (data augmentation) teknikleri uygulanmıştır. Bu kapsamda, görüntülere yatay ve dikey çevirme (flip), saat yönünde ve saat yönü tersine 90° döndürme, -21° ile +21° arasında renk tonu (hue) değişimi, maksimum 1.3 piksele kadar bulanıklık (blur) ve %0.61'e kadar rastgele gürültü (noise) ekleme gibi yöntemler kullanılmıştır. Ayrıca, hiperparametreler (learning rate, batch size, epochs vb.) optimize edilerek modelin genel başarımı önemli ölçüde artırılmıştır. Bunun sonuncunda ise 9222 (%80-train), 384 (%10-test) ve 384 (%10-validation) şeklinde ayrılmıştır.

GitHub üzerindeki açık kaynak kodlar referans alınarak YOLOv12 modeli eğitilmiştir. YOLOv12, gerçek zamanlı nesne tespitinde öne çıkan; hız ve doğruluk açısından optimize edilmiş bir derin öğrenme mimarisidir. Önceki sürümlere kıyasla, Dynamic Head, Task-aware Feature Modulation ve Fine-Grained Feature Aggregation gibi gelişmiş bileşenlerle donatılmıştır. Bu sayede, farklı boyutlardaki nesneleri daha yüksek doğrulukla tespit edebilmekte ve düşük çözünürlüklü hedeflerde bile anlamlı sonuçlar sunabilmektedir.

CNN tabanlı bu model, girdi görüntü üzerinde bölgesel tahminler yaparak her bir bölgeye ait nesne sınıfı ve konum bilgisini (bounding box) üretir. YOLOv12'nin en büyük avantajı, görüntüyü tek bir geçişte (single forward pass) analiz ederek yüksek hızda çıktı verebilmesidir. Bu özellik, özellikle uydu görüntülerinde çok sayıda nesnenin yer aldığı sahnelerin işlenmesini kolaylaştırmaktadır.

## 3. BULGULAR

Elde edilen sonuçlar, YOLOv12 modelinin uydu görüntülerinde askeri uçak tespiti konusunda yüksek performans sergilediğini ortaya koymuştur. Belirlenen metriklere göre %76,6 doğruluk elde edilmiştir. Sınıf bazlı doğruluk ise aşağıdaki çizelge üzerinde gösterilmiştir (Tablo 1).

**Tablo 1.** Sınıf bazlı doğruluk tablosu

| Class | Images | Instances | Box(P) | R | mAP 50 | mAP 50-95 |
|---|---|---|---|---|---|---|
| all | 384 | 2394 | 0.941 | 0.939 | 0.967 | 0.766 |
| A1 | 33 | 156 | 0.905 | 0.918 | 0.961 | 0.778 |
| A10 | 16 | 73 | 0.976 | 1 | 0.995 | 0.789 |
| A11 | 15 | 55 | 0.962 | 0.914 | 0.982 | 0.724 |
| A12 | 19 | 67 | 0.981 | 0.758 | 0.988 | 0.681 |
| A13 | 45 | 163 | 0.953 | 1 | 0.993 | 0.803 |
| A14 | 49 | 183 | 0.96 | 1 | 0.994 | 0.829 |
| A15 | 16 | 112 | 0.91 | 0.694 | 0.923 | 0.67 |
| A16 | 33 | 294 | 0.997 | 0.979 | 0.995 | 0.88 |
| A17 | 34 | 132 | 0.932 | 0.935 | 0.955 | 0.801 |
| A18 | 6 | 24 | 0.893 | 0.958 | 0.939 | 0.842 |
| A19 | 31 | 92 | 0.845 | 0.891 | 0.909 | 0.684 |
| A2 | 44 | 276 | 0.986 | 0.964 | 0.993 | 0.871 |
| A20 | 24 | 81 | 0.924 | 0.897 | 0.964 | 0.657 |
| A3 | 30 | 109 | 0.984 | 0.95 | 0.99 | 0.773 |
| A4 | 14 | 60 | 0.977 | 1 | 0.995 | 0.853 |
| A5 | 29 | 164 | 0.844 | 0.988 | 0.983 | 0.688 |
| A6 | 9 | 29 | 0.923 | 0.8 | 0.858 | 0.665 |
| A7 | 21 | 63 | 0.884 | 0.96 | 0.96 | 0.753 |
| A8 | 28 | 142 | 0.996 | 0.993 | 0.997 | 0.874 |
| A9 | 20 | 119 | 0.979 | 0.983 | 0.995 | 0.827 |

## 4. TARTIŞMA

Elde edilen sonuçlar, nesne tespiti alanında YOLOv12 modelinin şeklin sol tarafındaki görselde olduğu gibi genel anlamda yeterli bir performans sergilediğini göstermektedir. Ancak bazı durumlarda şeklin sağ tarafındaki görseldeki gibi sınıfları karıştırabilmektedir. (Şekil 1.)




**Şekil 1.** Örnek test sonuçları

YOLOv12 modeli, eğitim sürecinin ardından ONNX formatına dönüştürülerek, "Deepnes" adlı özel bir QGIS eklentisine başarıyla entegre edilmiştir. Bu entegrasyon, derin öğrenme tekniklerinin uydu görüntüsü analizinde ne kadar etkili olduğunu gösterirken, aynı zamanda modelin CBS altyapısına uyum sağlayarak gerçek dünya uygulamalarında kullanılabilirliğini de kanıtlamıştır.

## 5. SONUÇ

Bu çalışma, derin öğrenme temelli nesne tespit yöntemlerinin uydu görüntüleri analizinde kullanımını ve entegrasyonunu inceleyen yenilikçi bir yaklaşım sunmaktadır. YOLOv12 modelinin performansı, askeri uçak tespiti için etkili bir araç olduğunu gösterirken, QGIS eklentisi sayesinde bu modelin pratik CBS uygulamalarına entegre edilebileceği kanıtlanmıştır.

### Yazar Katkı Oranı

MK: Uygulama, Analiz, Yazma; BK: Analiz, Yazma; BB: Danışmanlık, Eleştirel İnceleme; TB: Fikir, Tasarım, Danışmanlık, Eleştirel İnceleme

### Çıkar Çatışması/Çakışması

Yazarlar arasında beyan edilecek herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

### KAYNAKÇA

Bakırman, T. (2023). HRPlanes: A High-Resolution Dataset for Aircraft Detection in Remote Sensing Images. Remote Sensing, 15(4), 1123.

Cheng, G., & Han, J. (2016). A survey on object detection in optical remote sensing images. ISPRS Journal of Photogrammetry and Remote Sensing, 117, 11–28.

Li, X., et al. (2020). Deep learning for remote sensing image classification: A survey. IEEE Geoscience and Remote Sensing Magazine, 8(2), 41–70.

Li, Y., et al. (2021). MAR20: A Benchmark for Military Aircraft Recognition in Remote Sensing Images. IEEE Transactions on Geoscience and Remote Sensing.

Lillesand, T., Kiefer, R. W., & Chipman, J. (2015). Remote Sensing and Image Interpretation (7th ed.). Wiley.

Longley, P. A., Goodchild, M. F., Maguire, D. J., & Rhind, D. W. (2015). Geographic Information Science & Systems. Wiley.

Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., & Johnson, B. A. (2019). Deep learning in remote sensing applications: A meta-analysis and review. ISPRS Journal of Photogrammetry and Remote Sensing, 152, 166–177.

QGIS Development Team. (2023). QGIS Geographic Information System. Open Source Geospatial Foundation.

Redmon, J., & Farhadi, A. (2018). YOLOv3: An Incremental Improvement. arXiv preprint arXiv:1804.02767.

Ren, S., He, K., Girshick, R., & Sun, J. (2017). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. IEEE Transactions on Pattern Analysis and Machine Intelligence, 39(6), 1137–1149.

Toth, C., & Jóźków, G. (2016). Remote sensing platforms and sensors: A survey. ISPRS Journal of Photogrammetry and Remote Sensing, 115, 22–36.

Wang, C. Y., Bochkovskiy, A., & Liao, H. Y. M. (2023). YOLOv12: Real-Time Object Detection with Enhanced Feature Fusion. arXiv preprint arXiv:2305.14412.

Zhang, X., Wang, Y., & Du, B. (2016). Object detection in optical remote sensing images: Advances and challenges. ISPRS Journal of Photogrammetry and Remote Sensing, 120, 1–15.

Zhang, Y., Liu, J., Wang, C., & Zhou, Y. (2022). Multi-scale Attention Networks for Aircraft Detection in High-Resolution Remote Sensing Images. IEEE Transactions on Geoscience and Remote Sensing, 60, 1–14.

https://github.com/roboflow/notebooks/blob/main/notebooks/train-yolov12-object-detection-model.ipynb

https://roboflow.com/

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

HASAK

**TUFUAB XIII. TEKNİK SEMPOZYUMU**

https://tufuab2025.beun.edu.tr

# İnsansız Hava Araçlarında İrtifa Tahmini İçin Derin Öğrenme Yaklaşımı

**Ahmet Ertuğrul ARIK**

**Anahtar Kelimeler**
Uzaktan Algılama,
Bilgisayarlı Görü,
Görüntü İşleme

**ÖZET**

Son yıllarda insansız hava araçlarının (İHA) çeşitli kritik görevlerde giderek daha önemli hale gelmesi, doğru ve güvenilir irtifa tahmini yapılmasını gerektirmektedir. GPS ve barometrik sensörler gibi geleneksel irtifa ölçüm yöntemleri genellikle çevresel faktörler nedeniyle sınırlamalarla karşılaşmaktadır. Bu çalışma, yerleşik kameralar tarafından alınan NADIR görüntülerini kullanarak irtifa tahmini için görsel tabanlı bir derin öğrenme yaklaşımı önermektedir. Farklı çevresel koşullar altında 300.000'den fazla görüntü içeren büyük ve çeşitli bir veri kümesi kullanılmıştır. Önceden eğitilmiş bir ResNet50 evrişimli sinir ağı, bu görüntülerden irtifa tahmini yapmak üzere regresyon görevleri için uyarlanmıştır. Model, test veri kümesinde 11,804 metre ortalama mutlak hata (MAE) ve 0,9712 $R^2$ puanı elde ederek yüksek tahmin doğruluğu göstermiştir. Sonuçlar, önerilen yöntemin geleneksel sensörlere güvenilir bir alternatif veya tamamlayıcı olarak hizmet edebileceğini ve İHA navigasyon ve görev planlama yeteneklerini geliştirebileceğini göstermektedir. Gelecekteki çalışmalar, zorlu koşullarda model performansını iyileştirmeye ve ek sensör verilerini entegre etmeye odaklanacaktır.

**Keywords**
Remote sensing,
Computer Vision,
Image Processing

**ABSTRACT**

In recent years, unmanned aerial vehicles (UAVs) have become increasingly important in various critical missions, necessitating accurate and reliable altitude estimation. Traditional altitude measurement methods such as GPS and barometric sensors often face limitations due to environmental factors. This study proposes a vision-based deep learning approach for UAV altitude estimation using NADIR images captured by onboard cameras. A large and diverse dataset comprising over 300,000 images under different environmental conditions was utilized. A pre-trained ResNet50 convolutional neural network was adapted for regression tasks to estimate altitude from these images. The model achieved a mean absolute error (MAE) of 11.804 meters and an $R^2$ score of 0.9712 on the test dataset, demonstrating high predictive accuracy. The results suggest that the proposed method can serve as a reliable alternative or complement to traditional sensors, enhancing UAV navigation and mission planning capabilities. Future work will focus on improving model performance in challenging conditions and integrating additional sensor data.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Makine Öğrenmesi Yöntemleri Kullanılarak Zonguldak İli için Taşkın Riski Değerlendirmesi

**Aydın Furkan Terzi*[1,2], Gülşah Kılıç[2], Ayşenur Koçyiğit[2], Koray Aksu[2], Hande Demirel[2]**

[1]*Milli Savunma Üniversitesi, Hava Harp Okulu, Askeri Bilimler Bölümü, İstanbul, Türkiye*
[2]*İstanbul Teknik Üniversitesi, İnşaat Fakültesi, Harita Mühendisliği Bölümü, İstanbul, Türkiye*

**Anahtar Kelimeler**
Afet yönetimi,
Coğrafi Bilgi Sistemi (CBS),
Makine öğrenmesi,
Risk azaltma,
Taşkın riski

**ÖZET**

Türkiye'de en çok yaşanan doğal afetlerin başında gelen sel ve taşkın; iklim değişikliği, düzensiz kentleşme ve altyapı yetersizlikleri gibi çeşitli faktörlerin etkisiyle kent yaşamını tehdit etmektedir. Bu çalışmanın temel amacı Zonguldak ilinin taşkın riskini makine öğrenmesi algoritmaları ve Coğrafi Bilgi Sistemleri (CBS) yardımıyla analiz etmektir. Bu amaç doğrultusunda, CBS ile entegre bir şekilde literatürde sıklıkla kullanılan ve doğruluk oranı yüksek olan makine öğrenmesi algoritmalarından Rastgele Orman yöntemi kullanılmıştır. Çalışmada; geçmiş taşkın olaylarından faydalanılarak eğim, bakı, yükseklik, yağış, drenaj yoğunluğu, akarsuya uzaklık ve arazi kullanımı gibi önemli çevresel parametreler belirlenmiş ve analiz edilmiştir. Makine öğrenmesi algoritmasıyla geliştirilen modelde, bu parametrelerin taşkın riski üzerindeki göreli etkisi değerlendirilmiş ve elde edilen sonuçlar CBS yazılımları aracılığıyla görselleştirilmiştir. Çalışmanın sonucu, karar vericiler için taşkın riskinin mekansal dağılımını ayrıntılı bir biçimde ortaya koymakta ve afet yönetiminin hazırlık ile zarar azaltma aşamalarına bilimsel katkı sunmaktadır. Bu çalışma, yerel yönetimlerin stratejik planlamaları, sürdürülebilir kentleşme politikaları ve risk azaltma projeleri için rehber niteliğinde veri sağlamaktadır.

# Assessment of Flood Risk in Zonguldak Province Utilizing Machine Learning Techniques

**Keywords**
Disaster management,
Geographic Information System (GIS),
Machine learning,
Risk mitigation,
Flood risk

**ABSTRACT**

Floods and inundations represent some of the most frequently encountered natural disasters in Türkiye, significantly endangering urban life due to factors such as climate change and irregular urbanization. This study's primary objective is to evaluate and visualize the flood risk within Zonguldak province at a spatial level. To this end, the Machine Learning algorithm was utilized in an integrated approach with Geographic Information Systems (GIS). During this research, environmental parameters, including slope, aspect, elevation, precipitation, drainage density, proximity to streams, and land use, were identified and analyzed based on historical flood events. The model developed using the Machine learning algorithm assessed the influence of these parameters on flood risk, and the results were represented visually through GIS. The findings of this study elucidate the spatial distribution of flood risk, providing critical insights for decision-makers. Additionally, the study offers scientific contributions that enhance the preparation and damage mitigation stages of disaster management. This study also provides important data for local governments' strategic planning.

## 1. GİRİŞ

Afetler, doğal ve insan kaynaklı olmak üzere iki ana gruba ayrılmaktadır. Avrupa Çevre Ajansı tarafından doğal afet, insan faaliyetlerinden kaynaklanmayan, şiddetli, ani ve yıkıcı değişim olarak tanımlanmaktadır (EEA, t.y.). İnsan kaynaklı afetler ise insan yapımı bir sistemin arızalanmasını içeren, insan kastı, ihmali veya hatasından kaynaklanan olaylardır (Monroe County Emergency Management, t.y.). Afet ve Acil Durum Yönetimi Başkanlığı'na göre ise insan kaynaklı afetler; nükleer, biyolojik ve kimyasal kazalar, taşımacılık kazaları, endüstriyel kazalar, aşırı kalabalıktan meydana gelen kazalar ve göçmen hareketleri gibi olaylardan oluşurken; doğal afetler ise şiddetli soğuklar, kuraklık ve kıtlık gibi yavaş gelişen doğal afetler ile deprem, sel ve su

* **Sorumlu Yazar**
*(aydinfurkan.terzi@msu.edu.tr) ORCID ID 0009-0006-2144-2635
(kilicg18@itu.edu.tr) ORCID ID 0009-0001-1327-6984
(kocyigit19@itu.edu.tr) ORCID ID 0009-0003-7750-8160
(hande.dem.rel@itu.edu.tr) ORCID ID 0000-0003-0338-791X
(aksuko@itu.edu.tr) ORCID ID 0000-0002-0584-0020

**Kaynak Göster (APA):**
Terzi A F, Kılıç G, Koçyiğit, Aksu K & Demirel H (2025). Makine Öğrenmesi Yöntemleri Kullanılarak Zonguldak İli için Taşkın Riski Değerlendirmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

TASLAK

taşkını, toprak kayması, çığ, fırtına, volkanik patlama ve yangın gibi ani gelişen doğal afetler olarak ikiye ayrılmaktadır (AFAD, t.y.)

Doğal afetler, bölgelerin coğrafi özellikleri başta olmak üzere çeşitli etkenlere bağlı olarak değişmektedir. Dünya genelinde meydana gelen doğal afetler incelendiğinde, yaşanan 31 farklı doğal afetin 28 tanesinin meteorolojik olaylardan kaynaklandığı görülmektedir. Ülkemizde de yaşanan doğal afetlerin büyük bir kısmı, meteorolojik kaynaklı olan sel ve taşkın, dolu, don, kuraklık, şiddetli yağış, çığ vb. afetlerdir (AFAD, t.y.). Afet ve Acil Durum Yönetimi Başkanlığı (AFAD) tarafından 2023 yılına ait Afet Yönetim ve Karar Destek Sistemi (AYDES) platformundan elde edilen veriler doğrultusunda yapılan değerlendirmeye göre, Türkiye'de meydana gelen doğal afetlerin büyük bir kısmı sel kaynaklıdır. Bu verilere göre, yaşanan afetlerin %39'u sel ve taşkın, %32'si orman yangını, %16'sı deprem, %11'i heyelan ve %2'si ise çığ ve yoğun kar yağışından kaynaklanmaktadır (AFAD, 2023).

Sel ve taşkın kavramları literatürde sıklıkla birbirinin yerine kullanılsa da farklı durumları ifade etmektedir. Sel, aşırı yağış, hızlı kar erimesi ve güçlü fırtına gibi meteorolojik olayların ardından meydana gelen büyük ölçekli su akışları sonucunda, normalde su altında olmayan alanların geçici olarak suyla kaplanması durumudur. Taşkınlar ise sellerin bir alt türüdür ve aşırı yağışlar, kar erimesi veya barajlardan kontrolsüz su salınımı gibi olaylarla birlikte, akarsuyun yatağından çıkarak çevresindeki alanlara zarar vermesi, günlük yaşamı aksatması ve yerel imkânlarla başa çıkılamayacak ölçekte su birikintilerinin oluşması olarak tanımlanmaktadır (TÜBA, t.y.).

Sel ve taşkınlar, en yaygın görülen ve zarar veren doğal afetler arasında yer almaktadır. Bu doğal afetlerin sıklığı ve şiddeti, iklim değişikliği ve düzensiz kentleşme ile birlikte artmaktadır (Kılıç ve Balçık, 2025). Batı Karadeniz Havzası'nda yer alan Zonguldak, sahip olduğu engebeli ve düzensiz topoğrafyası ve yoğun yağışlı iklimi ile birlikte sel ve taşkın olaylarının sıklıkla yaşandığı bir ildir. Bu havza alanı içerisinde 1956-2016 yılları arasında meydana gelen 225 taşkın olayının 38 tanesi Zonguldak'ta yaşanmıştır. Bu taşkınlar sonucunda Zonguldak'ta 17 can kaybı olmuştur (AFAD Zonguldak, 2021). Buradan da anlaşılacağı üzere sel ve taşkınların detaylı bir şekilde incelenmesi ve risklerin azaltılabilmesi için mekânsal tabanlı analizlere ihtiyaç duyulmaktadır.

Avrupa Birliği Taşkın Direktifi'ne uyum sürecinde havza bazlı taşkın yönetim planları Tarım ve Orman Bakanlığı Su Yönetimi Genel Müdürlüğü tarafından geliştirilmiştir (SYGM, 2007). Zonguldak ilini kapsayan Batı Karadeniz Havzası Taşkın Yöntem Planı'na göre taşkın yönetimi; hazırlık, müdahale, iyileştirme ve zarar azaltma aşamalarını kapsamaktadır. Hazırlık aşamasında hidrolojik ve hidrolik modelleme temelli bir yaklaşım benimsenmiştir. Bu süreçte, taşkın debileri, taşkın yayılım alanları ve derinlikleri hesaplanarak, farklı tekrar sürelerine göre taşkın tehlike ve risk seviyeleri belirlenmiştir (SYGM, 2019). Taşkın riski analizlerinde hidrolojik ve hidrolik modelleme dışında Coğrafi Bilgi Sistemlerinin (CBS) entegre şekilde Çok Kriterli Karar Verme Yöntemleri (ÇKYY), makine öğrenmesi ve derin öğrenme algoritmaları kullanılmaktadır. Bu yöntemler arasında özellikle makine öğrenmesi, büyük veri setlerini işleyebilme ve karmaşık ilişkileri tanımlayabilme kabiliyeti sayesinde öne çıkmaktadır (Khosravi vd., 2019).

Bu çalışmanın temel amacı, açık kaynaklı veri platformlarından elde edilen veriler aracılığıyla Zonguldak ilinin taşkın riskinin mekansal olarak çeşitli çevresel ve yapısal parametreler doğrultusunda değerlendirilmesidir. Taşkın riski değerlendirmesi, literatürde yaygın olarak kullanılan ve mekansal analizlerde doğruluğu yüksek sonuçlara ulaşılmasını sağlayan makine öğrenmesi algoritmalarından Rastgele Orman (RO) yöntemi ile gerçekleştirilmiştir.

## 2. YÖNTEM

Bu çalışmada, taşkın riskinin belirlenmesi ve görselleştirilmesi amacıyla CBS ile entegre bir şekilde makine öğrenmesi yaklaşımlarından RO algoritması kullanılmıştır. Çalışmanın yöntemi Şekil 1'de gösterilen dört adımdan oluşmaktadır. İlk adımda, literatür taraması doğrultusunda taşkın riskine etki eden çevresel parametreler belirlenmiştir. Bu parametreler arasında eğim, bakı, yükseklik, yağış, akarsuya uzaklık, arazi kullanımı, nüfus yoğunluğu ve ulaşım yoğunluğu yer almakta olup, söz konusu değişkenler aynı hücre boyutlarına sahip raster formatında katmanlara dönüştürülerek analiz için uygun hale getirilmiştir.

İkinci adımda, çalışma alanında geçmiş yıllarda meydana gelen sel ve taşkın olayları geçmişteki haber kaynakları ve tarihi sel taşkınlarından elde edilerek taşkın olan ve olmayan noktalar modele girdi olarak sağlanmıştır. Bu veriler, modelin doğruluğunu test edebilmek amacıyla %30 test seti ve %70 eğitim seti olarak ikiye ayrılmıştır.

Üçüncü adımda, belirlenen parametrelerin kullanıldığı RO algoritması ile taşkın riskini tahmin eden bir sınıflandırma modeli geliştirilmiştir. Bu model sayesinde, her bir parametrenin taşkın riski üzerindeki etkisi "feature of importance" (değişken önem düzeyi) yöntemiyle değerlendirilmiş ve modelin karar verme süreci şeffaf hale getirilmiştir. Üretilen modelin performansının ölçülmesi için ROC-AUC (Alıcı Çalıştırma Özellik Eğrisinin Altında Kalan Alan) skoru kullanılmıştır.

Son adımda ise, modelin çıktıları CBS ortamında görselleştirilerek taşkın riski haritası oluşturulmuştur. Üretilen bu harita, taşkın riskinin alansal dağılımını göstererek karar vericiler için önemli bir rehber niteliği taşımaktadır. Çalışma, afet yönetiminin hazırlık ve risk azaltma evrelerine katkı sağlamayı, yerel yönetimlerin stratejik planlamalarına bilimsel veri desteği sunmayı ve taşkın gibi doğal afetlerin etkilerini azaltmaya yönelik uygulamalara altyapı oluşturmayı amaçlamaktadır.

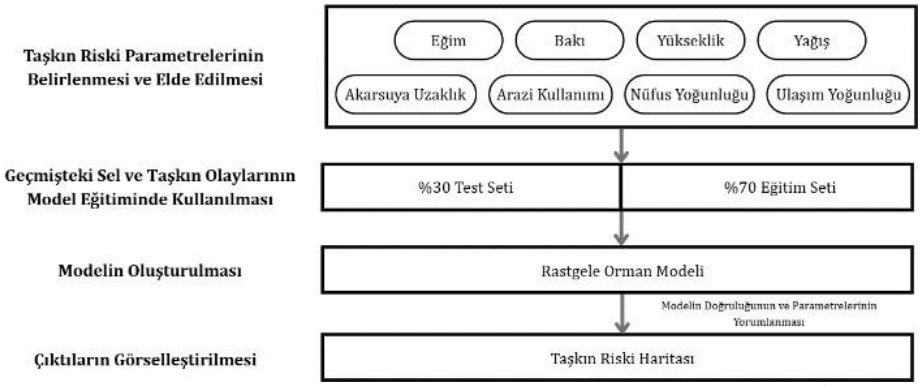


**Şekil 1.** Sistem mimarisi.

**KAYNAKÇA**


AFAD Zonguldak, (2021). Zonguldak İl Afet Risk Azaltma Planı (İRAP), T.C. İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı, Ankara, [Erişim Tarihi: 14.04.2025], https://zonguldak.afad.gov.tr/kurumlar/zonguldak.afa d/Genel/ZONGULDAK_IRAP.pdf

AFAD, (2023). 2023 yılı doğa kaynaklı olay istatistikleri, T.C. İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı, Ankara, [Erişim Tarihi: 14.04.2025], https://www.afad.gov.tr/kurumlar/afad.gov.tr/e_Kutup hane/Istatistikler/2023yilidogakaynakliolayistatistikler i-_1_.pdf

AFAD, (t.y.). Afet Türleri, T.C. İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı, Ankara, [Erişim Tarihi: 14.04.2025], https://www.afad.gov.tr/afet-turleri

EEA, (t.y.). Natural disaster, European Environment Agency, Kopenhang, [Erişim Tarihi: 14.04.2025], https://www.eea.europa.eu/help/glossary/eea-glossary/natural-disaster

Khosravi, K., Shahabi, H., Pham, B. T., Adamowski, J., Shirzadi, A., Pradhan, B., Dou, J., Ly, H., Gróf, G., Ho, H. L., Hong, H., Chapi, K., & Prakash, I. (2019). A comparative assessment of flood susceptibility modeling using Multi- Criteria Decision-Making Analysis and Machine Learning Methods. Journal of Hydrology. https://doi.org/10.1016/j.jhydrol.2019.03.073

Kılıç, G., & Balçık, F. B. (2025). Flood-Risk Map for Büyükçekmece District Based on Socioeconomic Factors. The 8th International Electronic Conference on Water Sciences, Online. https://doi.org/10.3390/eesp2025032011

Monroe County Emergency Management, (t.y.). Man-made disaster, Florida, [Erişim Tarihi: 14.04.2025], https://www.monroecounty-fl.gov/904/Man-Made-Disaster#:~:text=Man%2Dmade%20disasters%20have %20an,%2C%20cyber%2Dattacks%2C%20etc.

SYGM, (2007). Taşkın Direktifi (2007/60/EC) – AB Mevzuatı Türkçe Çeviri, T.C. Tarım ve Orman Bakanlığı Su Yönetimi Genel Müdürlüğü, Ankara, [Erişim Tarihi: 14.04.2025], https://www.tarimorman.gov.tr/SYGM/Belgeler/ab%20mevzuat%C4%B1/taskin_direktifi.pdf

SYGM, (2019). Batı Karadeniz Taşkın Yönetim Planları [PDF dosyası], T.C. Tarım ve Orman Bakanlığı Su Yönetimi Genel Müdürlüğü, Ankara, [Erişim Tarihi: 14.04.2025], https://www.tarimorman.gov.tr/SYGM/Belgeler/Taşkın%20Yönetim%20Planları%2026.12.2022/Batı%20Kar deniz%20Taşkın%20Yönetim%20Planları.pdf

TÜBA, (t.y.). Türkçe Bilim Terimleri Sözlüğü, Türkiye Bilimler Akademisi, Ankara, [Erişim Tarihi: 14.04.2025], http://terim.tuba.gov.tr/


© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

**TUFUAB XIII. TEKNİK SEMPOZYUMU**
https://tufuab2025.beun.edu.tr

# Bornova Havzasında Fırtına Kabarmalarından Kaynaklanan Kıyı Taşkını Riskinin Değerlendirmesi: Senaryo Tabanlı Bir Yaklaşım

**Çiğdem Coşkun Hepcan[*1], Ahsen Tuğçe Yüksel[3], Aybüke Cangüzel[2], Şerif Hepcan[1], Yusuf Biçer[3] Ioan Cristian Ioja[4], Jürgen Breuste[5]**

*[1]Ege Üniversitesi, Ziraat Fakültesi, Peyzaj Mimarlığı Bölümü, İzmir, Türkiye*
*[2]Ege Üniversitesi, Fen Bilimleri Enstitüsü, Peyzaj Mimarlığı Anabilim Dalı, İzmir, Türkiye*
*[3]T.C. Çevre Şehircilik ve İklim Değişikliği Bakanlığı, Tapu ve Kadastro Genel Müdürlüğü, Ankara, Türkiye*
*[4]University of Bucharest, Department of Geography, Bucharest, Romania*
*[4]University of Hildesheim, Department of Geography, Hildesheim, Germany*

**Anahtar Kelimeler**
Fırtına kabarması,
Sel maruziyeti,
İklim dirençliliği,
Kıyı taşkını riski,
Maruziyet analizi

**ÖZET**

Deniz seviyesi yükselmesi, iklim değişikliğinin en görünür ve etkili sonuçlarından biri haline gelmiş ve özellikle kıyı kentlerinde ciddi riskler oluşturmuştur. Nüfus yoğunluğu, altyapı birikimi ve ekonomik faaliyetlerin kıyı bölgelerinde yoğunlaşması bu alanları son derece kırılgan hale getirmektedir. Şiddetli hava olaylarıyla birleşen fırtına kabarmaları, yerleşim alanları, ulaşım hatları ve su kaynakları için büyük tehdit oluşturmaktadır. Özellikle alçak kotlu bölgelerde bu riskler daha sık ve şiddetli görülmekte; bu da yerel yönetimlerin uyum stratejilerini hızla geliştirmesini zorunlu kılmaktadır. Bu çalışma, İzmir Körfezi'nin doğusunda yer alan ve Bornova ile Bayraklı ilçelerini kapsayan Bornova Havzası'nda fırtına kabarmasına bağlı kıyı taşkını riskini değerlendirmektedir (149,14 km$^2$; nüfus: 600.158). AFAD tarafından afet riski taşıyan alanlar olarak sınıflandırılan bu ilçeler için yüksek çözünürlüklü veri setleri (0.1 m DTM ve DSM, dört bantlı hava fotoğrafları, IPCC-6 tahminleri, TUDES verileri, bina ve nüfus verileri) ArcGIS yazılımı ile analiz edilmiştir. 2000–2024 dönemine ait verilerle oluşturulan senaryolar: iyimser (2,41 m), orta (3,16 m) ve kötü (4,30 m) olmak üzere üç farklı fırtına kabarması düzeyini temsil etmektedir. Buna göre sırasıyla 2,10 km$^2$, 3,13 km$^2$ ve 4,41 km$^2$ alanın etkilenmesi beklenmektedir. Deniz suyunun kara içine ilerlemesi en kötü senaryoda 1,6 km'ye kadar ulaşmaktadır. Etkilenen alanların %60'ından fazlası yapılaşmış bölgelerden oluşmakta; nüfusun ise %14–59'u bu riske maruz kalmaktadır. Sonuçlar, kıyı taşkını risklerinin yalnızca çevresel değil, aynı zamanda sosyoekonomik tehditler de barındırdığını ortaya koymakta; erken uyarı sistemleri, doğa temelli çözümler ve dirençli altyapı gibi uyum stratejilerinin gerekliliğini vurgulamaktadır.

# Assessing Coastal Flood Risk from Storm Surges in Bornova Watershed: A Scenario-Based Approach

**Keywords**
Storm surge,
Flood exposure,
Climate resilience,
Coastal flood risk,

**ABSTRACT**

Sea level rise has become one of the most visible and impactful consequences of climate change, particularly threatening coastal cities due to their high population density, infrastructure concentration, and economic activity. When coupled with severe weather events, storm surges significantly increase the risk to residential areas, transportation

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Coşkun Hepcan Ç, Yüksel A T, Cangüzel A, Hepcan Ş, Biçer Y, Ioja I C & Breuste J (2025). Bornova Havzasında Fırtına Kabarmalarından Kaynaklanan Kıyı Taşkını Riskinin Değerlendirmesi: Senaryo Tabanlı Bir Yaklaşım, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

Exposure analysis

networks, and water resources. Low-lying coastal zones are especially vulnerable, highlighting the urgent need for local climate adaptation strategies.

This study assesses the coastal flood risk from storm surges in the Bornova Watershed, located in the eastern part of İzmir Bay, encompassing the districts of Bornova and Bayraklı (149.14 km$^2$, population 600,158). These densely urbanized districts are classified as high-risk areas by AFAD. The study integrates high-resolution datasets, including 0.1 m DTM and DSM from the General Directorate of Land Registry and Cadastre (TKGM), four-band aerial imagery, tide data from the Turkish National Sea Level Monitoring System (TUDES), IPCC-6 projections, and demographic and building data.

Three storm surge scenarios were modeled based on TUDES data from 2000–2024: optimistic (2.41 m), moderate (3.16 m), and worst-case (4.30 m). Analyses conducted via ArcGIS reveal flood-affected areas of 2.10 km$^2$, 3.13 km$^2$, and 4.41 km$^2$, respectively, with seawater reaching up to 1.6 km inland. Over 60% of these areas are built-up, and up to 59% of the population could be exposed under the worst-case scenario.

The findings emphasize the urgent need for early warning systems, resilient infrastructure, and nature-based solutions to reduce the socio-environmental risks posed by coastal flooding.

## GİRİŞ

Fırtına kabarması (storm surge), deniz seviyesindeki ani ve geçici yükselmeler yoluyla kıyı kentlerinde ciddi çevresel ve sosyoekonomik tehditler oluşturmaktadır. İklim değişikliğinin etkisiyle bu olayların sıklığı ve şiddetinde artış beklenmekte; deniz seviyesindeki genel yükselme eğilimiyle birlikte etkileri daha yıkıcı hale gelmektedir (IPCC, 2021). Özellikle düşük rakımlı ve yoğun yapılaşmaya sahip kıyı kentlerinde fırtına kabarmaları, kentsel alt ve üst yapılar üzerinde baskı oluşturarak kent sistemlerinin işleyişini tehdit etmektedir.

Birçok kıyı kenti gibi İzmir de kıyı taşkınlarından etkilenmekte; bu durum kentsel işleyişi bozmakta ve kayıplara yol açmaktadır. Bu nedenle, afet risklerini azaltmaya yönelik maruziyet ve risk analizleri büyük önem taşımaktadır. Bu çalışma, İzmir Körfezi'nin doğusunda yer alan Bornova Havzası'nda fırtına kabarmasına bağlı kıyı taşkını riskini üç senaryo üzerinden değerlendirerek, yapısal ve mekânsal maruziyet düzeylerini analiz etmeyi amaçlamaktadır.

## ARAŞTIRMA ALANI

Bu çalışma, İzmir Körfezi'nin doğusunda yer alan ve kentin merkez kıyı ilçelerinden Bornova ile Bayraklı'yı kapsayan Bornova Havzası'nda (38°30'-38°21' K; 27°10'-27°21' D) gerçekleştirilmiştir. Yapılaşmanın son derece yoğun olduğu bir bölgeyi kapsayan toplam büyüklüğü 149,14 km$^2$' olan havzada, 2023 yılı verilerine göre 600.158 kişi yaşamaktadır (TÜİK, 2024). Havzada yıllık ortalama sıcaklık 18 °C, ortalama yağışlı gün sayısı 77, yıllık toplam yağış miktarı ise 712,1 mm'dir. Yağışların büyük çoğunluğu Aralık ile Mart ayları arasında düşmektedir (TSMS, 2025).

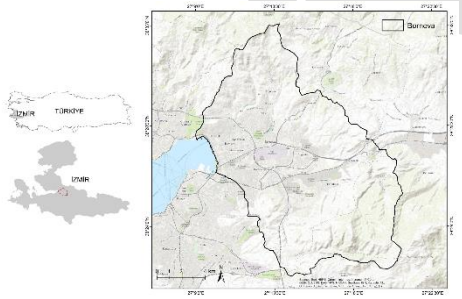


**Şekil 1.** Araştırma alanı

## YÖNTEM

Çalışmada, Tapu ve Kadastro Genel Müdürlüğü'nden temin edilen 0.1 m çözünürlüklü DTM ve DSM verileri, Harita Genel Müdürlüğü'ne ait dört bantlı hava fotoğrafları, Türkiye Ulusal Deniz Seviyesi İzleme Sistemi'ne (TUDES) ait Menteş istasyonu verileri, IPCC-6 raporunda belirtilen Akdeniz Bölgesi öngörüleri, bina ve Türkiye İstatistik Kurumu'nun adrese dayalı nüfus kayıt sistemi veri tabanından elde edilen 1 km$^2$ nüfus ızgara verisi (TÜİK, 2024) ile birlikte değerlendirilmiştir. Arazi kullanım haritası, hava fotoğraflarının nesne tabanlı sınıflandırılması (segmentation) ile oluşturulmuştur.

İklim değişikliğine bağlı deniz seviyesi yükselmesi için IPCC-6 raporunda belirtilen 1.10 m'lik değer kullanılmış (IPCC, 2022), fırtına kabarması için ise TUDES'in 2000-2024 verileri değerlendirilerek İzmir için üç farklı senaryo oluşturulmuştur: İyi senaryo: 2.41 m, Orta senaryo: 3.16 m, Kötü senaryo: 4.30 m. ArcGIS 10.8.2 yazılımı ile DTM, DSM, bina, nüfus ve arazi kullanım verileri üzerinden maruziyet analizleri gerçekleştirilmiştir.

## BULGULAR

Araştırma bulguları fırtına kabarmasına bağlı deniz seviyesi yükselmesinin senaryolara göre sırasıyla 2.10 km$^2$, 3.13 km$^2$ ve 4.41 km$^2$'lik alanı etkilediğini göstermektedir (Şekil 2).

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Coşkun Hepcan Ç, Yüksel A T, Cangüzel A, Hepcan Ş, Biçer Y, Ioja I C & Breuste J (2025). Bornova Havzasında Fırtına Kabarmalarından Kaynaklanan Kıyı Taşkını Riskinin Değerlendirmesi: Senaryo Tabanlı Bir Yaklaşım, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

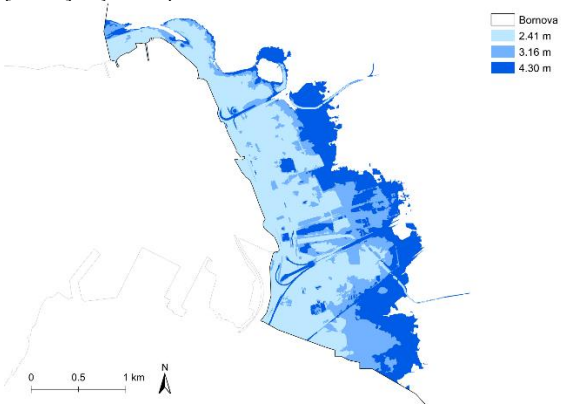


**Şekil 2.** Fırtına kabarması bulguları

Deniz suyunun kara içerisine ilerlemesi ise ortalama olarak iyi senaryoda 900 m, orta senaryoda 1450 m, kötü senaryoda ise 1600 m olarak belirlenmiştir. Etkilenen alanların %60'ından fazlası yapılaşmış alanlardan oluşmaktadır (Çizelge 1). Kıyı taşkınına maruz kalan nüfus oranı senaryolara göre sırasıyla %14 (iyi), %27 (orta) ve %59 (kötü) olarak hesaplanmıştır (Şekil 2).

**Çizelge 1. A**razi kullanım sınıfları maruziyeti km²

| **Arazi kullanım** | **Deniz seviyesi yükselmesi senaryoları** | | |
|---|---|---|---|
| | 2.41 m | 3.16 m | 4.30 m |
| **Bina** | 0,50 | 0,84 | 1,30 |
| **Yol** | 0,90 | 1,35 | 1,92 |
| **Yeşil alan** | 0,25 | 0,33 | 0,43 |
| **Ağaç** | 0,18 | 0,25 | 0,35 |
| **Toprak** | 0,22 | 0,28 | 0,35 |
| **Su** | 0,03 | 0,03 | 0,03 |

## TARTIŞMA

Bulgular, kıyı taşkınlarından en çok etkilenen alanların, kıyı düzlükleri üzerinde gelişmiş yapılaşmış bölgeler olduğunu ortaya koymaktadır. İzmir kenti Bayraklı ve Bornova, Bornova Ovası üzerine kurulmuş olup, yerleşim zamanla kıyı gerisindeki yamaçlara doğru yayılmıştır. Kentin gelişim süreci boyunca İzmir Körfezi çevresinde dolgu alanları oluşturulmuş ve kentin ana ulaşım hatları bu dolgu alanlar üzerine inşa edilmiştir.

Havzanın kıyı kesimleri, son yıllarda uygulanan kentsel dönüşüm projeleriyle birlikte İzmir'in yeni ticaret ve konut merkezleri haline gelmiştir. Ancak bu durum, kıyı taşkınlarına karşı bu bölgeleri daha hassas hale getirmekte ve yaşamsal faaliyetler üzerinde olumsuz etkiler yaratmaktadır. En kötü senaryoya göre, havza genelinde yaşayan nüfusun %60'ı fırtına kabarmasından etkilenmektedir. Araştırma bulguları, İzmir Büyükşehir Belediyesi'nin taşkın gözlem verileri ve daha önce yapılmış bilimsel çalışmalarla (Sılaydın Aydın vd., 2017) tutarlılık göstermektedir.

## SONUÇ

Sonuç olarak, Bornova Havzası'nda fırtına kabarması kaynaklı kıyı taşkını riski ciddi düzeydedir ve özellikle yapılaşmış alanlar ile yerleşik nüfusu tehdit ederek çevresel ve sosyoekonomik etkiler doğurmaktadır. Bu riskin azaltılması ve etkilerine uyum sağlanması için etkili çözümlerin geliştirilmesi büyük önem taşımaktadır.

Çalışma, farklı senaryolar altında taşkın riski taşıyan alanları ortaya koymakta ve uyum kapasitesinin artırılması gereken bölgeler hakkında önemli veriler sunmaktadır. Kullanılan yüksek çözünürlüklü ve hassas veriler analizlerin doğruluğunu artırmıştır. Kıyı boyunca uzanan yeşil alanlar, taşkın parkları ve ekosistem restorasyonu gibi doğa temelli çözümler önemli fırsatlar sunmakta; bu stratejilerin gri altyapı çözümleriyle entegrasyonu ise afet risklerini azaltmada etkili bir yaklaşım oluşturmaktadır. Bununla birlikte, politika temelli yaklaşımların geliştirilmesi, kentsel alt ve üst yapının iklim değişikliğine dirençli hale getirilmesi, erken uyarı sistemlerinin kurulması ve uygulanması, kentsel dayanıklılığı artıracak ve Sürdürülebilir Kalkınma Amaçları'na ulaşılmasına katkı sağlayacaktır.

## TEŞEKKÜR

Bu çalışma, Avrupa Birliği ve Türkiye Cumhuriyeti tarafından desteklenen İklim Değişikliğine Uyum Hibe Programı kapsamında yürütülen CCAGP-121 numaralı projenin bir çıktısıdır. Yazarlar, değerli katkılarından dolayı Tapu ve Kadastro Genel Müdürlüğü'ne ve Erol Yüksel'e teşekkür eder.

## Yazar Katkı Oranı

Çalışmanın tasarımı ve kurgulanması: CCH, ATY, AC, veri üretimi ve analizi: CCH, ATY, AC, bulguların yorumlanması: CCH, ATY, AC, YB, SH, ICI, görselleştirme: CCH, ATY, AC, bildiri metni yazımı: CCH, ATY, AC, SH, YB, ICI, JB.

## Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

## KAYNAKÇA

AFAD, (2024). İRAP İl Afet Risk Azaltma Planı [Erişim tarihi: 23.04.2024], https://izmir.afad.gov.tr/kurumlar/izmir.afad/E-KUTUPHANE/Il-Planlari/IRAP_Izmir--2024.pdf

Demirkesen, A.C., Evrendilek, F., Berberoglu, S., & Kılıç, S. (2007). Coastal Flood Risk Analysis Using Landsat-7 ETM+ Imagery and SRTM DEM: A Case Study of Izmir, Turkey. Environ Monit Assess 131, 293–300, doi: https://doi.org/10.1007/s10661-006-9476-2.

IPCC, (2022). IPCC (2022) Climate Change 2022: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Sixth Assessment Report of

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Coşkun Hepcan Ç, Yüksel A T, Cangüzel A, Hepcan Ş, Biçer Y, Ioja I C & Breuste J (2025). Bornova Havzasında Fırtına Kabarmalarından Kaynaklanan Kıyı Taşkını Riskinin Değerlendirmesi: Senaryo Tabanlı Bir Yaklaşım, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

the Intergovernmental Panel on Climate Change [H.-O. Pörtner, D.C. Roberts, M. Tignor, E.S. Poloczanska, K. Mintenbeck, A. Alegría, M. Craig, S. Langsdorf, S. Löschke, V. Möller, A. Okem, B. Rama (eds.)]. Cambridge University Press. Cambridge University Press, Cambridge, UK and New York, NY, USA, 3056 pp., doi:10.1017/9781009325844.

Sılaydın Aydın M.B., Erdin H.E., & Kahraman, E,D. (2017). Determination of areas vulnerable to climate change due to spatial structure characteristics. İzmir Plan 27(3):274–285, doi: https://doi.org/10.14744/planlama.2017.61587

TSMS, (2025). Turkish State Meteorological Service https://www.mgm.gov.tr/eng/forecast-cities.aspx?m=IZMIR [Erişim tarihi: 19.05.2024].

TÜİK, (2023). Turkish Statistical Institute. Available online: https://www.tuik.gov.tr/ [Erişim tarihi: 29.10.2024].

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Coşkun Hepcan Ç, Yüksel A T, Cangüzel A, Hepcan Ş, Biçer Y, Ioja I C & Breuste J (2025). Bornova Havzasında Fırtına Kabarmalarından Kaynaklanan Kıyı Taşkını Riskinin Değerlendirmesi: Senaryo Tabanlı Bir Yaklaşım, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# GNSS'siz Navigasyon: Otokodlayıcı Derin Sinir Ağları ile İHA Konumlama Sistemi

**Ahmet Ertuğrul Arık**[*1]

[1]*Kapadokya Üniversitesi, Bilişim Sistemleir ve Teknolojileri Ürgüp*

**Anahtar Kelimeler**
Görsel Tabanlı Navigasyon Derin Öğrenme ile Konumlama, Bilgisayarlı Görü, Görüntü İşleme

**ÖZET**

Bu çalışma, GPS gibi uydu tabanlı konumlandırma sistemlerinin yetersiz veya engellendiği durumlarda insansız hava araçlarının (İHA) konum tespitini geliştirmeyi amaçlamaktadır. Önerilen yöntem, otokodlayıcı (autoencoder) derin sinir ağlarının girdi olarak aldığı uydu görüntüleri ile İHA'nın anlık çektiği NADİR fotoğraflarını işleyerek, şablon eşleme algoritmasıyla mevcut harita üzerinde en benzer konumu bulma esasına dayanmaktadır. Otokodlayıcı, görüntüdeki gürültüyü ve mevsimsel farklılıkları azaltarak kritik yapı özelliklerini vurgular; böylece referans haritalar ve uçuş esnasında alınan görüntüler arasındaki uyum artar. Sistemin etkinliği, şehirsel alanlardan kırsal ve ormanlık bölgelere kadar çeşitli ortamlarda test edilmiştir. Denemeler, ortalama konum hatalarının metre düzeyinde ve genel doğruluğun %80–90 aralığında seyrettiğini göstermiştir. GPS sinyallerinin zayıf ya da hiç mevcut olmadığı ortamlarda dahi yüksek doğrulukta konum tespiti elde edilmiş, bu da deprem veya sel gibi afet bölgelerinde arama-kurtarma çalışmalarından askeri operasyonlara kadar geniş bir kullanım alanı sunmuştur. Ayrıca, yöntem klasik görüntü işleme yaklaşımlarına göre ışık ve mevsim kaynaklı değişimlere daha dayanıklı, uygulama maliyeti daha düşüktür. Gelecek çalışmalar kapsamında farklı sensör verilerinin (lidar, termal kamera vb.) entegre edilmesi veya 3B arazi modellerinin kullanılmasıyla doğruluk ve uyarlanabilirlik daha da artırılabilecektir. Sonuç olarak, bu tez, GNSS bağımlılığını azaltmak ve karmaşık ortamlarda bile güvenilir navigasyon sağlamak adına önemli bir adım teşkil etmektedir.

# GNSS-Denied Navigation: UAV Localization System Based on Autoencoder Deep Neural Networks

**Keywords**
Vision-Based Navigation, Deep Learning-Based Localization, Computer Vision, Image Processing

**ABSTRACT**

This study aims to improve the localization of unmanned aerial vehicles (UAVs) in situations where satellite-based positioning systems, such as GPS, are inadequate or obstructed. The proposed method relies on autoencoder-based deep neural networks that process satellite imagery and real-time nadir photos captured by the UAV, followed by a template matching approach to identify the most similar location on a reference map. The autoencoder reduces noise and seasonal differences while emphasizing critical structural features, thereby enhancing the alignment between reference maps and in-flight images. The system's performance was tested across diverse environments, ranging from urban areas to rural and forested regions. Experiments demonstrated meter-level mean location errors and overall accuracies between 80% and 90%. High-accuracy positioning was achieved even in scenarios where GPS signals were weak or entirely unavailable, offering broad potential applications in disaster relief missions—such as earthquake or flood zones—as well as military operations. Moreover, compared to classical image processing techniques, the proposed approach is more robust against variations in lighting and seasonal conditions, and it is also cost-effective to implement. Future research may incorporate additional sensor data (e.g., lidar, thermal cameras) or 3D terrain models to further enhance accuracy and adaptability. In summary, this thesis represents a critical step toward reducing GNSS dependence and ensuring reliable navigation in complex environments.

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Arık A E (2025). GNSS'siz Navigasyon: Otokodlayıcı Derin Sinir Ağları ile İHA Konumlama Sistemi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

İnsansız hava araçları (İHA), günümüzde savunma, sivil, endüstriyel ve bilimsel pek çok alanda yaygın biçimde kullanılmaktadır (Shakhatreh vd., 2019; Valavanis & Vachtsevanos, 2015). Bu araçlar, afet yönetimi, keşif-gözetleme, tarımsal analiz, güvenlik ve benzeri alanlarda kritik roller üstlenmektedir. Ancak, İHA navigasyon sistemleri çoğunlukla küresel uydu konumlama hizmetlerine (GNSS) bağımlıdır ve GPS sinyallerinin bloke edildiği, zayıf olduğu veya aldatma (spoofing) gibi tehditlere maruz kaldığı durumlarda operasyonel güvenilirlik azalmaktadır (Kerns vd., 2014). Dolayısıyla, uydu tabanlı konumlandırma verilerine bağımlılığı azaltan ya da ortadan kaldıran alternatif bir navigasyon yaklaşımı, İHA'ların kullanım alanlarını önemli ölçüde genişletebilecektir.

Bu genişletilmiş özet, GNSS olmayan veya yetersiz koşullarda İHA'ların güvenilir ve otonom biçimde konum tespiti yapabilmesi için tasarlanmış bir yöntemi ele almaktadır. Yöntem, temel olarak derin öğrenme tabanlı otokodlayıcı (autoencoder) sinir ağı ile şablon eşleme (template matching) prensiplerinin bütünleşmesine dayanmaktadır. Uydu görüntüleri ve İHA'nın aldığı anlık NADİR fotoğraflar, otokodlayıcı mimariyle işlenmekte, ardından ilgili görüntü şablonu harita üzerinde aranarak en yüksek benzerlik bulunan konum, İHA'nın o anki pozisyonu olarak belirlenmektedir. Böylece, GPS gibi harici sinyal kaynaklarına bağımlılık en aza indirilmektedir.

## 2. YÖNTEM

Bu çalışmada, görsel temelli navigasyon sistemi iki temel bileşen üzerinde şekillenmektedir: Otokodlayıcı Derin Sinir Ağı ve Şablon Eşleme Algoritması.

### 2.1. Otokodlayıcı Derin Sinir Ağı

Otokodlayıcılar, girilen yüksek boyutlu veriyi (örneğin uydu veya İHA kamerası görüntüsü) daha düşük boyutlu bir kodlama uzayına sıkıştırıp, ardından tekrar özgün boyutuna geri dönüştürmeyi öğrenen sinir ağlarıdır (Goodfellow vd., 2016). Burada hedef, gürültü, mevsimsel değişim, ışık koşulları gibi değişken faktörlerin etkisini en aza indirerek, görüntülerin "karakteristik" yapısını ortaya çıkarmaktır (Vincent vd., 2010). Otokodlayıcı bu sayede, İHA'nın farklı zaman ya da irtifalarda çektiği fotoğrafları, önceden kaydedilmiş uydu ya da harita görüntüleriyle daha kolay eşleştirilebilecek ortak bir temsile dönüştürür (Fragoso vd., 2021).

### 2.2. Şablon Eşleme (Template Matching)

İkinci aşamada, otokodlayıcıdan elde edilen "işlenmiş" İHA görüntüsü ile referans haritanın aynı boyutlardaki parçaları arasında benzerlik ölçümü yapılır. Genellikle normalize edilmiş çapraz korelasyon (NCC) veya benzeri bir benzerlik metriği kullanılır (Brunelli, 2009). Elde edilen benzerlik haritasındaki en yüksek korelasyon değeri, İHA görüntüsündeki alanın harita üzerinde hangi konuma karşılık geldiğini gösterir. Bu işlem, hem kentsel (binalar, yol ağları, yoğun yapılaşma) hem de kırsal/ormanlık (bitki örtüsü, tarım alanları, farklı mevsimsel dokular) ortamlarda uygulanacak şekilde adapte edilmiştir (Guan & Bai, 2012).

### 2.3. Veri Toplama ve İşleme

Eğitim Verisi: Google Earth veya benzeri platformlardan elde edilen uydu verileri, farklı çözünürlük ve koordinatlarda toplanarak otokodlayıcıya uygun şekilde kırpılmış, yeniden boyutlandırılmış ve normalize edilmiştir.

Test Verisi: Farklı yüksekliklerde ve farklı coğrafi bölgelerde uçan İHA'dan gelen gerçek zamanlı NADİR görüntüleridir. Bu veriler, klasik ön işleme adımlarından (ör. renk düzeltmesi, kontrast ayarı) geçirildikten sonra otokodlayıcıya beslenmiştir.

## 3. BULGULAR

Önerilen yaklaşımın etkinliği, kentsel alanlar (yüksek ve yoğun binalar, düzensiz yol ağları vb.) ile kırsal/ormanlık alanlar (tarım arazileri, ağaçlıklı bölgeler, arazi eğimi) gibi çeşitli ortamlarda yapılan uçuş denemeleriyle değerlendirilmiştir. Hem simülasyon ortamında hem de gerçek uçuş verilerinde elde edilen bulgular şu şekilde özetlenebilir:

Konum Hatası: Ortalama konum hatası çoğu testte metre düzeyinde kalmıştır. Bazı zorlayıcı senaryolarda (düşük irtifa, yoğun gölgeleme, mevsimsel renk farklılıkları) hata artış eğilimi göstermiş olsa da, toplam doğruluk büyük ölçüde %80–90 aralığındadır.

Mevsimsel Dayanıklılık: Otokodlayıcı mimarisi, görüntüdeki bitki örtüsü değişimlerini büyük oranda filtreleyerek, harita-veri eşleştirmesinin başarısını artırmıştır (Wei vd., 2022).

Işık ve Gölge Uyumu: Gölgeleme veya yetersiz aydınlatma gibi faktörler klasik yöntemleri olumsuz etkilerken, otokodlayıcı yaklaşımı gölgeleme kaynaklı gürültüyü bir ölçüde maskeleyerek başarılı konum tespiti sağlamıştır.

## 4. TARTIŞMA

Yapılan deneyler, GPS bağımlılığının en aza indirilebileceğini ve otokodlayıcı sinir ağı ile şablon eşleme kombinasyonunun, zorlayıcı çevre koşullarında dahi İHA'lara güvenilir konumlama olanağı sunduğunu göstermektedir. Bu sonuçlar, GPS verisinin olmadığı senaryolarda savunma, arama-kurtarma ve hassas tarım gibi kritik uygulamaların aksamadan yürütülebilmesi açısından önemlidir (Hou vd., 2021). Ayrıca, gürültü giderme odaklı derin öğrenme yaklaşımlarının, klasik görüntü eşleme yöntemlerine kıyasla daha esnek ve uyarlanabilir olduğu gözlenmiştir. Ancak, çok ağır hava koşulları ya da engellerin aşırı yoğun olduğu kent kanalları (derin sokaklar, tüneller) gibi uç örneklerde, ek sensör füzyonuna (lidar, radar vb.) ihtiyaç duyulabilir.

## 5. SONUÇ

Bu çalışma, İHA'ların GNSS sinyallerine erişimin mümkün olmadığı ya da güvenilirliğin düşük olduğu ortamlarda nasıl konumlandırma yapabileceğine dair yenilikçi ve etkin bir çözüm önermektedir. Otokodlayıcı derin sinir ağıyla gürültü ve mevsimsel farklılıklar azaltıldığında, şablon eşleme ile harita üzerinde doğru bir konum eşleştirmesi yapılabilmektedir. Elde edilen sonuçlar, metre düzeyinde konum hatası ve yüksek

doğruluk oranlarıyla yöntemin pratik kullanılabilirliğini kanıtlamaktadır. Gelecekte, daha gelişmiş 3B arazi modellerinin veya ek sensör verilerinin entegrasyonuyla yöntem daha da güçlendirilebilir. Böylelikle, kentsel hava lojistiğinden afet yönetimine pek çok farklı alanda GNSS bağımlılığının azalması ve güvenilir navigasyonun sürdürülebilmesi hedeflenmektedir.

**KAYNAKÇA**

Brunelli, R. (2009). Template Matching Techniques in Computer Vision: Theory and Practice. Wiley.

Fragoso, V., Lee, K., McCoy, S., & Chung, S. (2021). Robust Visual Terrain-Relative Navigation via Learned Invariant Feature Transformations. IEEE Transactions on Robotics, 37(6), 1817–1832.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.

Guan, G., & Bai, L. (2012). GPU Accelerated Real-Time Self-Contained UAV Visual Navigation System. Journal of Intelligent & Robotic Systems, 65(1–4), 1–14.

Hou, K., Wang, Y., Zhao, B., & Feng, Y. (2021). UAV Positioning Without GNSS: A Structure-from-Motion and Bundle Adjustment Based Method Fused With Satellite Images. Sensors, 21(19), 6571.

Kerns, A. J., Shepard, D. P., Bhatti, J. A., & Humphreys, T. E. (2014). Unmanned aircraft capture and control via GPS spoofing. Journal of Field Robotics, 31(4), 617–636.

Shakhatreh, H., Sawalmeh, A. A., Al-Fuqaha, A., Khreishah, A., Khalil, I., Othman, N. S., & Guizani, M. (2019). Unmanned Aerial Vehicles (UAVs): A Survey on Civil Applications and Key Research Challenges. IEEE Access, 7, 48572–48634.

Valavanis, K. P., & Vachtsevanos, G. J. (Eds.). (2015). Handbook of Unmanned Aerial Vehicles. Springer.

Vincent, P., Larochelle, H., Bengio, Y., & Manzagol, P.-A. (2010). Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. Journal of Machine Learning Research, 11, 3371–3408.

Wei, Y., Jin, B., Liu, S., Yu, M., Yin, Z., & Kamal, S. (2022). Towards robust UAV flight with image-based 2D navigation. Robotica, 40(2), 379–396.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Nokta Bulutu Verilerinden 3B Bina Modeli Üretilmesi için QGIS Eklentisinin Geliştirilmesi

**İlknur Mutlu Çetin*[1] Ekrem Ayyıldız*[2]**

[1]*Tapu ve Kadastro Genel Müdürlüğü, Ankara, Türkiye*

**Anahtar Kelimeler**
Nokta bulutu,
QGIS,
QGIS eklentisi,
Coğrafi bilgi sistemleri,
3B bina modeli

**ÖZET**

Üç boyutlu (3B) şehir modellemeleri, teknolojik gelişmelerin etkisiyle yalnızca bir görselleştirme aracı olmaktan çıkarak; şehir planlaması, acil durum yönetimi, nüfus yoğunluğu analizleri ve afet yönetimi gibi pek çok coğrafi uygulama için temel bir veri kaynağı haline gelmiştir. Bu artan ihtiyaç doğrultusunda, doğru, güncel ve hızlı model üretimi önem kazanmış; bu amaçla birçok yeni teknik ve yöntem geliştirilmiştir. Bu çalışmada, bu ihtiyaca yönelik olarak "Cloud To Mesh" adlı bir QGIS eklentisi geliştirilmiş ve teknik altyapıya sahip olmayan kullanıcıların dahi, yalnızca nokta bulutu verisi kullanarak seçtikleri binalar için 3B bina modeli oluşturabilmeleri hedeflenmiştir. Kullanıcı dostu bir arayüze sahip olan eklenti, Bern, Zürih ve New York şehirlerinden seçilen farklı karmaşıklıktaki binalar üzerinde test edilmiştir. Elde edilen sonuçlar, eklentinin düşük karmaşıklıktaki binalarda doğru ve hızlı modellemeler gerçekleştirdiğini, ancak yüksek karmaşıklıktaki binalarda modelleme süresinin arttığını ve bazı durumlarda hatalı ya da başarısız çıktılar verdiğini göstermiştir. Buna rağmen, eklenti 3B bina modelleme sürecini sadeleştirme ve otomatikleştirme açısından önemli bir potansiyele sahiptir. Gelecek çalışmalar, eklentinin performansının artırılmasını, işlem süresinin optimize edilmesini ve çoklu bina modellemesinin desteklenmesini hedeflemektedir.

# Development of a QGIS Plugin for 3D Building Model Reconstruction From Point Cloud Data

**Keywords**
Point cloud,
QGIS,
QGIS plugin,
GIS,
3D building model

**ABSTRACT**

Three-dimensional (3D) city modeling has evolved beyond a mere visualization tool, becoming an essential data source for various geographic applications including urban planning, emergency management, population density analysis, and disaster response. In light of this rising demand, producing models that are accurate, up-to-date, and generated rapidly has become increasingly critical, leading to the development of numerous innovative techniques and methodologies. This study introduces a QGIS plugin named "Cloud To Mesh" designed to empower even those without technical background to generate 3D building models from point cloud data. The plugin features a user-friendly interface and was tested on buildings of varying complexity in Bern, Zurich, and New York. Results indicate that while the plugin generate accurate models for less complex structures, higher complexity buildings require longer processing times and may occasionally yield faulty or unsuccessful outcomes. Nevertheless, the plugin demonstrates significant potential in simplifying and automating the 3D building modeling process. Future work will focus on enhancing its performance, optimizing processing times, and supporting multi-building modeling.

* **Sorumlu Yazar**

*(tk48684@tkgm.gov.tr) ORCID ID 0000-0001-5289-1915
(tk43237@tkgm.gov.tr) ORCID ID 0000-0002-0805-1529

**Kaynak Göster (APA):**

Mutlu Çetin İ & Ayyıldız E (2025). Nokta bulutu verisinden 3B bina modeli üretimi için geliştirilen Qgis eklentisi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

3B modelleme; nokta bulutu verisi, hava fotoğrafları gibi çeşitli veri kaynakları kullanılarak 3B nesnelerin dijital temsillerinin oluşturulmasıdır. Bir çok alanda duyulan ihtiyaç ile günümüzde hızlı ve doğru modellerin üretimi önem kazanmış ve son 30 yılda önemli bir çalışma alanı haline gelmiştir (Wu vd., 2017). Başlangıçta bu modeller sadece görselleştirme amacıyla kullanılsa da, günümüzde; turizm, şehir planlama, afet yönetimi, çevresel simülasyonlar gibi pek çok alanda veri kaynağı olarak yaygın şekilde de kullanılmaktadır (Biljecki vd., 2015). Böylelikle bu modellerin en doğru ve güncel şekilde üretilmesi kritik bir konu haline gelmiştir ve bu konuda bir çok yöntem ve method her geçen gün geliştirilmektedir.

Bu bildiride, açık kaynaklı bir coğrafi bilgi sistemi olan QGIS (Quantum GIS) platformu için geliştirilen "Cloud To Mesh" isimli bir eklenti (plugin) tanıtılmaktadır. Bu eklenti, nokta bulutu ve bina izdüşümü verisini kullanarak 3B katı bina modeli üretimi yapan hazır bir modelin QGIS sistemine entegre edilmesini amaçlamıştır. Bu 3B bina modellemesindeki tüm karmaşıklığı ortadan kaldırıp, kullanıcı dostu bir arayüz sunmasıyla birlikte; teknik alt yapısı olmayan bir kullanıcı için dahi 3B bina modeli üretimini mümkün kılmaktadır.

## 2. YÖNTEM

### 2.1. Çalışma alanı ve veriler

Eklenti performansının değerlendirilmesi için yapılacak testlerde, bina çeşitliliğini artırmak adına farklı mimari karışıklık düzeyinde bina tiplerini içeren Zürih, Bern ve New York şehirleri çalışma bölgesi olarak seçilmiştir. Bu şehirler için las (nokta bulutu) verisi açık kaynaklı platformlardan (Swiss Federal Office of Topography, 2024 ve NYC Open Data, 2024) temin edilirken, bina izdüşüm verisi - shp formatında - OpenStreetMap (OSM) (OpenStreetMap, 2024) aracılığıyla indirilmiştir.

### 2.2. Plugin içerisinde kullanılan model

Eklenti kapsamında kullanılan model hazır olarak temin edildiğinde dolayı, bu çalışma kapsamında modelin çalışma prensibinden kısıtlı bahsedilmişitir.

Modelin temelini, nokta bulutu verisinin işlenmesine yönelik özel bir Python kütüphanesi olan *PointcloudLib* oluşturmaktadır. Süreç, nokta bulutu verisinin grid temelli bir yapıya dönüştürülmesiyle başlar; bu yapı, binanın iz düşüm verisinin de yardımıyla binanın tüm geometrisini modellemeye olanak tanır. Model, her noktanın normal vektörünü hesaplayarak, bu nokataların ait olabileceği düzlemleri belirler. Elde edilen çok sayıda aday düzlem arasından, bina oluşumunu mantıklı ve yapısal olarak geçerli kılacak olanlar seçilir. Modele doğru adayları seçmesi için sunulan kriterler, bina geometrisinin gerçekçi ve kullanılabilir bir 3B mesh modeline dönüştürülmesini sağlar. Modelleme sürecinin her aşamasında üretilen çıktılar VTK, STL, PLY ve OFF gibi formatlarda kaydedilebilir.

### 2.3. QGIS eklentisi geliştirme süreci

"Cloud To Mesh" eklentisi, QGIS'in nokta bulutu verisini destekleyen sürümlerinden biri olan QGIS 3.34 üzerine inşa edilmiştir. Modelin entegresi için Python dili kullanılmış ve arayüz için QT Creator (QT-Creator, 2024) uygulamasından faydalanılmıştır. Şekil 1'de görüleceği üzere; eklenti içerisinde, giriş verisi ekleme adımında kullanıcıya iki farklı seçenek sunulmuştur. Bunlar; kullanılan hazır modelin istediği formata göre veriyi önceden işleyip yüklemek veya indirilen ham veriyi yükleyip, veri işleme adımını da eklenti üzerinden sağlamaktır. Başka bir deyişle, kullanıcı doğrudan indirdiği ham veriyi kullanabilmekle birlikte aynı zamanda süreci hızlandırmak için işlenmiş veriyi de tercih edebilir.

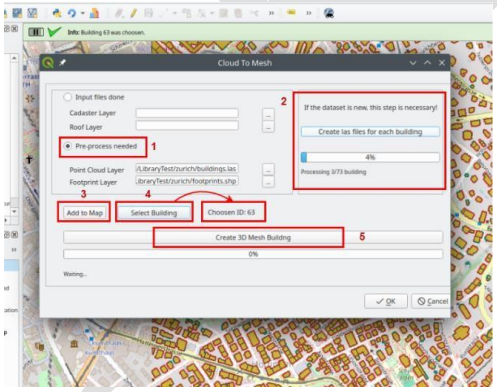


**Şekil 1.** Qgis eklentisinin iş akışı

Her iki durumda da veri seti QGIS map üzerine OpenStreetMap tarafından sağlanan altlık ile birlikte yüklendikten sonra, QGIS uygulaması üzerinde görülmektedir ve kullanıcı fare yardımıyla modellemek istediği binayı seçebilmektedir. Bina seçimi sonrası plugin yönlendirmeleri ile birlikte, 3B mesh bina modeli yaratılma süreci başlatılmaktadır. Plugin arayüzünü ve modelleme sürecini gösteren bir örnek Şekil 2'de görülmektedir.

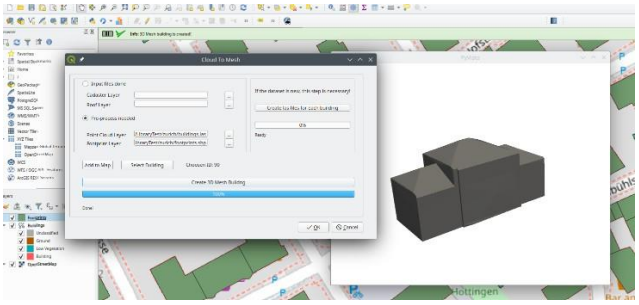

**Şekil 2.** Qgis eklentisi arayüzünün modellenmiş bir veri ile gösterimi.

### 2.4. Görselleştirme ve değerlemdirme

Model üretiminin tamamlanmasından önce, eklenti kullanıcıya model üretim süreci ile ilgili istatiski veriler de sağlamaktadır. Bu veriler seçilen bina hakkında; bina

köşe noktası sayısını ve bina yüksekliğini baz alarak bir karmaşıklık düzeyi hesaplayıp bunu kullanıcıya sunmaktadır. Örneğin bir bina için köşe nokta sayısı 6 veya daha az durumunda karmaşıklık düzeyi 1 (düşük) olarak belirlenirken, 7 ve 10 arası için 2 (orta) ve daha yüksek köşe nokta sayısına sahip binalar için 3 (yüksek) değeri belirlenmiştir. Zorluk derecesi ise, karmaşıklık düzeyini baz alırken aynı zamanda bina yükseklik parametresini de ekleyerek binayı tekrar değerlendirmiştir. Örneğin Şekil 3'de verilen değerlerden, seçilen binanın 10 ve üzeri köşe nokta sayısı içeren yüksek katlı bir bina olduğu çıkarımını yapabilir ve modelleme sürecinin zaman alabileceğini öngörebiliriz. Kısacası bu sunulan değerler ile kullanıcıya model üretiminde beklenen süre hakkında fikir vermesi amaçlanmıştır. Bu bilgilerin ardından eklenti üretim sürecini tamamladığında açılır yeni bir pencere aracılığıyla 3B katı bina modleini kullanıcıya sunar.

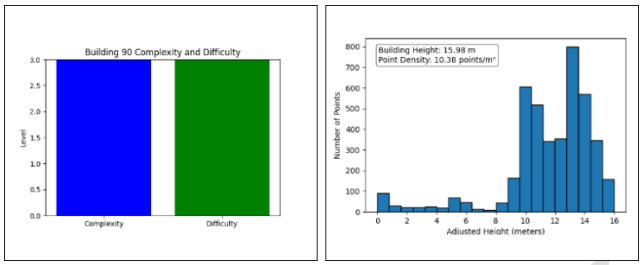


**Şekil 3.** Eklenti tarafından sağlanan, seçilen bina ile ilgili istatistiki bilgiler.

## 3. BULGULAR

"Cloud To Mesh" eklentisi, 3 farklı şehirde, farklı karmaşıklık düzeyine sahip binalar üzerinde test edilmiştir. Elde edilen sonuçlar, metrik bir parametre (RMSE) ile değerledirmek istense de, örnek veri üzerinden yapılan hesaplamalar göstermiştir ki; bu çalışma ksapamında üretilen modeller için RMSE uygun ve güvenilir bir metrik değildir. Bu nedenle, sonuçlar açık kaynak veri olarak sağlanan gerçek 3B modeller ile görsel değerlendirme yapılarak değelndirilmiştir. Şekil 3'de ilgili şehirler için eklenti performansı grafik gösterimi ile sunulmuş ve 3 farklı durum olarak kategorize edilmiştir. Grafikte yeşil renk başarılı ve doğru model üretimini temsil ederken, sarı renk ise başarılı model üretimi olduğunu ancak bu modelin gerçek bina modeli ile örtüşmediğini ifade etmektedir. Kırmızı renk ise model üretimin başarısız olduğu durumları göstermektedir.

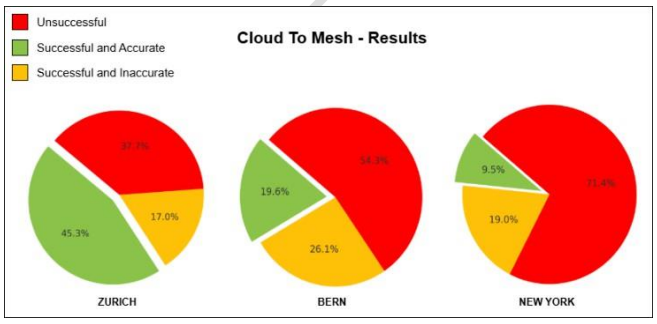


**Şekil 3.** Eklenti test sonuçlarının grafik gösterimi.

Test sürecinde görülmüştür ki, eklenti karmaşıklık düzeyi çok yüksek olmayan binalar içeren Zürih şehrinde %42'lik bir yüzdeyle başarılı olmuştur. Ancak Bern şehrine geldiğimizde, çalışma alanında tarihi binaların olması sebebiyle binaların köşe nokta sayısına bağlı olarak karmaşıklık düzeyi artmıştır. Bu Bern şehri için başarı oranının %19'a gerilemesine neden olmuştuır. Benzer şekilde, gökdelenlere sahip New York şehri için eklenti modelleme konusunda çok başarı gösterememiş ve başarı yüzdesi %9 oranında kalmıştır.

**Çizelge1.** Test edilen binaların karmaşıklık düzeyi çercevesinde gösterilmesi

| ŞEHİRLER | Toplam | Başarılı | Başarısız |
|---|---|---|---|
| Zürih | 53 | 33 | 20 |
| | | (H:19 M:13 L:1) | (H:15 M:2 L:3) |
| Bern | 46 | 21 | 25 |
| | | (H:17 M:3 L:1) | (H:24 M:1 L:0) |
| New York | 21 | 6 | 15 |
| | | (H:6 M:0 L:0) | (H:15 M:0 L:0) |

Çizelge 1'de de ayrıca görüleceği üzere, bina karmaşıklığına göre (yüksek [H], orta [M], düşük [L]) sınıflandırılan test verileri, başarı oranlarının karmaşıklık düzeyiyle doğrudan ilişkili olduğunu ortaya koymaktadır. Özellikle orta zorluk düzeyine sahip binalarda (ör. Zürih'te M:13/15 başarı), eklentinin yüksek başarı sağladığı gözlemlenmiştir. Buna karşılık, yüksek karmaşıklığa sahip binalarda başarı oranı belirgin şekilde düşmekte, bu durum özellikle New York örneğinde %28.6 gibi düşük bir oranla kendini göstermektedir.

## 4. TARTIŞMA

Eklenti, Zürih, Bern ve New York gibi farklı bölgelerde test edilmiş ve eklenti performansının bina karmaşıklığına; yani, bina köşe nokta sayısına ve bina yüksekliğine bağlı olduğu gözlemlenmiştir. Ancak bunların yanı sıra bilgisyar donanımı gibi çevresel faktörlerinde eklenti performansı üzerinde etkisi olduğu saptanmıştır.

"Cloud To Mesh" eklentisi az köşe noktasına sahip, ve yüksek olamayan binalar için saniyeler içerisinde model üretimi yaparken, karmaşıklık düzeyi arttıkça model üretim süresi artmakta, hatalı model üretimi yapabilmekte veya tamamıyla başarısızlıkla sonuçlanabilmektedir. Nokta bulutu verisinden 3B katı bina modeli üretme amacıyla tasarlanan QGIS eklentisi, basit binalar için doğru bir şekilde çalışsa dahi performansı çeşitli faktörlere bağlı ve kısıtlıdır.

## 5. SONUÇ

Bu çalışma, QGIS gibi açık kaynaklı yazılımlar aracılığıyla karmaşıklık düzeyi yüksek 3B modelleme sürecinin, teknik altyapıya sahip olmayan kullanıcılar için bile mümkün hâle getirilebildiğini ortaya koymuştur. Geliştirlen eklenti, düşük karmaşıklık düzeyine sahip binalar için oldukça başarılıdır, ancak geliştirilmesi gereken noktalar bulunmaktadır. Eklentinin daha gelişmiş donanımlarla test edilip performansının iyileştiilmesi, farklı veri formatlarının desteklenmesi ve

birden fazla bina için eş zamanlı modelleme yapabilmesi gelecek çalışma konularıdır.

**TEŞEKKÜR**

Bildiri, sorumlu yazarın 2024 yılında Berlin Teknik Üniversitesi'nde tamamladığı master tezinden üretilmiştir. Master tez danışmanım Prof. Martin Kada'ya ve ikinci danışmanım Prof. Marc-Oliver Löwner'e teşekkürlerimi iletirim.

**Yazar Katkı Oranı**

Sorumlu yazar çalışmanın tamamından sorumludur.

**Araştırma ve Yayın Etiği Beyanı**

Bildiri kapsamında bahsedilen, eklenti içerisine entegre edilen hazır model Berlin Teknik Üniversitesi'nden Dr. Julien Baerenzung tarafından sağlanmıştır.

**KAYNAKÇA**

**Makale**

Biljecki, F., Stoter, J., Ledoux, H., Zlatanova, S., & Çöltekin, A. Applications of 3d city models: State of the art review. ISPRS International Journal of Geo- Information, 4(4):2842–2889, 2015.

Huang, J., Stoter, J., Peters, R., & Nan, L. (2022) City3d: Large-scale building reconstruction from airborne lidar point clouds., Remote Sensing, 14:2254, 05

Nan, L. & Wonka, P. (2017) Polyfit: Polygonal surface reconstruction from point clouds. In Proceedings of the IEEE International Conference on Computer Vision (ICCV).

NYC Open Data, (2024). USA, [Erişim tarihi: 10.11.2024] https://opendata.cityofnewyork.us/

OpenStreetMap, (2024). Map view, [Erişim tarihi: 10.11.2024] https://www.openstreetmap.org/

Swiss Federal Office of Topography, (2024). The classified point cloud of switzerland, Switzerland, [Erişim tarihi: 09.08.2024] https://www.swisstopo.admin.ch/en/height-model-swisssurface3d

QT-Creator, (2024). Overview, [Erişim tarihi: 25.10.2024] https://doc.qt.io/qtcreator/creator-overview.html

Wu, B., Yu, B., Wu, Q., Yao, S., Zhao, F., Mao, W., & Wu, A. (2017). A graph-based approach for 3d building model reconstruction from airborne lidar point clouds., Remote Sensing, 9(1)

TASLAK

**TUFUAB XIII. TEKNİK SEMPOZYUMU**
https://tufuab2025.beun.edu.tr

# Orman Yangınları Sonrası Yanmış Alan Tespiti ve Haritalanmasında Makine Öğrenme Modellerinin Transfer Edilebilirliğinin Değerlendirilmesi

**Gülce Başak Selçuk*[1], Osman Yavuz Altuntaş[1], İsmail Çölkesen[1]**

[1]*Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Kocaeli, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Çevresel izleme,
Orman yangını,
Google Earth Engine,
Makine Öğrenmesi

**ÖZET**

Orman yangınları, ekosistem üzerinde geri dönülemez etkilere sebep olan ve ciddi açıdan çevresel, ekonomik ve sosyal etkileri içerisinde bulunduran doğal afetler arasındadır. Geleneksel yöntemler, yangın alanlarının tespit edilmesinde hem ekonomik hem de zamansal maliyetlidir. Bu çerçevede, uzaktan algılama teknolojileri ve makine öğrenme algoritmalarının entegrasyonu yangın sonrası etkilenen alanların hızlı ve yüksek doğrulukta tespiti noktasında önemli avantajlar sağlamaktadır. Bu çalışmada, orman yangınlarına ilişkin arşiv veriler ile eğitilen makine öğrenme algoritmalarının farklı alanlara transfer edilebilirliği konusu ele alınmış ve yanmış alan tespiti noktasındaki performansları incelenmiştir. Bu amaca yönelik olarak, 2019-2023 yılları arasında Türkiye'de yaşanan 21 farklı alandaki orman yangını değerlendirmeye alınmış ve Google Earth Engine platformu aracılığıyla bu alanları kapsayan Sentinel-2 görüntüleri analiz edilmiştir. Yangın öncesi ve sonrası görüntüler yardımıyla Normalleşmiş Yanma Oranı (NBR) indekslerine ilişkin fark haritaları üretilmiş ve yanmış alanlara ilişkin etiket verileri elde edilmiştir. Çalışma kapsamında, Destek Vektör Makineleri (DVM), Rastgele Orman (RO) ve Aşırı Gradyan Artırma (XGBoost) makine öğrenme algoritmaları tahmin modeli olarak değerlendirmeye alınmış ve oluşturulan modellerin transfer edilebilirliği karşılaştırmalı olarak analiz edilmiştir. Elde edilen sonuçlar, transfer edilen tahmin modelleri arasında DVM algoritmasının farklı alanlardaki yanmış alanların tespit noktasında %94.44 doğruluğa ulaştığını göstermektedir. Çalışmadan elde edilen bulgular, yangından etkilenen alanların tespiti ve haritalanması probleminin çözümünde noktasında transfer edilebilir makine öğrenme modellerinin potansiyel kullanımını ortya koymaktadır.

# Evaluating the Transferability of Machine Learning Models for Post-Fire Burned Area Detection and Mapping

**Keywords**
Remote Sensing,
Environmental monitoring,
Forest fire,
Google Earth Engine,
Machine Learning

**ABSTRACT**

Forest fires are among the natural disasters that cause irreversible impacts on ecosystems and have significant environmental, economic, and social consequences. Traditional methods for detecting burned areas are both time-consuming and costly. In this context, the integration of remote sensing technologies and machine learning algorithms provides significant advantages in rapidly and accurately identifying post-fire-affected areas. This study addresses the transferability of machine learning algorithms trained with archived data on forest fires to different locations and examines their performance in detecting burned areas. For this purpose, 21 different forest fire events that occurred in Turkey between 2019 and 2023 were evaluated, and Sentinel-2 imagery covering these areas was analyzed via the Google Earth Engine platform. Using pre- and post-fire images, difference maps based on the Normalized Burn Ratio (NBR) index were generated, and labeled data related to burned areas were obtained. Within the study, Support Vector Machines (SVM), Random Forest (RF), and Extreme Gradient Boosting (XGBoost) algorithms were evaluated as prediction models, and their transferability was comparatively analyzed. The results showed that among the transferred models, the SVM algorithm achieved an accuracy of 94.44% in detecting burned areas across different locations. The findings of the study revealed the potential use of

***Sorumlu Yazar**

*g.selcuk2021@gtu.edu.tr ORCID ID 0009-0000-9444-2966
oyavuzaltuntas@gtu.edu.tr ORCID ID 0000-0001-5940-4091
icolkesen@gtu.edu.tr ORCID ID 0000-0001-9670-3023

**Kaynak Göster (APA):**

Selçuk G. B, Altuntaş O. Y & Çölkesen İ (2025). Orman Yanginlari Sonrasi Yanmiş Alan Tespiti Ve Haritalanmasinda Makine Öğrenme Modellerinin Transfer Edilebilirliğinin Değerlendirilmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

transferable machine learning models in solving the problem of identifying and mapping fire-affected areas.

## 1. GİRİŞ

Orman yangınları, çevre ve canlı yaşamını olumsuz etkileyen başlıca doğal ve antropojenik kaynaklı afetlerden bir tanesidir (Lavanya ve Padmaja, 2014). Bu açıdan ele alındığında, yangın afetinin tüm yönleriyle anlaşılması ve etkili afet yönetimi planlaması açısından yangından etkilenen alanlar hakkında doğru ve güvenilir bilgiye ihtiyaç duyulmaktadır (Tonbul vd., 2019). Dolayısıyla, orman yangınlarının meydana geldiği alanların sürekli olarak hassas, doğru ve hızlı bir şekilde takip edilmesi önem arz etmektedir. Geleneksel yöntemler orman yangını riskini değerlendirmek açısından çok faydalı olup saha doğrulaması için kritik bir öneme sahiptir. Buna karşın yöntem maliyetli, zaman alıcı ve deneyim gerektirmektedir (Çolak ve Sunar, 2020). Uzaktan algılama teknolojileri, gerek yangın anında gerekse yangın sonrasında afetin etkilerinin detaylı bir şekilde analiz edilmesi noktasında önemli bilgiler sağlamaktadır (Sunar ve Özkan, 2001). Yangın öncesi ve sonrası uzaktan algılanmış görüntüler yardımıyla yangından etkilenen alanların tespitinde spektral indeks tabanlı yaklaşımlar sıklıkla kullanılmaktadır (Tonbul vd., 2022). Bu amaçla yakın kızılötesi ve orta dalga kızılötesi yansımaların farkından hesaplanan Normalize Yanma Oranı (NBR) en sık kullanılan spektral indekstir [Key ve Benson, 1999). Yangın alanı ve şiddetinin çok zamanlı olarak tespit edilmesi amacıyla, yangın öncesi ve sonrası görüntülerden üretilen NBR indekslerinin farkı alınarak hesaplanan Diferansiyel NBR (dNBR) kullanılmaktadır (Gibson vd., 2020).

Literatürde indeks tabanlı yaklaşımların yanında, yangın sonrası görüntüler üzerinden yanmış alanların tespitinde Destek vektör Makineleri (DVM), karar ağaçları ve karar ağaçlarını esas alan toplu öğrenme algoritmaları gibi yapay zekâ teknikleri de yaygın olarak kullanılmaktadır. DVM algoritmasının temel çalışma prensibi, kernel fonksiyonları yardımıyla sınıflar arasındaki ayrımı sağlayan optimum bir karar sınırı (hiperdüzlem) belirlemektedir (Cortes ve Vapnik, 1995). Diğer taraftan, popüler topluluk öğrenme algoritması olan Rastgele Orman (RO), birden fazla karar ağacının verilen bir problem için eğitilmesini ve her bir ağacın tahminlerini çoğunluk oylaması ilkesine göre birleştirerek nihai sınıf etiketinin tahmin edilmesi prensibine dayanmaktadır (Breimann, 2001). Benzer şekilde karar ağacı tabanlı Aşırı Gradyan Arttırma Makine (XGBoost) algoritması ise kullanılan her bir ağacın hatasını düzelterek sonuç sınıf etiketini belirlenmesini esas almaktadır (Chen ve Guestrin, 2016).

Son yıllarda belirli bir problem için oluşturulan makine öğrenmesi ve derin öğrenme modellerinin, farklı alanlarda aynı problemin çözümü (transfer edilebilirliği) noktasında kullanımının araştırılması noktasında çalışmalar yapılmaktadır. Örneğin Roteta vd., (2021) Landsat ve Sentinel-2 uydu görüntülerine dayalı olarak hesaplanan spektral indeksler kullanılarak belirlenen yangın alanı ve buradan üretilen piksellerle ön eğitimli RO modeli desteklenerek yangın alanının büyümesini modelleyen bir arayüz tasarlanmıştır. Bar vd., (2020), Landsat-8 ve Sentinel-2 uydu görüntü bantlarına ek olarak spektral indeksler ile DVM, karar ağacı ve RO makine öğrenmesi modelleri yangın alanlarını tespit etmek amacıyla kullanılmıştır. Elde edilen sonuçlara göre, karar ağacı tabanlı modellerin genel doğruluk oranının %97'den yüksek olduğunu ve Landsat-8 uydu görüntülerinin Avrupa Uzay Ajansı İklim Değişikliği verileri ve MODIS yangın alanı ürünleriyle daha iyi uyum sağladığı görülmüştür (sırasıyla $R^2_{MAKS.}$ = 0.93 ve $R^2_{MAKS.}$ = 0.91).

Bu çalışmada bulut tabanlı GEE platformu üzerinden yangın öncesi ve sonrasına ait Sentinel-2 görüntüleri ve dNBR indeks haritaları kullanılarak eğitilen makine öğrenme modellerinin farklı orman yangınları sonrası yanmış alanların tespitinde performansları analiz edilmiştir.

## 2. YÖNTEM

Bu çalışmada, orman yangın alanlarının tespit edilmesine yönelik GEE platformu ile makine öğrenme modelleri kullanılarak ve test alanlarına ilişkin üretilen tematik haritaların doğruluk analizleri gerçekleştirilmiştir.

### 2.1 Veri Seti ve Çalışma Alanı

Çalışma kapsamında, Şekil 1'de gösterilen ülkemizin farklı coğrafi bölgelerinde meydana gelen 21 farklı orman yangını değerlendirmeye alınmış olup, bulut tabanlı GEE platformu üzerinden yangın alanlarını kapsayan afet öncesi ve sonrasına ait Sentinel-2 (Level-2) uydu görüntüleri kullanılmıştır (Şekil 1.).

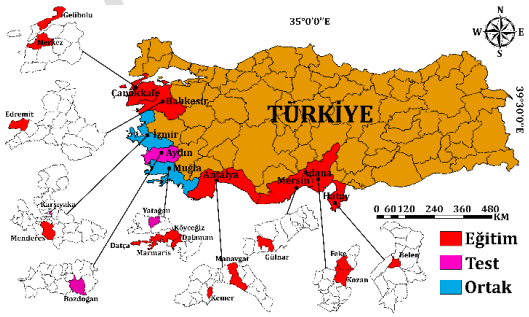


**Şekil 1.** Çalışma alanları.

## 3. METODOLOJİ

Bu çalışmada, GEE platformundan elde edilen çok zamanlı Sentinel-2 uydu görüntüleri ile makine öğrenimi algoritmalarının, yanmış alanlarının belirlenmesindeki kullanımı incelenmiştir. Çalışma Şekil 2'de gösterildiği üzere üç temel aşamadan oluşmaktadır: (1) yangın öncesi ve sonrası görüntülerin seçilmesi ve ön işlemler, (2) spektral indekslerin hesaplanması ve makine öğrenimi modellerinin eğitilmesi ve doğruluk analizleri, (3) eğitilmiş modellerin farklı alanlarda yanmış alanların tespiti (transfer edilebilirliği) noktasında performanslarının analiz edilmesini içermektedir.

Türkiye'de meydana gelen orman yangınlarını analiz etmek amacıyla, bulutsuz uydu görüntüleri seçilmiş ve yangın öncesi/ sonrası görüntüler, manuel olarak çizilen geometri sınırlarına göre filtrelenmiştir. GEE platformu kullanılarak %25'in altında bulut oranına sahip görüntüler belirlenmiştir. Ardından, 2019–2023 yılları arasındaki orman yangınlarını kapsayan zaman filtresi uygulanarak elde edilen çok zamanlı görüntüler üzerinden, dNBR indeksi hesaplanmış ve bu veriler makine öğrenimi algoritmalarının eğitimi için kullanılmıştır. Son olarak, yangın alanlarının tespitine yönelik tematik haritalar üretilmiş ve modellerin

transfer edilebilirliği açısından doğrulukları analiz edilmiştir.

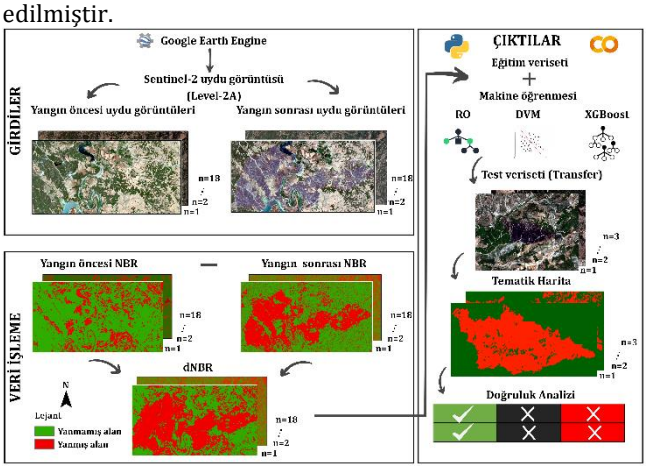


**Şekil 2.** Çalışmada takip edilen işlem adımları.

## 4. BULGULAR

Modellerin eğitimi için seçilen uydu görüntülerinden yanmış ve yanmamış alanları temsil eden piksellere ilişkin spektral bant değerleri ve etiket verileri kullanılarak, DVM, RO ve XGBoost modelleri oluşturulmuş ve test pikselleri kullanarak model performansları analiz edilmiştir. Sonrasında eğitilen modellerin transfer edilebilirlik performansları, model oluşumunda kullanılmayan 2024 yılında Aydın-Bozdoğan, Muğla-Yatağan ve İzmir-Karşıyaka'da yaşanan yangınlar sonrasında elde edilen Sentinel-2 görüntüleri kullanılarak analiz edilmiştir. Şekil 3'de transfer edilen modellerin ürettiği tematik haritalar ve hesaplanan genel doğruluk ve yanmış alanlara ilişkin F-Skor sonuçları verilmiştir. Sonuçlar, DVM algoritmasının diğer iki modele %2 seviyelerinde daha yüksek tahmin doğruluğu ürettiğini göstermektedir.

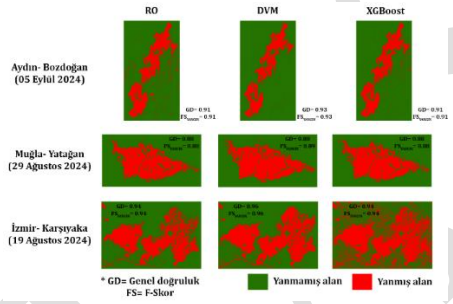


**Şekil 3.** Modellerin yangın transfer etme kapasitesi.

## 5. TARTIŞMA ve SONUÇ

Bu çalışma kapsamında, orman yangınlarının Sentinel-2 Level-2 uydu görüntüleri kullanılarak yangın indeksleri kullanılarak yangınlardan toplanan örnekler ile makine öğrenme algoritmaları yardımıyla yangın alanının tespiti için doğruluğu tahmin edilmiş olup kullanılan makine öğrenme algoritmalarından yangın alanı tespitinde en yüksek genel doğruluk oranının DVM algoritması olduğu sonucuna ulaşılmıştır. Çalışma sonucunda, yanmış alanların tespitinde transfer edilebilir makine öğrenme algoritmalarının potansiyel kullanımını ve etkinliğini göstermektedir.

Çalışmaya yazarlar eşit oranda katkı sağlamıştır.

### Çıkar Çatışması/Çakışması

Çalışmada herhangi bir kurum, kuruluş, kişi ile mali çıkar çatışması yoktur ve yazarlar arasında çıkar çatışması bulunmamaktadır.

### Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

### KAYNAKÇA

Bar, S., Parida, B. R., & Pandey, A. C. (2020). Landsat-8 and Sentinel-2 based Forest fire burn area mapping using machine learning algorithms on GEE cloud platform over Uttarakhand, Western Himalaya. Remote Sensing Applications: Society and Environment. doi: 10.1016/j.rsase.2020.100324

Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining, San Francisco, https://doi.org/10.1145/2939672.2939785

Cortes, C., & Vapnik, V. (1995). Support-vector networks. Machine learning. doi: 10.1007/BF00994018

Çolak, E., & Sunar, F. (2020). Evaluation of forest fire risk in the Mediterranean Turkish forests: A case study of Menderes region, Izmir. International journal of disaster risk reduction. doi: 10.1016/j.ijdrr.2020.101479

Gibson, R., Danaher, T., Hehir, W., & Collins, L. (2020). A remote sensing approach to mapping fire severity in south-eastern Australia using sentinel 2 and random forest. Remote sensing of environment. doi: 10.1016/j.rse.2020.111702

Key, C. H., & Benson, N. C. (1999). The Normalized Burn Ratio (NBR): A Landsat TM radiometric measure of burn severity. United States Geological Survey, Northern Rocky Mountain Science Center: Bozeman, MT, USA.

Lavanya, B., & Padmaja, B. (2014). A Novel approach for identification of forest fires using land surface temperature images. IOSR Journal of Computer Engineering. doi: 10.9790/0661-16547883

Roteta, E., Bastarrika, A., Franquesa, M., & Chuvieco, E. (2021). Landsat and sentinel-2 based burned area mapping tools in google earth engine. Remote Sensing. doi: 10.3390/rs13040816

Sunar, F., & Özkan, C. (2001). Forest fire analysis with remote sensing data. International Journal of Remote Sensing. doi: 10.1080/01431160118510

Tonbul, H., Colkesen, I., & Kavzoglu, T. (2019). Forest fire and burn severity analysis in Cefalù region of Italy using Sentinel-2 imagery. In Proceedings of the International Symposium on Applied Geoinformatics (ISAG), Istanbul.

Tonbul, H., Colkesen, I., & Kavzoglu, T. (2022). Pixel-and Object-Based ensemble learning for forest burn severity using USGS FIREMON and Mediterranean condition dNBRs in Aegean ecosystem (Turkey). Advances in Space Research. doi: 10.1016/j.asr.2022.02.051

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

### Yazar Katkı Oranı

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# GEDI ve Sentinel-2 Verilerinin Yapay Zeka Tabanlı Yaklaşımlarla Entegrasyonu: Orman Bitki Örtüsü Tepe Yüksekliğinin Modellenmesi

**Sefa Karabaş*[1], Gülay Karabaş[2]**

[1]Düzce Üniversitesi, Orman Fakültesi, Orman Mühendisliği, Düzce, Türkiye
[2]Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, Tapu ve Kadastro Genel Müdürlüğü, Ankara, Türkiye

**Anahtar Kelimeler**
GEDI,
Derin Örenme,
Makine Öğrenmesi,
Sentinel-2

**ÖZET**

GEDI ve Sentinel-2 verilerinin entegrasyonu, yapay zeka tabanlı modellerle sağlanabilir ve geniş alanlarda orman bitki örtüsü yükseklik metrikleri üretilebilir. GEDI L2A ürünü, orman yapısı ve biyokütleye dair kapsamlı değerlendirmeler yoluyla ormancılığın gelişiminde oldukça önemli bir rol üstlenmektedir. Bu çalışmanın amacı, GEDI ve Sentinel-2 görüntülerini yapay zeka tabanlı yaklaşımlar kullanılarak entegre etmek ve orman bitki örtüsü tepe yüksekliğini tahmin etmektir. Çalışma alanı içindeki tüm ışınları seçmek için 2021 yılında çıkan Manavgat Orman Yangın sınırı kullanılmıştır. Çalışmada, YZ algoritmalarının GEDI ve Sentinel-2 uydu görüntüleri verileri ile entegrasyonunun mümkün olduğu anlaşılmaktadır. RMSE değeri 6.52 ile derin öğrenme algoritması olan MLP modeli seçilmiştir. Sonuç olarak, ülkemiz ormancılığının gündeminde olan hem orman yangın davranışlarının modellenmesinde kullanılabilecek hem de ormanlarımızın karbon bağlama, tutma ve depolama fonksiyonlarına ilişkin belirsizliklerin giderilmesi noktasında, YZ algoritmalarının GEDI ve Sentinel-2 verileri ile birleştirilerek geniş alanlara yüksek doğrulukta ve düşük maliyetle uygulanabilme potansiyeli taşıdığı anlaşılmaktadır.

# Integration of GEDI and Sentinel-2 Data With AI-Based Approaches: Modelling Forest Canopy Height

**Keywords**
GEDI,
Deep Learning,
Machine Learning,
Sentinel-2

**ABSTRACT**

The integration of GEDI and Sentinel-2 data can be achieved with artificial intelligence-based models and forest vegetation height metrics can be produced in large areas. The GEDI L2A product plays a very important role in the development of forestry through comprehensive assessments of forest structure and biomass. The aim of this study is to integrate GEDI and Sentinel-2 images using artificial intelligence-based approaches and to estimate the forest vegetation crown height. The Manavgat Forest Fire boundary, which occurred in 2021, was used to select all rays within the study area. In the study, it is understood that the integration of AI algorithms with GEDI and Sentinel-2 satellite imagery data is possible. The deep learning algorithm MLP model was selected with an RMSE value of 6.52. As a result, it is understood that AI algorithms can be used in modeling forest fire behavior, which is on the agenda of our country's forestry, and can be applied to large areas with high accuracy and low cost by combining them with GEDI and Sentinel-2 data in order to eliminate uncertainties regarding the carbon binding, retention and storage functions of our forests.

## 1. GİRİŞ

Yapay zeka (YZ) algoritmaları, özellikle makine öğrenmesi (ML) ve derin öğrenme (DL) alanlarında otomatik veri işleme ve karar verme süreçlerini mümkün kılan karmaşık bir yöntemler ağı oluşturmaktadır. ML verilerden öğrenme ve bu verileri temel alan tahminlerde bulunma yeteneği kazandırmayı amaçlamaktadır (Narula, 2023). DL ise, çok katmanlı sinir ağlarını kullanan bir ML alt alanıdır. DL modellerinin mimarisi, hiyerarşik özellikleri öğrenmesine olanak tanımaktadır (LeCun vd., 2015).

* **Sefa Karabaş**
*(sefakarabas@gmail.com) ORCID ID 0009 – 0008 – 1911 – 7328
(tk48603@tkgm.gov.tr) ORCID ID 0009-0002-4707-5897

**Kaynak Göster (APA):**
Karabaş S & Karabaş G (2025). GEDI ve Sentinel-2 Verilerinin Yapay Zeka Tabanlı Yaklaşımlarla Entegrasyonu: Orman Bitki Örtüsü Tepe Yüksekliğinin Modellenmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

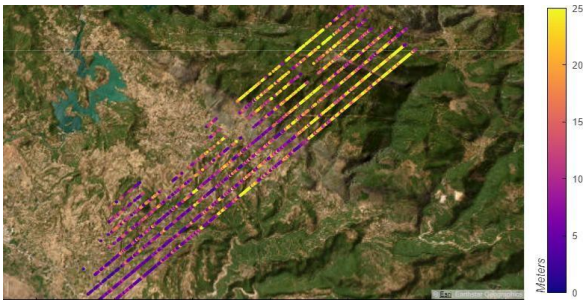


**Şekil 1.** Elde edilen GEDI rh metriklerinin çalışma sahası üzerindeki izdüşümü (n=19701) gösterilmektedir.

Küresel Ekosistem Dinamikleri Araştırması (GEDI) misyonu, Nisan 2019'dan bu yana Uluslararası Uzay İstasyonu'nda faaliyet göstermektedir ve karasal ekosistemlerin yapısını tanımlamayı amaçlamaktadır (Healey, 2020). GEDI, bitki örtüsünün düşey profilleerini yüksek mekansal çözünürlükle yakalayabilen tam dalga formu LiDAR teknolojisini kullanmaktadır (Fayad vd., 2021). Kullanılan bu LiDAR teknolojisi, lazer darbeleri gönderip bu darbelerin orman bitki örtüsü ve yer yüzünden yansıyarak geri dönme süresini ölçmektedir (Lin vd., 2020).

GEDI L2A ürünü, orman yapısı ve biyokütleye dair kapsamlı değerlendirmeler yoluyla ormancılığın gelişiminde oldukça önemli bir rol üstlenmektedir. GEDI verilerinden türetilen orman bitki örtüsü tepe yüksekliğine dair metrikler, özellikle rh98, rh95 ve rh90 gibi göreceli yükseklik metrikleri ile çeşitli orman tiplerinde yerüstü biyokütlenin önemli indikatörleri olarak öne çıkmaktadır.

Bu çalışmada konu edinilen ve ülkemiz ormancılığının gündeminde olan bazı önemli konular (1) Orman yangın davranış tahminlerinde kullanılabilecek bitki örtüsünün yapısına dair yüksek çözünürlüklü verilerin eksikliği, (2) Orman ekosistemlerinin karbon yakalama, bağlama ve depolama özelliklerindeki belirsizlikler olarak sıralanabilir. Bu çalışmanın temel amacı bahsedilen bu sorunların çözümü noktasında GEDI ve Sentinel-2 verilerinin yapay zeka tabanlı yaklaşımlarla entegre ederek orman bitki örtüsü tepe yüksekliğinin düşük maliyet ve yüksek çözünürlükle modellenmesidir.

## 2. YÖNTEM

### 2.1. GEDI ve Sentinel-2 Verilerinin Hazırlanması

Bu çalıışmada GEDI Seviye 2A (L2A) verileri kullanılmıştır. GEDI L2A verileri her ayakizi içindeki çeşitli dalga formlarından çıkarılan elem, boylam, bitki örtüsü tepe yüksekliği ve yüzey enerji metriklerini içermektedir (Örn: rh90, rh95, rh98 gibi). Çalışma alanı içindeki tüm ışınları seçmek için 2021 yılında çıkan Manavgat Orman Yangın sınırı kullanılmıştır. GEDI L2A verileri Mart-2019 ile Temmuz-2021 yılları arasında kapsayacak şekilde süzgeçten geçirilmiştir. Standartlara uygun olmayan tüm GEDI atışları Kalite bayrağı (QF = 0) özelliği ile süzülmüştür. Bu verilerin detayylı analizleri 3.12.8 sürümüne ait ilgili Python paketleri kullanılarak gerçekleştirilmiştir (Şekil 1).

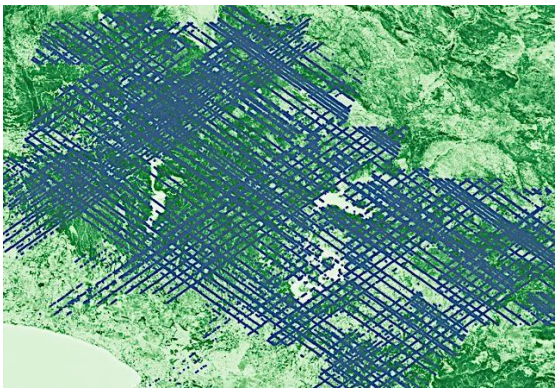

**Şekil 2.** Filtreleme işleminden geçirilen bazı GEDI verilerine ait rh98 metrikleri gösterilmek

### 2.2. Sentinel-2 Uydu Görüntülerinin Hazırlanması

Sentinel-2 uydusundan elde edilen veriler Mart- 2019 ve Temmuz-2021 tarihleri arasını kapsayacak şekilde filtrelenmiştir. Filtrelenen bu uydu görüntüleri koleksiyonunda bulut maskesi uygulanarak (QA60 bandı üzerinden) yalnızca %10'dan az bulut içeren görüntüler değerlendirmeye alınmıştır. Bulutlardan arındırılmış görüntüler B1-B12 bantlarını içerecek şekilde ortalama kompozit alınarak 10 metre çözünürlükte yeniden üretillmiştir. NDVI, EVI ve SAVI spektral indisleri hesaplanmıştır (Çizelge 1). Tüm hesaplamalar Google Earth Engine platformunda Javascript programlama dili kullanılarak yapılmıştır.

**Çizelge1.** Hesaplanan spektral indisler

| | |
|---|---|
| **NDVI** | : (B8 - B4) / (B8 + B4) |
| **EVI** | : 2.5 × (B8 - B4) / (B8 + 6×B4 - 7.5×B2 + 1) |
| **SAVI** | : ((B8 - B4) / (B8 + B4 + L)) × (1 + L) |

### 2.3. Makine ve Derin Öğrenme Algoritmaları

Bu çalışmada kullanılan algoritmalar arasında LR (Doğrusal regresyon), RF (Rastgele orman regresyonu), XGB (XGBoost), SVR (Destek vektör regresyonu), MLP (Çok katmanlı perseptron regresörü) bulunmaktadır. Model tahminlerinin doğruluğunu değerlendirmek amacıyla Ortalama Bias Hatası (MBE), Kök Ortalama Kareler Hatası (RMSE), ve Belirleme Katsayısı ($R^2$) istatistikleri kullanımıştır. Tüm algoritmalar Python programlama dili ile Scikit-learn kütüphanesi kullanılarak uygulanmıştır. İlgili algoritmalara ait hiperparametreler kullanılarak optimize edilmiştir.

## 3. BULGULAR

### 3.1. GEDI Verilerinin Analizi

GEDI verilerinin filtreleme işlemleri gerçekleştirildikten sonra 7903 adet noktaya ait veri elde edilmiştir. Bu verilerin bir kısmı Şekil 2'de gösterilmektedir.

GEDI ve Sentinel-2 uydu görüntüleri bantlarından elde edilen veriler ML ve DL algoritmalarına veriler üçte biri test üçte ikisi modelin eğitimi için kullanılmıştır.

**Çizelge2.** Modeller, R2 ve MSE'ye ait değerler gösterilmektedir.

**Şekil 2.** Filtreleme işleminden geçirilen bazı GEDI verilerine ait rh98 metrikleri gösterilmek

GEDI verilerinin tarım ve toprak yüzeyi gibi bölgelerde 5m'ye kadar ormanlık alanlarda ise 40 metreye varan bitki örtüsü tepe yüksekliğinin olduğunu görsel olarak görülmüştür (Şekil 3).

| Model | $R^2$ | MSE |
|---|---|---|
| LR | 0.27 | 46.75 |
| RF | 0.32 | 43.83 |
| XGboost | 0.31 | 44.07 |
| SVR | 0.24 | 47.62 |
| MLP | 0.34 | 42.63 |

MLP modeli diğer modellere kıyasla daha yüksek R2 ve daha düşük MSE değerlerine sahip olduğu için GEDI ve Sentinel-2 uydu görüntülerinin entegrasyonunda kullanılmak üzere seçilmiştir (Çizelge 2). MLP modelinde ortalama bias hata (MBE) -0.025 olarak hesaplanmıştır. Kök ortalama kareler hatası (RMSE) 6.52m olarak hesaplamıştır.

### 3.2. Sentinel-2 Uydu Görüntülerinin Analizi

Sentinel-2 uydu görüntülerinden elde edilen ortalama kompozit görüntü koleksiyonunda bulunan spectral bantlara (B1-B12) ek olarak NDVI, EVI ve SAVI metriklerine ilişkin bantlar eklenmiştir.

B1, B2, B3, B4 ve NDVI bantlarının spektral yansıma değerleri 0.01 ile 0.1 arasında değişmektedir. B6, B7, B8, B8A, B9, B11 ve B12 bantlarının spektral yansıma değerleri 0.15 ile 0.3 arasındadır. EVI ve SAVI metriklerinin spektral yansıma değerleri 0.3 ile 0.8 arasında değişmektedir (Şekil 4).

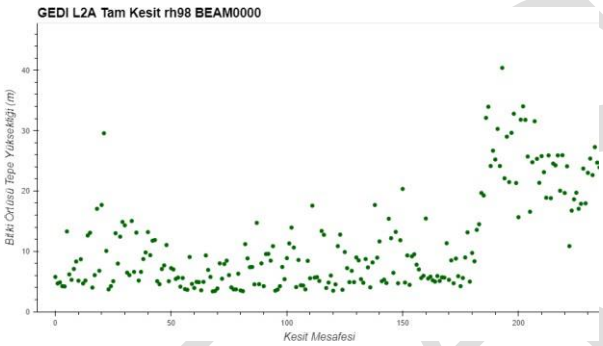


**Şekil 3.** GEDI L2A BEAM0000 ürününden elde edilen rh98 metriklerinin tam kesit profili gösterilmektedir.

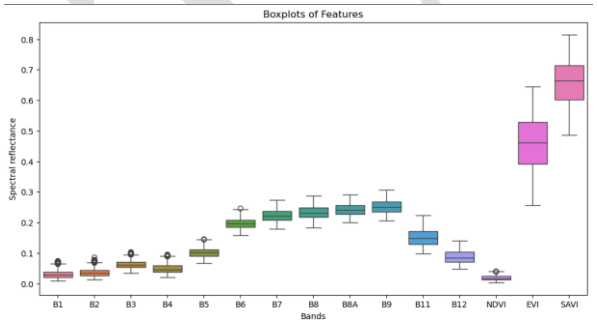


**Şekil 4.** GEDI L2A BEAM0000 ürününden elde edilen rh98 metriklerinin tam kesit profili gösterilmektedir.

### 3.3. ML ve DL Model Analizi

### 3.4. GEDI ve Sentinel-2 Verilerinin Entegrasyonu

Sentinel-2 verileri üretilen MLP model ile GEDI rh98 metriklerinin tahmininde kullanılmıştır. Bitki örtüsü tepe yüksekliği 30m ve üstü koyu yeşil ile 5m ve altı açık yeşil ile gösterilmektedir.

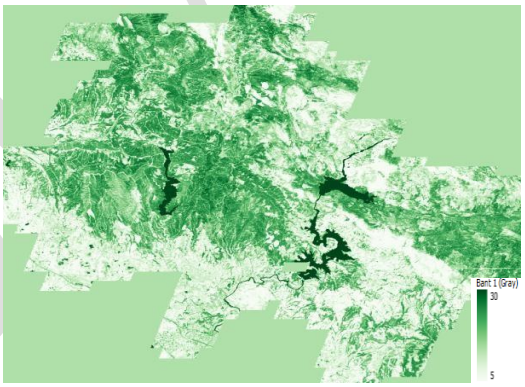


## 4. TARTIŞMA

YZ algoritmalarının GEDI ve Sentinel-2 uydu görüntüleri verileri ile entegrasyonunun mümkün olduğu anlaşılmaktadır. Bu çalışmada 5 model arasından RMSE değeri en düşük olan MLP modeli seçilmiştir. MLP modelin orman bitki örtüsü tepe yüksekliğinin negatif biasa sahip olması dikkat çekmektedir. Hem $R^2$ artırılması hem de RMSE'nin düşürülmesi için yersel veya havadan lidar yöntemleri ile doğrulama yapılması

model gelişimi için çok faydalı olacaktır. Böylece geliştirilen model geniş alanlarda düşük maliyet ve yüksek doğrulukta verilerin üretilebileceği anlaşılmaktadır.

## 5. SONUÇ

Sonuç olarak, ülkemiz ormancılığının gündeminde olan hem orman yangın davranışlarının modellenmesinde kullanılabilecek hem de ormanlarımızın karbon bağlama, tutma ve depolama fonksiyonlarına ilişkin belirsizliklerin giderilmesi noktasında, YZ algoritmalarının GEDI ve Sentinel-2 verileri ile birleştirilerek geniş alanlara yüksek doğrulukta ve düşük maliyetle uygulanabilme potansiyeli taşıdığı anlaşılmaktadır.

**Yazar Katkı Oranı**

Yazarlar aynı oranda katkı sağlamıştır.

**Çıkar Çatışması/Çakışması**

Yazarlar arasında herhangi bir çıkar çatışması yoktur.

**KAYNAKÇ**


Fayad, I., Baghdadi, N. N., Alvares, C. A., Stape, J. L., Bailly, J. S., Scolforo, H. F., Zribi, M., & Maire, G. L. (2021). Assessment of Gedi's LIDAR data for the estimation of Canopy Heights and wood volume of eucalyptus plantations in Brazil. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *14*, 7095–7110.

Healey, S. P., Yang, Z., Gorelick, N., & Ilyushchenko, S. (2020). Highly local model calibration with a new Gedi LIDAR asset on Google Earth engine reduces landsat forest height signal saturation. *Remote Sensing*, *12*(17), 2840.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*(7553), 436–444. https://doi.org/10.1038/nature14539

Lin, X., Xu, M., Cao, C., Dang, Y., Bashir, B., Xie, B., & Huang, Z. (2020). Estimates of forest canopy height using a combination of ICESat-2/Atlas Data and STEREO-photogrammetry. *Remote Sensing*, *12*(21), 3649.

Narula, P. (2023). Analysis of common supervised learning algorithms through application. *Advanced Computational Intelligence: An International Journal (ACII)*, *10*(1/2/3), 29–48.



© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.


TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Kültürel Miras Belgelenmesinde SLAM Tabanlı El Tipi LiDAR Sistemlerinin Değerlendirmesi: Palazzo della Fraternita dei Laici Örneği

**Kasım Erdal*[1], Büşranur Güvercin[2], Hasan Bilgehan Makineci[2]**

[1]*ÜÇA Mühendislik & Harita, Konya, Türkiye*
[2]*Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Harita Mühendisliği Bölümü, Konya, Türkiye*

**Anahtar Kelimeler**
Mobil LiDAR,
SLAM,
Nokta Bulutu,
Kültürel Miras,
Bulut-Bulut Karşılaştırma

**ÖZET**

Bu çalışma, SLAM (Simultaneous Localization and Mapping) tabanlı el tipi mobil LiDAR sistemlerinin kültürel miras belgelenmesindeki etkinliğini karşılaştırmalı olarak analiz etmeyi amaçlamaktadır. Bu kapsamda Leica BLK2GO, GeoSLAM ve Stonex X120 cihazları kullanılarak İtalya'nın Arezzo kentinde yer alan Palazzo della Fraternita dei Laici yapısında veri toplanmıştır. Her üç sistemin teknik özellikleri, tarama menzilleri ve SLAM algoritmalarına göre ürettikleri nokta bulutları; yoğunluk, doğruluk ve görsel kalite açısından değerlendirilmiştir. CloudCompare yazılımı ile gerçekleştirilen "buluttan buluta karşılaştırma (C2C)" yöntemi, sistemler arası geometrik farklılıkları ortaya koymak için kullanılmıştır. Elde edilen sonuçlar, BLK2GO'nun yüksek nokta yoğunluğu ile daha ayrıntılı veri sunduğunu, GeoSLAM'in geniş alanlardaki verimliliğiyle öne çıktığını ve Stonex X120'nin yüksek menzil avantajına rağmen detay düzeyinde sınırlı kaldığını göstermiştir. Çalışma, SLAM tabanlı mobil LiDAR sistemlerinin mimari belgelenme, kültürel miras modelleme ve dijital arşivleme süreçlerindeki uygulama potansiyelini vurgulamakta ve sistemlerin avantajları ile sınırlılıklarını teknik açıdan ortaya koymaktadır.

# Evaluation of SLAM-Based Handheld LiDAR Systems for Cultural Heritage Documentation: The Case of Palazzo della Fraternita dei Laici

**Keywords**
Mobile LiDAR,
SLAM,
Point Cloud,
Cultural Heritage,
Cloud-to-Cloud Comparison

**ABSTRACT**

This study aims to comparatively analyze the effectiveness of handheld SLAM (Simultaneous Localization and Mapping)-based mobile LiDAR systems in cultural heritage documentation. Data were collected using the Leica BLK2GO, GeoSLAM, and Stonex X120 devices on the Palazzo della Fraternita dei Laici building located in Arezzo, Italy. The technical specifications, scanning ranges, and SLAM algorithms of these systems were evaluated in terms of point cloud density, geometric accuracy, and visual quality. The "Cloud-to-Cloud (C2C)" comparison method, implemented with CloudCompare software, detected geometric differences between the datasets. The results revealed that the BLK2GO provided higher point density and more detailed scans, GeoSLAM offered efficiency in wide-area mapping, and the Stonex X120, despite its high range, had limitations in detail representation. This study emphasizes the application potential of SLAM-based mobile LiDAR systems in architectural documentation, cultural heritage modeling, and digital archiving processes while presenting their technical strengths and limitations.

## 1. GİRİŞ

Lazer tarama teknolojileri mekânsal verilerin hassas, hızlı ve yoğun şekilde toplanmasında; mimari belgeleme, kültürel miras çalışmaları ve dijital ikiz üretimi gibi birçok alanda kritik bir rol üstlenmiştir (Karasaka & Beg, 2021) .Lazer tarama teknolojiler arasında mobil LiDAR sistemleri, taşınabilirlikleri ve SLAM (Simultaneous Localization and Mapping)

* **Sorumlu Yazar**
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**
Erdal K, Güvercin B & Makineci H B (2025). Kültürel Miras Belgelenmesinde SLAM Tabanlı El Tipi LiDAR Sistemlerinin Değerlendirmesi: Palazzo della Fraternita dei Laici Örneği, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

algoritmalarına dayalı konumlandırma yetenekleri sayesinde geleneksel yersel lazer tarayıcı sistemlerine alternatif olarak öne çıkmaktadır (Makineci & Erdal, 2023). SLAM tabanlı sistemler, özellikle GNSS sinyallerinin yetersiz olduğu kapalı veya karmaşık ortamlarda, eş zamanlı olarak kendi konumlarını belirleyebilme ve çevrelerinin üç boyutlu modelini oluşturabilme kapasitesine sahiptir (Hou, Hübner, Schmidt, & Iwaszczuk, 2024).

Mobil LiDAR sistemleri farklı donanım yapılarına, tarama prensiplerine ve SLAM algoritmalarına sahip olduğundan benzer çalışma alanlarında farklı sistemlerden elde edilen nokta bulutları arasında kalite, yoğunluk ve doğruluk bakımından farklılıklar ortaya çıkabilmektedir. Bu nedenle, farklı mobil LiDAR sistemlerinin performanslarının doğrudan karşılaştırmalı analizlerle değerlendirilmesi, bu sistemlerin uygulama potansiyelini ve sınırlılıklarını anlamak açısından önemlidir (Erdal, 2024). Bu bağlamda bu çalışmanın temel amacı BLK2GO, GeoSLAM ve Stonex X120 marka/model üç farklı mobil LiDAR sisteminden elde edilen nokta bulutlarının geometrik doğruluğunu, yoğunluğunu ve görsel kalitesini karşılaştırmalı olarak analiz etmektir. Söz konusu tarama çalışmaları İtalya'nın Arezzo kentinde yer alan kültürel miras niteliğindeki Palazzo della Fraternita dei Laici yapısı üzerinde gerçekleştirilmiştir. Nokta bulutları arasındaki benzerlik ve farklılıklar, "Doğrudan Buluttan Buluta Karşılaştırma (Cloud-to-Cloud, C2C)" algoritması temelinde değerlendirilmiştir. Ayrıca karşılaştırma sürecinde yapının çeşitli bölgelerindeki nokta sapmaları detaylı şekilde analiz edilerek, sistemlerin sahadaki performansları teknik açıdan sorgulanmıştır.

Bu çalışma hem mobil LiDAR teknolojilerinin veri kalitesi açısından birbirleriyle kıyaslanmasına hem de SLAM algoritmasına dayalı sistemlerin uygulama düzeyindeki etkinliğine dair kapsamlı bir değerlendirme sunmaktadır. Bu bağlamda elde edilen bulgular başta dijital belgeleme ve kültürel miras modelleme olmak üzere çeşitli disiplinlerde mobil LiDAR teknolojisinin daha etkili kullanımına yönelik önemli katkılar sunmaktadır.

## 2. YÖNTEM

Bu bölümde kullanılan ekipmanların donanımsal ve algoritmik bileşenleri incelenecektir. Elde edilen sonuç ürünlerinin karşılaştırılmasında kullanılan algoritmaya değinilecektir ve çalışma alanı tanıtılacaktır.

## 3. SLAM YÖNTEMİ

Bir robotun bilinmeyen bir ortamda, hareketlerine paralel olarak hem ortamın haritasını oluşturması hem de bu harita içinde kendi konumunu belirleyebilmesi problemi, SLAM yönteminin tanımını oluşturmaktadır (Durrant-Whyte & Bailey, 2006). Otonom sistemler için kritik olan bu yöntem, sistem hareket ettikçe çevreden alınan gözlemleri analiz etmektedir ve konum hatalarını azaltmak amacıyla döngü kapanması gerçekleştirmektedir (Sualeh & Kim, 2019). Döngü kapanması SLAM yönteminin temel bileşeni olarak değerlendirilmektedir. SLAM yönteminin temel yapısı incelendiğinde artan veri hacmi ve zaman gecikmeleri, yöntemin matematiksel ve algoritmik yapısının gelişmesini zorunlu kılmıştır (Ahmed, Masood, Fremont, & Fantoni, 2023). SLAM yönteminin geliştirilmesiyle oluşan yeni algoritmalar genellikle açık kaynak kodlu olarak sunulmuştur ve bu durum SLAM yönteminin farklı varyantlarının oluşmasına olanak tanımıştır. Bu varyantların bir bölümü olarak görülmekte olan modern SLAM algoritmaları; askeri sistemlerden, akıllı cihazlara ve insansız hava araçlarına kadar çok sayıda uygulama alanında kullanılmaktadır (Erdal, 2024; Placed et al., 2023; Sualeh & Kim, 2019). Harita mühendisliği disiplinin, GNSS'in yetersiz kaldığı iç mekânlarda konum bilgisi elde etmek ve dış mekânlarda harita üretimini desteklemek amacıyla SLAM algoritmaları büyük önem taşımaktadır. Mobil cihazlara entegre edilen bu algoritmalar sayesinde düşük maliyetli ve taşınabilir çözümlerle veri toplanabilmektedir (Karam, Vosselman, Peter, Hosseinyalamdary, & Lehtola, 2019; Makineci & Erdal, 2021, 2023; Özdemir, Erdal, Veziroğlu, & Ateş, 2022). Modern SLAM yaklaşımlarının büyük çoğunluğu grafik tabanlıdır. Bu yapılar sistem hareketlerini ve sensör ölçümlerini grafik elemanları (düğüm ve kenar) ile temsil etmektedir. Haritalandırma amaçlı ölçümler odometri, LiDAR ve kamera gibi sensörlerden elde edilirken, grafik üzerindeki optimizasyon en küçük kareler ve Bayes temelli yöntemlerle sağlanmaktadır. Sürecin verimliliğini artırmak için algoritma iki ana parçaya bölünmüştür: ön kısım veri toplarken, arka kısım en uygun konumu hesaplamaktadır. Bu döngü, sistem çalıştığı sürece sürekli tekrar etmektedir (Erdal, 2024; Lluvia, Lazkano, & Ansuategi, 2021).

## 4. EL TİPİ LİDAR SİSTEMLERİ

Çalışma kapsamında üç farklı el tipi LiDAR sistemi olan Leica BLK2GO, GeoSLAM ve Stonex X120 kullanılarak veriler toplanmıştır. Sistemlerin teknik özellikleri ve sahip oldukları SLAM algoritmaları karşılaştırmalı olarak incelenmiştir. Leica BLK2GO, 830 nm lazer dalga boyunda çalışmakta olup 25 metreye kadar menzile ve 420.000 nokta/sn tarama hızına sahiptir. Görüntü tabanlı ve grafik tabanlı SLAM özelliklerini bir araya getiren "GrandSLAM" algoritmasını kullanmaktadır (Del Duca & Machado, 2023).

GeoSLAM, 905 nm dalga boyunda darbeli ışıkla çalışmakta ve 100 metreye kadar menzil sunmaktadır. Sistem bileşenindeki SLAM yöntemine ait algoritma bilgisi tam olarak paylaşılmamış olsa da sistemin grafik tabanlı SLAM algoritması ile çalıştığı belirtilmiştir (Sammartano & Spanò, 2018).

Stonex X120 ise 830 nm lazerle çalışmakta ve 120 metreye kadar tarama yapabilmektedir. Üç adet 5 MP kamera içeren bu sistemin de 3B grafik tabanlı SLAM algoritmasıyla çalıştığı ifade edilmiştir. Her üç sistemin donanım farklılıkları ve kullandıkları SLAM algoritmalarının yapısı, nokta bulutu kalitesi ve veri toplama verimliliği açısından değerlendirilmiştir.

## 5. ÇALIŞMA ALANI

Çalışma İtalya'nın Arezzo şehrinde, Piazza Grande'de yer alan tarihi Palazzo della Fraternita dei Laici sarayında gerçekleştirilmiştir (Şekil 1). Zamanla çeşitli işlevler üstlenmiş olan saray, günümüzde müze ve kültürel etkinliklere ev sahipliği yapmaktadır.




**Şekil 1.** Çalışma Alanı Palazzo della Fraternita dei Laici sarayı

## 6. BULUTTAN BULUTA KARŞILAŞTIRMA (C2C)

Çalışma kapsamında, CloudCompare yazılımı kullanılarak Doğrudan Buluttan Buluta Karşılaştırma algoritmasıyla analiz yapılmıştır. Algoritma önce her bir noktanın en yakın komşusuna olan Öklid mesafesini analiz ederek veri yoğunluğunu belirlemekte, ardından iki nokta bulutu arasındaki ayrımı ölçmek için Hausdorff mesafesi kullanılmaktadır. Hausdorff mesafesi, her iki bulut arasındaki en uzak eşleşen nokta çiftini dikkate alarak en kötü durum farkını ortaya koymakta ve böylece iki veri seti arasındaki geometrik farklılıklar kapsamlı şekilde analiz edilebilmektedir. Bu yöntemin önemli bir avantajı, nokta yoğunluğuna dair herhangi bir varsayımda bulunmadan çalışabilmesidir (Diaz et al., 2024).

## 7. BULGULAR ve TARTIŞMA

Çalışma kapsamında üç farklı mobil lidar sistemi kullanılarak nokta verisi üretilmiştir. Üretilen nokta verilerinin karşılaştırılması her bir sistemin performansını farklı açılardan değerlendirmeye olanak sağlamıştır. BLK2GO, GeoSLAM ve Stonex X120 sistemlerinin her biri farklı teknolojik özelliklere sahip olmakla birlikte, tarama kalitesi, doğruluk ve yoğunluk bakımından önemli farklar ortaya koymaktadır. Çalışmadaki bulgular mevcut literatürle paralel bir şekilde mobil LiDAR sistemlerinin farklı tasarımlarının ve SLAM algoritmalarının, veri kalitesini ve doğruluğunu nasıl etkileyebileceğini ortaya koymaktadır.

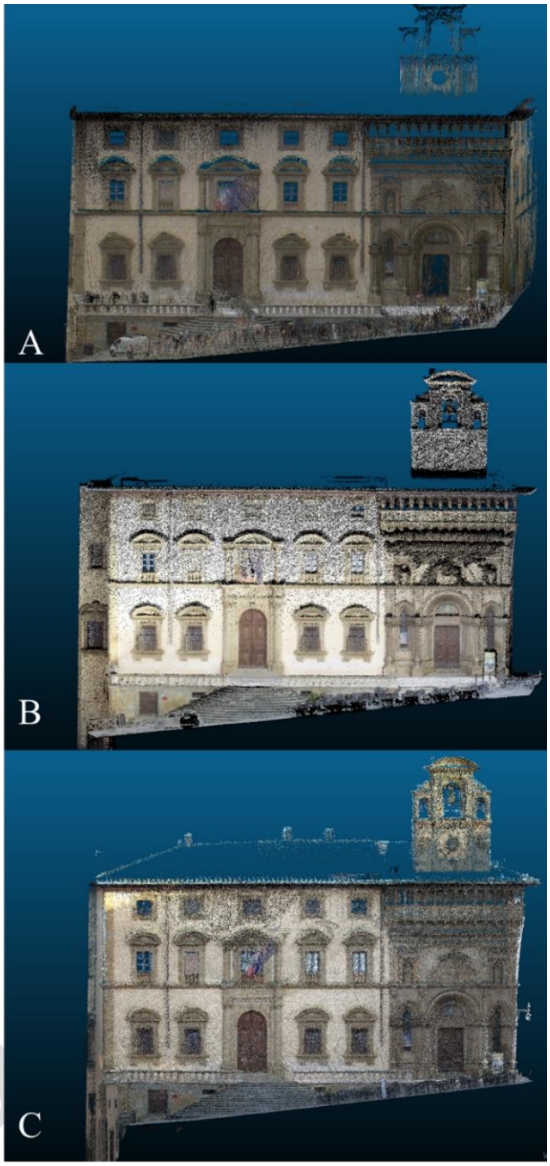


**Şekil 2.** Tarama Sonuçları (A. BLK2GO, B. GeoSLAM ve C. Stonex X120 )

BLK2GO, 830 nm dalga boyuna sahip lazer teknolojisi ve yüksek çözünürlüklü kameralarla donatılmış kompakt bir sistemdir. Yapılan karşılaştırmalarda, BLK2GO'nun nokta yoğunluğunun diğer sistemlere göre daha yüksek olduğu, dolayısıyla daha ayrıntılı bir tarama sunduğu gözlemlenmiştir. Özellikle yapıların ön yüzeylerinin ve cephelerinin yüksek doğrulukla tarandığı ve daha fazla ayrıntı sunduğu görülmüştür. Bununla birlikte, GeoSLAM ve Stonex X120 ile karşılaştırıldığında, BLK2GO'nun düşük menzil (maksimum 25 m) kapasitesi, büyük alanlarda tarama yapıldığında sınırlayıcı bir faktör olarak ortaya çıkmıştır. Literatürde de benzer şekilde, BLK2GO'nun kompakt yapısının taşınabilirliği açısından avantaj sağladığı, menzil sınırlamaları nedeniyle daha büyük alanların taranmasında zorluklarla karşılaşıldığı belirtilmektedir (Del Duca & Machado, 2023). GeoSLAM, 905 nm dalga boyu ve 100 m'ye kadar olan menzil kapasitesi ile daha geniş alanlarda daha verimli tarama yapabilmektedir. Ancak elde edilen nokta verilerinin yoğunluğu, BLK2GO'ya kıyasla belirgin bir şekilde daha düşük olmuştur. Tarama sırasında özellikle yapıların üst kısımlarında doku kaybı ve nokta sapmalarının arttığı gözlemlenmiştir. GeoSLAM'un grafik tabanlı SLAM

algoritması, yapıların üst kısımlarında veri kaybına neden olabilirken bu durum literatürde de benzer şekilde belirtilmiştir. GeoSLAM'un algoritma yapısının, daha büyük yapılar ve geniş alanlar için daha uygun olmasına rağmen detaylı alanlarda sınırlamalar oluşturabileceği vurgulanmaktadır (Herban, Costantino, Alfio, & Pepe, 2022; Sammartano & Spanò, 2018). Stonex X120, özellikle uzun menzil (120 m) kapasitesiyle dikkat çekerken nokta yoğunluğu açısından GeoSLAM ve BLK2GO ile kıyaslandığında daha düşük performans sergilemiştir. Bununla birlikte yüksek menzili sayesinde geniş alanlarda daha fazla veri toplama imkânı sunmuş ve bu da özellikle geniş yapılar ve açık alanlarda tarama işlemi için önemli bir avantaj sağlamıştır. Stonex X120'in tarama doğruluğu çatı gibi daha zor erişilen bölgelerdeki verilerin eksikliği nedeniyle daha düşük olmuştur. Nokta bulutları arasındaki karşılaştırma işlemleri, üç farklı mobil LiDAR sisteminin geometrik doğruluğu hakkında ilginç bulgular ortaya koymuştur. Özellikle A1 (BLK2GO) ve A2 (GeoSLAM) arasındaki karşılaştırmada, her iki sistemin renk dokusunun farklı olduğu ve A1'in, yapı yüzeyinin gerçek rengine daha yakın olduğu belirlenmiştir. Bu durum BLK2GO'nun daha yoğun ve ayrıntılı veri sağlama kapasitesinin bir göstergesi olarak yorumlanabilir. Ayrıca A1 ve A3 arasındaki karşılaştırma her iki sistemin çatılar gibi ulaşılması güç alanlarda daha büyük sapmalar gösterdiğini ortaya koymuştur. Bu bulgular LiDAR sensörlerinin ve algoritmalarının, yapıların farklı kısımlarındaki doğruluk seviyelerini etkileyebileceğini ortaya koymaktadır. Son olarak yapılan karşılaştırmalar, her üç sistemin de benzer mesafe aralıklarında noktalar arasında ortalama mesafeyi önemli ölçüde azalttığını ve bu durumun her bir sistemin kendi doğruluk seviyelerine göre değişiklik gösterdiğini göstermektedir.

## 8. SONUÇ

Bu çalışmada, üç farklı SLAM tabanlı mobil LiDAR sisteminin kültürel miras belgelenmesi uygulamaları açısından performansları karşılaştırılmıştır. Elde edilen bulgular, her sistemin kendine özgü avantajlara sahip olduğunu ortaya koymuştur. BLK2GO, yüksek çözünürlükte detaylar üretme kapasitesi ile öne çıkarken; GeoSLAM, daha geniş alanlarda verimli veri üretimiyle dikkat çekmiştir. Stonex X120 ise uzun menzil avantajına rağmen, detaylı alanlarda nokta yoğunluğu bakımından sınırlı kalmıştır. Özellikle yapıların çatı ve karmaşık yüzeylerinde sistemler arasında farklı seviyelerde sapmalar gözlemlenmiş, bu da cihaz seçiminin proje türüne göre değişmesi gerektiğini göstermektedir.

## TEŞEKKÜR

Bu çalışmanın verilerinin sağlanmasında ve araştırmanın bilimsel gelişimine katkılarından dolayı Padova Üniversitesi CIRGEO (Centro Interdipartimentale di Ricerca Geomatica) Araştırma Merkezi Başkanı Sayın Prof. Dr. Alberto Guarnieri'ye teşekkür ederiz. Ayrıca, veri toplama sürecindeki teknik destekleri için tüm saha ekibine teşekkürlerimizi sunarız.

## Yazar Katkı Oranı

Kasım Erdal ve Büşranur Güvercin, çalışmanın veri toplama sürecinde aktif rol almıştır. Makalenin yazımı ve düzenlenmesi Hasan Bilgehan Makineci tarafından gerçekleştirilmiştir. Konseptin oluşturulması, içerik geliştirme, literatür uyumu ve son kontroller Kasım Erdal ve Hasan Bilgehan Makineci tarafından yapılmıştır.

## Çıkar Çatışması/Çakışması

Yazarlar arasında bu çalışma kapsamında herhangi bir çıkar çatışması veya çakışması bulunmamaktadır.

## Araştırma ve Yayın Etiği Beyanı

Bu çalışma, bilimsel araştırma ve yayın etiğine uygun şekilde yürütülmüş olup, araştırma sürecinde herhangi bir etik ihlal gerçekleşmemiştir. Çalışmada kullanılan veriler, izinli bir şekilde ve akademik kullanım amacıyla toplanmıştır.

## KAYNAKÇA

Ahmed, M. F., Masood, K., Fremont, V., & Fantoni, I. (2023). Active SLAM: A Review on Last Decade. *Sensors, 23*(19). doi:10.3390/s23198097

Del Duca, G., & Machado, C. (2023). Assessing the Quality of the Leica BLK2GO Mobile Laser Scanner versus the Focus 3D S120 Static Terrestrial Laser Scanner for a Preliminary Study of Garden Digital Surveying. *Heritage, 6*(2), 1007-1027. doi:10.3390/heritage6020057

Diaz, V., van Oosterom, P., Meijers, M., Verbree, E., Ahmed, N., & van Lankveld, T. (2024, 2024//). *Comparison of Cloud-to-Cloud Distance Calculation Methods - Is the Most Complex Always the Most Suitable?* Paper presented at the Recent Advances in 3D Geoinformation Science, Cham.

Durrant-Whyte, H., & Bailey, T. (2006). Simultaneous localization and mapping: part I. *IEEE Robotics & Automation Magazine, 13*(2), 99-110. doi:10.1109/MRA.2006.1638022

Erdal, K. (2024). *Investigation of the Accuracy of Maps Produced With Simultanious Mapping and Algorithm*

.

Herban, S., Costantino, D., Alfio, V. S., & Pepe, M. (2022). Use of Low-Cost Spherical Cameras for the Digitisation of Cultural Heritage Structures into 3D Point Clouds. *Journal of Imaging, 8*(1). doi:10.3390/jimaging8010013

Hou, J., Hübner, P., Schmidt, J., & Iwaszczuk, D. (2024). Indoor Mapping with Entertainment Devices: Evaluating the Impact of Different Mapping Strategies for Microsoft HoloLens 2 and Apple iPhone 14 Pro. *Sensors, 24*(4). doi:10.3390/s24041062

Karam, S., Vosselman, G., Peter, M., Hosseinyalamdary, S., & Lehtola, V. (2019). Design, Calibration, and Evaluation of a Backpack Indoor Mobile Mapping System. *Remote Sensing, 11*(8). doi:10.3390/rs11080905

Karasaka, L., & Beg, A. A. R. J. G. (2021). Yersel lazer tarama yöntemi ile farklı geometrik yapıdaki özelliklerin modellenmesi. *6*(1), 54-60.

Lluvia, I., Lazkano, E., & Ansuategi, A. (2021). Active Mapping and Robot Exploration: A Survey. *Sensors, 21*(7). doi:10.3390/s21072445

Makineci, H. B., & Erdal, K. (2021). Documentation of Cultural Heritage with Backpack LiDAR Usage on Photogrammetric Purpose. [Sırt Lidarının Fotogrametrik Amaçlı Kullanımıyla Kültürel Mirasın Dokümantasyonu]. *Türkiye Lidar Dergisi, 3*(1), 1-6. doi:10.51946/melid.921032

Makineci, H. B., & Erdal, K. (2023). Adaptation analysis of produced 3D models from UAV-SLAM and UAV-TLS data combinations. *Mersin Photogrammetry Journal, 5*(1), 18-23. doi:10.53093/mephoj.1269630

Özdemir, E., Erdal, K., Veziroğlu, F., & Ateş, S. S. (2022). Tuz Mağaralarında Sırt Çantası LiDAR Sisteminin 3B Model Üretiminde Kullanılması; Tuzluca, Iğdır Örneği. [The Use of the Backpack LiDAR System in the Genarate of 3D Models in Salt Caves; The Example of Tuzluca, Igdir]. *Türkiye Uzaktan Algılama Dergisi, 4*(1), 36-42. doi:10.51489/tuzal.1112140

Placed, J. A., Strader, J., Carrillo, H., Atanasov, N., Indelman, V., Carlone, L., & Castellanos, J. A. (2023). A Survey on Active Simultaneous Localization and Mapping: State of the Art and New Frontiers. *IEEE Transactions on Robotics, 39*(3), 1686-1705. doi:10.1109/TRO.2023.3248510

Sammartano, G., & Spanò, A. (2018). Point clouds by SLAM-based mobile mapping systems: accuracy and geometric content validation in multisensor survey and stand-alone acquisition. *Applied Geomatics, 10*(4), 317-339. doi:10.1007/s12518-018-0221-7

Sualeh, M., & Kim, G.-W. (2019). Simultaneous Localization and Mapping in the Epoch of Semantics: A Survey. *International Journal of Control, Automation and Systems, 17*(3), 729-742. doi:10.1007/s12555-018-0130-x

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Atatürk Barajı Su Alanı Değişimlerinin Uzaktan Algılama Verileri ve Makine Öğrenimi ile Modellenmesi

**Çağrı Kapusuz*[1], Osman Orhan[2], Ahmet Tarık Torun[3]**

[1]*Mersin Üniversitesi, Fen Bilimleri Enstitüsü, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri ABD., Mersin, Türkiye*
[2]*Mersin Üniversitesi, Fen Bilimleri Enstitüsü, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri ABD., Mersin, Türkiye*
[3]*Ankara Hacı Bayram Veli Üniversitesi, Tapu Kadastro Yüksekokulu, Emlak ve Emlak Yönetimi Bölümü, Ankara, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Su Alanı Tespiti,
Makine Öğrenmesi
Zaman Serisi Analizi
Atatürk Barajı

**ÖZET**

Uzaktan algılama teknikleri, su kaynaklarının izlenmesi ve sürdürülebilir şekilde yönetilebilmesi için önemli veri kaynakları ve araçları sağlamaktadır. Bu çalışmada, 2017-2024 yılları arasında Atatürk Barajı'ndaki su alanı değişimleri Sentinel-1 uydu görüntüleri kullanılarak analiz edilmiş ve geleceğe yönelik tahminler yapılmıştır. Su alanı tespiti için NRI (Normalize Edilmiş Radar İndeksi) ve DBDI (Desibel Fark İndeksi) indeksleri hesaplanmış, belirlenen eşik değerler uygulanarak su alanı maskeleri oluşturulmuştur. Gelecek tahminleri için SARIMA ve LSTM modeller geliştirilmiş ve performansları karşılaştırılmıştır. Modeller arasında en iyi performansı, zaman serisi verilerindeki uzun vadeli bağımlılıkları öğrenme yeteneği sayesinde Sarıma modeli göstermiştir. SARIMA ve LSTM modeli hata oranlarına baktığımızda en düşük hata oranına sahip olan modelin Sarıma modeli olduğu gözlemlenmiştir. Analiz sonuçları, barajın su alanında mevsimsel değişimlerin belirgin olduğunu ve 2025-2026 dönemi için artış trendi öngörüldüğünü ortaya koymuştur. Çalışmanın, yalnızca Atatürk Barajı için değil, diğer su kaynaklarının izlenmesi ve yönetimi için de önemli bir referans niteliğinde olduğu düşünülmektedir.

# Modeling Water Surface Area Changes of the Atatürk Dam Using Remote Sensing Data and Machine Learning

**Keywords**
Remote sensing,
Water Area Detection,
Machine Learning,
Time Series Analysis
Atatürk Dam

**ABSTRACT**

Remote sensing techniques provide important data sources and tools for monitoring and sustainable management of water resources. In this study, water area changes in Atatürk Dam between 2017 and 2024 were analyzed using Sentinel-1 satellite imagery and future predictions were made. NRI (Normalized Radar Index) and DBDI (Decibel Difference Index) indices were calculated for water area detection, and water area masks were created by applying the determined threshold values. SARIMA and LSTM models were developed for future forecasts and their performances were compared. Among the models, SARIMA model performed the best thanks to its ability to learn long-term dependencies in time series data. When we look at the error rates of the SARIMA and LSTM models, it is observed that the SARIMA model has the lowest error rate. The results of the analysis revealed that seasonal changes in the water area of the dam are significant and an increasing trend is predicted for the period 2025-2026. The study is considered to be an important reference not only for Atatürk Dam but also for monitoring and management of other water resources.

* **Sorumlu Yazar**

*(kapusuzcagri@gmail.com) ORCID ID 0000-0002-8691-5396
(osmanorhan@mersin.edu.tr) ORCID ID 0000-0002-1362-8206
(ahmet-torun@hbv.edu.tr) ORCID ID 0000-0002-7927-4703

**Kaynak Göster (APA):**

Kapusuz Ç, Orhan O & Torun,A.T (2025)., Atatürk Barajı Su Alanı Değişimlerinin Uzaktan Algılama Verileri ve Makine Öğrenimi ile Modellenmesi.,13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

TASLAK

## 1. GİRİŞ

Su kaynaklarının izlenmesi ve yönetimi, artan nüfus, iklim değişikliği ve su kaynaklarının sürdürülebilir kullanımı gibi küresel sorunlar nedeniyle giderek daha kritik bir hale gelmiştir. Barajlar, enerji üretimi, tarımsal sulama ve içme suyu temini gibi birçok alanda stratejik bir öneme sahiptir. Bu bağlamda, Atatürk Barajı, Türkiye'nin en büyük barajlarından biri olarak hem bölgesel hem de ulusal ölçekte su kaynaklarının yönetiminde önemli bir rol oynamaktadır.

Uzaktan algılama teknolojileri, geniş alanlarda düzenli ve güvenilir veri sağlayarak su kaynaklarının izlenmesinde önemli avantajlar sunmaktadır. Özellikle Sentinel-1 gibi çoklu polarizasyonlu Sentetik Açıklıklı Radar (SAR) verileri, bulut örtüsünden etkilenmeden su alanlarının tespiti ve değişimlerinin izlenmesi için etkili bir araçtır (Martinis et al., 2018). Bu çalışmada, Sentinel-1 verilerinden elde edilen VV ve VH polarizasyonları kullanılarak Normalized Radar Index (NRI) ve Decibel Difference Index (DBDI) hesaplanmıştır. NRI, VV ve VH polarizasyonları arasındaki normalize farkı kullanarak su yüzeylerini tespit ederken (Twele et al., 2016), DBDI ise polarizasyonların logaritmik farkına dayanmaktadır (Henry et al., 2006).

Makine öğrenimi yöntemleri, uzaktan algılama verilerinin analizinde giderek daha fazla kullanılmaktadır. Zaman serisi analizinde kullanılan SARIMA (Seasonal AutoRegressive Integrated Moving Average) ve LSTM gibi modeller, su alanı değişimlerinin tahmin edilmesinde önemli avantajlar sunmaktadır. Özellikle LSTM (Long Short-Term Memory) modeli, zaman serisi verilerindeki uzun vadeli bağımlılıkları öğrenme yeteneği sayesinde diğer modellere kıyasla daha yüksek doğruluk sağlamaktadır (Hochreiter & Schmidhuber, 1997; Prapti vd., 2022).

Bu çalışmada, 2017-2024 yılları arasında Atatürk Barajı'ndaki su alanı değişimleri Sentinel-1 uydu görüntüleri kullanılarak analiz edilmiş ve geleceğe yönelik tahminler yapılmıştır. Çalışmanın amacı, uzaktan algılama ve makine öğrenimi yöntemlerini birleştirerek su kaynaklarının izlenmesi ve sürdürülebilir yönetimi için yenilikçi bir yaklaşım sunmaktır. Bu bağlamda, çalışma hem Atatürk Barajı hem de diğer su kaynaklarının yönetimi için önemli bir referans niteliği taşımaktadır.

## 2. YÖNTEM

2017-2024 yıllarına ait 96 adet Sentinel-1 uydu görüntüleri, Google Earth Engine platformundan alınmıştır. Her bir Sentinel-1 SAR görüntüsü için su alanlarının çıkarılmasında, öncelikle görüntüler üzerinde radyometrik ve geometrik düzeltmeler uygulanmıştır. Ardından, su ve kara yüzeylerinin radar geri saçılım değerleri arasındaki farkı ortaya koyan Normalize Radar Indeks (NRI) ve Desibel fark Indeksi (DBDI) gibi indeksler hesaplanmıştır (Şekil 3). Bu indeksler, su yüzeylerinin genellikle daha düşük geri saçılım değerlerine sahip olması prensibine dayanmaktadır. Eşik değer belirleme yöntemi olarak, literatürde yaygın şekilde kullanılan otomatik eşikleme ve gözlemsel analiz yaklaşımları kullanılmıştır. Öncelikle, indeks değerlerinin histogramı incelenmiş ve su ile kara alanlarını en iyi şekilde ayıran bir eşik değeri belirlenmiştir. Otsu yöntemi gibi otomatik algoritmalar, piksel değerlerinin dağılımına göre optimum eşik değerini belirlemede kullanılmıştır. Bazı durumlarda ise, çalışma alanına özgü olarak farklı tarihlerdeki referans su alanları ile karşılaştırma yapılarak, en iyi ayrımı sağlayan eşik değeri manuel olarak da test edilmiştir.

Belirlenen eşik değerinin altında kalan pikseller su, üzerinde kalanlar ise kara olarak sınıflandırılmıştır. Sonuç olarak, her bir Sentinel-1 görüntüsü için su alanı maskesi oluşturulmuş ve bu maskelerden toplam su alanı ($km^2$) hesaplanmıştır.

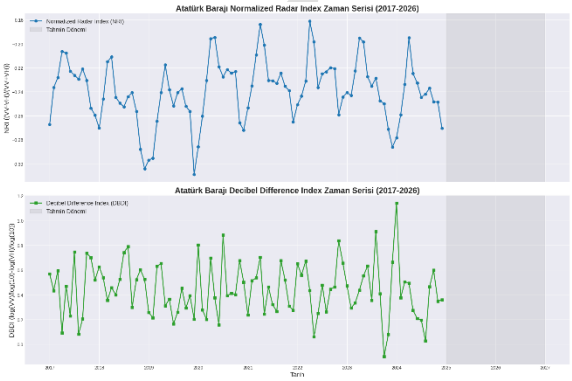


**Şekil 1.** NRI ve DBDI İndekslerine Göre Su Alanı Değişim İstatistikleri.

Zaman serisi analizinde SARIMA ve LSTM modelleri kullanılmıştır. SARIMA modeli, zaman serisi verilerindeki mevsimsel ve trend bileşenlerini modellemek için kullanılan bir istatistiksel yöntemdir. LSTM modeli, zaman serisi verilerindeki uzun vadeli bağımlılıkları öğrenmek için kullanılan bir derin öğrenme yöntemidir.

SARIMA mevsimsel ve trend bileşenlerini modellemek için ve LSTM ise uzun vadeli bağımlılıkları öğrenmek için tercih edilmiştir. Modellerin performansı RMSE, MAE, MAPE ve $R^2$ metrikleriyle değerlendirilmiştir.

## 3. BULGULAR

Atatürk Barajı'ndaki su alanı değişim analizinde, SARIMA modeli en düşük hata oranıyla en iyi performansı göstermiştir. LSTM modeli ise SARIMA modeline kıyasla daha yüksek bir hata oranı sunmuştur. Zaman serisi analizi, 2017-2024 yılları arasında su alanında belirgin bir dalgalanmanın olduğunu ve bu dalgalanmanın 2021'den itibaren hızlandığını ortaya koymuştur. SARIMA ve LSTM modelleri geleceğe yönelik daha dengeli ve gerçekçi tahminler sunmaktadır (Şekil 3). Bu bulgular, su yönetimi stratejileri için önemli bilgiler sağlamaktadır. 2017-2024 yılları arasında Atatürk Barajı'ndaki su alanında, özellikle 2021'den itibaren belirgin bir azalma gözlemlenmiştir. Trend, sürekli düşüşü; mevsimsel bileşen ise yıllık değişimlerin yağış ve buharlaşma ile ilişkisini göstermektedir. Artık bileşen ise rastgele değişimleri ifade etmektedir (Şekil 2).

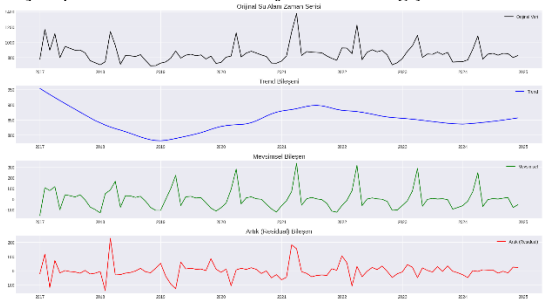

**Şekil 2.** Orijinal veri, trend, mevsimsel ve artık bileşenlerin zaman serisi analizi.

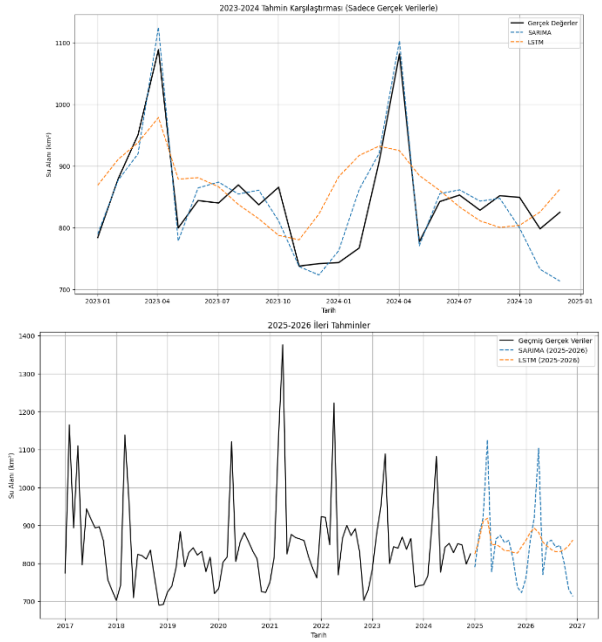


**Şekil 3.** Modellerin test verisi üzerindeki tahminleri ve geleceğe yönelik tahminleri.

**Çizelge1.** Model Performans İstatistikleri

| MODEL | RMSE | MAE | MAPE | $R^2$ |
|---|---|---|---|---|
| SARIMA | 39.96 | 28.64 | 3.42 | 0.79 |
| LSTM | 74.04 | 59.77 | 7.12 | 0.29 |

Not: RMSE, MAE ve MAPE, modellerin tahmin hatalarını ölçer; daha düşük değerler daha iyi performansı gösterir. $R^2$, modelin açıklama gücünü ifade eder; 1'e yakın değerler iyi, negatif değerler kötü performansı gösterir.

## 4. TARTIŞMA

Bu çalışmada, uzaktan algılama ve makine öğrenimi ile Atatürk Barajı'ndaki su alanı değişimleri analiz edilmiştir. Sentinel-1 SAR verileri üzerinden analiz edilmiştir. Optik uydu görüntülerinde karşılaşılan bulut örtüsü gibi sınırlamalar yerine, radar verilerinin bulut ve hava koşullarından etkilenmemesi nedeniyle daha güvenilir sonuçlar elde edilmiştir. Çalışmada, 2021 yılından itibaren su alanında belirgin bir azalma gözlemlenmiştir. SARIMA modeli en iyi performansı sergilemiş, LSTM ise daha düşük performans göstermiştir. Gelecekte, farklı uydu verilerinin birleştirilmesi ve gelişmiş modellerin kullanılması önerilmektedir.

## 5. SONUÇ

Bu çalışma, Atatürk Barajı'ndaki su alanı değişimlerini analiz etmek için uzaktan algılama ve makine öğrenmesi tekniklerini birleştirerek yenilikçi bir yaklaşım sunmaktadır. Sentinel-1 verilerinin ve SARIMA modelinin birlikte kullanılması sulak alanlardaki değişimin izlenmesinde başarılı sonuçlar vermiştir. Bu yöntemler, sulak alanların daha etkin bir şekilde izlenmesi ve sürdürülebilir bir çevre yönetimi için araştırmacı ve yöneticilere yol gösterir niteliktedir.

### Yazar Katkı Oranı

**Çağrı Kapusuz:** Veri analizleri, veri çıktıları, veri yorumlaması.
**Osman Orhan:** Veri analizleri, çıktıların yorumlanması.
**Ahmet Tarık Torun:** Verilerin yorumlanması, yazım denetleme ve düzenleme.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

### KAYNAKÇA

Henry, J.-B., Chastanet, P., Fellah, K., & Desnos, Y.-L. (2006). Envisat multi-polarized ASAR data for flood mapping. *International Journal of Remote Sensing*, 27(10), 1921-1929.

Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.

Martinis, S., Kersten, J., & Twele, A. (2018). A fully automated TerraSAR-X based flood service. *ISPRS Journal of Photogrammetry and Remote Sensing*, 104, 203-212.

Prapti, D. R., Shahar, N. A. N., & Shariff, A. R. B. M. (2022). State-of-the-art review of assessing water quality from space. *In IOP Conference Series: Earth and Environmental Science* (Vol. 1064, No. 1, p. 012040). IOP Publishing.

Twele, A., Cao, W., Plank, S., & Martinis, S. (2016). Sentinel-1-based flood mapping: A fully automated processing chain. *International Journal of Remote Sensing*, 37(13), 2990-3004.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Farklı Derin Öğrenme Tabanlı Segmentasyon Mimarileri Kullanılarak Gerçek Ortofoto ve Sayısal Yüzey Modeli ile Kayıt Dışı Yapıların Belirlenmesi

**Güray Çetin**[1], **Ekrem Ayyıldız**[1]

[1]*Tapu ve Kadastro Genel Müdürlüğü Ankara, Türkiye*

**Anahtar Kelimeler**
Derin Öğrenme
Segmentasyon,
Bina tespiti,
Ortofoto,
Sayısal Yüzey Modeli (SYM)

**ÖZET**

Kentsel planlama ve yönetim süreçlerinde bina verilerinin güncel tutulması büyük önem taşımaktadır. Fakat eksiklikler veriler, güncelleme gecikmeleri ve kayıtzı yapılar bu süreci zorlaştırmaktadır. Bu çalışmada, kayıtlı olmayan yapıların tespiti amacıyla segmentasyon modelleri ile konumsal analizlerin entegre edildiği bir yöntem uygulanmıştır. 20 cm çözünürlüklü gerçek ortofotolar, 1 m çözünürlüklü sayısal yüzey modelleri ve bina verisi kullanılarak 8 km$^2$'lik eğitim ve 1.5 km$^2$'lik test verisi oluşturulmuştur. RGB ve yükseklik bilgisi eklenmiş RGB verilerle birlikte veri artırma tekniklerinin model başarısına etkisi değerlendirilmiştir. UNet, UNet++, LinkNet, DeepLabv3, DeepLabv3+, MA-Net, FPN ve PAN mimarileri toplam 32 oturumla eğitilmiştir. En yüksek başarı, 4 bantlı veri kullanarak %85,55 IoU skoru ile ResNet-50 tabanlı UNet++ modelinden elde edilmiştir. En yüksek metrik değeri elde eden model kullanılarak, ortofotolarda görsel olarak tespit edilen ancak veritabanında yer almayan yapılar model doğruluğundaki sınırlamalara rağmen başarılı şekilde tespit edilmiştir. Bu yöntem, kentsel veri tabanlarındaki eksikliklerin belirlenmesine katkı sağlayarak güncellik konusuna katkı sağlamasını hedeflemektedir.

# Detection of Non-Registered Building Records Using Deep Learning-Based Segmentation Architectures with True Orthophoto and Digital Surface Model

**Keywords**
Deep Learning,
Segmentation,
Building Detection,
Orthophoto,
Digital Surface Model (DSM)

**ABSTRACT**

Keeping building data up to date is of great importance in urban planning and management processes. However, data deficiencies, update delays, and unregistered buildings make this process challenging. In this study, a method integrating segmentation models with spatial analysis was applied to detect unregistered buildings. Training and test datasets covering 8 km$^2$ and 1.5 km$^2$, respectively, were created using 20 cm resolution true orthophotos, 1 m resolution digital surface models, and building data. The effect of data augmentation techniques on model performance was evaluated using both RGB and height-stacked RGB data. A total of 32 training sessions were conducted with UNet, UNet++, LinkNet, DeepLabv3, DeepLabv3+, MA-Net, FPN, and PAN architectures. The highest performance was achieved with the ResNet-50-based UNet++ model using 4-band input, reaching an IoU score of 85.55%. Using the model that achieved the highest metric values, buildings that were visually identified in orthophotos but not present in the database were successfully detected despite the limitations in model accuracy. This method aims to contribute to identifying gaps in urban databases and supports efforts to keep them up to date.

## 1. GİRİŞ

Güncel mekânsal verilere erişim kent yönetimi, politika geliştirme ve kaynak planlaması açısından büyük bir öneme sahiptir (Chen vd., 2020;Bakırman vd., 2022). Eksik veya mevcut durumu yansıtmayan veriler, yanlış kararlar alınması, denetimsel gecikmeler ve kaynak israfları gibi istenmeyen sonuçlara yol açabilmektedir (Awrangjeb vd., 2015). Mevcut bina bilgilerini içeren kadastral veri tabanları ve coğrafi bilgi sistemleri, yeni

* Sorumlu yazar

*(tk48685@tkgm.gov.tr) ORCID ID 0000-0002-2264-6457
(tk43237@tkgm.gov.tr) ORCID ID 0000-0002-0805-1529

**Kaynak Göster (APA):**

Çetin G & Ayyıldız E (2025) Farklı Derin Öğrenme Tabanlı Segmentasyon Mimarileri Kullanılarak Gerçek Ortofoto ve Sayısal Yüzey Modeli ile Kayıt Dışı Yapıların Belirlenmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

yapıların entegrasyonundaki gecikmeler, güncelleme sıklığı veya izinsiz inşa edilen yapıların kayıtlarda yer almaması gibi farklı nedenlerle, arazideki güncel ve mevcut durumu yansıtamayabilir. Bu durum, veri tabanları ile arazideki gerçek durum arasında farklılıklar ve tutarsızlıklar oluşmasına neden olarak güncellik sorununu beraberinde getirebilmektedir.

Derin öğrenme tekniklerindeki gelişmeler, coğrafi verilerin elde edilmesi ve işlenmesiyle ilgili zaman alıcı süreçler için daha pratik ve otomatik çözümler geliştirme olanağı sunmaktadır (Song vd., 2023). Son dönemlerde derin öğrenme tabanlı yaklaşımlar, bina tespiti ve kayıtsız yapıların belirlenmesine konusunda kullanılmaktadır. Ostankovic ve Afanasyev (2018) uydu görüntüleri üzerinde geliştirdikleri bir iş akışı ile GoogLeNet modeli kullanarak tespit edilen yapıların konumlarını resmi kadastro verileriyle doğrulayan bir çalışma gerçekleştirmiştir. Li vd. (2020) ise normalleştirilmiş sayısal yüzey modelleri (SYM), gerçek ortofoto ve kadastro haritalarını kullanarak FC-DenseNet tabanlı bir yöntemle resmi kayıtlarda yer almayan binaları tespit etmiş ve bunları yeni ve eski olarak sınıflandırmıştır. Liu vd. (2020), Deeplabv3+ mimarisi ile nehir kenarındaki kayıt dışı yapıların otomatik olarak belirlenmesini çalışmasını gerçekleştirmiştir. Fan (2023) ise İHA görüntüleri üzerinde Faster R-CNN kullanarak %91,2 doğruluk oranına ulaşmış ve çalışma alanındaki birçok kaçak yapıyı başarılı bir şekilde tespit etmiştir.

Bu çalışma, mevcut yapılar ile veri tabanında kayıtlı yapılar arasındaki uyumsuzlukların belirlenmesini hedeflemektedir. Elde edilen sonuçlar, hem mekânsal veri tabanlarındaki eksikliklerin belirlenmesine hem de güncellenmesi gereken bölgelerin tespitine yönelik katkı sunmasını hedeflemektedir.

## 2. YÖNTEM

Açık kaynaklı Berlin Geoportal platformu tarafından sağlanan 20 cm çözünürlüklü gerçek ortofotolar, 1 m çözünürlüklü SYM ve vektör bina veri seti kullanılarak çalışma için özel bir eğitim veri seti oluşturulmuştur. Eğitim verisi çeşitli yapı tiplerini içeren 10.000x10.000 piksel boyutlarında iki ortofoto bölgesi olarak seçilmiştir. Uygulama alanı olarak veritabanı ile ortofotolar arasında farklılıklar göze çarpan yaklaşık 1,5 km²'lik bölge belirlenmiştir. Bu bölgede veritabanında yer almayan binalar tespit edilip manuel olarak eklenmiş, böylece hem eğitilen modellerin metrik değerlendirilmesi için test verisi hem de çalışma kapsamındaki uygulamalar için bir test alanı oluşturulmuştur.

Vektör ve raster veriler arasındaki çözünürlük farkı nedeniyle görsel kontrol ve düzeltmeler yapılmış, ardından bina izdüşüm vektörlerinden 0-1 değer aralığında maskeler üretilmiştir. 1 m çözünürlüklü SYM, ortofotolarla uyumlu hale getirilmek üzere 20 cm çözünürlüğe yeniden örneklenmiş ve 0–1 aralığına normalize edilmiştir.. SYM, RGB (Red Green Blue) görüntülere 4. bant olarak eklenmiştir. Eğitim verisindeki görüntüler boydan %25 örtüşmeli olarak 512×512 piksel boyutlarında parçalara ayrılmış ve yatay çevirme, döndürme ve yeniden boyutlandırma veri artırımı(augmentation) teknikleri uygulanmıştır. Eğitim verisi olarak 1,458 görüntü parçası üretilmiş ve bunun 1167'si eğitim verisi ve 291 tanesi validasyon verisi olarak kullanılmıştır. 140 tane bindirmesiz görüntü parçası ise test verisi olarak kullanılmıştır.

Bu çalışmada, Segmentation Models (Iakubovskii, 2019) kütüphanesi tarafından sağlanan ve literatürde yaygın olarak kullanılan sekiz farklı segmentasyon mimarisi tercih edilmiştir. Bu mimariler UNet (Ronneberger vd., 2015), UNet++ (Zhou vd., 2018), LinkNet (Chaurasia & Culurciello, 2017), Multi-Scale Attention Network (MA-Net) (Fan vd., 2020), Feature Pyramid Networks (FPN) (Lin vd., 2017), Pyramid Attention Network (PAN) (Li vd., 2018), DeepLabV3 (Chen vd., 2017) ve DeepLabV3+ (Chen vd., 2018) şeklindedir Kütüphane tarafından sağlanan ve çalışmada seçilen 8 mimari model, hem 3 bantlı hem de 4 bantlı verilerle eğitime uygunluğu yapılan testlerle doğrulanarak tercih edilmiştir.

Her bir model, 3 bantlı görüntü verisi (RGB) ve yükseklik bilgisi eklenmiş 4 bantlı görüntü verisi ile hem veri artırımı uygulanarak hem de uygulanmadan olmak üzere dört farklı yapılandırmada test edilmiş ve toplamda 32 eğitim oturumu gerçekleştirilmiştir. Eğitimlerde ResNet50 encoder tercih edilmiş ve ImageNet üzerinde önceden eğitilmiş ağırlıklar kullanılmıştır. Dice Loss kayıp fonksiyonu ve Adam optimizasyon algoritması uygulanmıştır. Başlangıç öğrenme oranı 0.001 olarak belirlenmiş ve ReduceLROnPlateau scheduler kullanılmıştır. Modeller test verisi üzerinde Intersection over Union (IoU) ve F1 skoru ile değerlendirilmiştir. En yüksek metrik değeri elde edilen model, veri tabanındaki bina uyumsuzluklarının tespiti için uygulama bölgesinde kullanılmıştır. Daha sonra model çıktıları morfolojik işlemlerle iyileştirilmiş ve ardından vektör hale getirilmiştir. Son aşamada, model çıktıları ile veri tabanındaki veriler vektörel karşılaştırılmaya tabi tutularak veri tabanındaki eksiklikler otomatik olarak tespit edilmiştir.

Uygulama Python programlama diliyle gerçekleştirilmiş olup, model eğitimi için PyTorch; veri işlemleri için Rasterio, Pandas, GeoPandas ve Numpy, görselleştirme ve düzenleme işlemleri için ise QGIS yazılımı kullanılmıştır.

## 3. BULGULAR

Oturumlar sonucunda, 3 bantlı verilerin eğitiminde veri artırımı uygulanmasının, MA-Net modelindeki %2.12'lik IoU düşüşü dışında, modellerin metrik sonuçlarında ortalama IoU (mIoU) artışı olarak %0.2 ile %1.1 arasında iyileşme sağladığı gözlemlenmiştir. 3 bantlı veriler ile yapılan eğitimler sonucunda, DeepLabv3+ modeli veri artırımı yöntemiyle %83.13 mIoU ve %89.63 F1 değerleri ile en yüksek performansı sergilemiştir. Bu sonucu Unet++ (%83.06 mIoU ve %89.58 F1) ve UNet (%82.81 mIoU ve %82.81 F1 ) modelleri izlemiştir. 3 bantlı eğitimde veri artırımı kullanılmadan en yüksek sonucu %82.47 mIoU değeri ile UNet++ modelinde elde edilmiştir ve DeepLabV3 ve FPN modelleri en yüksek ikinci ve üçüncü değeri elde etmiştir. 3 bantlı eğitimde en düşük performansa sahip olan MA-Net modeli veri arttırımsız yöntemle %78.99 mIoU

değeri ve veri arttırımı ile %76.86 mIoU değerlerini elde etmiştir. 4 bantlı verilerde yapılan eğitim oturumları sonucunda ise veri artırım yöntemi kullanılmadan en yüksek metrik değerine LinkNet %84.68 mIoU ve %90,62 ile en yüksek ortalama F1 skorunu elde etmiştir. Bunu %84,62 mIoU ve %90,50 ortalama F1 skoru ile UNet++ modeli yakından takip etmiştir. FPN ile eğitilen model ise %84,44 mIoU ve %90,42 ortalama F1 skoru ile bir sonraki en yüksek performansı göstermiştir. Ancak DeepLabV3+, veri artırımı uygulanmayan yapılandırmada %30,29 mIoU ile %32,22 ortalama F1 skoruyla en düşük sonuçları vermiştir. Bu durum, modelin veri kümesi üzerinde yeterince genelleme yapamadığını göstermektedir. Modellerin çoğu, veri artırımı uygulandığında performanslarında artış gözlemlenmiş ve en yüksek metrik değerleri bu deneylerde elde edilmiştir.

LinkNet modelindeki %0,20 mIoU düşüşü ve Deeplabv3+ modelindeki %54,82 mIoU artışı dışında, veri artırımı diğer tüm modellerde %0,35 ile %2,42 arasında değişen oranlarda performans iyileştirmesi sağlamıştır. UNet++ %85,55 ve %91,07 ortalama F1 skoru ortalama IoU değeriyle tüm oturumların test verisi üzerinde en yüksek metrik değerini elde etmiştir. Hemen ardından PAN, %85,47 mIoU ve %91,03 ortalama F1 skoru ile UNet++'i yakından takip etmiştir. Ayrıca, veri artırımı uygulanmadan yapılan deneylerde en düşük skorlara sahip olan DeepLabV3+, %54,82 mIoU ve %58,58 ortalama F1 skoru artışıyla en büyük gelişmeyi göstermiştir. En yüksek metrik değerine sahip olan UNet++ modeli ile uygulamanın diğer kısmı için uygulama alanında model çıktıları oluşturulmuştur. Gürültünün azaltılması ve binaların vektör sonuçlarının daha sağlıklı elde edilebilmesi için morfolojik işlemler uygulanmıştır. Elde edilen bina geometrileri ile mevcut bina verisi karşılaştırılarak, yeterli düzeyde örtüşmeyen yapılar, potansiyel yeni veya kayıt dışı olarak işaretlenmiştir. Şekil 1'de, model çıktısı ile mevcut veri tabanı karşılaştırması görselleştirilmiştir. Mavi renkteki yapılar model tarafından segmente edilen ve uygulama sonucunda veritabanında bulunamayan yapıları, kırmızı renktekiler ise mevcut veri tabanında yer alan kayıtlı yapıları temsil etmektedir.

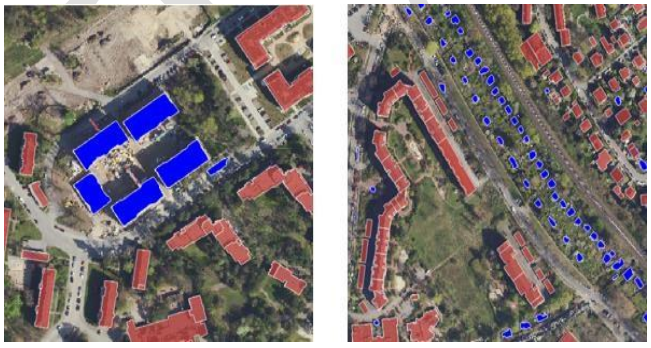

**Şekil 1.** Test alanında tespit edilen bina vektörlerinin (mavi renkli) görselleştirilmesi.

## 4. TARTIŞMA

Yükseklik bilgisi entegre edilmiş görüntüler ile eğitilmiş modellerin daha yüksek metrik değerleri elde edilmiş olmasına karşın köprü üzerindeki demiryolu kesiti gibi bazı yapılar bina olarak yanlış segmente edildiği gözlemlenmiştir. Fakat 3 bantlı veriyle eğitilen modeller bu tür hatalardan kaçınmıştır. Gölge alanlarda ise yalnızca 4 bantlı modeller sınırlı da olsa doğru tespit yapabilmiştir. Yükseklik bilgisi zorlu senaryolarda fayda sağlasa da, bazı yanlış segmentasyonlara neden olmuştur. Ayrıca veri artırma metotlarının modellerin eğitimlerinde genelleme yeteneklerini artırdığı ve aşırı öğrenme sorunundan kaçınmalarına katkı sağladığı gözlemlenmiştir.

## 5. SONUÇ

Bu çalışmada, olası yeni ve kayıt dışı yapıların belirlenmesi amacıyla derin öğrenme tabanlı bir yaklaşım uygulanmıştır. Uygulama sonuçları, yöntemin veri tabanı eksikliklerini ve güncelleme ihtiyacı olan alanları tespit etmede işlevsel bir araç olabileceğini göstermektedir.

Ancak sürecin başarısı, doğrudan model çıktısının doğruluğuna bağlıdır. Modelin karşılaştığı sınırlamalar ve hatalar uygulama sonuçlarını doğrudan etkileyebilmektedir. Özellikle düşük çözünürlüklü görüntüler, mevsimsel farklılıklar ve aydınlatma koşulları model performansını etkilemektedir. Bitişik nizamdaki yapıların segmentasyonunda binaların bütün olarak ele alınması, diğer bir kısıtlayıcı unsur olarak öne çıkmaktadır.

Uygulama bölgesinde veritabanı ile yaklaşık 200 adet uyumsuz yapı, model çıktıları ve uygulama aracılığıyla büyük ölçüde tespit edilebilmiştir. Bu yapılar içerisinde hobi bahçeleri, inşaatı devam eden yapılar, kamelya benzeri yapılar ve bazı yanlış segmentasyon örnekleri yer aldığı gözlemlenmiştir. Ayrıca, ağaçlık alanlarda bulunan bazı yapıların model tarafından tespit edilemediği belirlenmiştir. Her ne kadar büyük ölçüde uyumsuzluklar belirlenebilmiş olsa da, modelin bazı sınırlamaları nedeniyle bu yapıların veritabanına eklenmeden önce görsel olarak doğrulanması gerekmektedir. Sonuç olarak, bu yöntem bina envanterinin güncellenmesinde ve olası kayıt dışı yapıların belirlenmesinde pratik, ölçeklenebilir bir yaklaşım sunmaktadır.

**TEŞEKKÜR**

Bildiri, sorumlu yazarın Berlin Teknik Üniversitesi'nde tamamladığı yüksek lisans tezinden (2024) üretilmiştir. Tez danışmanlarım Prof. Dr.-Ing. Martin Kada ve Msc. Lilli Kaufhold'a teşekkürlerimi sunuyorum.

**Yazar Katkı Oranı**

Sorumlu yazar çalışmanın tamamından sorumludur.

**Araştırma ve Yayın Etiği Beyanı**

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

## KAYNAKÇA

Awrangjeb, M., Fraser, C. S., & Lu, G. (2015). Building change detection from LiDAR point cloud data based on connected component analysis. *ISPRS annals of the photogrammetry, remote sensing and spatial information sciences*, *2*, 393-400.

Bakirman, T., Komurcu, I., & Sertel, E. (2022). Comparative analysis of deep learning based building extraction methods with the new VHR Istanbul dataset. *Expert Systems with Applications*, *202*, 117346.

Chaurasia, A., & Culurciello, E. (2017, December). Linknet: Exploiting encoder representations for efficient semantic segmentation. In *2017 IEEE visual communications and image processing (VCIP)* (pp. 1-4). IEEE.

Chen, L. C., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation. In *Proceedings of the European conference on computer vision (ECCV)* (pp. 801-818).

Chen, L. C., Papandreou, G., Schroff, F., & Adam, H. (2017). Rethinking atrous convolution for semantic image segmentation. *arXiv preprint arXiv:1706.05587*.

Chen, Q., Wang, L., Waslander, S. L., & Liu, X. (2020). An end-to-end shape modeling framework for vectorized building outline generation from aerial images. *ISPRS Journal of Photogrammetry and Remote Sensing*, *170*, 114-126.

Fan, C. L. (2023, April). Identifying Illegal Buildings Using UAV Images and Faster R-CNN Based on Deep Learning. In International Conference on Soft Computing for Security Applications (pp. 503-514). Singapore: Springer Nature Singapore.

Fan, T., Wang, G., Li, Y., & Wang, H. (2020). Ma-net: A multi-scale attention network for liver and tumor segmentation. *IEEE Access*, *8*, 179656-179665.

Iakubovskii, P. (2019). *Segmentation Models PyTorch*. GitHub repository. https://github.com/qubvel/segmentation_models.pytorch: [Erişim tarihi: 15 Nisan 2024]

Li, H., Xiong, P., An, J., & Wang, L. (2018). Pyramid attention network for semantic segmentation. *arXiv preprint arXiv:1805.10180*.

Li, Q., Shi, Y., Auer, S., Roschlaub, R., Möst, K., Schmitt, M., & Zhu, X. X. (2020). Detection of Undocumented Buildings Using Convolutional Neural Network and Official Geodata. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2, 517-524.

Lin, T. Y., Dollár, P., Girshick, R., He, K., Hariharan, B., & Belongie, S. (2017). Feature pyramid networks for object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2117-2125).

Liu, Z., Liu, W., Qi, H., Li, Y., Zhang, G., & Zhang, T. (2020). Extracting River Illegal Buildings from UAV Image Based on Deeplabv3+. In Geoinformatics in Sustainable Ecosystem and Society: 7th International Conference, GSES 2019, and First International Conference, GeoAI 2019, Guangzhou, China, November 21–25, 2019, Revised Selected Papers 7 (pp. 259-272). Springer Singapore.

Ostankovich, V., & Afanasyev, I. (2018, September). Illegal buildings detection from satellite images using googlenet and cadastral map. In 2018 international conference on Intelligent Systems (IS) (pp. 616-623). IEEE.

Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *Medical image computing and computer-assisted intervention–MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18* (pp. 234-241). Springer international publishing.

Song, Y., Kalacska, M., Gašparović, M., Yao, J., & Najibi, N. (2023). Advances in geocomputation and geospatial artificial intelligence (GeoAI) for mapping. *International Journal of Applied Earth Observation and Geoinformation*, *120*, 103300.

Zhou, Z., Rahman Siddiquee, M. M., Tajbakhsh, N., & Liang, J. (2018). Unet++: A nested u-net architecture for medical image segmentation. In *Deep learning in medical image analysis and multimodal learning for clinical decision support: 4th international workshop, DLMIA 2018, and 8th international workshop, ML-CDS 2018, held in conjunction with MICCAI 2018, Granada, Spain, September 20, 2018, proceedings 4* (pp. 3-11). Springer International Publishing.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Makine Öğrenmesi Temelli Marmara Bölgesi'ndeki Göl ve Baraj Alanlarının Değişim Analizi

**Tolga Işık*[1], Onur Can Bayrak[1], Uğur Acar[1]**

[1]*Yıldız Teknik Üniversitesi, İnşaat Fakültesi, Harita Müh. Bölümü, İstanbul, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Makine Öğrenmesi,
Su Kaynakları
Görüntü İşleme

**ÖZET**

Su kaynaklarının sürdürülebilir yönetimi, özellikle yarı-kurak iklime sahip Türkiye gibi ülkelerde büyük önem arz etmektedir. İklim değişikliği, artan su tüketimi ve insan kaynaklı etkiler, göl ve barajlardaki su seviyelerinde önemli değişimlere yol açmaktadır. Bu çalışmada, İstanbul ve çevresindeki 10 adet göl ve barajın (İznik, Manyas, Ulubat, Sapanca, Büyükçekmece, Küçükçekmece, Terkos, Sazlıdere, Ömerli ve Darlık) 2000-2024 yılları arasındaki değişimleri uzaktan algılama ve makine öğrenmesi yöntemleriyle analiz edilmiştir. Uydu görüntüleri Google Earth Engine (GEE) platformu kullanılarak değerlendirilmiş; Landsat ve Sentinel-2 uydularından elde edilen, bulutluluk oranı %10'dan düşük olan görüntüler tercih edilmiştir. Analizlerde ağustos ayı esas alınmış, uygun görüntü bulunamayan durumlarda temmuz ve haziran ayları değerlendirmeye dahil edilmiştir. Göllerin yüzey alanlarının belirlenmesi amacıyla Rasgele Orman (RO) ve Destek Vektör Makineleri (DVM) gibi iki farklı makine öğrenmesi algoritması ile NDWI, MNDWI ve AWEI su indisleri kullanılmıştır. Sınıflandırma işlemi RGB bantları üzerinden gerçekleştirilmiş; her göl için dengeli biçimde seçilen su ve kara etiketli piksellerle modeller eğitilmiştir. Model performansları doğruluk, kesinlik, duyarlılık ve F1-skoru metrikleriyle değerlendirilmiştir. Elde edilen sonuçlar, su alanlarındaki yıllık değişimlerin izlenmesinde makine öğrenmesi ve uzaktan algılama tekniklerinin etkinliğini ortaya koymaktadır.

# Machine Learning-Based Change Detection of Lake and Reservoir Areas in the Marmara Region

**Keywords**
Remote Sensing,
Machine Learning,
Water Resources,
Image Processing

**ABSTRACT**

The sustainable management of water resources is of great importance, especially in countries with semi-arid climates such as Türkiye. Climate change, increasing water consumption, and anthropogenic impacts have led to significant changes in water levels in lakes and reservoirs. In this study, changes in 10 lakes and reservoirs located in and around Istanbul (İznik, Manyas, Ulubat, Sapanca, Büyükçekmece, Küçükçekmece, Terkos, Sazlıdere, Ömerli, and Darlık) between 2000 and 2024 were analyzed using remote sensing and machine learning methods. Satellite images were processed on the Google Earth Engine (GEE) platform, and images with less than 10% cloud cover, obtained from Landsat and Sentinel-2 satellites, were selected for analysis. August was prioritized as the time frame for the analyses, while images from July and June were used when August data were not available. To determine the surface areas of the lakes, two machine learning algorithms—Random Forest (RF) and Support Vector Machines

* **Sorumlu Yazar**

*(tolga.isik@std.yildiz.edu.tr) ORCID ID 0009-0003-0460-6448
(onurcb@yildiz.edu.tr) ORCID ID 0000-0002-5147-747X
(uacar@yildiz.edu.tr) ORCID ID 0000-0003-3676-4259

**Kaynak Göster (APA):**

Işık T, Bayrak O C & Acar U (2025). Makine Öğrenmesi Temelli Marmara Bölgesi'ndeki Göl ve Baraj Alanlarının Değişim Analizi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

(SVM)—were applied, along with three water indices: NDWI, MNDWI, and AWEI. The classification was carried out using RGB bands, and training datasets containing balanced numbers of water and land pixels were created for each lake. Model performances were evaluated using accuracy, precision, recall, and F1-score metrics. The results demonstrate the effectiveness of remote sensing and machine learning techniques in monitoring annual changes in water bodies, providing a valuable decision-support tool for managing freshwater resources.

## 1. GİRİŞ

Su, hayatın devamlılığı için vazgeçilmez doğal kaynaklardan biridir. Türkiye gibi özellikle yarı-kurak iklime sahip ülkelerde su kaynaklarının sürdürülebilir yönetimi büyük önem taşımaktadır (Çağlayan vd., 2020). 2030 yılına kadar suya erişimin ve kıtlık durumunun %40 seviyelerine çıkacağı öngörülmektedir (Doğan, 2023). 2008 yılında 44 milyar $m^3$ olan su tüketimi 2020 yıllarına gelindiğinde 57 milyar $m^3$'e ulaşmıştır (Sarış, 2021). Göller ve barajlar bu açıdan kentler için tatlı su depolayıcı ve sağlayıcılarıdır. Tatlı su kaynaklarının büyük bir bölümünü oluşturan göller, su temini açısından kritik ekosistemlerdir (Maberly vd., 2020).

Özellikle son yıllarda, iklim değişikliği ve insan kaynaklı müdahaleler nedeniyle birçok gölde ciddi su kayıpları yaşanmaktadır (Taş ve Akpınar, 2021). Bunun önemli sebeplerinden biri, tarımsal sulama amacıyla taban sularının yoğun şekilde kullanılması, akarsuların barajlarla tutulması ve göllerin doğal beslenme dengesinin bozulmasıdır (Bahadır, 2013).

Çeşitli uzaktan algılama teknikleriyle bu tür etkilerin izlenmesi mümkündür (Cai vd., 2022). Makine öğrenmesi gibi sürdürülebilir ve zaman kazandıran teknikleri ile bu problemlere çözüm aranmaktadır (Akça ve Balık Şanlı, 2022). Bu teknikler sayesinde göllerin alanına ilişkin güncel, güvenilir ve zamansal analizler yapılabilmektedir (Erdem vd., 2018).

Bu yöntemler arasında su indisleri, su kütlelerini belirlemek ve zaman içindeki değişimlerini izlemek için sıkça kullanılan teknikler arasındadır. NDWI (Normalized Difference Water Index), MNDWI (Modified NDWI), AWEI (Automated Water Extraction Index) gibi su indisleri, uydu görüntülerinden su alanlarını ayırt etmek için geliştirilmiştir (Laonamsai vd., 2023).

Çalışma kapsamında, uzaktan algılama görüntülerinde makine öğrenmesi yöntemleri ve su indisleri kullanarak İstanbul ve çevresindeki 10 adet göl ve barajın 2000-2024 yılları arasındaki değişimi belirlenmiştir.

## 2. VERİ

Çalışma kapsamında; İznik Gölü, Manyas Gölü, Ulubat Gölü, Sapanca Gölü, Büyükçekmece Gölü, Küçükçekmece Gölü, Terkos Gölü, Sazlıdere Barajı, Ömerli Barajı ve Darlık Barajı'na ait uydu görüntüleri Google Earth Engine (GEE) platformu kullanılarak analiz edilmiştir. 2000-2024 yılları arasını kapsayan 24 yıllık bir zaman diliminde bu göllerdeki/barajlardaki değişimin analiz edilebilmesi için; 2000 ile 2016 yılları arasında Landsat 5, Landsat 7 ve Landsat 8 uyduları kullanılırken 2015-2024 yılları arasında Sentinel-2 uydu görüntüleri seçilmiştir.

Analize tabi tutulacak uydu görüntülerinden bulutluluk oranı>%10 olan görüntüler analize dahil edilmemiştir.

Zaman aralığı olarak kuraklık etkisinin en çok olduğu Ağustus ayı tercih edilmiştir. Ancak, bazı görüntülerdeki bulut örtüsü veya teknik bozukluklar nedeniyle Temmuz ve Haziran aylarına ait görüntüler değerlendirilmiştir.

## 3. YÖNTEM

Göllerdeki/barajlardaki alanların belirlenmesi için Rasgele Orman (RO) (Breiman, 1991) ve Destek Vektör Makineleri (DVM) (Cortes ve Vapnik, 1995) olmak üzere iki tane makine öğrenmesi algoritması ve NDWI, MNDWI ve AWEI olmak üzere üç tane su çıkarımı indisi kullanılmıştır.

Makine öğrenmesi yöntemleriyle sınıflandırma işlemi için uydu görüntülerinin RGB bantları kullanılmıştır. Makine öğrenmesi algoritmalarının eğitimi ve doğrulaması için su ve kara yüzeylerini temsil eden eğitim verileri oluşturulmuştur. Her göl için, Su ve Kara sınıflarını içeren 120'şer piksel seçilmiştir. Bu etiketleme işlemi, her gölün kendi sınırları içerisinden ve çevresindeki kara alanlarından dengeli bir şekilde yapılmıştır.

Bu piksellerden %70' i RO ve SVM modellerinin eğitiminde, %30 kısmı ise test aşamasında kullanılmıştır. (testing)olacak şekilde rastgele ikiye ayrılmıştır.

Modellerin performansını değerlendirmek amacıyla karmaşıklık matrisi oluşturulmuş ve bu matristen elde edilen Doğruluk (Accuracy), Kesinlik (Precision), Duyarlılık (Recall) ve F1-skoru (F1-score) metrikleri hesaplanmıştır.

Su indisleri ise GEE üzerinde belirlenen alanlarda uygulanmış olup su ve kara alanları ayrıştırılmıştır. Göllerin yüzey alanları, su sınıfına giren piksellerin toplamı üzerinden hesaplanmıştır.

## 4. BULGULAR

Genişletilmiş özet sınırındaki sayfa sınırından dolayı sadece İznik Gölü' ne ait makine öğrenmesi temelli sınıflandırma sonuçları Çizelge 1' de, görsel sonuçlar Şekil 1' de ve 24 yıllık değişim Şekil 2' de gösterilmiştir.

**Çizelge1.** İznik Gölü elde edilen makine öğrenmesi temelli sınıflandırma sonuçları

| Yöntem | Doğruluk | Hassasiyet | Duyarlılık | F1-Skor |
|---|---|---|---|---|
| RO | 0.966 | 0.974 | 0.95 | 0.962 |
| DVM | 0.943 | 0.951 | 0.925 | 0.938 |

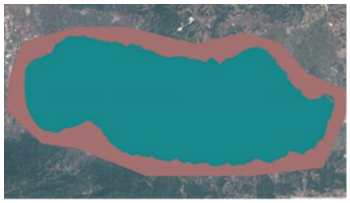


**Şekil 1.** İznik Gölü' nde RO ile gerçekleştirilen örnek sınıflandırma sonucu.

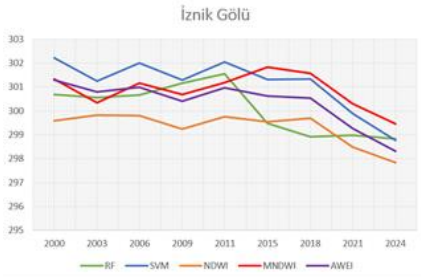


**Şekil 2.** İznik Gölü' nün yıllara göre değişiminin km$^2$ biriminde gösterimi.

## 5. TARTIŞMA ve SONUÇ

2000-2024 yılları arasında İznik Gölü' nde 2.38, km$^2$'lik azalma gözlemlenmiştir. Bu analizler Manyas Gölü, Ulubat Gölü, Sapanca Gölü, Büyükçekmece Gölü, Küçükçekmece Gölü, Terkos Gölü, Sazlıdere Barajı, Ömerli Barajı ve Darlık Barajı için de yapılarak bu bölgelerdeki su alanlarının değişimi belirlenmiştir.

**TEŞEKKÜR**

Bu çalışma, TÜBİTAK 2209/A Üniversite Öğrencileri Araştırma Projeleri Destek Programı kapsamında "Makine Öğrenmesi ile Türkiye'deki Göllerin Kuraklık Analizi" başlıklı proje kapsamında gerçekleştirilmiştir.

**Yazar Katkı Oranı**

**Tolga Işık:** Veri Analizi, Yazılım, Görselleştirme, Literatür Taraması, Yazım **Onur Can Bayrak:** Düzenleme, Metodoloji Geliştirme, Yazım **Uğur Acar**: Danışmanlık, Sonuçların Değerlendirilmesi, Revizyon

**Çıkar Çatışması/Çakışması**

Yazarlar arasında herhangi bir çıkar çatışması yoktur.

**KAYNAKÇA**

Akça, Ş., & Balık Şanlı, F. (2022). Kıyı çizgisinin makine öğrenmesi tabanlı mean-shift, rastgele orman ve destek vektör makineleri ile belirlenmesi. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 37(3), 835-842.

Bahadır, M. (2013). Akşehir Gölü'nde alansal değişimlerin uzaktan algılama teknikleri ile belirlenmesi. Marmara Coğrafya Dergisi, (28), 246-275.

Breiman, L. (2001). Random forests. Machine learning, 45, 5-32.

Cai, H., Li, C., Luan, X., Ai, B., Yan, L., & Wen, Z. (2022). Analysis of the spatiotemporal evolution of the coastline of Jiaozhou Bay and its driving factors. Ocean & Coastal Management, 226, 106246.

Çağlayan, E. B., Erel, F., Samur, E. B., Deniz, M., Mobariz, M. A., & Kaplan, G. (2020). Uzaktan algılama teknikler ile Akşehir Gölü'ndeki alansal değişiminin izlenmesi. Türkiye Uzaktan Algılama Dergisi, 2(2), 70-76.

Cortes, C., & Vapnik, V. (1995). Support-vector networks. Machine learning, 20, 273-297.

Doğan, M. (2023). Sürdürülebilirlik: Su ve suyun önemi. Avrasya Sosyal ve Ekonomi Araştırmaları Dergisi, 10(1), 176-192.

Erdem, F., Derinpınar, M. A., Nasırzadehdızajı, R., Oy, S., Şeker, D. Z., & Bayram, B. (2018). Rastgele Orman yöntemi kullanılarak kıyı çizgisi çıkarımı İstanbul örneği. Geomatik, 3(2), 100-107.

Laonamsai, J., Julphunthong, P., Saprathet, T., Kimmany, B., Ganchanasuragit, T., Chomcheawchan, P., & Tomun, N. (2023). Utilizing NDWI, MNDWI, SAVI, WRI, and AWEI for estimating erosion and deposition in Ping River in Thailand. Hydrology, 10(3), 70.

Maberly, S. C., O'Donnell, R. A., Woolway, R. I., Cutler, M. E., Gong, M., Jones, I. D., ... & Tyler, A. N. (2020). Global lake thermal regions shift under climate change. Nature Communications, 11(1), 1232.

Sarış, F. (2021). Türkiye'de evsel su tedarik ve tüketim istatistiklerinin değerlendirilmesi. Coğrafi Bilimler Dergisi/Turkish Journal of Geographical Sciences, 19(1), 195-216.

Taş, M. A., & Akpınar, E. (2021). Burdur havzasındaki göllerde yaşanan seviye değişikliklerinin coğrafi bilgi sistemleri (CBS) ve uzaktan algılama (UA) ile tespiti. Doğu Coğrafya Dergisi, 26(46), 37-54.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# DLGC-ABM: Ağaç Taç Segmentasyonu için Grafik Kesme ve Karınca Kolonisi Optimizasyonuna Dayalı Bir Yöntem

**Sude Gül Yel*[1], Esra Tunç Görmüş[2]**

[1]*Artvin Çoruh Üniversitesi, Artvin Meslek Yüksekokulu, Mimarlık ve Şehir Planlama, Artvin, Türkiye*
[2] *Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği, Trabzon, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama, SLIC, Ağaç Taç Segmentasyonu, Grafik Evrişimli Ağ, Karınca Koloni Optimizasyonu

**ÖZET**

Yoğun tepe örtüsüne sahip ormanlarda, orman yönetimi ve ekosistem çeşitliliğini izlemek amacıyla yürütülen arazi çalışmaları zaman alıcı ve maliyetlidir. Bu sınırlamaları aşmak için uzaktan algılama verilerinden yararlanmak gereklidir. Optik ve LiDAR verileri, bireysel ağaç taçlarının otomatik olarak belirlenmesini sağlarken; özellikle optik veriler, tür tespitine olanak tanıyarak arazi temelli yöntemlere kıyasla daha hızlı ve ekonomik çözümler sunar. Ayrıca bu veriler, orman gibi karmaşık ekosistemlerin geniş alanlarda sürekli ve bütüncül şekilde izlenmesini sağlar. Bu çalışmada, bireysel ağaç taçlarının hassas segmentasyonu için grafik tabanlı bütüncül bir metodoloji olan Dynamic Localized Graph-Cut + Ant-Based Merge (DLGC-ABM – Dinamik Yerelleştirilmiş Grafik Kesme ve Karınca Tabanlı Birleştirme) yöntemi önerilmektedir. Yöntem; RGB, Tepe Örtüsü Yükseklik Modeli (CHM) ve çeşitli bitki indekslerinden oluşan çok kaynaklı uzaktan algılama verilerini girdi olarak kullanır ve süperpiksel algoritması olan SLIC ile ön segmentasyon gerçekleştirir. Her segmentin yapısal ve dokusal öznitelikleri çıkarılarak, grafik kesme yöntemiyle ilgisiz segmentlerle olan bağlantılar koparılır. Grafik Evrişimli Ağ (GCN) ile elde edilen semantik gömüler, sahipsiz kalan segmentlerin Karınca Kolonisi Optimizasyonu (ACO) algoritması aracılığıyla en uygun ağaç taç gruplarına yönlendirilmesinde kullanılır. ACO ile desteklenmiş bu çok aşamalı yaklaşım, ağaç taç segmentasyonunda daha yüksek doğruluk, yapısal tutarlılık ve geniş alanlara uygulanabilirlik sunmaktadır.

# DLGC-ABM: A Graph-Cut and Ant Colony Optimization-Based Method for Tree Crown Segmentation

**Keywords**
Remote Sensing, SLIC, Tree Crown Segmentation, Graph Convolutional Network, Ant Colony Optimization

**ABSTRACT**

In forests with dense canopy cover, field-based studies aimed at monitoring forest management and ecosystem diversity are often time-consuming and costly. To overcome these limitations, it is essential to utilize remote sensing data. Optical and LiDAR data enable the automatic delineation of individual tree crowns, with optical imagery in particular offering faster and more cost-effective alternatives to ground-based methods by facilitating species identification. Moreover, such data allow for continuous and comprehensive monitoring of complex ecosystems like forests over large spatial extents. In this study, we propose a comprehensive graph-based methodology called Dynamic Localized Graph-Cut + Ant-Based Merge (DLGC-ABM) for the precise segmentation of individual tree crowns. The method integrates multi-source remote sensing inputs, including RGB imagery, Canopy Height Model (CHM), and various vegetation indices, and begins with an initial segmentation using the SLIC superpixel algorithm. Structural and textural features are extracted from each segment, and irrelevant connections are eliminated using a graph-cut approach. Semantic embeddings obtained through a Graph Convolutional Network (GCN) are then used to assign the unclassified segments to the most suitable crown clusters via the Ant Colony Optimization (ACO) algorithm. This multi-stage approach, supported by ACO, delivers higher segmentation accuracy, structural consistency, and scalability across large forested areas.

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Yrl S G & Tunç Görmüş E (2025). DLGC-ABM: Ağaç Taç Segmentasyonu için Grafik Kesme ve Karınca Kolonisi Optimizasyonuna Dayalı Bir Yöntem, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Orman ekosistemlerinin izlenmesi, planlanması ve sürdürülebilir yönetimi açısından bireysel ağaç düzeyinde elde edilen bilgiler büyük önem taşımaktadır. Bu tür verilere ulaşmak için geleneksel olarak başvurulan arazi gözlemleri ve ölçümleri, geniş alanlar söz konusu olduğunda zaman alıcı, maliyetli ve operasyonel olarak sınırlayıcıdır (Dale vd., 2001; Hycza vd., 2018; Yrttimaa vd., 2020)

Bu sınırlamaları aşmak amacıyla geliştirilen uzaktan algılama tabanlı yaklaşımlar, özellikle yüksek çözünürlüklü optik veriler ve LiDAR ölçümlerinin birleşimiyle birlikte, bireysel ağaç taçlarının tespitini ve karakterizasyonunu mümkün kılmıştır(Immitzer vd., 2012; Zhao vd., 2020, Zhang vd., 2023). Ancak taçların segmentasyonu, özellikle yoğun örtülü ve karışık tür yapısına sahip ormanlarda hâlâ önemli zorluklar barındırmaktadır. Segmentasyon işlemi sırasında taçların birbirine karışması, bir ağaca ait parçaların farklı segmentlerde kalması ya da bir segmentin birden fazla ağacı kapsaması gibi sorunlar, çıktının doğruluğunu ve kullanılabilirliğini doğrudan etkilemektedir (Lee vd., 2016).

Grafik tabanlı sınıflandırma yöntemleri; öklidyen geometriye dayalı derin öğrenme modellerinin ve yüksek miktarda etiketli veri gerektiren geleneksel yaklaşımların aksine, öklidyen olmayan yapılarda ve sınırlı etiketli veriyle de başarılı sonuçlar verebilmektedir (Qin vd., 2018; Wang vd., 2023). Bu başarı, Karınca Kolonisi Optimizasyonu (ACO) gibi doğadan esinlenen optimizasyon algoritmaları ile desteklenen grafik tabanlı segmentasyon yaklaşımları sayesinde daha da artırılabilmektedir.

Bu çalışma, söz konusu güçlü yönleri bir araya getirerek geliştirilen DLGC-ABM (Dinamik Yerelleştirilmiş Grafik Kesme ve Karınca Tabanlı Birleştirme) adlı yöntemle, bireysel ağaç taçlarının yüksek doğrulukta segmentasyonunu hedeflemektedir. Geliştirilen yaklaşım; RGB, CHM ve çeşitli bitki indekslerinden oluşan çok kaynaklı uzaktan algılama verileriyle çalışmakta, segmentasyon sürecini grafik temelli yapılar ve çok aşamalı karar mekanizmalarıyla desteklemektedir.

## 2. YÖNTEM

DLGC-ABM yöntemi, bireysel ağaç taçlarının yüksek doğrulukla ayrıştırılmasını hedefleyen, grafik tabanlı çok aşamalı bir segmentasyon yaklaşımıdır. Bu yöntem, yüksek konumsal çözünürlüklü orto görüntü (RGB), kanopi yükseklik modeli (CHM) ve çeşitli bitki indekslerinden oluşan çok kaynaklı uzaktan algılama verilerini girdi olarak kullanmakta ve karar süreçlerinde hem yerel grafik kesme hem de doğadan esinlenen ACO tekniklerini entegre etmektedir. Metodoloji beş temel aşamadan oluşmaktadır.

İlk aşamada, RGB görüntüsü üzerinden SLIC (Simple Linear Iterative Clustering) algoritması uygulanarak süperpiksel temelli ön segmentasyon gerçekleştirilir. Bu segmentler, görsel benzerliğe dayalı homojen yapılar sunar ve segmentasyonun ilk birimlerini oluşturur. Aynı zamanda CHM üzerinde belirlenen lokal maksimum noktaları, bireysel ağaçların olası tepe noktalarını temsil eder ve bu noktaların düştüğü segmentler "Çekirdek Segment" olarak tanımlanır. Bu segmentler, her bir ağacın merkezini temsil eden temel çekirdek birimlerdir.

İkinci aşamada, her segment için RGB bantları, CHM ve çeşitli bitki indeksleri (NDVI, PRI, NDII vb.) kullanılarak spektral, yapısal ve dokusal öznitelikler çıkarılır. Bu öznitelikler, Grafik Evrişimli Ağ (GCN) kullanılarak yüksek boyutlu semantik temsillere dönüştürülür. Elde edilen gömüler kullanılarak segmentler arasındaki benzerlikler hesaplanır ve bu benzerlikler doğrultusunda komşu segmentler arasında ağırlıklı bir grafik yapısı oluşturulur. Bu yapıda her bir segment bir düğüm, benzerlikler ise kenar olarak temsil edilir.

Üçüncü aşamada, çekirdek segmentlerin çevresinde oluşturulan yerel grafiklerde grafik kesme algoritması uygulanır. Bu işlem, anlamsal benzerlikleri düşük olan segmentlerle olan bağlantıların koparılmasını sağlar. Böylece her çekirdek segment etrafında benzer segmentlerden oluşan ilk taç kümeleri oluşturulur. Grafik kesme işlemi sonucunda herhangi bir gruba ait olmayan ya da düşük benzerlik nedeniyle ilişkilendirilemeyen segmentler sistemde bağımsız olarak kalır.

Dördüncü adımda, sahipsiz kalan bu segmentlerin birden fazla ağaca ait olabileceği göz önünde bulundurularak, segmentin iç yapısı piksel düzeyinde analiz edilir. Her segment içinde piksel tabanlı bir grafik yapısı oluşturulur ve her pikselin komşu çekirdek segmentlerle olan benzerliği hesaplanır. Bu benzerlikler dikkate alınarak; segmentin içindeki pikseller, ilgili ağaçlara ait olacak şekilde grafik kesme yöntemiyle alt parçalara ayrılır. Böylece, başlangıçta birden fazla ağaca ait bilgiyi barındıran karma segmentler, piksel temelli algoritmik bölünme ile ayrıştırılmış olur.

Son aşamada, yeni oluşturulan mikro segmentlerin hangi ağaca ait olduğuna karar vermek için ACO algoritması kullanılır. GCN ile elde edilen anlamsal temsillerin yanı sıra yükseklik farkı ve spektral benzerlik verileri kullanılıp, her segment için uygun ağaç grubuna aitlik skoru hesaplanır. Karıncalar bu skorları referans alarak yönlendirilir ve bağımsız parçaların en uygun çekirdek segmentlerle eşleşmesi sağlanır. Tüm bu aşamaların sonunda, optimize edilmiş, doğru segmente edilmiş taç poligonlarından oluşan nihai segmentasyon haritası elde edilir.

## 3. BULGULAR

Yöntemin ilk aşamasında gerçekleştirilen süperpiksel segmentasyonu, homojen görsel bölgeleri başarılı biçimde ayırmıştır, ancak aynı ağaca ait parçaların farklı segmentlerde kalması ya da bir segmentin birden fazla ağaca ait bilgiyi içermesi gibi sorunlara yol açmıştır. Bu yapısal karışıklık, yalnızca süperpiksel tabanlı segmentasyonla çalışmanın yeterli olmadığını ve sonraki iyileştirme aşamalarının önemini ortaya koymuştur.

GCN ile elde edilen semantik temsiller, segmentler arası benzerliklerin daha anlamlı biçimde değerlendirilmesine olanak sağlamış; özellikle yapı ve yükseklik farklarını dikkate alan grafik kesme algoritması, çekirdek segmentler etrafında daha bütüncül taç gruplarının oluşmasını sağlamıştır. Bu

aşamada elde edilen segment kümeleri, bireysel taç sınırlarını yakalamada önemli bir iyileşme göstermiştir.

Grafik kesimi sonrasında sahipsiz kalan segmentler piksel düzeyinde yeniden değerlendirilerek ACO algoritması tarafından yönlendirilmiştir. ACO; sahipsiz parçaların ait olduğu taçlara doğru şekilde atanmasını mümkün kılmıştır. ACO yönlendirme sürecinde kullanılan GCN gömü benzerliği, yükseklik farkı ve spektral uyum üçlüsü, segment-ağaç eşleşmesinin doğruluğunu artırmıştır. Grafik kesme işlemi sırasında verilerin ağırlık katsayılarının Izgara Arama yöntemiyle belirlenmesi karar sürecini bilimsel biçimde güçlendirilmiştir.

Yöntemin performansı, saha verileriyle karşılaştırmalı olarak değerlendirildiğinde; bireysel ağaç taçlarının şekil bütünlüğünü koruyan, üst üste binmeleri minimize eden ve tür ayrımı açısından daha temsil gücü yüksek segmentasyon çıktıları elde edildiği görülmüştür.

## 4. TARTIŞMA

DLGC-ABM yöntemiyle elde edilen sonuçlar, bireysel ağaç taçlarının segmentasyonunda hem geometrik bütünlük hem de sınıflandırma açısından önemli iyileşmeler sağlandığını göstermektedir. Literatürde yaygın olarak kullanılan süperpiksel tabanlı yöntemler, özellikle karma orman yapılarında taçlar arası sınırların belirsizleştiği alanlarda yetersiz kalmaktadır (Martins vd., 2021). Literatürde SLIC çoğu zaman bir başlangıç segmentasyonu olarak kullanılarak, çeşitli makine/derin öğrenme yöntemleriyle güçlendirilmiştir (Zhou vd., 2020). Bu çalışmada, süperpiksel segmentasyonun grafik temelli karar mekanizmalarıyla desteklenmesi, bu sınır sorunlarının büyük ölçüde aşılmasını mümkün kılmıştır.

GCN kullanımı, segmentler arası semantik ilişkilerin daha doğru modellenmesini sağlamış, ACO algoritması ise klasik eşikleme temelli yöntemlerin ötesinde, bağlamsal karar vermeye dayalı yönlendirme süreçleriyle önemli katkı sunmuştur. Benzer biçimde, bireysel ağaç tespiti için grafik kesme yaklaşımının yerelleştirilmiş olarak uygulanması, geniş alanlarda yapı bozulmasını minimize ederek, ağaca özgü segmentlerin oluşturulmasına katkı sağlamıştır (Strîmbu ve Strimbu, 2015).

Elde edilen bulgular, DLGC-ABM metodolojisinin, yüksek çözünürlüklü verilerle desteklendiğinde karmaşık orman yapılarında dahi etkili çalışabileceğini ortaya koymaktadır. Bu bağlamda yöntem hem orman yönetimi hem de biyolojik çeşitlilik analizleri açısından değerli bir karar destek aracı olarak öne çıkmaktadır.

## 5. SONUÇ

Bu çalışma, bireysel ağaç taçlarının hassas segmentasyonu için grafik tabanlı çok aşamalı bir yöntem olan DLGC-ABM'yi önermektedir. Süperpiksel temelli başlangıç segmentasyonunun, GCN destekli anlamsal gömü ve yerelleştirilmiş grafik kesme algoritması ile desteklenmesi; ardından ACO algoritması ile boşta kalan segmentlerin uygun taçlara yönlendirilmesi sayesinde, ormanlık alanlarda yüksek doğrulukta ve yapısal olarak tutarlı segmentasyon çıktıları elde edilmiştir. Yöntemin, farklı ağaç türlerinin bulunduğu karma orman yapılarında dahi başarılı bir şekilde uygulanabilir olduğu görülmüş ve klasik yaklaşımlara kıyasla anlamlı avantajlar sunduğu ortaya konmuştur.

### Yazar Katkı Oranı

Yazarların makaleye katkısı eşittir.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

### KAYNAKÇA


Dale, V. H., Joyce, L. A., McNulty, S., Neilson, R. P., Ayres, M. P., Flannigan, M. D., ... & Wotton, B. M. (2001). Climate change and forest disturbances: climate change can affect forests by altering the frequency, intensity, duration, and timing of fire, drought, introduced species, insect and pathogen outbreaks, hurricanes, windstorms, ice storms, or landslides. BioScience. doi: 10.1641/00063568(2001)051[0723:CCAFD]2.0.CO;2

Hycza, T., Stereńczak, K., & Bałazy, R. (2018). Potential use of hyperspectral data to classify forest tree species. New Zealand Journal of Forestry Science. Doi: 10.1186/s40490-018-0123-9

Immitzer, M., Atzberger, C., & Koukal, T. (2012). Tree species classification with random forest using very high spatial resolution 8-band WorldView-2 satellite data. Remote Sensing. Doi: 10.3390/rs4092661

Lee, J., Cai, X., Lellmann, J., Dalponte, M., Malhi, Y., Butt, N., ... & Coomes, D. A. (2016). Individual tree species classification from airborne multisensor imagery using robust PCA. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. Doi: 10.1109/JSTARS.2016.2569408

Martins, J. A. C., Menezes, G., Gonçalves, W., Sant'Ana, D. A., Osco, L. P., Liesenberg, V., ... & Junior, J. M. (2021). Machine learning and SLIC for tree canopies segmentation in urban areas. Ecological Informatics. Doi: 10.1016/j.ecoinf.2021.101465

Qin, A., Shang, Z., Tian, J., Wang, Y., Zhang, T., & Tang, Y. Y. (2018). Spectral–spatial graph convolutional networks for semisupervised hyperspectral image classification. IEEE Geoscience and Remote Sensing Letters. Doi: 10.1109/LGRS.2018.2869563.

Strîmbu, V. F., & Strîmbu, B. M. (2015). A graph-based segmentation algorithm for tree crown extraction using airborne LiDAR data. ISPRS Journal of Photogrammetry and Remote Sensing. Doi: 10.1016/j.isprsjprs.2015.01.018

Wang, X., Wang, J., Lian, Z., & Yang, N. (2023). Semi-Supervised Tree Species Classification for Multi-Source Remote Sensing Images Based on a Graph Convolutional Neural Network. Forests. Doi: 10.3390/f14061211

Yrttimaa, T., Saarinen, N., Kankare, V., Hynynen, J., Huuskonen, S., Holopainen, M., ... & Vastaranta, M. (2020). Performance of terrestrial laser scanning to characterize managed Scots pine (Pinus sylvestris L.) stands is dependent on forest structural variation. ISPRS Journal of Photogrammetry and Remote Sensing. Doi: 10.1016/j.isprsjprs.2020.08.017

Zhang, M., Li, W., Zhao, X., Liu, H., Tao, R., & Du, Q. (2023). Morphological transformation and spatial-logical aggregation for tree species classification using hyperspectral imagery. IEEE Transactions on Geoscience and Remote Sensing. Doi: 10.1109/TGRS.2022.3233847

Zhao, D., Pang, Y., Liu, L., & Li, Z. (2020). Individual tree classification using airborne LiDAR and hyperspectral data in a natural mixed forest of northeast China. Forests. Doi: 10.3390/f11030303

Zhou, Y., Wang, L., Jiang, K., Xue, L., An, F., Chen, B., & Yun, T. (2020). Individual tree crown segmentation based on aerial image using superpixel and topological features. Journal of Applied Remote Sensing. Doi: 10.1117/1.JRS.14.022210




© Sude Gül Yel ve Esra Tunç Görmüş, 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

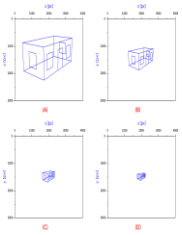

# Ağırlıklı 2B Dönüşüm İle İyileştirilmiş Yüz Tanıma Algoritması

**Türker Akbulut[1], Orhan Kurt*[2]**

[1]*TÜRKSAT A.Ş., E-Devlet, Yazılım Grubu, Ankara, Türkiye*
[2]*Kocaeli Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Kocaeli, Türkiye*

**Anahtar Kelimeler**

Yüz Tanıma,
Makine Öğrenmesi,
DLIB-FR Kütüphanesi,
Ağırlıklı 2B Dönüşüm,
Procrustes Analizi

**ÖZET**

Yüz tanıma işlemi üç aşamadan oluşur. Birinci aşamada yüzün hareketli ya da hareketsiz görüntülerdeki konumunu belirlemektir. İkinci aşama ise yüzü tanımlayan önemli karakteristik noktaların yerlerini seçmektir. En önem aşama olan üçüncü aşama ise bu karakteristik noktalardan yararlanarak kişiyi tanımlayan bir ölçüt geliştirmektir. C++ dilinde OpenCV kütüphanesine dayalı olarak geliştirilen DLIB kütüphanesinin yüz tanıma alt programları, ilk iki aşama için oldukça etkin sonuçlar vermektedir. Bir çok çalışmada üçüncü aşama için farklı iki görüntü arasındaki benzerlik Procrustes Analizi yardım ile hesaplanan farklılık katsayısı ile yapılmaktadır. Bu çalışmada benzer yol izlenmiş, fakat yüzü tanımlayan karakteristik noktalar için farklı ağırlıklar önerilerek yöntemin başarısı önemli derece artırılmıştır. Bu çalışmada, DLIB-FR (DLIB – Yüz Tanıma) önceden eğitilmiş 68 noktalı yüz tanıma Derin Öğrenme Ağı (DÖA) kullanılmış ve yüzün karakteristik noktaları belirlenmiştir. Anlık ya da durağan dijital görüntüler üzerindeki karakteristik özellikleri (kaş, göz, burun, iç ve dış dudak, çene) belirleyen noktalar ile veri tabanında saklanan benzer görüntülerin benzerliği ağırlıklı afin dönüşümü dayanan TBA ile elde edilen tek bir sayı ile özellikle kötü seçilmiş görüntüler üzerinde tam başarının sağlandığı görülmüştür.

# Improved Face Recognition Algorithm by Weighted 2D Transformation

**Keywords**

Face Recognition,
Machine learning,
DLIB-FR Library,
Weighted 2D Transformation,
Procrustes Analysis

**ABSTRACT**

The face recognition process consists of three stages. The first stage is to determine the position of the face in moving images or pictures. The second stage is to select the locations of the important characteristic points that define the face. The third, most important stage is to develop a criterion that defines the person by using these characteristic points. The face recognition subprograms of the DLIB library, developed in the C++ language based on the OpenCV library, give very effective results for the first two stages. In many studies, the similarity between two images for the third stage is done with the some values calculated with PCA. In this study, a similar path was followed, but different weights were suggested for the characteristic points that define the face, and the success of the method was significantly increased. In this study, the 68-point face recognition DLN pre-trained on DLIB-FR was used, and the characteristic points of the face were determined. It has been observed that PCA, which is based on the similarity of the points determining the characteristic features (eyebrow, eye, nose, inner and outer lips, chin) on moving static digital images and similar images stored in the database, provides full success especially on badly selected images with a single number obtained by PCA based on weighted affine transformation. In this study, the significant success difference between the equally weighted PCA used in practice and the weighted PCA is discussed.

*** Sorumlu Yazar**

(turkerakbulut@gmail.com ) ORCID ID 0009-0004-8169-3634
*(orhnkrt@gmail.com) ORCID ID 0000-0002-2711-2024

**Kaynak Göster (APA):**

Akbulut T S & Kurt O (2025). Ağırlıklı 2B Dönüşüm İle İyileştirilmiş Yüz Tanıma Algoritması, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB)

TASUK

## 1. GİRİŞ

Video görüntülerinden anlık yüz tanıma problemi en çok çalışan Bilgisayarlı Görü (BG) problemlerinden birisidir. Bilgisayar teknolojisindeki gelişmeler ile birlikte Yapay Zeka (YZ) uygulamalarının yaygınlaşması ve popülerleşmesi, YZ nin yüz tanıma problemlerinde kullanımının da önünü açmıştır. Görüntüden obje tanıma alanının bir alt basamağı olan yüz tanıma ile ilgili bir çok YZ yazılımı geliştirilmiştir (King, 2009, 2022, 2025, ; Cao vd. 2013; Sagonas vd. 2016; DLIB, 2022; Jabberi vd., 2024; OpenCV, 2025).

Çalışmada kullanılan Makine Öğrenmesi Algoritması) King (2009) tarafından C++ ortamında yazılmıştır ve aynı yazara ait DLIB kütüphanelerinin bir parçasıdır. Bu kütüphanelere ve yüz tanıma için gerekli olan C++ kodlarına internetden kolayca erişilebilir. Bu kütüphanelerin grafik altlığını oluşturulan OpenCV kütüphanelerine de internetden kolayca erişilebilir (DLIB, 2022; OpenCV, 2025). Uygulamada C++ kodları yerine arka planında bu kodların çalıştığı Python versiyonları daha çok tercih edilmektedir. Bu çalışma için kullanılan alt programlar Python ortamında DLIB ve OpenCV kütüphanelerine dayalı olarak geliştirilmiştir.

Bu çalışmada bu kütüphaneler kullanılarak elde edilen 68 karakteristik noktayı kullanarak geometrik bir ölçüt geliştirilmiştir. Bu geometrik ölçüt test edilirken de özellikle çözünürlükleri farklı ve renk karakterleri farklı görüntüler tercih edilmiştir. Önerilen yöntemin başarısı karşılaştırmalı olarak sunulmuştur.

## 2. YÖNTEM

Çalışmada yüz tanıma işlemi üç aşamadan oluşmaktadır. Birinci aşama görüntü üzerinde yer alan yüzün konumunu belirlemektedir. Bu işlem yüzü içine alan dikdörtgen alanının merkezini, boyunu ve enini belirlemeye karşılık gelir. Bu aşama eğitilmiş Derin Öğrenme Ağları (DÖA) kullanılarak yapılır. Daha sonra yüzü tanımlayan temel özellikler belirlenir. Bu işlemler için DLIB-FR kütüphanesi (DLIB - Face Recognation) algoritması yaygın olarak kullanılmakta ve DÖA eğitim katsayılarına internetden erişilebilmektedir. DLIB-FR algoritması resim ya da videodan elde edilen görüntülerdeki 68 karakteristik noktayı kendine özgü MÖA ile etkin olarak bulmaktadır (Şekil 1). Internet üzerinden DLIB-FR algoritmasının çalışması ile ilgili bir çok kod örneğine de kolayca ulaşılabilir. (King, 2009, 2022, 2025; Cao vd. 2013; Sagonas vd. 2016; DLIB, 2022; Jabberi vd., 2024; OpenCV, 2025).

İlk iki aşama ile ilgili çok fazla yayın ve kod bulunmaktadır. Yüzün kime ait olduğu ile ilgili olan üçüncü aşamada belirlenen 68 nokta arasındaki geometrik özelikler üzerine tasarlanır. Bunlardan en çok kullanılanı temeli öz değer ve öz vektör ayrıştırmaya karşılık gelen Temel Bileşenler Analizidir (TBA). İki farklı koordinat kümesi olan asıl ve hedef görüntü koordinatların benzerliği, nokta kümelerinin aynı karşılaştırması esasına dayanır. Bu aşamada oluşan matrisler dikdörtgen olduklarından TDA (Tekil Değer Ayrıştırma) ile nokta kümeleri arasındaki farklılığı yansıtan ve tek bir ölçüt olan aykırılık (disparity) sayısına bakılarak benzerlik analizi yapılır. Özünde normlandırılmış koordinatlar arasındaki dönüşüme karşılık gelen bu işlem Procrustes Analizi (PA) olarak da adlandırılır (Cao vd. 2013; Kurt, 2018).

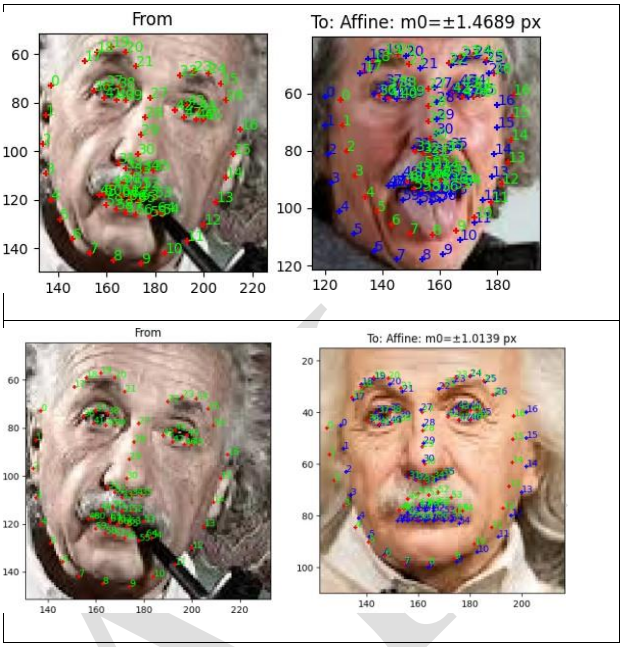


**Şekil 1.** Albert Einstein'n 68 adet karakteristik (From:Resim, To:Veri tabanı) noktaları

Uygulamada kullanılan yüz tanıma işlemlerinin büyük çoğunluğunda bu yol tercih edilmektedir. Yüzü Belirleyen 68 nokta eşit ağırlıklı seçilerek yapılan bu aşama her zaman doğru sonuç vermediği görülmüştür. Bu çalışmada karakteristik noktalar ağırlandırılarak kullanılmış ve yüz tanıma işleminin daha doğru belirlendiği gözlenmiştir (Albert Einstein).

### 2.1. İki Boyutlu Dönüşümler

Karşılaştırma yapılacak olan görüntüler farklı çözünürlükte olabilir. Bu neden ile PA uygulanmadan önce iki resim arasındaki öteleme, dönüklük ve ölçek sorunun giderilmesi için, 2B (2 Boyutlu) dönüşüm yapılmalıdır. Aşağıda (1) bağıntısı 2B-Afin (6 bilinmeyenli) dönüşüm bağıntısıdır.

$$\begin{aligned} u_j &= a_0 + a_1 \cdot x_j + a_2 \cdot y_j \\ v_j &= b_0 + b_1 \cdot x_j + b_2 \cdot y_j \end{aligned} \qquad (1)$$

(1) eşitliğinde geçen büyüklükler $j = \{1, 2, \ldots, 68\}$, veri tabanında saklanan karakteristik noktalar $(u_j, v_j)$, resimden ya da videodan elde edilen karakteristik noktalar $(x_j, y_j)$ ile temsil edilmiştir. Bağıntıda geçen diğer büyüklükler $(a_k, b_k)$ dönüşüm katsayılarıdır. Bu katsayılar $a_1 = b_2$ ve $-a_2 = b_1$ olacak şekilde seçilir ise (1) eşitliği (4 bilinmeyenli) benzerlik (Helmert) dönüşümü halini alır. Mevcut uygulamalarda koordinat çiftleri eşit ağırlıklı olarak seçilir. Bu çalışmada $(p_j = 1)$ ve $(p_j \neq 1)$ dönüşüm sonuçları test edilmiştir (Kurt, 2002; 2013).

#### 2.1.1. Aykırılık (Disparity)Analizi

İki farklı görüntü arasında yapılan afin dönüşüm sonucunda 68 adet ortak nokta ile dönüşüm parametreleri kestirilir. Bu parametreler kullanılarak

$(x_j, y_j)$ koordinatları veri tabanına dönüştürülür ($\tilde{u}_j, \tilde{v}_j$). Aykırılık (disparity) derecesi (2) bağıntısı ile belirlenerek, görüntüler arasındaki aykırılık bulunur.

$$Disparity = Procrutes([\ \mathbf{x}\quad \mathbf{y}\ ]\ [\ \tilde{\mathbf{u}}\quad \tilde{\mathbf{v}}\ ]) \qquad (2)$$

Aykırılık (Disparity) ~0 ise bu iki görüntü aynı kişiye aittir (Çizelge 1).

## 3. BULGULAR

Ağırlıklı afin dönüşüm sonucunda aykırılık analizi sonuçlarının daha tutarlı olduğu "Çizelge 1" den kolayca görülebilmektedir. Çizelgede Disp (I) ile gösterilen sütunda Einstain ve Hawking-1 in aynı kişi olduğu sonucuna varılabilir (Çizelge 1).

**Çizelge1.** Afine RMS ve aykırılık değerleri.

| Resim | Veri Tab. | ±$m_0$ (P) | ±$s_0$ (I) | Disp(P) | Disp(I) |
|---|---|---|---|---|---|
| Einstein-2 | Einstein-0 | 1.4689 | 2.3001 | 0.0001 | 0.0018 |
| Einstein-2 | Einstein-1 | 1.0139 | 2.1349 | 0.0010 | 0.0001 |
| Einstein-2 | Einstein-2 | 0.0000 | 0.0000 | 0.0000 | 0.0000 |
| Einstein-2 | Curie-0 | 23.9541 | 37.2460 | 0.0119 | 0.0052 |
| Einstein-2 | Curie-1 | 3.1314 | 3.5499 | 0.0132 | 0.0051 |
| Einstein-2 | Tesla-0 | 6.7174 | 7.7430 | 0.0099 | 0.0005 |
| Einstein-2 | Feyman-0 | 1.9649 | 3.0037 | 0.0363 | 0.0158 |
| Einstein-2 | Feyman-1 | 1.4320 | 1.7227 | 0.0090 | 0.0023 |
| Einstein-2 | Feyman-2 | 2.0599 | 3.3908 | 0.0244 | 0.0096 |
| Einstein-2 | Hawking-1 | 5.1172 | 9.7914 | 0.0078 | 0.0004 |
| Einstein-2 | Gagarin-0 | 2.1751 | 2.7416 | 0.0187 | 0.0049 |

Ağırlıklı afin dönüşüm sonucunda aykırılık analizi sonuçlarının daha tutarlı olduğu "Çizelge 1" den kolayca görülebilmektedir. Çizelgede Disp (I) ile gösterilen sütunda Einstain ve Hawking-1 in aynı kişi olduğu sonucuna varılabilir.

## 4. SONUÇ

Bu çalışmada DLIB-FB kütüphanesi ile ele edilen 68 noktalı karakteristik nokta ile, iki görüntü arasındaki aykırılığın azlığı üzerinden benzerlik analizi yapılmıştır. Ağırlık afin dönüşüm önerisinin başarısı farklı dijital özelik gösteren görüntüler üzerinden gösterilmiştir.

## TEŞEKKÜR

GNU Ortamda karşılıksız bilgi paylaşan isimiz kahramanlara sonuz teşekkürlerimi sunarım.

## Yazar Katkı Oranı

***T. Akbulut:*** Ubuntu (debian tabanlı) OS üzerinde Python ortamında CV, Dlib kütüphanelerine dayalı kenar belirleme yazılım altlığı oluşturma ve Procrustes algoritması ile dinamik yüz tanıma problemini çözmek.
***O. Kurt:*** Temel yazılım altlığı üzerine Linux Mint (debian tabanlı) OS üzerinde Python ortamında 2B dönüşüm ve yüz tanıma doğruluk testi alt programları yazmak. Dinamik yüz tanıma sonuçlarını test etmek.

## Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması yoktur.

## KAYNAKÇA

Akbulut, T. ve Eser, M., (2004). Raster Bilgilerin Vektör Bilgilere Dönüşümü, (Diploma Çalışması), Zonguldak Bülent Ecevit Üniversitesi, Harita Mühendisliği Bölümü, Zonguldak.

Akbulut, T. ve Kurt, O. (2005). Taranmış Görüntü Üzerindeki Kontrol Nokta Doğruluklarının Artırılması İçin Basit Algoritmalar, TMMOB-HKMO, 10. Türkiye Harita Bilimsel ve Teknik Kurultayı, 28 Mart - 1 Nisan 2005, Ankara, Türkiye, doi: 10.13140/2.1.2798.5600.

Cao, Q., Ying, Y., S Li, P. (2013). Similarity Metric Learning for Face Recognition, *2013 IEEE International Conference on Computer Vision*, Sydney, NSW, Australia, 2013, pp. 2408-2415, doi: 10.1109/ICCV.2013.299.

DLIB (2022). Dlib C++ Library, [Erişim tarihi: 01.04.2025], http://dlib.net/

Jabberi, M., Wali, A., Chaudhuri, B.B., Alimi, A.M. (2023). 68 landmarks are efficient for 3D face alignment: what about more?. Multimed Tools Appl **82**, 41435– 41469, https://doi.org/10.1007/s11042-023-14770-x.

King, D.E. (2009). Dlib-ml: A Machine Learning Toolkit, Jour. of Machine Learning Research 10, 1755-1758, http://www.jmlr.org/papers/volume10/king09a/king09a.pdf.

King, D.E. (2025). A toolkit for making real world machine learning and data analysis applications in C++, https://github.com/davisking/dlib: [Erişim tarihi: 21.03.2025].

Kurt, O. (2002). İki Boyutlu Benzerlik ve Afin Dönüşümleri, Zonguldak Bülent Ecevit Üniversitesi, Harita Mühendisliği Bölümü, Seminer Çalışması, https://www.researchgate.net/publication/28100 5862: [Erişim tarihi: 01.04.2025].

Kurt, O. (2013). Advanced Adjustment, Lecture Notes, https://www.researchgate.net/publication/38955 4795: [Erişim tarihi: 01.04.2025].

OpenCV (2025). Open Source Computer Vision, OpenCV by doxygen, [Erişim tarihi: 01.04.2025], https://docs.opencv.org/4.x/index.html

Python (2025). [Erişim tarihi: 01.04.2025], https://www.python.org/

Sagonas, C., Antonakos, E., Tzimiropoulos, G, Zafeiriou, S. S Pantic, M. (2016). 300 Faces In-The-Wild Challenge: database and results, Image and Vision Computing 47, (2016) 3–18, https://ibug.doc.ic.ac.uk/media/uploads/documents/sagonas_2016_imavis.pdf.

© Türker Akbulut ve Orhan Kurt 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# İstanbul Havalimanı'nın Yakın Çevresindeki Yüzey Kentsel Isı Adası Oluşumuna Etkisinin İncelenmesi

**Mitat Can Yıldız[1], Emirhan Özdemir[1], Rüştü Çallı[1], Fehmi Veziroğlu[1], Aliihsan Şekertekin*[1]**

[1]*Iğdır Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Mimarlık ve Şehir Planlama Bölümü, Iğdır, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Termal Kızılötesi,
Görüntü İşleme,
UTFVI

**ÖZET**

Bu çalışma, İstanbul Havalimanı'nın inşa sürecinin yakın çevresinde Yüzey Kentsel Isı Adası (YKIA) etkisini nasıl değiştirdiğini değerlendirmek amacıyla gerçekleştirilmiştir. Çalışmada 2014 (inşa öncesi) ve 2019 (inşa sonrası) yıllarına ait Landsat 8 uydu görüntülerinden elde edilen Yüzey Sıcaklığı (YS) verileri kullanılarak Kentsel Termal Alan Varyans İndeksi (UTFVI) hesaplanmıştır. Elde edilen sonuçlara göre, en konforlu sınıf olan UTFVI<0 alanları 2014'te 51.512 km$^2$ iken, 2019'da 43.635 km$^2$'ye düşmüştür. Aynı dönemde orta termal stres sınıfı 4.872 km$^2$'den 6.284 km$^2$'ye yükselmiş, çok yüksek termal stres sınıfı ise mutlak anlamda sınırlı bir alan kaplamasına rağmen 0.003 km$^2$'den 0.226 km$^2$'ye yükselmiştir.

# Investigation of the Effect of Istanbul Airport on the Formation of Surface Urban Heat Island in its Nearby Surroundings

**Keywords**
Remote sensing,
Thermal Infrared,
Image Processing,
UTFVI

**ABSTRACT**

This study evaluates how the construction of Istanbul Airport altered the Surface Urban Heat Island (SUHI) effect in its immediate vicinity. Using Landsat 8 satellite-derived surface temperature data from 2014 (pre-construction) and 2019 (post-construction), the Urban Thermal Field Variance Index (UTFVI) was calculated. The results revealed that the most thermally comfortable zone (UTFVI<0) shrank from 51.512 km$^2$ in 2014 to 43.635 km$^2$ in 2019. Concurrently, the moderate thermal stress class increased from 4.872 km$^2$ to 6.284 km$^2$, while the very high thermal stress class, though covering a limited absolute area, expanded sharply from 0.003 km$^2$ to 0.226 km$^2$.

## 1. GİRİŞ

Artan şehirleşme ile birlikte doğayla bütünleşik yeşil alanlar giderek azalmakta; bu alanların yerini ısıyı tutma kapasitesi yüksek beton ve asfalt yüzeyler almaktadır (Ismael vd., 2024). Bu dönüşüm, kentlerde sıcaklık, nem ve diğer meteorolojik koşulları etkileyerek mikroklimatik farklılıkların ortaya çıkmasına yol açmaktadır. Özellikle büyük şehirler, çevrelerine kıyasla daha yüksek sıcaklıklara sahip özgün iklimsel özellikler geliştirmekte olup, bu olgu literatürde Kentsel Isı Adası (KIA) etkisi olarak tanımlanmaktadır. Yüzey KIA uzaktan algılama teknolojisi gibi dolaylı ölçümlerle belirlenmektedir. YKIA etkisi, ekosistem dengesi, insan sağlığı, enerji kullanımı ve çevresel sürdürülebilirlik açısından da kritik sonuçlar doğurmaktadır (Arnfield, 2003; Renard vd., 2019; Ullah vd., 2022; Alkan vd., 2017; Yıldız vd., 2019; Güneş vd., 2021).

Büyük ölçekli altyapı projeleri, özellikle doğal arazi örtüsünün dönüşümüne neden olarak bölgesel ölçekte YKIA etkisini artırabilmektedir. Bu bağlamda, 2018 yılında hizmete açılan İstanbul Havalimanı, geniş yüzey alanı, yoğun yapay zemin örtüsü ve bulunduğu konum itibarıyla bölgesel iklim üzerinde önemli etkiler yaratabilecek potansiyele sahiptir. Bu çalışmada, İstanbul Havalimanı'nın inşa öncesi ve sonrası dönemlere ait YKIA etkisi bağlamında değerlendirilmesi amaçlanmaktadır.

* **Sorumlu Yazar**
(mcan.yildiz@igdir.edu.tr) ORCID ID 0000-0003-1090-0726
(emirhan.ozdemir@igdir.edu.tr) ORCID ID 0000-0001-8306-834X
(rustu.calli@igdir.edu.tr) ORCID ID 0000-0003-4508-3316
(fehmi.veziroglu@igdir.edu.tr) ORCID ID 0000-0002-0712-7640
*(aliihsan.sekertekin@igdir.edu.tr) ORCID ID 0000-0002-4715-5160

**Kaynak Göster (APA):**
Yıldız MC, Özdemir E, Çallı R, Veziroğlu F & Şekertekin A (2025). İstanbul Havalimanı'nın Yakın Çevresindeki Yüzey Kentsel Isı Adası Oluşumuna Etkisinin İncelenmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 2. YÖNTEM

### 2.1. Çalışma Alanı

İstanbul Havalimanı (İstanbul Grand Airport "*İGA*"), Türkiye'nin İstanbul ilinde, Avrupa Yakası'nda yer alan Arnavutköy ilçesi sınırlarında konumlanmıştır (Şekil 1). Konumu itibarıyla Avrupa ile Asya arasında stratejik bir noktada yer alan havalimanı, Türkiye'nin küresel bir hava ulaşım merkezi olmasında önemli bir rol oynamaktadır. Ülkemizdeki en büyük projelerden biri olan İstanbul havalimanı YKIA etkisinin analizi için araştırmacılara doğal bir ortam sunduğu için bu çalışmada dikkate alınmıştır.




**Şekil 1.** İstanbul Havalimanının ve çalışma alanının (kırmızı sınırlar) harita üzerinde gösterimi.

### 2.2. Materyal

Bu çalışmada verilerin işlenmesi ve analizinde Google Earth Engine (GEE) platformundan yararlanılmıştır. İstanbul Havalimanı ve yakın çevresinde YKIA etkisinin zamansal değişimini analiz edebilmek amacıyla, 21 Ekim 2014 ve 03 Ekim 2019 tarihlerinde alınan iki uydu verisi kullanılmıştır. Kullanılan veriler, Landsat 8 Collection 2, Level 2, Tier 1 (LANDSAT/LC08/C02/T1_L2) veri kümesine aittir.

### 2.3. Metodoloji

Çalışma kapsamında havalimanının inşasından önceki ve sonraki dönemleri temsil edecek şekilde 2014 yılı (inşa öncesi) ve 2024 yılı (inşa sonrası) tarihli Landsat 8 uydusuna ait görüntüler tercih edilmiştir. İlgili uydu görüntülerinin işlenmesi sürecinde, Landsat 8 uydusunun YS ürünü olan ST_B10 kullanılarak YS değerleri hesaplanmıştır (https://www.usgs.gov/landsat-missions/landsat-collection-2-surface-temperature). Bu hesaplama sürecinde uydu tarafından sağlanan radyometrik sıcaklık değerleri, fiziksel sıcaklığa dönüştürülmek amacıyla aşağıdaki dönüşüm formülden yararlanılmıştır:

$$YS = (ST_{B10} \times 0.00341802) + 149 \quad (1)$$

Elde edilen YS verileri ile çalışmanın temel odak noktası olan Kentsel Termal Alan Varyans İndeksi (Urban Thermal Field Variance Index- UTFVI) hesaplanmıştır. UTFVI hesaplaması aşağıdaki formüle dayanmaktadır (Zhang vd., 2006):

$$\text{UTFVI} = (YS - YS_{ortalama}) \,/\, YS_{ortalama} \quad (2)$$

Burada YS yüzey sıcaklığı görüntüsünü, $YS_{ortalama}$ ifadesi ise çalışma alanı sınırları içerisindeki ortalama YS'yi temsil etmektedir. UTFVI değerleri, literatürde kabul gören termal stres eşiklerine göre altı sınıfa ayrılmıştır (Zhang vd., 2006). Söz konusu sınıflar; termal konforlu alanlardan, çok yüksek termal strese maruz kalan bölgelere kadar geniş bir skalada sınıflandırılmıştır (Çizelge 1).

**Çizelge 1**. UTFVI Sınıflandırması ve Termal Stres Aralıkları

| UTFVI Değer Aralığı | Termal Stres Sınıflandırması |
|---|---|
| UTFVI <0 | Termal Konforlu |
| 0 ≤ UTFVI < 0.005 | Düşük Termal Stres |
| 0.005 ≤ UTFVI < 0.010 | Orta-Düşük Termal Stres |
| 0.010 ≤ UTFVI < 0.015 | Orta Termal Stres |
| 0.015 ≤ UTFVI < 0.020 | Orta-Yüksek Termal Stres |
| UTFVI ≥ 0.020 | Çok Yüksek Termal Stres |

## 3. BULGULAR

Bu çalışmada, İstanbul Havalimanı'nın inşa sürecinden önceki (2014) ve sonraki (2019) dönemlere ait Landsat 8 uydu görüntülerinden türetilen YS verileri kullanılarak hesaplanan UTFVI değerleri, zamansal ve mekânsal boyutta analiz edilmiştir. Araştırma kapsamında elde edilen termal stres dağılımı haritalarından, 2014 yılına ait durum Şekil 1'de, 2019 yılına ait durum ise Şekil 2'de sunulmaktadır.

Şekil 2'de yer alan 2014 yılı UTFVI görüntüsü incelendiğinde, çalışma alanının büyük bir bölümünün termal konforlu alanlar (UTFVI <0) ve düşük termal stres sınıfları (0≤UTFVI<0.005) kapsamında yer aldığı gözlemlenmektedir.

2019 yılına ait UTFVI görüntüsü (Şekil 2) incelendiğinde, havalimanı inşaatının ardından bölgedeki termal yapı gözle görülür biçimde değişmiştir. Havalimanı sahasının merkezinde yer alan bölgelerde orta, orta-yüksek ve çok yüksek termal stres sınıflarının (sarı, turuncu ve kırmızı tonlar) belirgin bir biçimde yoğunlaştığı görülmektedir. Özellikle pistler, terminal binaları ve apron çevresi gibi yapay yüzeylerin yoğun olduğu alanlar, homojen bir şekilde yüksek sıcaklık

TASLAK

değerleriyle örtüşmekte ve çevresel termal yapının radikal biçimde değiştiğini işaret etmektedir. Mekânsal analizlerin yanı sıra, Çizelge 2'de sunulan yüzey alan verileri de bu durumu niceliksel olarak desteklemektedir.

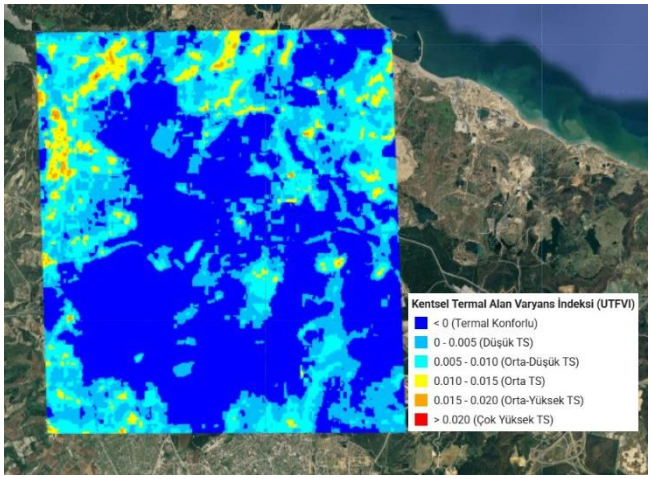


**Şekil 2.** 2014 yılına ait UTFVI sınıflandırmasına göre termal stres dağılım haritası

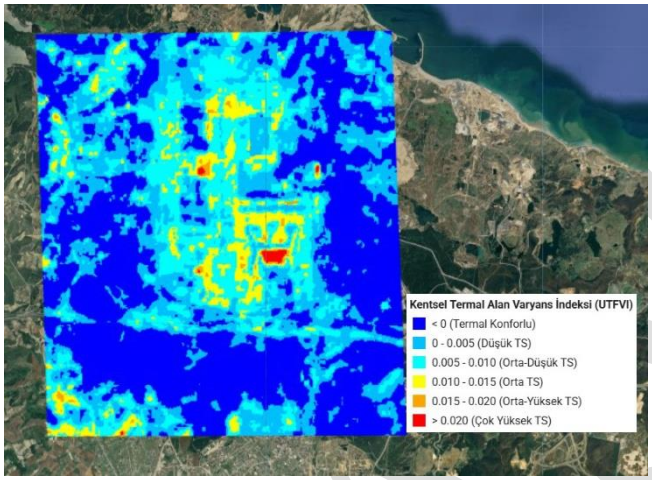


**Şekil 3.** 2019 yılına ait UTFVI sınıflandırmasına göre termal stres dağılım haritası

**Çizelge 2.** 2014 ve 2019 yıllarına ait UTFVI sınıflarına göre alan büyüklükleri ($km^2$)

| UTFVI Değer Aralığı | Alanlar ($km^2$) | |
|---|---|---|
| | **2014** | **2019** |
| <0 (Termal Konforlu) | 51.512 | 43.635 |
| 0-0.005 (Düşük TS) | 25.795 | 29.428 |
| 0.005-0.010 (Orta-Düşük TS) | 19.202 | 21.765 |
| 0.010- 0.015 (Orta TS) | 4.872 | 6.284 |
| 0.015- 0.020 (Orta-Yüksek TS) | 0.435 | 0.481 |
| > 0.020 (Çok Yüksek TS) | 0.003 | 0.226 |

2014 ve 2019 yıllarına ait UTFVI sınıflarının yüzey alanları karşılaştırıldığında, en konforlu sınıf olan UTFVI<0 kategorisinde 2014 yılında yaklaşık 51.512 $km^2$ olan alan, 2019 yılı itibarıyla 43.635 $km^2$'ye düşmüştür. Bununla birlikte, düşük termal stres ve üzeri sınıflarda gözlenen artış dikkat çekicidir. Aynı şekilde, orta-yüksek ve çok yüksek termal stres sınıflarında da artış gözlenmektedir.

## 4. TARTIŞMA

Sayfa sınırı nedeniyle tam metin de yer verilecektir.

## 5. SONUÇ

Bu çalışma, İstanbul Havalimanı'nın inşa sürecinin bölgesel arazi örtüsü üzerindeki etkilerini mekânsal ve zamansal boyutlarda değerlendirmeyi amaçlamıştır. Landsat 8 uydu verileri kullanılarak hesaplanan UTFVI, 2014 ve 2019 yıllarına ait termal stres dağılımının karşılaştırılmasına olanak sağlamıştır. Elde edilen bulgular, havalimanı inşaatı öncesinde bölgenin büyük ölçüde termal konfor sağlayan doğal yüzey örtüsüne sahip olduğunu, ancak inşaat süreci sonrasında bu alanların yapay yüzeylerle yer değiştirerek termal stres artışına yol açtığını ortaya koymuştur.

## KAYNAKÇA

Alkan, A., Adıgüzel, F., & Kaya, E. (2017). Batman Kentinde Kentsel Isınmanın Azaltılmasında Yeşil Alanların Önemi. Coğrafya Dergisi, (34), 62-76.

Arnfield, A. J. (2003). Two decades of urban climate research: a review of turbulence, exchanges of energy and water, and the urban heat island. International Journal of Climatology: a Journal of the Royal Meteorological Society, 23(1), 1-26.

EPA. (2008). Reducing urban heat islands: Compendium of strategies. https://www.epa.gov/heatislands/heat-island-compendium (erişim 10 Nisan 2025).

Güneş, C., Pekkan, E., & Tün, M. (2021). Eskişehir Kent Merkezinde Yer Alan Üniversite Kampüslerindeki Kentsel Isı Adası Etkilerinin Landsat-8 Uydu Görüntüleri Üzerinden Araştırılması. Ulusal Çevre Bilimleri Araştırma Dergisi, 4(1), 22-32.

Ismael, S. F., Alias, A. H., Haron, N. A., Zaidan, B. B., & Abdulghani, A. M. (2024). Mitigating Urban Heat Island Effects: A Review of Innovative Pavement Technologies and Integrated Solutions. Structural Durability & Health Monitoring (SDHM), 18(5), 1–19.

Renard, F., Alonso, L., Fitts, Y., Hadjiosif, A., & Comby, J. (2019). Evaluation of the effect of urban redevelopment on surface urban heat islands. Remote Sensing, 11(3), 299.

Ullah, N., Siddique, M. A., Ding, M., Grigoryan, S., Zhang, T., & Hu, Y. (2022). Spatiotemporal impact of urbanization on urban heat island and urban thermal field variance index of Tianjin City, China. Buildings, 12(4), 399.

Yıldız, N. D., Avdan, U., & Avdan, Z. (2019, August). Kentsel Mekân Farklılıklarının Isı Adası Oluşumuna Etkisinin Belirlenmesi: Erzurum Kenti Örneği. In SETSCI-Conference Proceedings (Vol. 7, pp. 220-224). SETSCI-Conference Proceedings.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Kentsel Alanlarda Uydu Tabanlı Yüzey Sıcaklığı ve Yüzey Albedosu Arasındaki İlişkinin İncelenmesi: Zonguldak Örneği

**Rüştü Çallı[1], Emirhan Özdemir[1], Mitat Can Yıldız[1], Fehmi Veziroğlu[1], Aliihsan Şekertekin*[1]**

[1]*Iğdır Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Mimarlık ve Şehir Planlama Bölümü, Iğdır, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Termal uzaktan algılama,
Liang albedo modeli,
Mikroklimal varyasyonlar

**ÖZET**

Bu çalışma, Zonguldak kentsel alanlarında uydu tabanlı Yer Yüzey Sıcaklığı (YYS) ile yüzey albedosu arasındaki ilişkiyi incelemeyi amaçlamaktadır. Landsat 8 uydu görüntüleri ve Google Earth Engine (GEE) platformu kullanılarak, 28 Haziran 2024 tarihine ait verilerle analizler gerçekleştirilmiştir. Rastgele Orman (RO) algoritması ile yapılan arazi örtüsü sınıflandırmasında kentsel, ormanlık ve sulak alanlar belirlenmiş; yalnızca kentsel pikseller seçilerek YYS ve albedo değerleri hesaplanmıştır. Termal bant (ST_B10) ve Liang (2001) yöntemiyle elde edilen sonuçlara göre, yüzey sıcaklığı 10°C ile 53°C, albedo ise 0.05 ile 0.55 aralığında değişim göstermiştir. Korelasyon analizinde, albedo ile YYS arasında istatistiksel olarak anlamlı bir ilişki bulunmamıştır (Pearson r=0.0109).

# Examining the Relationship Between Satellite-Based Surface Temperature and Surface Albedo in Urban Areas: Case Study of Zonguldak

**Keywords**
Remote Sensing,
Thermal remote sensing,
Liang albedo model,
Microclimatic variations

**ABSTRACT**

This study investigates the relationship between satellite-derived land surface temperature (LST) and surface albedo in urban areas of Zonguldak, Turkey. Using Landsat 8 imagery and the Google Earth Engine (GEE) platform, data from June 28, 2024, were processed. A Random Forest algorithm classified land cover into urban, forested, and wetland areas, with subsequent analysis focused exclusively on urban pixels. LST was derived from the thermal band (ST_B10), while albedo was calculated using Liang (2001)'s weighted coefficients. Results showed LST values ranging between 10°C and 53°C, and albedo values between 0.05 and 0.55. Correlation analysis revealed no statistically significant linear relationship between albedo and LST (Pearson r=0.0109).

## 1. GİRİŞ

Kentsel alanlarda uydu tabanlı yer yüzey sıcaklığı (YYS) ile yüzey albedosu (bir yüzeyin gelen güneş ışığını yansıtma oranı) arasındaki ilişkinin araştırılması, son yıllarda bir ilgi görmüştür. Günümüzde kentleşmenin hızla artması, doğal yüzeylerin yerini yapay yüzeylerin almasına neden olmuş, bu da şehirlerin mikro iklim koşullarını önemli ölçüde değiştirmiştir (de Souza vd., 2016). KIA etkisinin temel nedenlerinden biri, kentsel yüzeylerin güneş enerjisini farklı oranlarda yansıtma ve tutma kapasitesidir (Rizwan ve Dennis, 2008).

Albedo, Dünya'nın radyasyon bütçesini yöneten temel iklim değişkenlerinden biri olarak tanımlanmış ve hem yer ölçümleri hem de uydu verileriyle elde edilme yöntemleri değerlendirilmiştir (Salleh vd., 2014).

Bu çalışmada, Zonguldak ili örneğinde, kentsel alanlara ait yüzey sıcaklığı ve albedo değerleri arasındaki ilişki, 2024 yılına ait Landsat uydu verisi kullanılarak incelenmiştir. Çalışmada, öncelikle Rastgele Orman (RO) algoritması ile çıkarılan kentsel alan sınıfına ait pikseller seçilerek bu alanlara ait YYS ve albedo değerleri elde edilmiştir. Elde edilen veriler üzerinden YYS ve albedo arasındaki korelasyon ilişkisi değerlendirilmiştir.

* **Sorumlu Yazar**
(rustu.calli@igdir.edu.tr) ORCID ID 0000-0003-4508-3316
(emirhan.ozdemir@igdir.edu.tr) ORCID ID 0000-0001-8306-834X
(mcan.yildiz@igdir.edu.tr) ORCID ID 0000-0003-1090-0726
(fehmi.veziroglu@igdir.edu.tr) ORCID ID 0000-0002-0712-7640
*(aliihsan.sekertekin@igdir.edu.tr) ORCID ID 0000-0002-4715-5160

**Kaynak Göster (APA):**
Çallı R, Özdemir E, Yıldız MC, Veziroğlu F & Şekertekin A (2025). Kentsel Alanlarda Uydu Tabanlı Yüzey Sıcaklığı ve Yüzey Albedosu Arasındaki İlişkinin İncelenmesi: Zonguldak Örneği, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 2. YÖNTEM

### 2.1. Çalışma Alanı

Zonguldak ili, Türkiye'nin kuzeybatısında, Karadeniz Bölgesi'nin batı kesiminde yer almakta olup, coğrafi konumu, doğal kaynakları ve topografik çeşitliliğiyle dikkat çeker. Yaklaşık 3.481 $km^2$ yüzölçümüne sahip olan il, ormanlık ve dağlık alanlarla kaplıdır (Şekil 1). Bu araştırmada, çalışma alanı olarak Şekil 1'de sınırları sunulan Zonguldak şehir merkezi ve yakın çevresindeki kentsel alanlar dikkate alınmıştır.

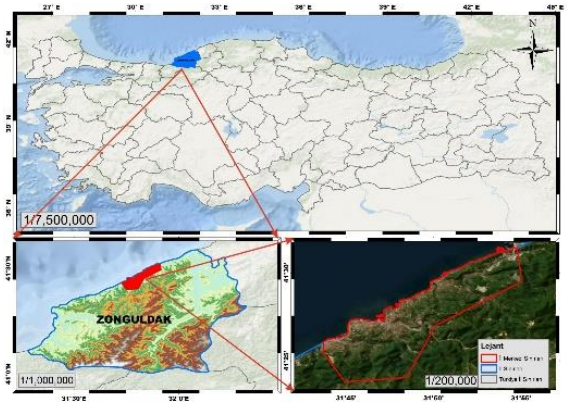


**Şekil 1.** Çalışma Alanı

### 2.2. Materyal

Bu çalışmada, kentsel yüzey sıcaklığı ve albedo verilerinin analizi için 28 Haziran 2024 tarihinde alınmış Landsat 8 uydu verisi kullanılmıştır. Veri işleme ve analiz süreci, Google Earth Engine (GEE) platformu kullanılarak gerçekleştirilmiştir. Landsat 8 verileri GEE üzerinde işlenerek, Zonguldak ilindeki kentsel alanlar için yüzey sıcaklığı ve albedo değerleri çıkarılmış ve bu veriler üzerinden analizler yapılmıştır.

### 2.3. Metodoloji

RO, denetimli öğrenme algoritmalarından biri olup, özellikle sınıflandırma ve regresyon problemleri için yaygın olarak kullanılmaktadır (Belgiu ve Drăguţ, 2016). Bu çalışmada, vejetasyon, ormanlık alanlar, kentsel alanlar, açık alanlar ve sulak alanların sınıflandırılması için RO algoritması kullanılmıştır. Sınıflandırma sonrası vejestasyon ve ormanlık alanlar birleştirilerek yeşil alan sınıfı oluşturulmuştur. Ayrıca kentsel alanlar ile çok fazla karışan açık alanlar da kentsel alan sınıfına dahil edilmiştir. Landsat 8 görüntüsünden elde edilen yansıtım bantları sınıflandırma sürecinde kullanılmıştır.

Yüzey sıcaklığının hesaplanmasında ise Landsat 8 uydusunun ST_B10 termal bandı kullanılarak, uydu tarafından ölçülen parlaklık sıcaklıkları Amerikan Jeoloji Araştırmaları Kurumu (USGS) tarafından önerilen dönüşüm katsayıları yardımıyla fiziksel sıcaklık değerlerine dönüştürülmüştür (https://www.usgs.gov/faqs/how-do-i-use-a-scale-factor-landsat-level-2-science-products).

Albedo hesaplamalarında, literatürde sıklıkla başvurulan Liang (2001) tarafından önerilen ağırlıklı katsayılar aracılığıyla albedo değerleri hesaplanmış ve albedo haritaları oluşturulmuştur.

Araştırmanın son aşamasında, yüzey sıcaklığı ve yüzey albedosu verileri hem istatistiksel hem de görsel analizlere temel teşkil edecek şekilde dışa aktarılmıştır.

## 3. BULGULAR

Çalışmada RO ile eğitilen model, %89 genel doğruluk ve 0.85 Kappa değeri uydu verilerini sınıflandırmıştır (Şekil 2). Sınıflandırma sonrasında Kentsel Alan sınıfına ait vektör veri YYS ve albedo çıkarımları için kaydedilmiştir.

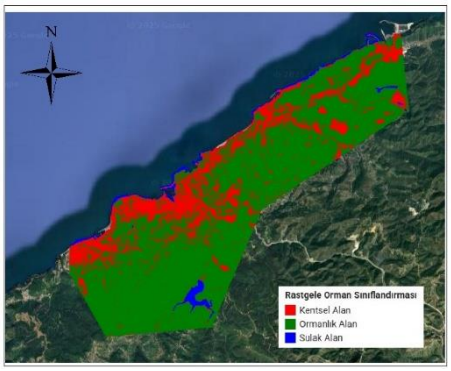


**Şekil 2.** RO Algoritması ile elde edilen arazi kullanımı ve arazi örtüsü görüntüsü

Şekil 3 kentsel alanlar için elde edilen vektör dosyası dikkate alınarak YYS değerlerini sunmaktadır. Şekil 3'de görüldüğü üzere, YYS haritasında minimum değer 20.7°C maksimum değer 53°C olarak elde edilmiştir.

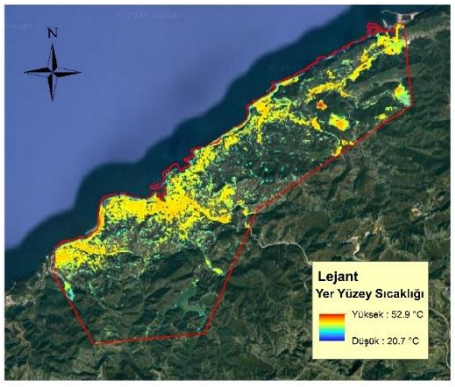


**Şekil 3.** Yer Yüzey Sıcaklığı

Kentsel alanlara ait yüzey albedo değerleri, Liang (2001) tarafından önerilen katsayılar dikkate alınarak hesaplanmış ve sonuçlar Şekil 4'te görselleştirilmiştir. Albedo haritalandırmasında, çalışma alanında tespit edilen minimum (0.05) ve maksimum (0.55) değerler temel alınmıştır.

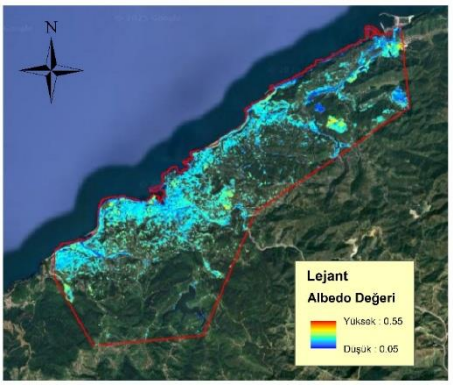


**Şekil 4.** Albedo Değeri

Yüzey sıcaklığı ile yüzey albedosu arasındaki niceliksel ilişkiyi belirlemek amacıyla oluşturulan dağılım grafiği Şekil 5'te sunulmuştur. Grafik incelendiğinde, albedo değerlerinin 0.05 ile 0.55; yüzey sıcaklığı değerlerinin ise 20.7°C ile 52.9°C arasında değiştiği gözlemlenmektedir. Dağılım eğilimi, düşük albedo değerlerine sahip yüzeylerde sıcaklıkların genellikle yüksek seviyelerde yoğunlaştığını; albedo arttıkça yüzey sıcaklığında belirgin bir azalma eğilimi olduğunu göstermektedir.

Ancak Şekil 4'teki grafikte de görüldüğü üzere, albedo değerleri 0.05- 0.2 aralığında olan alanlarda yüzey sıcaklıklarının çoğunlukla 25°C - 50°C arasında değiştiği tespit edilmiştir. Albedo değerinin 0.3 ve üzeri olduğu durumlarda, yüzey sıcaklığında hafif bir düşüş eğilimi gözlemlenmekle birlikte, bu eğilim istatistiksel açıdan güçlü bir korelasyon göstermemektedir. Yapılan korelasyon analizinde hesaplanan Pearson korelasyon katsayısı 0.0109 olarak bulunmuş ve bu sonuç, yüzey sıcaklığı ile albedo arasında doğrusal anlamda istatistiksel olarak anlamlı bir ilişki olmadığını ortaya koymuştur.

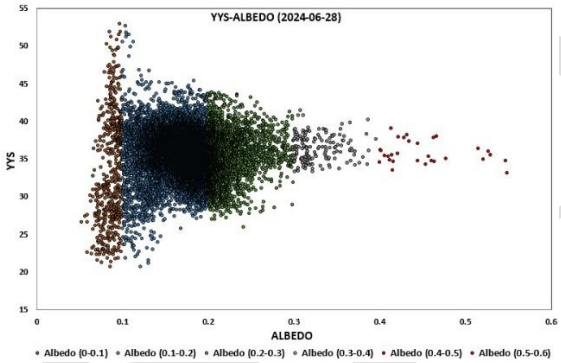


**Şekil 5.** YYS ve Albedo saçılım grafiği

Elde edilen bulgular, yüzey sıcaklığını belirleyen faktörlerin yalnızca albedo ile açıklanamayacağını; yerel ölçekte bitki örtüsü yoğunluğu, gölgelilik, yüzey malzeme özellikleri, yapılaşma şekli ve topografya gibi çok sayıda çevresel unsurun bu ilişki üzerinde etkili olduğunu göstermektedir.

## 4. SONUÇ

Çalışmada elde edilen bulgular, yüzey sıcaklıklarının kentsel alanlarda mekânsal olarak homojen dağılmadığını; özellikle şehir merkezi, sanayi bölgeleri ve ana ulaşım arterlerinin çevresinde sıcaklık değerlerinin belirgin biçimde arttığını ortaya koymuştur.

Yüzey albedosu değerleri ise 0.05 ile 0.55 arasında değişmekte olup, dağılım grafikleri üzerinden gerçekleştirilen analizlerde, albedo değerinin artışıyla yüzey sıcaklıklarında hafif bir düşüş eğilimi gözlenmiş olsa da, bu ilişkinin istatistiksel olarak anlamlı düzeyde olmadığı belirlenmiştir. Nitekim hesaplanan Pearson korelasyon katsayısı (r=0.0109), yüzey sıcaklığı ile albedo arasında doğrusal bir ilişkinin bulunmadığını ortaya koymuştur.

## KAYNAKÇA

Belgiu, M., & Drăguţ, L. (2016). Random forest in remote sensing: A review of applications and future directions. ISPRS journal of photogrammetry and remote sensing, 114, 24-31.

De Souza, D. O., dos Santos Alvalá, R. C., & do Nascimento, M. G. (2016). Urbanization effects on the microclimate of Manaus: A modeling study. Atmospheric Research, 167, 237-248.

Liang, S. (2001). Narrowband to broadband conversions of land surface albedo I: Algorithms. Remote sensing of environment, 76(2), 213-238.

Rizwan, A. M., & Dennis, L. Y. (2008). A review on the generation, determination and mitigation of Urban Heat Island. Journal of environmental sciences, 20(1), 120-128.

Salleh, S. A., Latif, Z. A., Pradhan, B., Wan Mohd, W. M. N., & Chan, A. (2014). Functional relation of land surface albedo with climatological variables: a review on remote sensing techniques and recent research developments. Geocarto International, 29(2), 147-163.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Marmara Denizi ve Adalarını Kapsayan Yüksek Çözünürlüklü Worldview-2 Uydu Görüntüsünün Geometrik Doğruluk Düzeyinin Araştırılması

**Gürcan Büyüksalih*[1], Cem Gazioğlu[1], Karsten Jacobsen[2]**

[1]*İstanbul Üniversitesi, Deniz Bilimleri ve İşletmeciliği Enstitüsü, İstanbul, Türkiye*
[2]*Leibniz Hanover Üniversitesi, Fotogrametri ve Jeoenformasyon Enstitüsü, Hanover, Almanya*

**Anahtar Kelimeler**
Denizel Çevre, WorldView-2, Uydu Görüntü Yöneltmesi, Geometrik Doğruluk Analizi

**ÖZET**

Marmara Denizi'nde yer alan Prenses Adaları çevresinde yapılacak batimetri çalışmaları için GeoTIFF formatında WorldView-2 (WV-2) görüntüsü temin edilmiştir. Görüntü, büyük oranda Marmara Denizini, adaları ve İstanbul'un kara kısmından çok az bir bölümü kapsamaktadır. Yöneltme aşamasında doğrudan GeoTIFF çözümü, RPK yaklaşımı ve 3-boyutlu afin dönüşüm metotları kullanılmıştır. Geometrik doğruluk analizinde Google Earth üzerinden sayısallaştırılan Yer Kontrol Noktalarından (YKN) yararlanılmıştır. Çalışma sonucunda, doğru yöneltme tekniği olarak 3-boyutlu afin dönüşümü kullanılması gerektiği sonucuna varılmıştır. Geometrik düzeltmesi yapılan yüksek çözünürlüklü uydu görüntüleri ve spektral bantları, su derinliğinin tesbitinde kullanılabilmektedir. Ancak, batimetrik hesaplamalar, değişik faktörlerden etkilenebilmektedir. Görüntü piksellerinin gri değerleri, suyun şeffaflığına bağımlı olmaktadır. Bu durum, su yüzeyinden siyah beyaz bir diskin ayırtedilebildiği maksimum su derinliği olan Secchi derinliği ile tanımlanmaktadır. Suyun şeffaflığı, sudaki bulanıklığa ve partikül yoğunluğuna göre önemli ölçüde değişebilmektedir. Bulanıklığa sebep olan materyaller, akan suyla gelen tortular ve besin içeriği taşıyan algler olabilmektedir. Bunun yanısıra yansıma düzeyi, denizin dalgalı olmasından güçlü bir şekilde etkilenmekte ve bu da suyun penetrasyonunu sınırlayabilmektedir. Bu çalışmada tüm bu faktörlerin etkisi detaylı incelenmiş ve açıklanmıştır.

# Geometric Accuracy Analysis of High Resolution Worldview-2 Satellite Image Covering the Marmara Sea and Its Islands

**Keywords**
Marine Environment, WorldView-2, Satellite Image Orientation, Geometric Accuracy Analysis

**ABSTRACT**

WorldView-2 (WV-2) image in GeoTIFF format was provided for bathymetry studies to be carried out around the Princess Islands in the Sea of Marmara. The image largely covers the Sea of Marmara, the islands and a small part of the land of Istanbul. Direct GeoTIFF solution, RPK approach and 3-dimensional affine transformation methods were used for image orientation. Ground Control Points (GCP) digitized via Google Earth were used in the geometric accuracy analysis. As a result of the study, it was concluded that 3-dimensional affine transformation should be used as the correct orientation technique. Geometrically corrected high-resolution satellite images and spectral bands can be used to determine water depth. However, bathymetric calculations can be affected by different factors. The gray values of image pixels depend on the transparency of the water. This is defined by the Secchi depth, which is the maximum water depth at which a black and white disc can be distinguished from the water surface. The transparency of water can vary significantly depending on the turbidity and particle density in the water. Materials that cause turbidity may be sediments carried by flowing water and algae that carry nutrients. In addition, the level of reflection is strongly affected by the roughness of the sea, which can limit the penetration of water. In this study, the effects of all these factors are examined and explained in detail.

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Büyüksalih G, Gazioğlu C & Jacobsen K (2025). Marmara Denizi ve Adalarını Kapsayan Yüksek Çözünürlüklü Worldview-2 Uydu Görüntüsünün Geometrik Doğruluk Düzeyinin Araştırılması, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Marmara Denizi'nde yer alan Prenses Adaları çevresinde yapılacak batimetri çalışmaları için GeoTIFF formatında WorldView-2 (WV-2) görüntüsü temin edilmiştir. Görüntü büyük oranda Marmara Denizini, adaları ve İstanbul'un kara kısmından çok az bir bölümü kapsamaktadır. GeoTIFF WV-2 görüntüsünün geometrik tanımı net olmadığından bu çalışmada detaylı biçimde araştırması yapılmıştır. Görüntü, Rasyonel Polinom Katsayıları (RPK) verileriyle birlikte kullanıcıya sunulmaktadır. Görüntü yöneltmesi için doğrudan GeoTIFF çözümü, RPK yaklaşımı ve 3-boyutlu afin dönüşüm metotları kullanılmıştır. Geometrik doğruluk analizinde Google Earth üzerinden sayısallaştırılan Yer Kontrol Noktalarından (YKN) yararlanılmıştır. Çalışma sonucunda, doğru yöneltme tekniği olarak 3-boyutlu afin dönüşümü kullanılması gerektiği sonucuna varılmıştır.

## 2. YÖNTEM

Denizel uygulamalar için yaklaşık 2 m düzeyinde bir coğrafi konum doğruluğu gereklidir. Diğer alanlardaki deneyimlerimize dayanarak, Google Earth'ün bağıl doğruluğu, WV-2 görüntüsünün kapsadığı alanda 1,5 m ila 2 m aralığındadır. WV-2 görüntüsü ve Google Earth üzerinde 20 adet YKN'nın görüntü ve obje koordinatları ölçülmüş ve bu değerler, farklı matematik modeller kullanılarak analiz edilmiştir. Bunlar, Rasyonel Polinom Katsayıları (RPK) ve 3-Boyutlu afin dönüşüm yaklaşımlarıdır.

### 2.1. Batimetri

Hannover Leibniz Üniversitesi'ndeki Fotogrametri ve Jeoenformasyon Enstitüsü, geçmiş yıllarda hava ve uydu görüntülerinden sığ sularda coğrafi bilgi üretimi üzerine bir çalışma yürütmüştür (Jacobsen 2005, 72 sayfa). Bu çalışmada, görüntülerden su derinliğinin belirlenmesine yönelik farklı yöntemler analiz edilmiş ve açıklanmıştır.

Klasik fotogrametrik yöntem, su derinliğinin stereoskopik ölçümünü gerektirmektedir. Görüntü piksellerinin gri değerleri su derinliğine bağımlı olduğu gibi suyun şeffaflığından da etkilenmektedir. Bu durum, su yüzeyinden siyah beyaz bir diskin ayırtedilebildiği maksimum su derinliği olan Secchi derinliği ile tanımlanmaktadır. Suyun şeffaflığı, sudaki bulanıklığa partikül yoğunluğuna göre önemli ölçüde değişebilmektedir. Bulanıklığa sebep olan materyaller, akan suyla gelen tortular ve besin içeriği taşıyan algler olabilir. Su yüzeyinden güneş ışığı yansıması da sudaki görünürlüğü azaltabilmektedir. Bunun yanında, yansıma düzeyi, denizin dalgalı olmasından güçlü bir şekilde etkilenmekte ve bu da suyun penetrasyonunu sınırlayabilmektedir.

## 3. BULGULAR

Çizelge 1'de geometrik doğruluk değerleri verilmektedir. YKN'lerin denizden yüksekliği, 24 m'den 31 m'ye kadar olan 3 nokta ve 6 m'den yüksek olan bir nokta hariç, 0 m ila 2 m arasında değişmektedir. Bu çizelgeye dayalı olarak, kullanılan GeoTIFF görüntüsünün bir ortogörüntü olmadığı açıktır ve geometrik bir iyileştirme gereklidir. GeoTIFF olarak dağıtılan görüntünün yalnızca sabit yükseklikte bir düzleme yapılan basit bir projeksiyondan ibarettir. Görüntüyle gelen RPK verileri, Çizelge 1'den görüldüğü üzere yeterli olmamaktadır. Doğru geometrik düzeltme, sadece 3 boyutlu afin dönüşümle sağlanabilmektedir. Bu metot, YKN'lerin yüksekliğini hesaba katmakta ve X ve Y'de sırasıyla 1,30 m ve 1,23 m düzeyinde standart sapma üretmektedir. Bu doğruluk değerleriyle kontrol noktası ölçümündeki tanımlamaya karşılık gelen bir doğruluk düzeyine yaklaşılmaktadır.

| | SX | SY | YKN sayısı |
|---|---|---|---|
| Tüm YKN'lerle GeoTIFF görüntünün doğrudan kullanımı | 5.11 m | 6.64 m | 20 |
| GeoTIFF görüntünün sadece benzer yükseklik değerli YKN'ler ile doğrudan kullanımı | 2.32 m | 2.27 m | 17 |
| RPK'ların tüm YKN'ler ile birlikte kullanımı | 4.86 m | 6.64 m | 20 |
| RPK'ların benzer yükseklik değerli 17 YKN ile birlikte kullanımı | 1.09 m | 1.59 m | 17 |
| Tüm YKN'ler kullanılarak 3-boyutlu afin dönüşüm | 1.30 m | 1.23 m | 20 |

Tablo 1. Görüntü yöneltmesi sonuçları

## 4. TARTIŞMA

Coğrafi bilgi sistemi uygulamaları orto-görüntülere ihtiyaç duymaktadır. 3-boyutlu afin dönüşüme dayalı orto-görüntü üretimi AFF3DORTHO programı ile geliştirilmiştir. Sayısal yükseklik modeli olarak Alman Uzay Ajansının (DLR) TanDEMX 30m resolusyonlu editlenmiş TDM1-EDEM kullanılmıştır. Sayısal Yüzey Modeli (SYM), 1 yay saniyelik (~ 30 m) nokta aralığıyla ücretsiz olarak kullanıcılara verilmektedir. ABD'deki oldukça düz bir test alanında yapılan bir çalışmaya göre, lidar datalarından elde edilmiş referans bir SYM ile karşılaştırıldığında, TDM1-EDEM'in standart sapması 1,15 m ve NMAD doğruluk değeri 0,82 m düzeyindedir. Kullanılan diğer test alanlarında da TDM1-EDEM, diğer global SYM verilerine (GDEM3, SRTM, AW3D30 ve TDM90) göre daha doğru değerler üretmektedir. Sözkonusu WV-2 görüntüsünün 38° düzeyindeki ışın geliş açısı düşünüldüğünde yatay konum, düşey doğruluğun %78'i oranında etkilenmektedir. Bu durum, denizcilik uygulamaları açısından bir sorun oluşturmaz.

## 5. SONUÇ

WorldView-2 GeoTIFF görüntüsü deniz seviyesindeki bir projeksiyonu temsil etmektedir. Haliyle yüksekliği bu düzeyden farklılaşan yüzey detayların geometrik olarak doğru şekilde işlenmesi için 3 boyutlu afin dönüşüme gerek duyulmaktadır. Google Earth üzerinden sayısallaştırılan yer kontrol noktalarıyla 3 boyutlu afin dönüşüm sonucu 1,3 m düzeyinde tatmin edici bir standart sapma elde edilmektedir. Proje

alanındaki sınırlı yükseklik değişimi nedeniyle 3-boyutlu afin dönüşümün genel formülü yeterli olmaktadır. Ancak ilgi alanında yükseklik farklarının artması, 3-boyutlu afin dönüşümün genişletilmiş versiyonunun kullanımını beraberinde getirecektir.

Su derinliğinin optik görüntüler kullanılarak stereoskopik olarak belirlenmesi, suyun bulanıklığıyla sınırlanmaktadır. Ayrıca, güneş yansımasından kaçınılmalıdır. Optimum koşullar altında, kara yüzeyinde bulunan noktalarla hemen hemen eşit düzeyde doğruluk değerlerine ulaşılabilir.

Yalnızca görüntünün gri değerlerine dayanarak su derinliğini belirlemek oldukça zordur. Bu durum, ancak, yalnızca deniz yatağı çok homojen olduğunda ve bulanıklık tüm alan boyunca eşit olduğunda mümkün olabilmektedir. Su derinliği ile gri değerler arasındaki ilişki, ışın geliş açısına göre de değişmektedir.

**Yazar Katkı Oranı**

Yazarların makaleye katkıları eşit ve %100 oranındadır.

**KAYNAKÇA**

Al Najar, M., Thoumyre, G., Bergsma, E., Almar, R., Benshila, R., Wilson, D., 2021: Satellite derived bathymetry using deep learning, *Mach Learn* **112**, 1107–1130 (2023). https://doi.org/10.1007/s10994-021-05977-w

Bricaud, A., Babin, M., Morel, A., Claustre, H., 1995: Variability in the chlorophyll-specific absorption coefficients of natural phytoplankton: Analysis and parameterization, Journal of Geophysical research, vol. 100, No. C7, July 1995

Büyüksalih, G., Jacobsen, K., 2008: Digital Height Models in Mountainous Regions based on Space Information, EARSel Workshop Remote Sensing - New Challenges of High Resolution, Bochum

Hanley, H.B., Yamakawa. T., Fraser, C.S., 2002: Sensor Orientation for High Resolution Imagery, Pecora 15 / Land Satellite Information IV / ISPRS Archives XXXIV part 1

Mandlburger, G., Kölle, M., Nübel, H., Sörgel, U., 2021: BathyNet: A deep Neural network for water depth mapping from multispectral aerial images, PFG – Journal of Photogrammetry, Remote Sensing and Geoinformation Science, Vol 89, pp 71-89, 2021

Schwoerbel, J., 1999: Einführung in die Limnologie. Gustav Fischer Verlag, Stuttgart

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Derin Öğrenme Yöntemleri ile RADAR Görüntülerinden Su Çıkarımı

**Ahmet Ali Soysal*[1], Abdullah Kayı[1]**

[1]*Harita Genel Müdürlüğü, Ankara, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama, Fotogrametri, Bilgisayar Görüşü, RADAR, InSAR, SAR, Derin Öğrenme, U-Net, CNN, Su, SYM, Seviye-1,

**ÖZET**

Uzaktan algılama sistemlerinin gelişmesiyle birlikte küresel çapta SYM (Sayısal Yüzey Modeli) üretiminde Yapay Açıklıklı RADAR (SAR) teknolojisi yaygın olarak kullanılmaya başlanmıştır. SAR ile elde edilen SYM'de hatalar çoğunlukla su alanlarında oluşmaktadır. Geleneksel yöntemlerle su alanlarının belirlenmesi, operatör desteği gerektiren el ile analiz süreçlerine dayanmaktadır. Ancak, bu yöntemler zaman alıcı olup, doğruluk oranı operatöre göre değişkenlik gösterebilmektedir. Aynı zamanda, su alanlarını belirlemek Seviye-1 SYM üretiminde en büyük iş yükünü oluşturmaktadır. Bu çalışmada TanDEM-X Yapay Açıklıklı RADAR verilerinden SYM üretimi projesinde mevcutta uygulanan el ile su çıkarımını daha hızlı hale getirmek, doğruluğunu arttırmak ve iş yükünü azaltmak amacıyla derin öğrenme tabanlı bir model geliştirilmiştir. 505 adet 1°x1°'lik hücreden oluşan eğitim veri seti, 128x128 piksellik küçük parçalara bölünerek işlenmiştir. Eğitim süreci için toplamda 17.756 parça kullanılmış olup, bu görüntüler eğitim (14.204) ve test (3.552) veri setleri olarak ayrılmıştır. Derin öğrenme modeli olarak CNN tabanlı evrişimli sinir ağı U-Net tercih edilmiştir. Modelin performansı, doğruluk, karesel ortalama hata (KOH) ve birleşim üzerindeki kesişim (IOU) metrikleri ile değerlendirilmiştir. Çalışmanın sonucunda, el ile yöntemlerle elde edilen su alanları ile derin öğrenme modeli tarafından tahmin edilen alanlar karşılaştırılmıştır. Yapay zekâ destekli yöntemin, el ile yöntemlere kıyasla benzer sonuçlar sunduğu, operatörden bağımsız bir standart oluşturduğu ve zamandan tasarruf sağladığı gözlemlenmiştir.

# Deep Learning Based Water Body Extraction from RADAR Imagery

**Keywords**
Remote sensing, Photogrammetry, Computer Vision, RADAR, InSAR, SAR, Deep Learning, U-Net, CNN, Water Body, DEM, Level-2

**ABSTRACT**

With the advancement of remote sensing systems, Digital Surface Models (DSM) are now produced on a global scale using Synthetic Aperture RADAR (SAR) technology. Most of the errors in DSMs obtained via SAR occur in water bodies. Traditional methods for determining water bodies rely on operator support and analysis processes. However, these methods can be costly, require operator experience, and may show variability. At the same time, water body determination constitutes the largest workload in Level-1 DSM production.

In this study, a deep learning-based model was developed to reduce the workload and increase accuracy in a project involving DSM production from TanDEM-X SAR data. The dataset consisted of 505 images composed of 1°x1° cells, split into 128x128 pixel paches. Of these, 80% (14.204) were used as the training set and 20% (3.552) as the test set. A Convolutional Neural Network (CNN)-based U-Net architecture was used as the deep learning model. Model performance was evaulated using metrics such as accuracy, root mean square error (RMSE), and intersection over union(IOU).

As a result, the areas predicted by the deep learning model were compared with the areas identified by conventional methots. It was observed that the artifical intelligence-supported method produced similar resutls, created a standard independent of the operator, and provided time saving.

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Soysal A A & Kayı A (2025). Derin Öğrenme Yöntemleri ile RADAR Görüntülerinden Su Çıkarımı, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Uzaktan algılama sistemlerinin gelişmesi ile uydu SAR teknolojisi küresel çapta Sayısal Yüksekli Modeli (SYM) elde edilmesine etkin kullanılmaya başlanmıştır. Bu amaçla 15 Haziran 2007 tarihinde TerraSAR-X, 21 Haziran 2010 tarihinde de ikizi olan TanDEM-X uyduları Alman Havacılık Merkezi (German Aerospace Center) ve EADS Astrium ortaklığında uydusu fırlatılmıştır. Bu uydular dünya üzerine 514 km.' de homojen ve sürekli gözlemler yapmaktadır. 31 mm. dalga boyunda X bandında 2014 yılından itibaren de dünya genelinde SYM üretimlerine başlamıştır. 2 m. görece ve 10 m. mutlak doğrulukta, enleme bağlı olarak değişen, yaklaşık 12x12 metre grid aralığında $1^0$x $1^0$ hücre yapısında SYM'ler üretilmektedir **(URL-1).** SYM üretimi ülkeler arasında oluşturulmuş TREx (TanDEM-X High Resolution Elevation Exchange Program) adında proje ile yapılmakta projeye dahil olan her ülke sorumluluğundaki bölgenin üretimini tamamlamakta ve paylaşmaktadır. Türkiye projede lider ülke olarak yerini almıştır. Ülkemiz adına üretimler Harita Genel Müdürlüğü'nde 2017 yılında başlamış olup, üretim süreci devam etmektedir.

Projenin amacı ham haldeki SYM verisini Seviye-1 düzeyi olarak adlandırılan kaba hatalardan ve RADAR gürültülerinden arındırılmış bir veri haline getirmektir. Düzeltme işlem adımlarında çeşitli yöntemler ile RADAR gürültüleri düzeltilirken, su gürültüleri elle toplanmakta ve ardından doğru kotuna düzlenmektedir **(URL-2).** Düzeltme işleminde en uzun süre alan, zor olan ve operatöre göre farklı standartlarda olan adım su alanlarının belirlenmesi adımıdır. Su alanlarının belirlenmesini daha hızlı ve standart hale getirmek amacıyla bu çalışma yapılmıştır.

U-Net derin öğrenme modeli, Türkiye'nin bu zamana kadar ürettiği 505 adet $1^0$x $1^0$ hücre eğitim veri seti olarak kullanılmış, doğruluk, karesel ortalama hata ve birleşim üzerindeki kesişim metrikleri hesaplanmıştır.

## 2. YÖNTEM

Su alanlarının çıkarımında CNN mimarisine sahip U-Net modeli kullanılmıştır. U-Net, özellikle görüntü segmentasyonu için tasarlanmış bir evrişimli sinir ağı (CNN) modelidir. 2015 yılında Ronneberger ve ekibi tarafından tıbbi görüntü bölütlemesi amacıyla geliştirilmiştir, ancak zamanla uydu görüntüleri, biyomedikal görüntüleme, otonom sürüş ve uzaktan algılama gibi birçok alanda yaygın olarak kullanılmaya başlanmıştır (O.Ronneberger vd.).

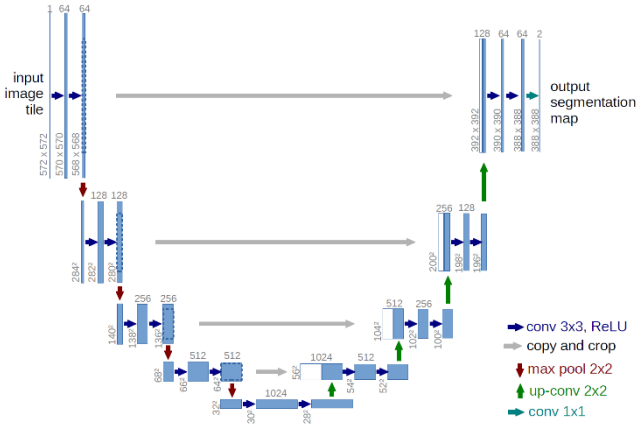


**Şekil 1**. U-Net Mimarisi

U-Net bir daralma yolu (sol taraf) ve bir genişleme yolundan (sağ taraf) oluşur. Adını bu U şeklinden almaktadır. Daralma yolu, normal bir evrişim ağının mimarisi gibi iki tane 3x3 konvolüsyonun tekrarlanarak uygulamasından oluşur. Bu uygulamalardan her biri, düzeltilmiş doğrusal birimden (ReLU) ve alt örnekleme için 2x2 maksimum havuzlama işlemleri içerir. Her alt örnekleme adımında, özellik kanallarının sayısı ikiye katlanır (2^n). Genişleme yolu ise, özellik haritasının bir üst örneklemesinden ve özellik kanallarının sayısını yarıya indiren bir 2x2 evrişimden ("yukarı evrişim") meydana gelir. Ayrıca, daralma yolundan uygun şekilde kırpılmış özellik haritasıyla bir birleşmeden ve iki 3x3 evrişimden oluşur. Her bir evrişimin ardından bir ReLU işlemi uygulanır. Kırpma işlemi, her evrişimde kenar piksellerinin kaybı nedeniyle gereklidir. Son katmanda, her 64 bileşenli özellik vektörünü istenen sayıda sınıfa eşlemek için 1x1'lik bir evrişim kullanılır. Bu sinir ağı toplamda 23 tane katmana sahiptir (Ronneberger vd.).

Veriseti 505 adet $1^0$x $1^0$ hücre yapısında RADAR AMP (Amplitude Mean Mosaic) görüntüleri ve aynı hücrelere ait su alanları maskesi içermektedir.

AMP (Amplitude Mean Mosaic) 0-255 arasında, tek bandlı RADAR sinyalinin dönüş gücünü gösteren görüntüdür. Yüzey tarafından soğrulan sinyaller siyah, soğrulmaya uğramayan ve çift yansıma ile geri dönen sinyaller açık renkte gösterilmektedir.



**Şekil 2**. RADAR Görüntüsü

Su alanlar etiketi ise operatör vasıtası ile toplanmış göl, nehir ve okyanus alanlarının belirli değerlerde olduğu, geri kalan alanların arka plan olan olarak tutulduğu tek bantlı bir veridir. Su alanları tek sınıf haline getirmek amacı ile ikili görüntüye çevrilmiş, su alanları 1, arka planlar 0 olarak belirlenmiştir.

TASLAK

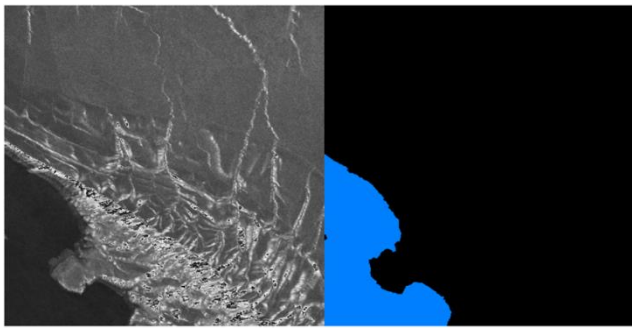

**Şekil 3.** RADAR Görüntüsü ve Su Maskesi

Ağ mimarisi gereği eğitim görüntüleri belli bir parçaya ayrılarak eğitilebilir. Bu sebeple 9001x9001 piksel RADAR AMP görüntüleri ve elle toplanan su etiketleri 128x128x1 piksellik tek bantlı parçalara ayrılmıştır. Toplamda 17.756 parça oluşturulmuş, bu parçalar eğitim (14.204) ve test (3.552) verisi olarak ayrılmıştır. Test verileri modelin performansının ölçülmesi amacı ile eğitimden ayrılmıştır. 3.552 parça eğitim bittikten sonra modelin doğruluğunu hesaplamak amacıyla kullanılmıştır.

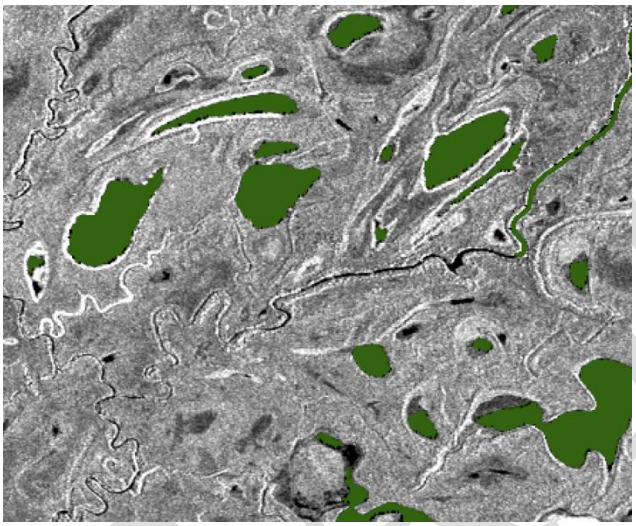

**Şekil 4.** Sonuç Maske

Model Python programlama dilinde Tensorflow kütüphanesi kullanılarak oluşturulmuş, ayrıca görüntü işlemleri için Rasterio kütüphanesi kullanılmıştır. Performansı arttırmak amacıyla işlemler GPU üzerinde yapılmıştır.

Sınıflandırma problemimiz tek sınıflı olduğundan modelin kayıp fonksiyonu (loss function) ikili çapraz entropi kaybı (Binary Crossentropy) olarak belirlenmiştir. 0 hiç kayıp yok, 1 tamamen kayıp olarak değerlendirilir.

Ayrıca modelin performansını ölçmek amacıyla doğruluk, KOH (karesel ortalama hata) ve IoU (Birleşim Üzerindeki Kesişim) metrikleri hesaplanmıştır.

Eğitim için veriseti hazırlandıktan ve model kayıp fonksiyonu belirlendiktein sonra model eğitim adımına geçilmiştir. Başlangıç olarak eğitim 100 adımda planlanmıştır. Eğer 5 adım üst üste kayıp fonksiyonunda iyileşme olmaz ise eğitimin birilmesi ayarlanmıştır.

Eğitim 15 adım sürmüş, 11. Adımda kayıp fonksiyonunda iyileşme olmamasından dolayı eğitim 11. Adımda bitmiştir.

## 3. BULGULAR

Yapılan çalışmanın sonucunda model metrikleri BCE=0.99617, Doğruluk=0.96162, KOH=0.28561, IoU=0.89153 olarak hesaplanmış, çalışmanın amacına uygun sonuçlar elde edilmiştir. Her adımdaki metrikler Çizelge 1 ve 4 arasında gösterilmektedir.

**Çizelge 1.** İkili çapraz entropi kaybı

| Adım | BCE Eğitim | BCE Doğrulama |
|---|---|---|
| 1 | 0,16991 | 0,13772 |
| 2 | 0,14473 | 0,12925 |
| 3 | 0,13034 | 0,12514 |
| 4 | 0,12269 | 0,11533 |
| 5 | 0,11658 | 0,11406 |
| 6 | 0,11129 | 0,12304 |
| 7 | 0,10684 | 0,10897 |
| 8 | 0,10263 | 0,10078 |
| 9 | 0,09874 | 0,11160 |
| 10 | 0,09533 | 0,11072 |
| 11 | 0,09241 | 0,09962 |
| 12 | 0,08898 | 0,10252 |
| 13 | 0,08512 | 0,10338 |
| 14 | 0,08167 | 0,10384 |
| 15 | 0,07782 | 0,10457 |
| 16 | 0,07521 | 0,10996 |

**Çizelge 2.** Doğruluk

| Adım | Doğruluk Eğitim | Doğruluk Doğrulama |
|---|---|---|
| 1 | 0,93695 | 0,95017 |
| 2 | 0,94628 | 0,95206 |
| 3 | 0,95113 | 0,95328 |
| 4 | 0,95346 | 0,95720 |
| 5 | 0,95532 | 0,95812 |
| 6 | 0,95726 | 0,95425 |
| 7 | 0,95866 | 0,95904 |
| 8 | 0,95989 | 0,96123 |
| 9 | 0,96130 | 0,95674 |
| 10 | 0,96267 | 0,95705 |
| 11 | 0,96381 | 0,96162 |
| 12 | 0,96513 | 0,96041 |
| 13 | 0,96684 | 0,96114 |
| 14 | 0,96818 | 0,96007 |
| 15 | 0,96973 | 0,96021 |
| 16 | 0,97083 | 0,95876 |

**Çizelge 3.** Karesel Ortalama Hata

| Adım | Doğruluk Eğitim | Doğruluk Doğrulama |
|---|---|---|
| 1 | 0,04875 | 0,03870 |
| 2 | 0,04136 | 0,03654 |
| 3 | 0,03738 | 0,03554 |
| 4 | 0,03531 | 0,03279 |
| 5 | 0,03365 | 0,03226 |
| 6 | 0,03219 | 0,03495 |
| 7 | 0,03098 | 0,03112 |
| 8 | 0,02982 | 0,02900 |
| 9 | 0,02870 | 0,03243 |
| 10 | 0,02770 | 0,03210 |
| 11 | 0,02684 | 0,02856 |
| 12 | 0,02583 | 0,02942 |
| 13 | 0,02464 | 0,02927 |
| 14 | 0,02363 | 0,02972 |
| 15 | 0,02249 | 0,02975 |
| 16 | 0,02170 | 0,03116 |

TUFUAB

**Çizelge 4.** IoU

| Adım | Doğruluk Eğitim | Doğruluk Doğrulama |
|---|---|---|
| 1 | 0,82993 | 0,86228 |
| 2 | 0,85301 | 0,86947 |
| 3 | 0,86542 | 0,87285 |
| 4 | 0,87138 | 0,88164 |
| 5 | 0,87601 | 0,88313 |
| 6 | 0,88087 | 0,87483 |
| 7 | 0,88438 | 0,88484 |
| 8 | 0,88750 | 0,89014 |
| 9 | 0,89109 | 0,87766 |
| 10 | 0,89464 | 0,87901 |
| 11 | 0,89762 | 0,89159 |
| 12 | 0,90110 | 0,88837 |
| 13 | 0,90565 | 0,89123 |
| 14 | 0,90919 | 0,88794 |
| 15 | 0,91341 | 0,88827 |
| 16 | 0,91640 | 0,88362 |

## 4. TARTIŞMA VE SONUÇ

Yapılan çalışmada sonuç metrikleri incelendiğinde model doğruluğunun yüksek olduğu görülmektedir. Eğitime sokulmamış farklı bölgelerde model ile yapılan tahminlerde operatörün su alanlarını toplamasına çok yakın sonuçlar alınmıştır. Bazı bölgelerde toplanmaması gereken su alanlarını operatörün topladığı ancak modelin toplamadığı görülmüştür.

Hücrenin içeriğine göre 2-5 gün arası değişkenlik gösteren su alanları toplama adımı dakikalara indirilmiş, operatörden kaynaklı standart farklılıkları ortadan kaldırılmış, operatör kaynaklı hataların önüne geçilmiştir. TREx projesinde 50 metre den dar, 6000 $m^2$ 'den küçük sular toplanmamaktadır. Model bu kuralları öğrenmiş, sonuçlar TREx projesi kurallarına uygun çıktı vermiştir.

Model aynı zamanda TREx projesinden bağımsız olarak AMP görüntülerinden su tespitinde kullanılabilir, küresel çaplı su kütle indeksi gibi hesaplamalarda fayda sağlayabilir.

### Yazar Katkı Oranı

Yazarların bildiriye katkısı eşittir.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

### KAYNAKÇA

O.Ronneberger, P.Fischer and T. Brox (2015). U-Net:Convolutional Networks for Biomedical Image Segmentation. doi: 10.48550/arXiv.1505.04597

**URL-1,** TerraSAR-X (2014) [Erişim tarihi: 01.04.2025], https://en.wikipedia.org/wiki/TerraSAR-X

**URL-2,** WorldDEM Technical Document**, (2015)** [Erişim tarihi: 01.04.2025], https://earth.esa.int/eogateway/documents/20142/37627/WorldDEM-Technical-Specification.pdf

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Fotogrametrik Yöntemlerle Deprem Sonrası Hasarlı Yapı Tespiti ve CBS Uygulamaları ile Zemin-Yapı Etkisinin İncelenmesi

**Uğur Gürbüz*[1], Hüseyin Kemaldere[2]**

[1]*Harita Genel Müdürlüğü, Fotogrametri Dairesi, Ankara, Türkiye*
[2]*Zonguldak Bülent Ecevit Üniversitesi, Harita Mühendisliği, Zonguldak, Türkiye*

**Anahtar Kelimeler**
Deprem,
Hasar Tespiti,
Değişim Analizi,
Bina Çıkarımı

**ÖZET**

Deprem esnasında doğrudan yıkılan binaların coğrafi verilerle yüksek doğruluklu olarak tespiti mümkündür. Bu doğruluk deprem tarihine en yakın, deprem öncesi ve deprem sonrası sayısal ortofoto ve sayısal yüzey modellerinin (sym) yeterli çözünürlükte ve doğru algoritmaların kullanımına bağlıdır. 6 Şubat 2023 tarihli ve Kahramanmaraş merkezli Elbistan-Pazarcık depremlerinde yaklaşık 91000 binada hasar meydana gelmiştir. Bu çalışmada deprem esnasında yıkılan binalar fotogrametrik yöntemler ve bölütleme algoritmaları kullanılarak tespit edilmiş ve zemin-yapı ile ilişkili öznitelikler (eğim, bina yüksekliği, zemin sertliği, zemin derinliği) topolojik veri tabanı ve cbs uygulamaları ile elde edilerek geniş bir alanda istatistiki etkisi incelenmiştir. Doğrudan yıkılan her bir binaya ait zemin-yapı parametreleri öznitelik olarak eklenmiştir. Yıkılan binalara ek olarak yıkılmayan binalar da analize dahil edilerek analizdeki istatistik değerlerinin doğruluğunun artırılması amaçlanmıştır. Tüm parametreler incelendiğinde sym verisinden üretilen sayısal arazi modelinden elde edilen eğim haritasında %4 eğim, %40 eğim arasında değişen eğim sınıflarının yıkımlara etkisinin %2.3 ile %5.8 arasında olduğu, bina yüksekliği arttıkça yıkılma oranının arttığı ve 2 katlı binalarda yaşanan %2.7'lik yıkım oranının 6 katlı binalarda %19.2'ye yükseldiği görülmüştür. Zemin derinliğinin daha düşük olduğu değerlendirilen binalarda bu yıkılma oranı %35'e kadar yükselmektedir. İlk 30 metrenin kayma hızını ifade eden vs(30) değerleri kullanılarak bir zemin katmanı üretildiğinde ise yumuşak zeminlerde %5.2 olan yıkım oranının sert zeminlerde %2.7'ye kadar düştüğü görülmüştür.

# Post-Earthquake Damage Detection Using Photogrammetric Methods and Assessment of Soil-Structure Interaction via GIS Applications

**Keywords**
Earthquake,
Damage Assessment,
Change Analysis,
Building Extraction

**ABSTRACT**

It is possible to accurately detect collapsed buildings during an earthquake using geospatial data. This accuracy depends on the temporal proximity to the earthquake and the resolution of pre- and post-event digital orthophotos and digital surface models (DSMs), as well as appropriate algorithms. In the Elbistan–Pazarcık earthquakes of 6 February 2023, centered in Kahramanmaraş, approximately 91,000 buildings were damaged. In this study, collapsed buildings were identified using photogrammetric methods and segmentation algorithms. Ground-structure attributes (slope, building height, soil stiffness, and depth) were extracted via topological databases and GIS applications to analyze their statistical influence over a wide area. Each collapsed building was enriched with these parameters. Non-collapsed buildings were also included to improve statistical reliability. Results show that slope classes ranging from 4% to 40% contributed to collapse rates between 2.3% and 5.8%. Building height was positively correlated with collapse rate, increasing from 2.7% for 2-story buildings to 19.2% for 6-story ones. Buildings with shallower soil depths showed collapse rates up to 35%. Using Vs(30) values, collapse rates were found to be 5.2% on soft soils and 2.7% on stiff soils.

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Gürbüz U & Kemaldere H (2025). Fotogrametrik Yöntemlerle Deprem Sonrası Hasarlı Yapı Tespiti ve CBS Uygulamaları ile Zemin-Yapı Etkisinin İncelenmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Deprem, Türkiye'nin kaçınılmaz gerçeklerinden biridir. İnsanlar, depremin etkilerini en aza indirmek için tedbirler almak ve dayanıklı yaşam alanları oluşturmak zorundadır. 6 Şubat 2023'te Kahramanmaraş merkezli meydana gelen iki büyük deprem (Mw 7.7 ve 7.6), yıkıcı etkileriyle bu gerçeği bir kez daha hatırlatmıştır (URL-1). Harita mühendisliğinin coğrafi verileri kullanabilme ve sonuçları analiz ederek ortaya koyma yeteneği yer bilimcilerin çalışmalarına da ciddi katkılar sağlayabilir. Genel kanının aksine, depremde yalnızca yapı malzemesi kalitesi ve müteahhit sorumluluğu değil, arazinin fiziksel özellikleri de büyük önem taşımaktadır. Bu nedenle harita mühendisliği disiplininin katkılarıyla, depremin arazi parametreleri üzerindeki etkileri araştırılmalıdır.
Adıyaman şehir merkezinde ortofoto ve sym verileri kullanılarak yıkılan binaların tespit edildiği yöntem de sağlıklı sonuçlar ortaya çıkmıştır (Soysal vd. 2023) Arazi eğiminin, zemin sertliğinin, bina yüksekliğinin ve binaların zemin derinliğinin binaların deprem davranışına etkisinin incelenmesi yıkımların nedenlerinin anlaşılması açısından önemlidir. Bu çalışmada öncelikle otomatik bina çıkarımı yöntemleri ile hasarlı yapılar tespit edilecektir. Bu binaların zemin-yapı parametreleri yönetmeliğe (TBDY 2018) uygun bir şekilde üretilerek özniteliklere dönüştürülecektir. Sonrasında tüm parametrelerin Coğrafi Bilgi Sistemleri uygulamaları ile analizi gerçekleştirilecektir. Kahramanmaraş, Adıyaman illeri ve Gaziantep'in Nurdağı ilçesi çalışma alanı olarak belirlenmiştir.

## 2. YÖNTEM

Hasarlı yapı tespiti ve parametre analizi yapılırken öncelikle deprem esnasında yıkılan binaların tespiti gereklidir. Deprem öncesi ve deprem sonrası sayısal ortofotolar ve sayısal yüzey modelleri yeterli görülen çözünürlüğe örneklenerek veri standartı sağlanmıştır. Yıkılan binalar tespit edildikten sonra belirlenen tüm parametreler coğrafi veriler kullanılarak üretilmiş ve öznitelik olarak tüm çalışma sahasına eklenmiştir. Üretilen bu özniteliklerden genel istatistiki bulgular elde edilmiştir. Deprem öncesi ve sonrası sym verilerinin farkları alınarak fark-Sym verisi üretilmiştir. K-means bölütleme algoritması ile sayısal ortofotolar 4 sınıfa ayrılmıştır. Ortofoto da gölgeleri ve ağaçları içerdiği görülen sınıfı içeren piksellerin denk geldiği tüm alanlar fark-Sym üzerinden de silinmiştir. Kalan alanların etrafı en küçük dikdörtgen fonksiyonu kullanılarak çevrilmiştir. Yıkılan binalara ait olduğu değerlendirilen alanlar deprem sonrası ortofotolardan incelenerek yanlış olarak kabul edilen alanlar için bazı kriterler belirlenmiştir. Bu aşamada 100 $m^2$'den küçük ve 3900 $m^2$'den büyük alanlar yıkılan binalar içerisinden silinmiştir. Bitişik nizamlı binaların da iç içe yıkıldığından dolayı bunların bir arada sınırlandırıldığı görülmüştür. Şekil 1'de iç içe yıkılan iki binanın deprem öncesi ortofoto görüntüsü yer almaktadır.



**Şekil 5.** Deprem Öncesi Bitişik Binalar

Bu binaları tek tek ifade edebilmek için "segment anything" algoritması kullanılarak bu binalar birbirinden ayrılmıştır. Tüm düzenleme işlemleri bittikten sonra bina sınırlarının ağırlık merkezleri baz alınarak yıkılan binalara ek olarak yıkılmayan binalarda çalışma alanına dahil edilmiştir. Şekil 2'de mavi alan ile çevrelenen ilk sonuçlar, segment-anything uygulaması sonrası kırmızı ile ifade edilen gerçek sınırlara dönüşmüştür.



**Şekil 6.** İç İçe Yıkılan Binalarda Sınırların Ayrılması

Yıkılan ve yıkılmayan binaların tamamına çalışma alanındaki "sym" verilerinden üretilen sayısal arazi modelinden(Sam) elde edilen eğim değerleri, vs(30) değerlerinden TBDY 2018'e göre üretilen zemin sertliği değerleri, topolojik veri tabanından eşleştirmeyle elde edilen zemin derinliği ve kat adedi verileri , TOPOVT veri tabanındaki yer isimleri ve diğer özellikler eklenerek tüm çalışma alanında ayrı ayrı ve birleştirilmiş etkilerin zemin-yapı parametreleri etkisi incelenmiştir.

## 3. BULGULAR

Deprem esnasında yıkılan binalara ilişkin istatistikler incelendiğinde tüm binaların yaklaşık olarak %4 ünün doğrudan yıkıldığı görülmüştür. Bu binalara topolojik veri tabanından yıkılmayan binalarda eklenerek analizlerin anlamlı sonuçlar ifade etmesi amaçlanmıştır.
Kat adedi, zemin sertliği ve eğim durumlarına göre tüm çalışma sahasındaki binalar değerlendirilmiş ve üç farklı risk grubuna göre gruplandırılmıştır. Parametrelere ait bulgular ayrı ayrı ve birleştirilmiş olarak değerlendirildiğinde anlamlı olabilecek sonuçlar elde edilmiştir. Çizelge 1'de birleştirlmiş etkilere ait bulgular bir arada verilmiştir.

**Çizelge1.** Birleşik Analizlere Bağlı Bulgular

| Parametre Türü | Riskli | Orta Riskli | Güvenilir |
|---|---|---|---|
| **Kat Adedi** | 4, 5, 6 Kat | 4, 7, 8, 9 Kat | 1, 2 ve 3 Kat |
| **Zemin Sınıfı** | Yumuşak | Orta-Sert | Sert |
| **Arazi Eğimi** | %4ve%17 arası | %17 ve %40 arası | - |

## 4. TARTIŞMA

Yüksek çözünürlüklü coğrafi veriler kullanılarak bina çıkarımı yapmak ve değişim analizleri ile afet sonrası hasarı en hızlı şekilde ortaya koymak için bu verileri doğru şekilde, uygun çözünürlükte kullanmak gereklidir.

Deprem esnasında doğrudan yıkılan binalara ait parametreler analiz edilerek, büyük depremlerde riskli binalar önceden tahmin edilebilir. Aynı yöntemle güvenli yerleşim alanları da tahmin edilebilir. Vs(30) değerlerinden üretilen zemin sertliği parametresi imar alanlarının belirlenmesinde de önem bir rol oynayabilir.

Bu çalışmanın temel eksiği binaların yapı yaşı bilgisini içermemesidir. Bina yaşı özniteliği de tüm çalışma alanında sağlandığında çok daha sağlıklı istatistiki veriler elde edilebilir.

Çalışma çok geniş bir alanı kapsadığı için istisnai durumların genel istatistiklere etkisinin çok düşük olduğu düşünülmektedir. Bu nedenle benzer çalışmalarda çalışma alanını ve analize katılan bina sayısını artırmak, bazı binaların özel durumlarından dolayı ortaya (kolon kesilmesi, zemin güçlendirilmesi vb.) istisnai durumların önüne geçecektir.

## 5. SONUÇ

Harita mühendisliğinin coğrafi verileri üretme, kullanma ve yorumlama becerilerini kullanarak deprem sonrasında en hızlı şekilde hasar durumunu ortaya koymasının mümkün olduğu görülmüştür. Coğrafi verilerden türetilen öznitelikleri CBS yeteneklerini de kullanarak toplu ve hızlı analiz etmek, yapılan tüm işleri istatistiki veriler ile ifade etmeye olanak sağlamaktadır. Bu durum harita mühendisliği ile diğer mühendisliklerin bir arada çalışmasının önemini de göstermektedir. Bu çalışmadan çıkarılan sonuçlarla yeni imar alanları önerilebilir ya da mevcut yapıların risk durumu hakkında tahminler yapılabilir. Ayrıca, özellikle on yıldan eski yerleşim yerlerinde zemin derinliği azaldıkça ve bina yüksekliği arttıkça yıkımların 3 kata kadar artabileceği de ortaya konulmuştur. Özniteliğe dönüştürülen vs(30) zemin kayma hızı değerlerine göre yıkımlar incelendiğinde yumuşak ve sert zeminlere inşa edilen binalar arasında yıkım oranının 2 kata kadar arttığı görülmüştür.

**TEŞEKKÜR**

Hasarlı binaların tespiti aşamasındaki desteği için meslektaşım Ahmet Ali SOYSAL'a teşekkür ederim. Depremle ilgili kavramların coğrafi analizlere entegrasyonu aşamasındaki bilimsel desteği için Doç. Dr. Eren PAMUK'a teşekkür ederim.

**Yazar Katkı Oranı**

Yazarların makaleye katkıları eşittir.

**Çıkar Çatışması/Çakışması**

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

## KAYNAKÇA

Ameri B, Fritsch D, (2019) Automatic 3D Building Reconstruction Using Plane-Roof Structures, Stutgart, Germany

Dash J, Steinle E, Singh R.P ve Böhr H.P (2004) Automatic Building Extraction From Laser Scanning Data: An Input Tool For Disaster Management, 317-322, doi: 10.1016/S0273-1177(03)00482-4

Soysal A, Karakullukçu F, Gürbüz U, Kemaldere H, Karabörk H ve Makineci B (2023) Yüksek Çözünürlüklü Ortofotolar ve Sayısal Yüzey Modelleri ile Deprem Sonrası Hasarlı Yapıların Belirlenmesi, *12. TUFUAB Teknik Sempozyumu,* 24-26 Mayıs 2023, Sivas, Türkiye

Tavukçu B, Tapan K.S ve İşcan L (2023) Sayısal Yüzey Modelinden Sayısal Arazi Modeli Üretimi, *12. TUFUAB Teknik Sempozyumu,* 24-26 Mayıs 2023, Sivas, Türkiye

Türkiye Bina ve Deprem Yönetmeliği TBDY (2018), Afet Acil Durum Yönetimi Başkanlığı, Resmi Gazete Tarihi (18 Mart 2018)

URL1<https://deprem.afad.gov.tr/assets/pdf/Kahramanmara%C5%9F%20Depremi%20%20Raporu_02.06.2023.pdf> Ziyaret Tarihi: 18.05.2024.

URL-2<https://www.usgs.gov/programs/earthquake-hazards/magnitude-types>, Ziyaret Tarihi: 18.05.2024.

URL3<https://www.koeri.boun.edu.tr/sismo/bilgi/depremnedir/index.htm#KONU1Eri>,ZiyaretTarihi: 05.05.2024.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Coğrafi Bilgi Sistemleri Tabanlı Çok Kriterli Sel Riski Analizi: E034N41 Hücresi Örneği

**Emre Orbay*[1], Burak Şengül[2], Kadir Sencer Tapan[1]**

[1]*MSB, Harita Genel Müdürlüğü, Fotogrametri Dairesi Başkanlığı, Ankara, Türkiye*

**Anahtar Kelimeler**
Sel riski,
Coğrafi Bilgi Sistemleri,
Sayısal Yükseklik Modeli,
Ağırlıklı Toplam Yöntemi

**ÖZET**

Son yıllarda küresel ısınma, iklim değişikliği ve hızlı kentleşme gibi çevresel faktörler, ani ve şiddetli yağışların artmasına neden olmuş; bu durum hem kırsal hem de kentsel alanlarda sel riskinin önemli ölçüde artmasına yol açmıştır. Bu çalışmanın amacı, Coğrafi Bilgi Sistemleri (CBS) tabanlı mekânsal analiz yöntemleri ile potansiyel sel riski taşıyan alanların belirlenmesidir. Çalışmada, sayısal yükseklik modeli (DEM) kullanılarak yüzey özellikleri analiz edilmiş ve akış yönü, akış birikimi, eğim, akarsulara uzaklık ve akış uzunluğu gibi katmanlar türetilmiştir. Akarsulara yakın ve görece düşük rakıma sahip alanlar, sel açısından daha hassas kabul edilerek ayrı bir analizle değerlendirilmiştir. Tüm bu veriler, risk düzeyine göre beş sınıfa ayrılmıştır. Son aşamada, bu faktörler çok kriterli bir yaklaşımla birleştirilmiş ve çalışma alanı üzerinde "çok düşük risk" ile "çok yüksek risk" arasında değişen risk seviyeleri hesaplanmıştır. Elde edilen sel risk haritası, tehlikeli alanların erken tespiti, planlama süreçlerinde öncelikli bölgelerin belirlenmesi ve afet risklerini azaltmaya yönelik kararların desteklenmesi açısından önemli bilgiler sunmaktadır. Bu yaklaşım, farklı coğrafi bölgelerde de kullanılabilecek esnek ve uygulanabilir bir yöntem sunmaktadır.

# GIS-Based Multi-Criteria Flood Hazard Assessment: A Case Study from the E034N41 Grid Cell

**Keywords**
Flood risk,
Geographic Information Systems,
Digital Elevation Model,
Multi-criteria Analysis

**ABSTRACT**

In recent years, environmental factors such as global warming, climate change, and rapid urbanization have led to an increase in sudden and intense rainfall, which has significantly heightened the risk of flooding in both rural and urban areas. The aim of this study is to identify potential flood-prone areas using spatial analysis methods supported by Geographic Information Systems (GIS). In the study, surface characteristics were analyzed using a Digital Elevation Model (DEM), and various layers such as flow direction, flow accumulation, slope, distance to streams, and flow length were derived. Areas that are close to streams and have low elevation were considered more sensitive to flooding and were evaluated separately. All raster data were classified into five categories based on risk levels. In the final stage, these factors were combined using a multi-criteria approach, and flood risk levels were calculated across the study area, ranging from "very low risk" to "very high risk". The resulting flood risk map provides important information for the early detection of hazardous areas, prioritization in spatial planning processes, and support for decision-making in disaster risk reduction. This approach offers a flexible and applicable method that can be used in various geographic regions with similar hydrological and topographical conditions.

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Orbay E, Şengül B & Tapan K S (2025). Coğrafi Bilgi Sistemleri Tabanlı Çok Kriterli Sel Riski Analizi: E034N41 Hücresi Örneği, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Küresel ısınma ve iklim değişikliğinin etkileri, son yıllarda dünyada olduğu gibi Türkiye'de de hidrolojik felaketlerin artmasına neden olmaktadır. Özellikle ani ve şiddetli yağışların sıklığının ve şiddetinin artması, taşkın ve sel olaylarının hem sayıca çoğalmasına hem de etkilerinin ağırlaşmasına yol açmıştır. Hızlı kentleşme, doğal su yollarının yapılaşma ile tahrip edilmesi ve yüzey geçirgenliğinin azalması da sel riskini artıran diğer önemli faktörler arasında yer almaktadır. Bu bağlamda, afet risklerinin önceden belirlenmesi, riskli bölgelerin haritalanması ve afet öncesi müdahale planlarının hazırlanması büyük önem taşımaktadır. Sel riski analizi, özellikle coğrafi bilgi sistemleri (CBS) destekli sayısal yöntemler sayesinde daha hassas, bölgesel ve detaylı biçimde gerçekleştirilebilmektedir. Sayısal Yükseklik Modeli (DEM), eğim, akış birikimi, akarsu yakınlığı ve akış uzunluğu gibi topografik ve hidrografik parametrelerin analiziyle, farklı risk seviyelerinin coğrafi olarak modellenmesi mümkündür.

Bu çalışmada, Karadeniz Bölgesi'nde yer alan ve son yıllarda ciddi taşkın felaketleriyle gündeme gelen Kastamonu'nun Bozkurt ilçesi ile Sinop'un Ayancık ilçesini kapsayan E034N41 raster veri hücresi örnek bölge olarak seçilmiştir. Bu bölge 2021 yılında yaşanan ve can kayıplarına yol açan sel felaketi nedeniyle analiz açısından kritik öneme sahiptir. Çalışmada, çok kriterli değerlendirme yöntemi kullanılmış; yeniden sınıflama işlemleriyle standartlaştırılan katmanlar, ağırlıklı toplam (Weighted Sum) yöntemi ile birleştirilerek sel risk haritası oluşturulmuştur.

## 2. YÖNTEM

Bu çalışmada, sel riski analizi Coğrafi Bilgi Sistemleri tabanlı mekânsal analiz yöntemleri kullanılarak gerçekleştirilmiştir. Analiz süreci ArcGIS Pro yazılımı kullanılarak yürütülmüş; raster ve vektör temelli veriler, çok kriterli değerlendirme yaklaşımı kapsamında işlenmiştir.

### 2.1. Veri Hazırlık Süreci

Çalışmanın ilk aşamasında, Sayısal Yükseklik Modeli (DEM – Digital Elevation Model) raster verisi kullanılmıştır. Öncelikle yüzeyin eğim özelliklerini belirlemek amacıyla Eğim Analizi (Slope Analysis) gerçekleştirilmiştir. Ardından DEM verisi üzerinde çukurların giderilmesi amacıyla Doldurma İşlemi (Fill) uygulanmıştır.

Bu adımı takiben, suyun yönünü ve birikme noktalarını belirlemek amacıyla sırasıyla Akış Yönü Analizi (Flow Direction) ve Akış Birikimi Analizi (Flow Accumulation) yapılmıştır. Akış birikimi raster verisi eşik değer kullanılarak sınıflandırılmış ve Akarsu Sıralama Analizi (Stream Order) gerçekleştirilmiştir. Daha küçük ve etkisiz akarsuların analiz dışı bırakılması için Koşullu İfade Analizi (Conditional Con) uygulanmıştır. Bu işlem sonucunda elde edilen akarsu ağı raster verisi, Raster Verisinden Vektör Veriye Dönüştürme Aracı (Stream to Feature) ile vektör formata çevrilmiştir.

Ardından, suyun her hücreden geçerken ne kadar yol kat ettiğini hesaplamak amacıyla Akış Uzunluğu Analizi (Flow Length) yapılmıştır. Ayrıca akarsulara olan yatay uzaklık, Akarsuya Doğrusal Uzaklık ile belirlenmiştir. Bu işlemler sonucunda elde edilen tüm raster katmanlar, yeniden sınıflandırma (Reclassify) için hazır hale getirilmiştir.

### 2.2. Risk Sınıflandırması ve Ağırlıklı Değerlendirme

Sel riskini etkileyen raster veri katmanlarının karşılaştırılabilir hale getirilmesi amacıyla yeniden sınıflandırma (Reclassify) işlemi uygulanmıştır. Bu işlemde her bir hücreye "çok düşük risk" ile "çok yüksek risk" arasında risk değerleri atanmıştır. Kullanılan sınıflandırma yöntemi, doğal veri dağılımlarını ayırma konusunda etkili olan Jenks Doğal Kırılım Yöntemi (Jenks Natural Breaks Method) olmuştur.

Yeniden sınıflandırılan katmanlar şunlardır: Eğim (Slope), Sayısal Yükseklik Modeli (DEM – Digital Elevation Model), Akarsuya Doğrusal Uzaklık (Euclidean Distance), Akış Uzunluğu, Akarsu Yakınlığı ve Akarsu Çevresi Riskli Alanlar (Stream Risk Zone). Sonuncusu, akarsulara çok yakın ve düşük rakımlı bölgeleri tespit etmek amacıyla özel olarak oluşturulmuş bir raster katmandır.

Tüm bu katmanlar, çok kriterli karar verme yaklaşımı kapsamında Ağırlıklı Toplam Yöntemi (Weighted Sum Method) ile birleştirilmiştir ve Tablo 1'de sunulmuştur. Her bir katmana sel riskine katkı düzeyine göre bir ağırlık atanmıştır. Hesaplama sürecinde her hücrenin toplam risk puanı aşağıdaki denklemle hesaplanmıştır:

$$R = \sum_{i=1}^{n} w_i \cdot x_i$$

Burada **R**, toplam sel riski puanını; $\boldsymbol{w_i}$, her katmanın ağırlığını; $\boldsymbol{x_i}$ ise o katmanın yeniden sınıflandırılmış risk değerini ifade etmektedir.

| Katman | Ağırlık (%) |
|---|---|
| Akarsu Çevresi Riskli Alanlar | 35 |
| Eğim | 30 |
| Sayısal Yükseklik Modeli | 20 |
| Akarsuya Doğrusal Uzaklık | 10 |
| Akış Uzunluğu | 5 |

Tablo 1. Kullanılan raster katmanlar ve ağırlık değerleri

## 3. BULGULAR

Sel riski analizinden elde edilen sonuçlar, çalışma alanındaki her raster hücresine çok düşük ile çok yüksek arasında bir risk değeri atanarak değerlendirilmiştir. Bu analiz ile farklı coğrafi ve topografik faktörlerin birleşiminden oluşan mekânsal risk dağılımı modellenmiştir.

Elde edilen sel riski haritasında, risk seviyesi; çok düşük risk, düşük risk, orta risk, yüksek risk ve çok yüksek risk olarak isimlendirilerek beş ayrı sınıfa ayrılmıştır.

Bu sınıflandırma, eğim, yükseklik, akarsulara uzaklık, akış uzunluğu gibi faktörlerin yanı sıra, akarsu yakınlığı ve düşük kotlu alanlardan oluşan özel risk alanlarının da ağırlıklı olarak değerlendirilmesiyle oluşturulmuştur.

TASLAK

Özellikle akarsuya çok yakın ve alçak rakımlı bölgelerde "Çok Yüksek Risk" sınıfı yoğun olarak gözlemlenmiştir.

Risk alanlarının mekânsal dağılımı, Şekil 1'de sunulan sel riski haritasında renk skalasıyla gösterilmiştir. Bu harita, öncelikli müdahale bölgelerinin belirlenmesi, arazi planlama çalışmaları ve afet yönetiminde karar destek aracı olarak kullanılabilecek niteliktedir.

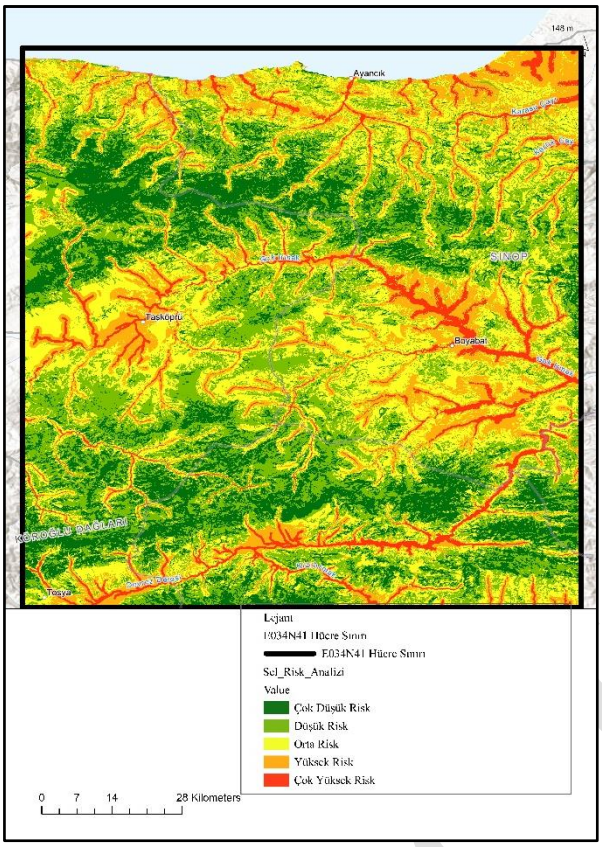


Şekil 1. Ağırlıklı analiz sonucu elde edilen beş kademeli sel riski haritası.

## 4. TARTIŞMA

Bu çalışmada, ağırlıklı çok kriterli analiz yöntemi kullanılarak oluşturulan sel riski haritası, bölgedeki topografik ve hidrolojik faktörlerin bütüncül bir şekilde değerlendirilmesine olanak sağlamıştır. Kullanılan raster katmanlar arasında özellikle akarsulara yakınlık ve alçak kotlu alanlar, sel riski haritasında en belirleyici etkiye sahip olmuş ve çok yüksek risk taşıyan bölgelerle büyük ölçüde örtüşmüştür. Bu durum, geçmiş yıllarda Bozkurt ve Ayancık'ta yaşanan sel felaketlerinde suyun hızla birikerek yerleşim alanlarını etkilemesiyle ortaya çıkan gerçek durumu doğrulamaktadır.

Akarsuya doğrusal uzaklık ve sayısal yükseklik modeli (DEM) gibi katmanlar, riskin bölgeye nasıl dağıldığını belirlemede etkili olmuş; eğim ve akış uzunluğu gibi faktörler ise daha çok ikinci derecede rol oynamıştır. Bu sonuç, özellikle alçak kotlu ve akarsu çevresindeki alanların potansiyel risk taşıdığı bilgisini desteklemektedir. Aynı zamanda, kullanılan Ağırlıklı Toplam Yöntemi (Weighted Sum Method), katmanlar arasında esnek ağırlık dağılımı yapılabilmesine olanak sağladığı için yöntemin uygulanabilirliğini artırmıştır.

Ancak yöntemin bazı sınırlılıkları da bulunmaktadır. Özellikle sadece topografik veriye dayalı bir analiz yapılmış olması, arazi kullanımı, geçirgenlik, bitki örtüsü gibi hidrografik olmayan faktörlerin dışarıda kalmasına neden olmuştur. Bu durum, modelin doğruluğunu yer yer sınırlandırabilir. Ayrıca kullanılan raster verilerin çözünürlüğü ve hassasiyeti, sonuçların detayı üzerinde doğrudan etkilidir.

## 5. SONUÇ

Bu çalışmada, son yıllarda şiddetli sel felaketlerinin yaşandığı Kastamonu'nun Bozkurt ilçesi ve Sinop'un Ayancık ilçesini kapsayan E034N41 raster hücresi örnek alan olarak seçilmiş ve bu bölgede beş kademeli bir sel riski analizi gerçekleştirilmiştir. Çalışma, Coğrafi Bilgi Sistemleri altyapısı ile raster analiz yöntemleri kullanılarak yürütülmüş, sel riskini etkileyen farklı faktörler çok kriterli değerlendirme yaklaşımıyla bir araya getirilmiştir.

Sayısal Yükseklik Modeli (DEM), Eğim, Akarsuya Doğrusal Uzaklık, Akış Uzunluğu gibi fiziksel verilerin yanı sıra, bu çalışmaya özgü oluşturulan Akarsu Yakınlığı ve Akarsu Çevresi Riskli Alanlar katmanı da analiz sürecine dahil edilmiştir. Bu katman, geçmiş afet deneyimlerine dayanarak modelin gerçekçiliğini artırmış ve ağırlıklı analiz sonucunda en yüksek etkiye sahip faktör olarak öne çıkmıştır.

Analiz sonucunda, beş sınıfa ayrılmış sel riski haritası üretilmiştir. Çok yüksek riskli bölgelerin çoğunlukla akarsulara çok yakın ve alçak rakımlı alanlarda yoğunlaştığı görülmüş, bu durum 2021 yılında yaşanan gerçek sel olaylarıyla da örtüşmüştür ve Şekil 2'de bu durum Bozkurt İlçesi özelinde gösterilmiştir. Bu bulgular, modelin afet öncesi planlama ve risk yönetimi açısından kullanılabilirliğini ortaya koymaktadır.

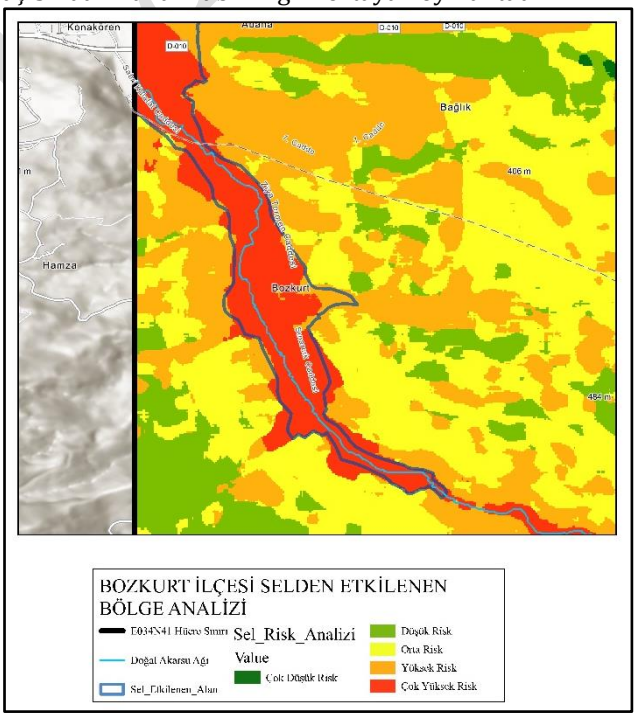


Şekil 2. Ağırlıklı analiz sonucu elde edilen beş kademeli sel riski haritasının Bozkurt İlçesinde 2021 yılında yaşanan selden etkilenen bölge ile yapılan görsel karşılaştırma.

Yapılan analizde, sadece "çok yüksek riskli" olarak sınıflandırılan alanlar dikkate alınmış ve bu alanların gerçek sel alanlarıyla ne kadar örtüştüğü incelenmiştir. Bu amaçla "intersect" işlemi ile hem modelin tahmin ettiği çok yüksek riskli alanlar hem de gerçek sel verileri birleştirilmiş ve ortak alanlar belirlenmiştir.

Elde edilen sonuçlara göre:

Gerçek sel alanı: 1.431.846,13 $m^2$

Doğru tahmin edilen (kesişen) alan: 1.303.886,53 $m^2$

Bu verilere dayanarak modelin Sensitivity (hassasiyet) değeri:

$$Sensitivity = \frac{TP}{TP + FN} = \frac{1.303.886,53}{1.431.846,13} \approx 0,911(\%91,1)$$

Burada TP= True Positive (Doğru Pozitif), FN= False Negative (Gerçek olup tahmin edilemeyen alan)

Bu sonuç, modelin gerçek sel olaylarının yaklaşık %91,1'sini başarıyla öngördüğünü göstermektedir. Bu oran, özellikle yalnızca "çok yüksek risk" sınıfı baz alındığında ortaya çıkmıştır. Bu işlem, raster veriye uygulanan Çoğunluk İstatistiği (Focal Statistics (Majority)) yöntemiyle gerçekleştirilmiştir. Özellikle bu çalışmada kullanılan 11x11 boyutundaki komşuluk penceresi, çevresindeki piksellerin çoğunluk değerine göre yeniden sınıflandırma yaparak seyrek ve uyumsuz pikselleri baskılamış ve haritada daha düzgün, homojen alanlar elde edilmesini sağlamıştır.

Çalışma kapsamında kullanılan Ağırlıklı Toplam Yöntemi (Weighted Sum Method), raster veriler üzerinde esnek bir ağırlıklandırma imkânı sunmuş ve analiz sonuçlarının görsel olarak yorumlanmasını kolaylaştırmıştır.

Bu çalışma, temel mekânsal sel riski bölgelerinin belirlenmesi açısından önemli bir örnek sunmakta ve daha ileri analizler için bir zemin oluşturmaktadır. Gelecekteki çalışmalarda, hidrometeorolojik verilerin, arazi örtüsü ve yapay zekâ destekli sınıflandırma yöntemlerinin modele entegre edilmesiyle çok daha kapsamlı ve yüksek doğrulukta sel riski analizleri yapılabileceği düşünülmektedir.

**TEŞEKKÜR**

Bu çalışma sürecinde bilgi birikimi, yönlendirmeleri ve teknik desteği ile katkı sağlayan komutanlarıma teşekkür ederim. Ayrıca, analizlerde kullanılan veri setlerinin temininde ve yazılım konusunda destek veren Harita Genel Müdürlüğü'ne minnettarlığımı sunarım.

**Yazar Katkı Oranı**

Çalışmaya yazarlar eşit oranda katkı sağlamıştır.

**Çıkar Çatışması/Çakışması**

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

**Araştırma ve Yayın Etiği Beyanı**

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

**KAYNAKÇA**

Günseli, İ. G. (2020). Determination of flood risk areas and mitigation strategies: A case study of the Menemen plain, İzmir *(Yüksek Lisans Tezi). İzmir Institute of Technology, Graduate School of Engineering and Sciences.*

Oğuz, K., Oğuz, E., & Coşkun, M. (2016). *Coğrafi Bilgi Sistemleri ile taşkın risk alanlarının belirlenmesi: Artvin ili örneği*. 4. Ulusal Taşkın Sempozyumu Bildirileri, 21–24 Kasım 2016, Rize.

Tek, D. (2019). *CBS ve uzaktan algılama yöntemleriyle Kâğıthane Deresi'nin (İstanbul) taşkın risk analizi* (Yüksek Lisans Tezi). İstanbul Üniversitesi, Fen Bilimleri Enstitüsü.Güncelleme Sistemi Tasarımı ve Uygulaması. TUFUAB VIII. Teknik Sempozyumu, Konya, Türkiye.

T.C. Meteoroloji Genel Müdürlüğü. (2021). 2021 yılı meteorolojik afetler değerlendirmesi. T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı. *https://www.mgm.gov.tr/files/genel/raporlar/afetler raporu2021.pdf*

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Baraj İnşaatının Yer Yüzey Sıcaklığı Üzerindeki Etkilerinin Termal Uydu Görüntüleri ile Değerlendirilmesi

**Talha TAŞKANAT*[1], Tolga Kaynak[2]**

[1]*Erciyes Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Kayseri, Türkiye*
[2]*Niğde Ömer Halisdemir Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Niğde, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Yusufeli Barajı,
Yer Yüzey Sıcaklığı (YYS),
Landsat 8

**ÖZET**

Uzaktan algılama (UA) ve görüntü işleme teknikleri, yüzey sıcaklığı değişimlerinin izlenmesinde önemli bir rol oynamaktadır. Bu çalışmada, Yusufeli Barajı'nın inşası sonrası bölgedeki termal değişimin analizi amaçlanmıştır. Landsat 8 Level-1 uydu görüntüleri kullanılarak, barajın inşaatına başlanmadan önce (Ağustos 2013), inşaat sırasında (Ağustos 2019) ve sonra (Ağustos 2024) olmak üzere üç farklı döneme ait Yer Yüzey Sıcaklığı (YYS) haritaları üretilmiştir. Yapılan analizler sonucunda, baraj gövdesi ve çevresinde belirgin bir sıcaklık düşüşü gözlemlenmiştir. Özellikle su yüzeyine karşılık gelen alanlarda YYS değerleri 18 °C'ye kadar düşerken, kırsal yerleşim çevrelerinde 46 °C'ye kadar çıkmıştır. Baraj öncesi döneme kıyasla, baraj sonrası dönemde bölgede ortalama yüzey sıcaklığında ortalama 6 °C civarında bir artış tespit edilmiştir. Bu durumun, barajın oluşturduğu su kütlesinin mikroklimatik etkileri ve yerel yüzey özelliklerinde meydana gelen değişimlerle ilişkili olduğu düşünülmektedir. Çalışmada elde edilen sonuçlar, büyük ölçekli baraj projelerinin yerel termal ortam üzerindeki etkilerini ortaya koymakta ve bu tür analizlerin çevresel etki değerlendirmelerinde dikkate alınması gerektiğini göstermektedir.

# Evaluation of Dam Construction Effects on Ground Surface Temperature Using Thermal Satellite Images

**Keywords**
Remote Sensing,
Yusufeli Dam,
Land Surface Temperature (LST),
Landsat 8

**ABSTRACT**

Remote sensing (RS) and image processing techniques play a significant role in monitoring surface temperature changes. In this study, the aim is to analyze the thermal changes in the region following the construction of the Yusufeli Dam. Using Landsat 8 Level-1 satellite imagery, Land Surface Temperature (LST) maps were generated for three different periods: before the construction (August 2013), during the construction (August 2019), and after the construction (August 2024). The analysis revealed a significant decrease in temperature in the dam body and its surrounding areas. In particular, LST values dropped to as low as 18 °C in areas corresponding to water surfaces, while in rural settlements, temperatures rose up to 46 °C. Compared to the pre-dam period, an average increase of approximately 6 °C in surface temperature was detected in the post-dam period. This change is believed to be related to the microclimatic effects of the water mass created by the dam and the alterations in local surface characteristics. The results of the study highlight the impact of large-scale dam projects on the local thermal environment and indicate that such analyses should be considered in environmental impact assessments.

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Taşkanat T & Kaynak T (2025). Baraj İnşaatının Yer Yüzey Sıcaklığı Üzerindeki Etkilerinin Termal Uydu Görüntüleri ile Değerlendirilmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

TUFUAB

## 1. GİRİŞ

UA teknikleri, büyük çaplı arazi dönüşümlerinin ve insan etkili çevresel değişimlerin izlenmesinde yaygın olarak kullanılan, zamansal ve mekansal analiz imkânı sunan güçlü bir teknolojidir (Chander et al., 2009; Weng, 2009). YYS, atmosferik etkilerden ayrıştırılmış termal enerji dengesini temsil etmekte olup, mikroklimatik koşulların ve arazi kullanım/örtüsü (LULC) değişimlerinin belirlenmesinde kritik bir parametredir (Sobrino vd., 2004). Baraj inşaatları, çevredeki nem dengesini, bitki örtüsü kompozisyonunu ve bölge mikroklimasını etkileyerek YYS üzerinde anlamlı farklılıklar oluşturabilmektedir (Zhou vd., 2016).

Bu bağlamda, bu çalışmanın amacı, Artvin ili sınırları içerisinde yer alan ve 2022 yılında tamamlanan Yusufeli Barajı'nın çevresel termal yapı üzerindeki etkisini, Landsat 8 uydu görüntüleri aracılığıyla YYS farklılıklarını ortaya koymaktır.

## 2. MATERYAL VE YÖNTEM

Çalışma alanı olarak Yusufeli Barajı ve çevresi seçilmiştir (Şekil 1). Yusufeli Barajı, Türkiye'nin Artvin ilinde, Çoruh Nehri üzerinde inşa edilmiş olan büyük bir hidroelektrik barajıdır. Baraj inşaatının temeli 2013 yılında atılmış 2022 yılının son aylarında inşaat çalışmaları tamamlanmıştır. Baraj şu anda; çift eğrilikli ince beton kemer kategorisinde dünyanın en yüksek beşinci konumundadır. Baraj gövdesi nedeniyle Yusufeli ilçe merkezi de dahil olmak üzere birçok yerleşim yeri sular altında kalmış, bölge halkı yeni yerleşim alanlarına taşınmıştır. Bu yönüyle proje hem mühendislik başarısı hem de sosyal ve çevresel etkileri açısından dikkat çekmektedir.

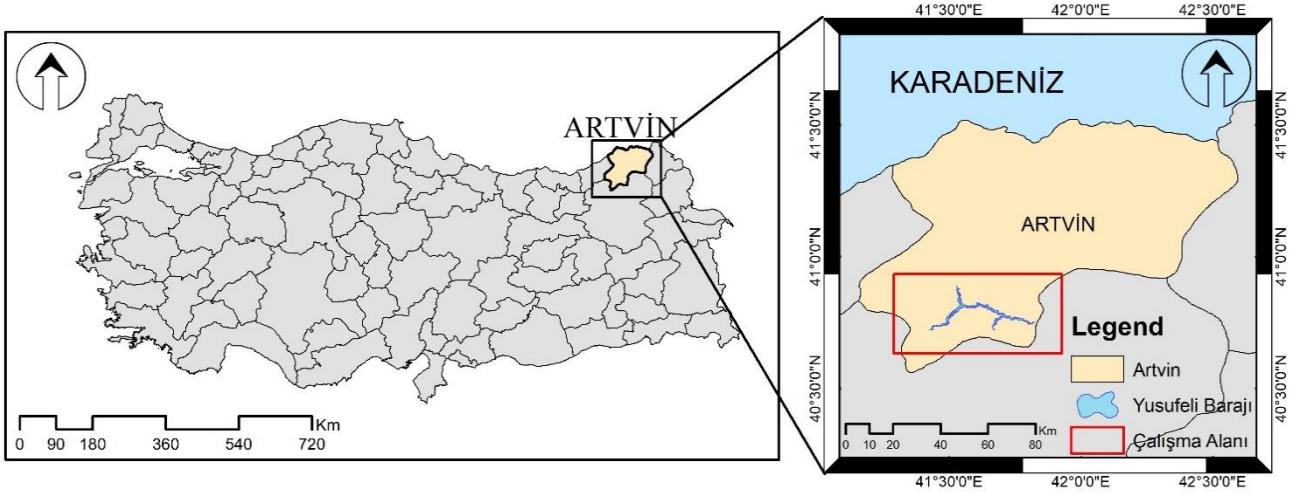


**Şekil 7.** Çalışma alanı yerbulduru haritası

YYS haritalarının üretiminde literatürde Landsat uydu görüntülerinin Level-1 veya Level-2 veri setleri kullanılmaktadır. Level-1 verileri temel görselleştirme ve genel analizler için uygun olmakla birlikte yüksek doğrulukta YYS ya da bitki örtüsü hesaplamaları gibi yüzey düzeyinde çalışmalar için kullanılmadan önce ek atmosferik düzeltmeler ve yayınırlık tahmini gerektirir. Level-2 ise atmosferik olarak düzeltilmiş yüzey yansıma ve yüzey sıcaklığı içeren bilimsel kullanıma hazır veri setleridir. Bu veri setleri, arazi örtüsü sınıflandırması ve çevresel izleme gibi bilimsel uygulamalar için doğrudan kullanıma uygundur. Ancak, kullanılmadan önce düşük bulutluluk gibi belirli kalite koşullarına dikkat edilmelidir. Fakat Level-2 bantlarından YYS üretiminde kullanılan termal bant, bu tür haritaların üretiminde oldukça yüksek sonuçlar verebilmektedir (Thammaboribal vd., 2025).

Bu nedenle çalışma kapsamında YYS haritalarının üretiminde Level-1 veri setlerindeki termal bant (Band 10) kullanılmıştır. YYS oluşturulurken öncelikle spektral radyans ($L_\lambda$) değerleri hesaplanmakta, daha sonra bu değerler yardımıyla parlaklık sıcaklığı (BT) elde edilmektedir. (Chander vd., 2009).

Ayrıca YYS hesabında Band 5 (yakın kızılötesi) ve Band 4 (kırmızı) kullanılarak NDVI değerleri hesaplanmakta; ardından bitki örtüsü yoğunluğuna göre $P_v$ değeri elde edilmekte ve bu değerler aracılığıyla piksel bazlı emissivite (ε) görüntüleri oluşturulmaktadır (Sobrino vd., 2004). YYS, Eşitlik 1'de verilen denklem ile hesaplanmaktadır.

$$YYS = BT/[1 + (\lambda \times BT/\rho) \times \ln(\varepsilon)] \qquad (1)$$

Burada $\lambda = 10.895$ µm (Band 10 merkez dalga boyu), $\rho = \frac{h \times c}{\sigma} = 1438 \times 10^{-2}$ mK olarak sabit kabul edilmektedir.

Bu çalışma kapsamında, Landsat 8 uydu platformuna ait, bulutluluğu %5'in altında olan ve çalışma alanını kapsayan 07.08.2013, 23.08.2019 ve 21.08.2024 tarihli Level-1 görüntüleri kullanılmıştır. Tüm raster analizleri ve bant işlemleri ArcGIS yazılımında Raster Calculator modülü yardımıyla yürütülmüştür.

## 3. BULGULAR

Çalışma kapsamında yapılan analizler sonucunda, 2024 yılı verilerine göre oluşturulan YYS haritasında (Şekil 1a), sıcaklık değerlerinin 18.34 °C ile 46.04 °C arasında dağıldığı görülmektedir. Barajın tamamlanmasının ardından, özellikle su ile dolmuş

baraj gövdesi ve çevresindeki alanlarda YYS'nin 30 °C'nin altına düştüğü gözlenmiştir. 2019 yılına ait YYS haritasında (Şekil 1b), sıcaklık değerleri 9.66 °C ile 40.41 °C arasında ölçülmüştür. Baraj inşaat sürecinin devam ettiği bu dönemde, çalışma alanı genelinde sıcaklıkların 2013 yılına göre daha düşük seviyelerde gerçekleştiği tespit edilmiştir. 2013 yılına ait sıcaklık değerlerinin 14.94 °C ile 43.05 °C arasında değiştiği belirlenmiştir (Şekil 1c). Bu dönemde Yusufeli Barajı henüz inşa edilmemiş olup, baraj alanında yer alan doğal akarsu yatağı ve bitki örtüsünün etkisiyle özellikle vadi tabanlarında görece daha düşük sıcaklıklar hesaplanmıştır.

YYS haritalarının zamansal farkını gösteren dYYS haritaları (Şekil 3a-c), 2024 ve 2013 yılları arasındaki yüzey sıcaklığı değişimlerini yansıtmaktadır. Yusufeli Barajı'nın bulunduğu bölgede ve özellikle su kütlesi ile kaplanmış alanlarda, YYS değerlerinde –14.25 °C'ye varan negatif farklılıklar tespit edilmiştir. Bu durum, baraj gölünün ısı emici ve düzenleyici özelliklerinden kaynaklanan mikroklimatik bir soğuma etkisiyle açıklanabilir.

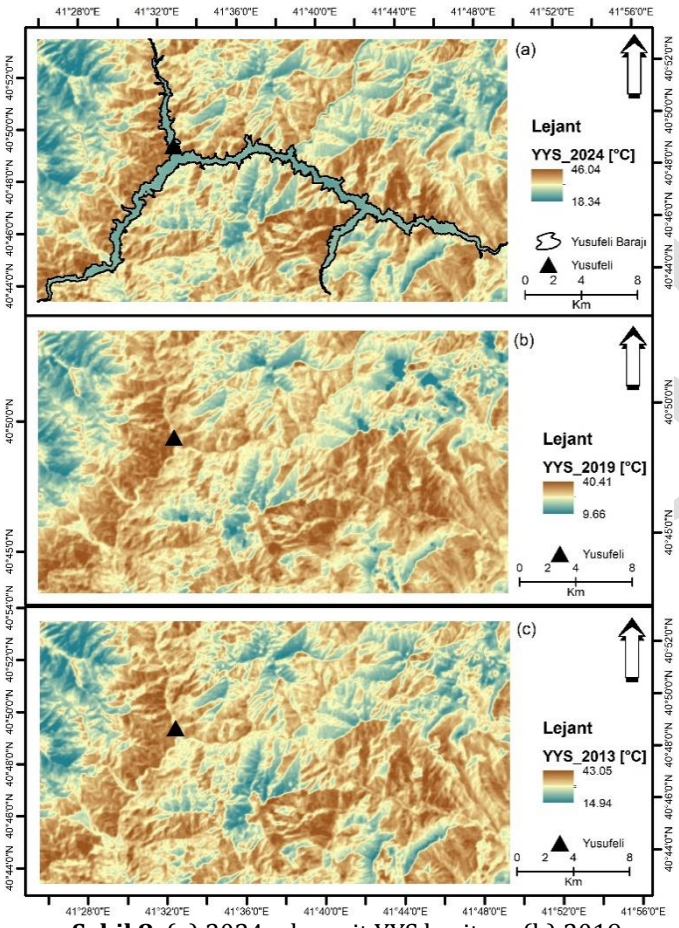


**Şekil 8.** (a) 2024 yılına ait YYS haritası, (b) 2019 yılına ait YYS haritası ve (c) 2013 yılına ait YYS haritası

Çalışmada elde edilen 2024 yılına ait YYS haritalarının doğruluğunu değerlendirmek amacıyla, Türkiye Cumhuriyeti Meteoroloji Genel Müdürlüğü (MGM) tarafından yayımlanan 2024 yılı Ağustos ayına ait minimum, maksimum ve ortalama hava sıcaklığı haritaları ile karşılaştırmalı bir analiz gerçekleştirilmiştir. Bu veriler kendi aralarında karşılaştırıldığında yüksek düzeyde benzerlik göstermiştir. Bu durum, çalışmada oluşturulan YYS'lerin meteorolojik gözlemlerle uyumlu olduğunu ve bölgesel ölçekte güvenilir analizler sunduğunu göstermektedir (MGM, 2024).

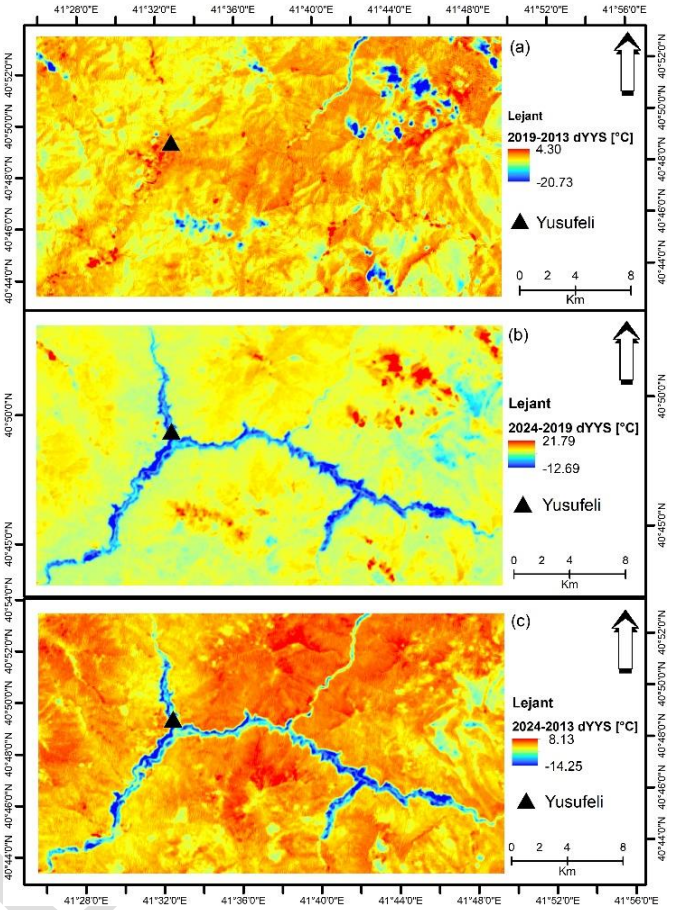


**Şekil 3.** (a) 2019-2013 yılına ait YYS'ye yönelik zamansal fark (dYYS) haritası, (b) 2024-2019 yılına ait YYS'ye yönelik zamansal fark (dYYS) haritası ve (c) 2024-2013 yılına ait YYS'ye yönelik zamansal fark (dYYS) haritası

## 4. TARTIŞMA

Elde edilen bulgular, su kütlelerinin yüzey sıcaklığını düzenleyici etkisini desteklemektedir. Literatüre paralel olarak, baraj gibi büyük su yapılarının çevresindeki termal ortamı yumuşatarak genliği azaltıcı etki oluşturduğu bildirilmektedir (Zhou et al., 2016). Bu çalışmada da benzer bir durum gözlemlenmiş, baraj alanının yüzey sıcaklığını anlamlı ölçüde düşürdüğü belirlenmiştir. Öte yandan, su dışı yapay yüzeylerde, özellikle yerleşim ve yol alanlarında sıcaklık artışının devam ettiği dikkat çekmektedir. Bu durum, yüzey örtüsünde meydana gelen değişimlerin YYS üzerindeki etkisinin alan özelinde farklılaşabileceğini göstermektedir.

## 5. SONUÇ

Bu çalışma, Yusufeli Barajı'nın YYS üzerindeki etkisini Landsat 8 Level-1 veri seti ile analiz edilmiş ve baraj inşaatının çevresel termal yapıya etkilerini ortaya koymuştur. Bulgular, baraj su kütlesinin mikroklimatik bir soğutucu etkisi olduğuna işaret etmektedir. Uzaktan algılama temelli YYS analizlerinin, çevresel etki değerlendirme (ÇED) süreçlerinde karar vericilere

bilimsel katkı sağlayabileceği ortaya konmuştur. Gelecekteki çalışmalarda yıllık veya mevsimsel zamansal serilerin analiz edilmesi, baraj etkisinin daha ayrıntılı ortaya çıkmasını sağlayacaktır.

**Yazar Katkı Oranı**

Çalışmaya yazarlar eşit oranda katkıda bulunmuşlardır.

**Çıkar Çatışması/Çakışması**

Çalışmada herhangi bir kurum, kuruluş, kişi ile mali çıkar çatışması yoktur ve yazarlar arasında çıkar çatışması bulunmamaktadır.

**Araştırma ve Yayın etiği beyanı**

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

**KAYNAKÇA**


Chander, G., Markham, B. L., & Helder, D. L. (2009). Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. Remote Sensing of Environment, 113(5), 893–903. https://doi.org/10.1016/j.rse.2009.01.007

MGM, (2024). Meteoroloji Genel Müdürlüğü, Ağustos 2024 Sıcaklık Yağış Değerlendirmesi, Ankara. [Erişim Tarihi: 13.05.2025], https://www.mgm.gov.tr/veridegerlendirme/sicaklik-analizi.aspx?ay=agustos

Sobrino, J. A., Jiménez-Muñoz, J. C., & Paolini, L. (2004). Land surface temperature retrieval from LANDSAT TM 5. Remote Sensing of Environment, 90(4), 434–440. https://doi.org/10.1016/j.rse.2004.02.003

Thammaboribal, P., Triapthti, N., & Lipiloet, S. (2025). Comparative Analysis of Land Surface Temperature (LST) Retrieved from Landsat Level 1 and Level 2 Data: A Case Study in Pathumthani Province, Thailand. *International Journal of Geoinformatics*, *21*(4), 160–177. https://doi.org/10.52939/ijg.v21i4.4089

Weng, Q. (2009). Thermal infrared remote sensing for urban climate and environmental studies: Methods, applications, and trends. ISPRS Journal of Photogrammetry and Remote Sensing, 64(4), 335–344. https://doi.org/10.1016/j.isprsjprs.2009.03.007

Zhou, D., Zhang, L., Li, D., Huang, D., & Zhu, C. (2016). Climate–vegetation control on the diurnal and seasonal variations of surface urban heat islands in China. Environmental Research Letters, 11(5), 054009. https://doi.org/10.1088/1748-9326/11/5/054009



© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.


TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Multispektral İHA Verileri ile Bitki İndeksi Çıkarımı İçin Kalibrasyon Panellerinin Gerekliliği

**Alperen Erdoğan*[1], Ömer Mutluoğlu[2]**

[1]*Yozgat Bozok Üniversitesi, Şefaatli Meslek Yüksekokulu, Mimarlık ve Şehir Planlama, Yozgat, Türkiye*
[2]*Konya Teknik Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Mimarlık ve Şehir Planlama, Konya, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Kalibrasyon Panel,
Bitki İndeks,
İHA

**ÖZET**

Günümüzde İnsansız Hava Araçları'na (İHA) multispektral algılayıcıların entegre edilmesi, uzaktan algılama teknolojilerinde önemli bir atılım sağlamış; modelleme, haritalama ve özellikle tarımsal uygulamaların izlenmesi gibi birçok alanda yeni olanakların ortaya çıkmasına imkân tanımıştır. Ancak, multispektral görüntülerin etkin bir biçimde kullanılabilmesi için atmosferik koşullar ve güneş ışınımındaki değişimlerin etkisi göz önünde bulundurularak, dijital sayıların (DN) doğru yansıma değerlerine dönüştürülmesi gerekmektedir. Bu dönüşüm süreci, standart bir uygulama olan kalibrasyon hedeflerinin kullanımı ile gerçekleştirilmektedir. Kalibrasyonu yapılmış görüntüler üzerinden çeşitli bitki indeksleri üretilmekte ve bu indeksler aracılığıyla bitki sağlığı, azot ve klorofil içeriği, yeşil yaprak biyokütlesi ve verim gibi önemli tarımsal parametreler hakkında bilgi elde edilebilmektedir. Bununla birlikte, algılayıcı teknolojilerindeki hızlı gelişim ve yeni nesil sensörlerin eklenmesi, kalibrasyon paneli kullanımının zorunluluğu konusunda literatürde bazı belirsizliklere yol açmıştır. Bu çalışmada, DJİ Mavic 3M multispektral kameraya sahip İHA ile elde edilen görüntüler kullanılarak üretilen bitki indeksleri ve bant değerleri üzerinden, kalibrasyon paneli kullanımının doğruluk ve veri kalitesi üzerindeki etkileri değerlendirilmiştir.

# The Necessity of Calibration Panels for Plant Index Extraction with Multispectral UAV Data

**Keywords**
Remote Sensing,
Calibration Panel,
Plant Index,
UAV

**ABSTRACT**

Today, the integration of multispectral sensors into unmanned aerial vehicles (UAVs) has made significant strides in remote sensing technologies, enabling new possibilities in various fields, such as modeling, mapping, and especially monitoring agricultural applications. However, in order to effectively use multispectral images, it is necessary to convert digital numbers (DN) into accurate reflectance values, taking into account the effects of atmospheric conditions and variations in solar radiation. This conversion process is carried out using calibration targets, which is a standard practice. Various plant indices are produced from calibrated images, and through these indices, information can be obtained about important agricultural parameters such as plant health, nitrogen and chlorophyll content, green leaf biomass, and yield. However, the rapid development of sensing technologies and the addition of next-generation sensors have led to some uncertainties in the literature regarding the necessity of using calibration panels. In this study, we looked at how using a calibration panel affected the accuracy and quality of data by analyzing the plant indices and band values from images taken by a drone with a DJİ Mavic 3M multispectral camera.

## 1. GİRİŞ

Geleneksel uydu tabanlı uzaktan algılama sistemleri, geniş alanların izlenmesine olanak tanısa da düşük mekânsal ve zamansal çözünürlükleri sınırlılıklar nedeniyle özellikle küçük ölçekli tarımsal alanlarda hassas tarım uygulamaları açısından yetersiz kalmaktadır (Laliberte vd, 2011). Son yıllarda, gelişmiş sensörlere sahip ve görece düşük maliyetli İHA'lar, uzaktan algılama alanında bir alternatif olarak ön plana çıkmaktadır. Özellikle multispektral kameralarla donatılmış İHA platformları, düşük operasyonel maliyetleri, ulaşılabilirlikleri, yüksek spektral ve mekânsal çözünürlük sunma kapasiteleri sayesinde dikkat çekmektedir. İHA tabanlı uzaktan algılama, uydu sistemlerini tamamlayıcı nitelikte olup, kısa sürede geniş alanlardan veri toplayabilmekte ve topografyaya ilişkin analizlerde yüksek doğruluklu çıktılar sağlayarak

* **Sorumlu Yazar**
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**
Erdoğan A & Mutluoğlu Ö. Multispektral İHA Verileri ile Bitki İndeksi Çıkarımı İçin Kalibrasyon Panellerinin Gerekliliği, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

mevcut boşlukları önemli ölçüde doldurmaktadır (Jhan ve Huang, 2016; Barjaktarovic ve Bruzzone, 2024).

Genellikle İHA platformlarından elde edilen zamansal veri analizleri; sensör özellikleri, aydınlatma koşulları, geometrik hizalama hataları ve atmosferik değişkenlik gibi çeşitli faktörlerden etkilenmektedir. Bu durum, dijital sayı değerlerinin (Digital Numbers – DN), yüzey yansımasını doğru biçimde temsil etmesini engeller (Hamylton ve Beaman, 2015). Radyometrik kalibrasyon, örneğin, azot ve klorofil içeriklerinin belirlenmesi ya da yeşil yaprak biyokütlesinin tahmin edilmesi gibi analizlerde, yansıtma oranı veya Normalize Edilmiş Fark Bitki İndeksi (NDVI) gibi bitki indekslerinin hesaplanmasında yüksek doğruluk sağlamaktadır (Zhou, 2022).

Bu çalışmada DJI Mavic 3M İHA multispektral görüntüleri kullanılarak, bitki indekslerinin hesabında kalibrasyon panellerinin kullanımının sonuca etkisi irdelenmiş ve gerekliliği araştırılmıştır.

## 2. YÖNTEM

Pix4dField yazılımına ait DJI Mavic 3M multispektral veri seti kullanılmıştır. Kullanılan kamera Yeşil (560 nm ±16nm), Kırmızı (650 nm ±16nm), Kırmızı Kenar (730 nm ±16nm) ve Yakın Kızılötesi (860 nm ±26nm) bantlarda görüntü vermektedir (DJİ, 2025).

### 2.1. Veri Setine Ait Bilgiler

Görüntüler Almanya'nın doğusunda Strausberg'te bir parsele aittir. 05/04/2024 tarihinde ve çoğunlukla bulutlu bir havada çekilmiştir. Çalışma alanı ve hava durumuna ait bilgiler Şekil 1'deki gibidir.

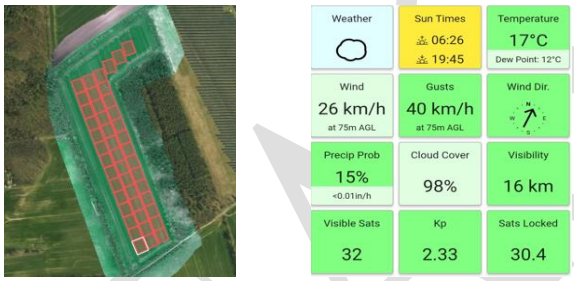


(a) (b)

**Şekil 1.** (a) Çalışma alanı, (b) Hava şartları ekran görüntüleri

Görüntü alımı gerçekleştirilen parsel yaklaşık 1000'er $m^2$ olacak şekilde 45 alana ayrılmıştır, oluşturulan bu parsellerin SAVI (Toprak Uyarlanmış Bitki Örtüsü İndeksi), CI-RE (Klorofil İndeks Kırmızı Kenar), GNDVI (Yeşil Normalleştirilmiş Fark Bitki Örtüsü İndeksi), LCI (Yaprak Klorofil İndeksi), MCARI (Ayarlanmış Klorofil Absorpsiyon Yansıma İndeksi), NDVI bitki indeks ve bant değerlerine ait bilgiler bulgular bölümünde Çizelge 1 ve Çizelge 2'de verilmiştir. Çizelge 1 de verilen bitki indekslerine ait değerler Micasense (Şekil 2) kalibrasyon paneli kullanılarak üretilmiştir.



**Şekil 2.** Micasense kalibrasyon paneli

## 3. BULGULAR

**Çizelge 1.** Kalibrasyon paneli kullanılarak üretilen indeksler

| | SAVI | CI-RE | GNDVI | LCI | MCARI | NDVI |
|---|---|---|---|---|---|---|
| **1** | 1.287 | 1.278 | 0.681 | 0.519 | 1.033 | 0.858 |
| **2** | 1.287 | 1.303 | 0.684 | 0.524 | 1.016 | 0.858 |
| **3** | 1.29 | 1.311 | 0.686 | 0.526 | 1.046 | 0.86 |
| **4** | 1.287 | 1.301 | 0.686 | 0.524 | 1.025 | 0.858 |
| **5** | 1.279 | 1.262 | 0.679 | 0.515 | 1.011 | 0.853 |
| **6** | 1.287 | 1.299 | 0.685 | 0.523 | 1.029 | 0.858 |
| **7** | 1.296 | 1.317 | 0.688 | 0.528 | 1.048 | 0.864 |
| **8** | 1.283 | 1.269 | 0.679 | 0.517 | 1.006 | 0.855 |
| **9** | 1.276 | 1.247 | 0.673 | 0.512 | 0.994 | 0.85 |
| **10** | 1.283 | 1.252 | 0.679 | 0.514 | 1.013 | 0.855 |
| **11** | 1.286 | 1.271 | 0.685 | 0.518 | 1.023 | 0.858 |
| **12** | 1.277 | 1.249 | 0.677 | 0.512 | 0.983 | 0.851 |
| **13** | 1.287 | 1.267 | 0.683 | 0.518 | 1.014 | 0.858 |
| **14** | 1.277 | 1.237 | 0.675 | 0.51 | 0.99 | 0.851 |
| **15** | 1.259 | 1.184 | 0.659 | 0.496 | 1.003 | 0.839 |
| **16** | 1.25 | 1.185 | 0.655 | 0.495 | 0.981 | 0.834 |
| **17** | 1.225 | 1.135 | 0.641 | 0.481 | 0.945 | 0.817 |
| **18** | 1.232 | 1.137 | 0.646 | 0.483 | 0.954 | 0.822 |
| **19** | 1.225 | 1.1 | 0.641 | 0.474 | 0.942 | 0.817 |
| **20** | 1.238 | 1.125 | 0.647 | 0.481 | 0.964 | 0.825 |
| **21** | 1.233 | 1.08 | 0.64 | 0.471 | 0.957 | 0.822 |
| **22** | 1.225 | 1.059 | 0.635 | 0.465 | 0.947 | 0.817 |
| **23** | 1.223 | 1.054 | 0.634 | 0.464 | 0.937 | 0.815 |
| **24** | 1.24 | 1.084 | 0.646 | 0.473 | 0.958 | 0.827 |
| **25** | 1.24 | 1.097 | 0.649 | 0.476 | 0.957 | 0.827 |
| **26** | 1.241 | 1.112 | 0.65 | 0.479 | 0.949 | 0.827 |
| **27** | 1.24 | 1.091 | 0.648 | 0.475 | 0.951 | 0.826 |
| **28** | 1.231 | 1.064 | 0.64 | 0.468 | 0.937 | 0.82 |
| **29** | 1.208 | 1.063 | 0.623 | 0.461 | 0.923 | 0.805 |
| **30** | 1.261 | 1.175 | 0.653 | 0.495 | 1.016 | 0.841 |
| **31** | 1.234 | 1.13 | 0.64 | 0.481 | 0.951 | 0.822 |
| **32** | 1.21 | 1.064 | 0.625 | 0.464 | 0.911 | 0.806 |
| **33** | 1.227 | 1.093 | 0.635 | 0.473 | 0.939 | 0.818 |
| **34** | 1.215 | 1.06 | 0.629 | 0.464 | 0.921 | 0.81 |
| **35** | 1.21 | 1.024 | 0.621 | 0.455 | 0.907 | 0.807 |
| **36** | 1.206 | 1.017 | 0.618 | 0.453 | 0.895 | 0.804 |
| **37** | 1.212 | 1.024 | 0.623 | 0.456 | 0.894 | 0.808 |
| **38** | 1.199 | 1.01 | 0.619 | 0.45 | 0.875 | 0.799 |
| **39** | 1.198 | 1.01 | 0.618 | 0.45 | 0.872 | 0.798 |
| **40** | 1.191 | 1.003 | 0.615 | 0.447 | 0.867 | 0.794 |
| **41** | 1.179 | 0.996 | 0.61 | 0.443 | 0.861 | 0.786 |
| **42** | 1.229 | 1.087 | 0.639 | 0.471 | 0.922 | 0.819 |
| **43** | 1.293 | 1.284 | 0.689 | 0.521 | 1.035 | 0.862 |
| **44** | 1.316 | 1.386 | 0.703 | 0.544 | 1.127 | 0.877 |
| **45** | 1.308 | 1.296 | 0.699 | 0.527 | 1.072 | 0.872 |

Kalibrasyon paneli kullanılmadan üretilen bitki indeks değerlerinde Pix4DField yazılımı ile sadece hava şartlarına ait ayarlar girilmiştir. Bu ayalar ile iletilen bitki indeks değerlerine ait Çizelge 2'de verilmiştir.

| | SAVI | CI-RE | GNDVI | LCI | MCARI | NDVI |
|---|---|---|---|---|---|---|
| **1** | 1.287 | 1.278 | 0.681 | 0.519 | 1.033 | 0.858 |
| **2** | 1.287 | 1.303 | 0.684 | 0.524 | 1.016 | 0.858 |
| **3** | 1.29 | 1.311 | 0.686 | 0.526 | 1.046 | 0.86 |
| **4** | 1.287 | 1.301 | 0.686 | 0.524 | 1.025 | 0.858 |
| **5** | 1.279 | 1.262 | 0.679 | 0.515 | 1.011 | 0.853 |
| **6** | 1.287 | 1.299 | 0.685 | 0.523 | 1.029 | 0.858 |
| **7** | 1.296 | 1.317 | 0.688 | 0.528 | 1.048 | 0.864 |
| **8** | 1.283 | 1.269 | 0.679 | 0.517 | 1.006 | 0.855 |
| **9** | 1.276 | 1.247 | 0.673 | 0.512 | 0.994 | 0.85 |
| **10** | 1.283 | 1.252 | 0.679 | 0.514 | 1.013 | 0.855 |
| **11** | 1.286 | 1.271 | 0.685 | 0.518 | 1.023 | 0.858 |
| **12** | 1.277 | 1.249 | 0.677 | 0.512 | 0.983 | 0.851 |
| **13** | 1.287 | 1.267 | 0.683 | 0.518 | 1.014 | 0.858 |
| **14** | 1.277 | 1.237 | 0.675 | 0.51 | 0.99 | 0.851 |
| **15** | 1.259 | 1.184 | 0.659 | 0.496 | 1.003 | 0.839 |
| **16** | 1.25 | 1.185 | 0.655 | 0.495 | 0.981 | 0.834 |
| **17** | 1.225 | 1.135 | 0.641 | 0.481 | 0.945 | 0.817 |
| **18** | 1.232 | 1.137 | 0.646 | 0.483 | 0.954 | 0.822 |
| **19** | 1.225 | 1.1 | 0.641 | 0.474 | 0.942 | 0.817 |
| **20** | 1.238 | 1.125 | 0.647 | 0.481 | 0.964 | 0.825 |
| **21** | 1.233 | 1.08 | 0.64 | 0.471 | 0.957 | 0.822 |
| **22** | 1.225 | 1.059 | 0.635 | 0.465 | 0.947 | 0.817 |
| **23** | 1.223 | 1.054 | 0.634 | 0.464 | 0.937 | 0.815 |
| **24** | 1.24 | 1.084 | 0.646 | 0.473 | 0.958 | 0.827 |
| **25** | 1.24 | 1.097 | 0.649 | 0.476 | 0.957 | 0.827 |
| **26** | 1.241 | 1.112 | 0.65 | 0.479 | 0.949 | 0.827 |
| **27** | 1.24 | 1.091 | 0.648 | 0.475 | 0.951 | 0.826 |
| **28** | 1.231 | 1.064 | 0.64 | 0.468 | 0.937 | 0.82 |
| **29** | 1.208 | 1.063 | 0.623 | 0.461 | 0.923 | 0.805 |
| **30** | 1.261 | 1.175 | 0.653 | 0.495 | 1.016 | 0.841 |
| **31** | 1.234 | 1.13 | 0.64 | 0.481 | 0.951 | 0.822 |
| **32** | 1.21 | 1.064 | 0.625 | 0.464 | 0.911 | 0.806 |
| **33** | 1.227 | 1.093 | 0.635 | 0.473 | 0.939 | 0.818 |
| **34** | 1.215 | 1.06 | 0.629 | 0.464 | 0.921 | 0.81 |
| **35** | 1.21 | 1.024 | 0.621 | 0.455 | 0.907 | 0.807 |
| **36** | 1.206 | 1.017 | 0.618 | 0.453 | 0.895 | 0.804 |
| **37** | 1.212 | 1.024 | 0.623 | 0.456 | 0.894 | 0.808 |
| **38** | 1.199 | 1.01 | 0.619 | 0.45 | 0.875 | 0.799 |
| **39** | 1.198 | 1.01 | 0.618 | 0.45 | 0.872 | 0.798 |
| **40** | 1.191 | 1.003 | 0.615 | 0.447 | 0.867 | 0.794 |
| **41** | 1.179 | 0.996 | 0.61 | 0.443 | 0.861 | 0.786 |
| **42** | 1.229 | 1.087 | 0.639 | 0.471 | 0.922 | 0.819 |
| **43** | 1.293 | 1.284 | 0.689 | 0.521 | 1.035 | 0.862 |
| **44** | 1.316 | 1.386 | 0.703 | 0.544 | 1.127 | 0.877 |
| **45** | 1.308 | 1.296 | 0.699 | 0.527 | 1.072 | 0.872 |

**Çizelge 2.** Kalibrasyon paneli kullanılmadan üretilen indeksler

Her iki yöntemle bulunan indeks değerleri normal dağılım testi sonucunda Kurtosis ve Skewness değerleri 1.5 ile +1.5 olduğu zaman normal dağılım olduğu kabul edilmektedir (Tabachnick and Fidell, 2013).

## 4. SONUÇ

Her iki yöntemle bulunan indeks değerleri normal dağılım testi sonucunda Kurtosis ve Skewness değerleri -1.5 ile +1.5 olduğu zaman normal dağılım olduğu kabul edilmektedir (Tabachnick and Fidell, 2013).

Kalibrasyon paneli kullanılan ve kullanılmayan bitki indekslerinin karesel ortalama hatalarına bakıldığında SAVI 0,0013, CI-RE 0,016, GNDVI 0,068, LCI 0,002,MCARI 0,001 olduğu hesaplanmıştır. Zaman serisi gerektirmeye tek ölçümle hesaplanan bitki indeks değerlerine göre bantlardaki yansıma değerlerini gerçeği yansıtmadığı ancak bant değerleri kullanılarak hesaplanan indeks değerlerinin kalibrasyon edilen görüntüler kullanılarak hesaplanan indeks değerlerine oldukça yakın sonuç gösterdiği görülmektedir.

## Yazar Katkı Oranı

Her iki yazar makaleye eşit katkı sunmuştur.

## Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

## KAYNAKLAR


Barjaktarovic, M., Santoni, M., & Bruzzone, L. (2024). Design and verification of a low-cost multispectral camera for precision agriculture application. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, doi: 10.1109/jstars.2024.3377104

DJİ, (2025), DJİ Agriculture, Dji Mavic 3M, [Erişim tarihi: 25.04.2025], https://ag.dji.com/mavic-3-m

Laliberte, A. S., Goforth, M. A., Steele, C. M., & Rango, A. (2011). Multispectral remote sensing from unmanned aircraft: Image processing workflows and applications for rangeland environments. Remote Sensing, 3(11). doi: 10.3390/rs3112529

Jhan, J. P., Rau, J. Y., & Huang, C. Y. (2016). Band-to-band registration and ortho-rectification of multilens/multispectral imagery: A case study of MiniMCA-12 acquired by a fixed-wing UAS. ISPRS Journal of Photogrammetry and Remote Sensing. doi: 10.1016/j.isprsjprs.2016.01.008

Hamylton, S. M., Hedley, J. D., & Beaman, R. J. (2015). Derivation of high-resolution bathymetry from multispectral satellite imagery: A comparison of empirical and optimisation methods through geographical error analysis. Remote Sensing, doi: 10.3390/rs71215829

He, Y., Bo, Y., Chai, L., Liu, X., & Li, A. (2016). Linking in situ LAI and fine resolution remote sensing data to map reference LAI over cropland and grassland using geostatistical regression method. International journal of applied earth observation and geoinformation, doi: 10.1016/j.jag.2016.02.010

Zhou, X., Liu, C., Xue, Y., Akbar, A., Jia, S., Zhou, Y., & Zeng, D. (2022). Radiometric calibration of a large-array commodity CMOS multispectral camera for UAV-borne remote sensing. International Journal of Applied Earth Observation and Geoinformation, doi: 10.1016/j.jag.2022.102968


© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# 1/25000 Ölçekli Haritaların Revizyon İhtiyacının Uzaktan Algılama ve Derin Öğrenme Yöntemleri ile Belirlenmesi

**Orhan Fırat[1], Nuri Erkin Öçer*[2], Dilek Küçük Matcı[2], Sayed Ishaq Deliry[2], Abdullah Saygılı[1], Altan Yılmaz[1], Uğur Avdan[2]**

*[1]Milli Savunma Bakanlığı, Harita Genel Müdürlüğü, Ankara, Türkiye*
*[2]Eskişehir Teknik Üniversitesi, Yer ve Uzay Bilimleri Enstitüsü, Eskişehir, Türkiye*

**Anahtar Kelimeler**
Bilgisayarlı Görü,
Harita Revizyonu,
Derin Öğrenme,
Uzaktan Algılama

**ÖZET**

1/25000 ölçekli haritalar; şehir planlama, ulaşım, tarım, çevre ve afet yönetimi gibi alanlarda kritik bir rol oynar. Ancak, bu haritaların oluşturulması ve güncellenmesi, özellikle artan nüfus ve şehirleşme nedeniyle zaman alıcı ve maliyetlidir. Yeryüzünde meydana gelen değişikliklerin sıklığı ve boyutlarının artması, her değişikliğin harita revizyonu gerektirmemesiyle birleştiğinde, bu süreci daha karmaşık hale getirir. Uzaktan algılama ve derin öğrenme teknolojilerindeki son gelişmeler, harita revizyonuna önemli katkılar sunma potansiyeli taşımaktadır. Bu çalışmada, hava ve uydu görüntüleriyle Konvolüsyonel Sinir Ağları kullanılarak 1/25000 ölçekli haritaların revizyon ihtiyacı otomatik ve bölgesel olarak belirlenmeye çalışılmıştır. Bu amaçla, revizyon ihtiyacını tespit edebilen derin öğrenme tabanlı bir model tasarlanmış; ortogörüntülerin ön işlemesi, etiketlenmesi, veri seti hazırlanması, modelin eğitimi ve test edilmesi süreçleri yürütülmüştür. Model, farklı özellik çıkarım ağlarıyla test edilmiş ve 640x640 piksellik gridlere ayrılmış bir test ortogörüntüsü üzerinde değerlendirilmiştir. Toplam 1936 grid için yapılan analizde, model ResNet101V2 ağı ile en yüksek F1 skorunu (0,7726) elde etmiştir. Önerilen yöntem, geniş alanlarda hızlı ve maliyet etkin bir çözüm sunarken, özellikle büyük ve belirgin değişikliklerin tespitinde başarılı sonuçlar vermiştir. Bununla birlikte, modelin bazı durumlarda sınırlılıkları olduğu gözlenmiştir. Bu sınırlılıklar ve bulgular, bildirinin nihai halinde detaylı olarak ele alınacaktır.

# Determining the Revision Needs of 1/25000 Scale Maps Using Remote Sensing and Deep Learning Methods

**Keywords**
Computer Vision,
Deep Learning,
Map Revision,
Remote sensing

**ABSTRACT**

1/25000 scale maps play a critical role in urban planning, transportation, agriculture, environmental management, and disaster response. However, creating and updating these maps is time-consuming and costly, particularly due to increasing population and urbanization. The growing frequency and magnitude of changes on the Earth's surface, combined with the fact that not every change necessitates a map revision, further complicates this process. Recent advancements in remote sensing and deep learning technologies offer significant potential to enhance map revision processes. This study aims to automatically and regionally determine the revision needs of 1/25000 scale maps using aerial and satellite imagery with Convolutional Neural Networks. To this end, a deep learning-based model was designed to detect revision requirements. The processes included preprocessing of orthophotos, labeling, dataset preparation, model training, and testing. The model was evaluated using different feature extraction networks on a test orthophoto divided into 640x640 pixel grids. Across 1936 grids, the model achieved the highest F1 score of 0.7726 with the ResNet101V2 network. The proposed method provides a fast and cost-effective solution for large areas, yielding successful results, particularly in detecting significant and prominent changes. However, certain limitations of the model were observed. These limitations and findings will be addressed in detail in the final version of the paper.

* **Sorumlu Yazar**
*(neocer@eskisehir.edu.tr) ORCID ID 0000-0001-7404-7686

**Kaynak Göster (APA):**
Fırat O, Öçer N E, Küçük Matçı D, Deliry S I, Saygılı A, Yılmaz A & Avdan U (2025). 1/25000 Ölçekli Haritaların Revizyon İhtiyacının Uzaktan Algılama ve Derin Öğrenme Yöntemleri ile Belirlenmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

1/25000 ölçekli haritalar, ülkemize dair topoğrafik detayları oldukça ayrıntılı bir şekilde sunan temel haritalardır. Bu haritalar hem arazi üzerindeki birçok detayı gösteren kapsamlı bilgi hem de bölge hakkında genel bir bakış sunmaktadır. Ayrıca, daha küçük ölçekli haritaların oluşturulmasında da önemli bir kaynak teşkil etmekte; 1/50.000 ve 1/100.000 ölçekli topoğrafik haritalar 1/25.000 ölçekli haritalardan genelleştirme yöntemiyle üretilmektedir. Türkiye Topoğrafik Vektör Veritabanı (TOPOVT) verileri de, bu haritaların dijital ve analiz edilebilir formatta, vektör tabanlı bir temsilini sunmaktadır. Bu haritalar Harita Genel Müdürlüğü (HGM) tarafından üretilmekte ve güncellemeleri de aynı kurum tarafından yapılmaktadır.

Üretimi büyük maliyetler gerektiren bu haritaların güncellenmesi de ayrı bir maliyet ve uzun, zahmetli bir süreç istemektedir. Arazinin doğal koşulları nadiren ve yavaş değişse de, topoğrafik detaylar (yollar, binalar, su kaynakları gibi coğrafi nesneler) sürekli bir değişim içindedir. Haritaların tamlığını ve güncelliğini korumak amacıyla periyodik olarak gerçekleştirilen revizyon çalışmaları, coğrafi bilginin güncelliğini sağlamada vazgeçilmez bir süreçtir. Bu süreç, yeni oluşan detayların eklenmesi, yok olanların silinmesi ve mevcut detayların güncellenmesi gibi işlemleri içerir. İstisnai durumlar dışında, harita revizyonlarında genellikle sadece topoğrafik detaylar göz önünde bulundurulmakta; münhani ve kot revizyonları değişimin yüksek olduğu yerlerde (örneğin baraj inşaası) yapılmaktadır.

Günümüzde hızlı şehirleşme, artan altyapı projeleri ve doğal afetler, harita revizyon çalışmalarının önemini giderek artırmaktadır. Güncel olmayan haritalar, yanlış kararlara ve kaynak israfına yol açabilir. Bu nedenle, farklı alanlarda yaygın olarak kullanılan 1/25.000 ölçekli haritalar için hızlı ve sürdürülebilir bir güncelleme prosedürüne sahip olmak büyük önem taşımaktadır.

## 2. YÖNTEM

Bu çalışma kapsamında, ön işlemeleri ve etiketlemeleri yapılarak hazır hale getirilen 1/25000 ölçekli haritalar için revizyon ihtiyacını belirlemek üzere, bu verileri uygun şekilde işleme kabiliyetinde olan özgün bir derin öğrenme modeli geliştirilmiştir. Bu model, hazırlanan verilerin kullanılmasıyla eğitilmiş ve doğrulanmış, ardından test kümesi üzerinde denenmiştir.

### 2.1. Revizyon İhtiyacı Tespit Modeli

Çalışma kapsamında, iki farklı tarihte alınan görüntü çiftleri arasındaki değişimin harita revizyonu için anlamlı olup olmadığını değerlendirmeye yönelik bir model tasarlanmıştır. Bu model, yalnızca iki görüntü arasındaki değişikliği tespit etmekle kalmayıp, aynı zamanda bu değişikliğin harita revizyonunu gerektiren türde bir değişiklik olup olmadığını da öğrenmektedir. Modelin revizyon gerektiren değişiklikleri ayırt edebilmesi, kullanılan etiketleme kriterleri ve model mimarisi vasıtasıyla sağlanmaktadır. Böylece, model görüntüler arasındaki herhangi bir değişimi değil, yalnızca "harita açısından anlamlı" değişiklikleri algılayacak şekilde eğitilmektedir.

Model, revizyon ihtiyacı tespitini özet olarak şu adımlar vasıtasıyla gerçekleştirmektedir: giriş katmanları, özellik çıkarımı, özelliklerin küresel havuzlaması, özelliklerin farkının alınması, özelliklerin birleştirilmesi, tam bağlantılı katmanlar ve çıktı.

### 2.2. Modelin Eğitimi

Modelde ikili çapraz entropi (binary crossentropy) kayıp fonksiyonu kullanılarak, doğru tahminler yapıldıkça düşük kayıp, yanlış tahminlerde ise yüksek kayıp üretilmesi sağlanmıştır. İkili çapraz entropi, sınıflar arasındaki farklılıkları değerlendiren ve modelin tahminlerini gerçek sınıf etiketlerine göre optimize eden bir fonksiyondur. Modelin her bir örnek için yaptığı tahmin ile gerçek sınıf etiketi arasındaki olasılıksal farkı ölçerek kayıp değeri üretmekte; böylece doğru sınıfa yakın tahminlerde düşük, yanlış sınıfa yakın tahminlerde ise yüksek kayıp değeri elde edilmektedir. Matematiksel olarak, bu kayıp her bir örnek için şu şekilde hesaplanmaktadır.

$$L = \frac{-1}{N}\sum_{i=1}^{N}\left(y_i \cdot log(p_i) + (1 - y_i) \cdot log(1 - p_i)\right) \quad (1)$$

Bu formülde; $y_i$, i. örneğin gerçek sınıf etiketini temsil etmektedir (0 veya 1), $p_i$, modelin i. örnek için tahmin ettiği olasılık değeri, N ise toplam örnek sayısını ifade etmektedir.

Çalışma kapsamında geliştirilen model Tensorflow ve Keras derin öğrenme çerçevelerinde çalıştırılmıştır. Modelde, özellik çıkarıcı olarak 'imagenet' görüntüleriyle ön eğitim almış ResNet101V2, EfficientNetV2S, DenseNet201, ConvNeXtBase, InceptionV3, NasNetMobile, MobileNet ve InceptionResNetV2 ağları kullanılmıştır. Deneyler, Ubuntu 22.04 işletim sisteminde AMD Ryzen 5 3600 işlemcili, 64 GB RAM'e sahip, Nvidia GeForce GTX 1080 Ti ekran kartlı bir bilgisayar kullanılarak Anaconda platformu üzerinde gerçekleştirilmiştir. Model; özellik çıkarım ağının, veri setinin, kayıp fonksiyonundaki sınıf ağırlıklarının, öğrenme takviminin değiştirilmesi gibi herhangi bir parametre değişikliğinden sonra tekrar eğitilmiştir. Eğitim; validasyon kümesi için öğrenme durduğunda, model eğitim kümesi için ezbere kaçmaya başladığında durdurulmuştur.

## 3. BULGULAR

Test kümesindeki veriler için çalıştırılan model en yüksek doğruluğu InceptionResNetV2, kesinliği DenseNet201, duyarlılığı EfficientNetV2S ve F1 skorunu ResNet101V2 özellik çıkarı ağlar ile çalıştırıldığında sağlamıştır. Test seti için elde edilen doğruluk metrikleri Tablo 1'de verilmiştir.

| Özellik Çıkarım Ağı | Doğruluk | FPR | Kesinlik | Duyarlılık | F1 Skoru |
|---|---|---|---|---|---|
| ResNet - Veri_v1 | 0,8295 | 0,0746 | 0,8494 | 0,6756 | 0,7526 |
| ResNet101V2 | 0,8352 | 0,0989 | 0,8212 | 0,7295 | **0,7726** |
| EfficientNetV2S | 0,8264 | 0,1366 | 0,7776 | **0,7672** | 0,7724 |
| DenseNet201 | 0,8115 | **0,0394** | **0,9004** | 0,5720 | 0,6996 |
| InceptionV3 | 0,8285 | 0,0570 | 0,8757 | 0,6447 | 0,7426 |
| NasNetMobile | 0,8223 | 0,1048 | 0,8074 | 0,7052 | 0,7529 |
| MobileNet | 0,8218 | 0,0939 | 0,8199 | 0,6864 | 0,7473 |
| InceptionResNetV2 | **0,8378** | 0,0754 | 0,8522 | 0,6985 | 0,7678 |

**Tablo 1.** Farklı özellik çıkarıcı ağlarla çalıştırılan modelin test kümesinde yer alan görüntüler için ürettiği sonuçlara dair doğruluk metrikleri

Çalışmada model, farklı özellik çıkarım ağları kullanılarak test ortogörüntüsüne uygulanmış ve 640 x 640 piksellik gridlere ayrılmış ortogörüntü parçaları için revizyon ihtiyaç tahminleri çıkarılmıştır (Şekil 1). Revizyon ihtiyacı için yer gerçeği sol üst hücrede verilmiştir. Burada kırmızıyla işaretlenmiş gridler, harita revizyonuna ihtiyaç duyulan parçalardır. Diğer hücrelerdeki çıktılar ise modellerin test ortogörüntüsü için revizyon ihtiyacına ihtiyaç olan parçalara yönelik yaptıkları tahminlerdir. Buna göre, her modelin belirli oranlarda gözden kaçırmış olduğu, aslında revizyon ihtiyacı olan görüntü parçaları bulunmasına rağmen, modellerin haritada revizyon ihtiyacı olan alanları büyük oranda tespit ettiği görülmektedir.

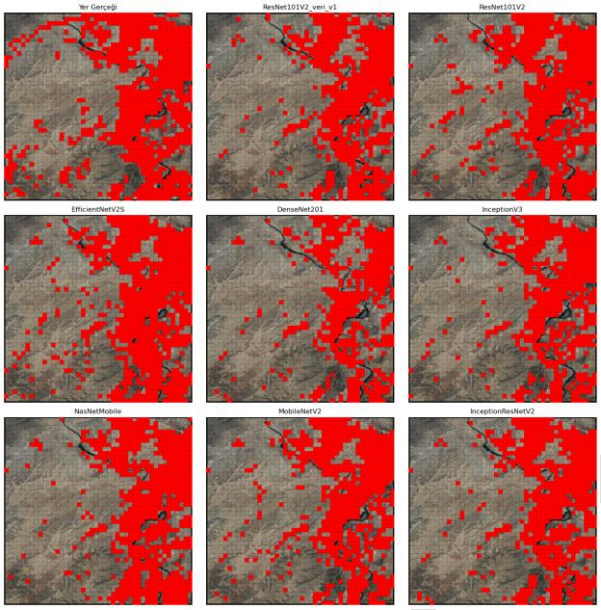


**Şekil 1.** Ortogörüntüde harita revizyon ihtiyacı olan parçalar kırmızıyla işaretlenmiştir. Sol üstteki görüntü yer gerçeğini, diğerleri ise model çıktılarını göstermektedir.

## 3. TARTIŞMA

Bu çalışmada, 1/25000 ölçekli haritaların revizyon ihtiyacını belirlemek amacıyla uzaktan algılama ve derin öğrenme yöntemleri kullanılmıştır. Harita güncellemelerinin zaman alıcı ve maliyetli süreçler olması nedeniyle, uydu görüntüleri ve derin öğrenme modellerini kullanarak bu ihtiyacı daha hızlı ve doğru bir şekilde belirleme potansiyelini değerlendirdik. Modelin performansının, belirli koşullarda başarılı olduğu, ancak bazı sınırlılıklara sahip olduğu görülmüştür.

Uzaktan algılama ve derin öğrenmenin birarada kullanılmasıyla yüksek çözünürlüklü uydu görüntüleri ile geniş alanlarda hızlı ve maliyet etkin bir analiz yöntemi geliştirilmiştir. Özellikle büyük ve belirgin değişikliklerden kaynaklanan revizyon ihtiyaçları için model oldukça başarılı sonuçlar vermiştir. Bu başarı, sahada yapılacak ayrıntılı incelemelere gerek kalmadan, harita güncelleme ihtiyacı olan bölgelerin önceden belirlenebilmesi açısından önemlidir. Çalışmanın bu yönü, saha çalışmalarının ve revizyon planlamalarının daha etkin bir şekilde gerçekleştirilmesine olanak tanıyacağı düşünülmektedir. Örneğin, revizyon ihtiyacı fazla olan bir paftanın bu şekilde hızlıca belirlenip, revizyon gerektiren bölgelere öncelik verilmesi sağlanabilir.

Çalışmada kullanılan veri seti, değişim olan ve olmayan alanları dengeli bir şekilde içermemektedir. Sınıf dengesizliği nedeniyle modelin revizyona ihtiyaç olan alanları tespit etme oranında sınırlamalar gözlemlenmiştir. Bu tür sınıf dengesizliği sorunlarına çözüm getirmek için literatürde odak kayıp (focal loss) gibi özel kayıp fonksiyonları önerilmektedir (Lin vd., 2017). Odak kayıp, dengesiz veri setlerinde modellerin küçük ve azınlıkta olan sınıfları daha iyi öğrenmesine yardımcı olabilir. Bu teknik, çalışmamızdaki küçük değişikliklerin tespiti gibi sınırlamaların üstesinden gelmek için etkili bir yaklaşım olarak değerlendirilebilir.

Tespitteki sınırlılıkta diğer bir etkenin, görüntülerdeki çözünürlük sınırlamaları ve modelin ölçekleme yeteneğinin sınırlı kalmasının da etkili olabileceği değerlendirilmektedir. Çalışmada kullanılan özellik çıkarıcı ağ mimarileri, genel sınıflandırma doğruluğu konusunda iyi iş çıkarmakla birlikte, ince ayrıntılar gerektiren küçük değişiklikleri ayırt etme konusunda yetersiz kalmıştır. Bu konudaki çeşitli literatür çalışmalarında, derin öğrenme tabanlı özellik çıkarıcı ağların küçük detayları algılamadaki sınırlamalarına değinilmektedir. Örneğin; He et al. (2016), ResNet ağlarının genel sınıflandırma doğruluğunda başarılı olduğunu ancak ince ayrıntılar gerektiren görevlerde ek derinlik katmanlarının sınırlamalar oluşturabileceğini belirtmiştir.

## SONUÇ

Bu çalışma, 1/25000 ölçekli haritaların revizyon ihtiyacının uzaktan algılama ve derin öğrenme yöntemleriyle belirlenmesi üzerine odaklanmış ve elde edilen bulgular, çeşitli tekniklerin etkinliğini ortaya koymuştur. Buna göre; model eğitiminde veri setinin dengeli oluşturulması, görüntü parça boyutları, model mimarisi, hiperparametre ayarları, gelişmiş değişim tespit algoritmalarının kullanımı gibi konuların üzerinde durulmuştur. Sonuç olarak, bu çalışma, uzaktan algılama ve derin öğrenme tekniklerinin 1/25000 ölçekli haritaların revizyon ihtiyaçlarının belirlenmesinde etkin bir şekilde kullanılabileceğini göstermektedir. Önerilen stratejilerin uygulanması, modelin doğruluğunu artırarak harita güncellemelerinin daha etkili ve güvenilir bir şekilde gerçekleştirilmesine katkı sağlayacaktır.

## TEŞEKKÜR

Bu çalışma TÜBİTAK tarafından 123Y268 no'lu 1002 programı kapsamında desteklenmiştir. Çalışmada kullanılan veriler HGM tarafından sağlanmıştır. Verilerin etiketlenmesinde yüksek lisans öğrencisi Harun İlkhan katkı sağlamıştır. Yazarlar bu destekler için teşekkürlerini sunarlar.

## KAYNAKÇA

Boser, B. E., Guyon, I. M., & Vapnik, V. N. (1992, July). A training algorithm for optimal margin classifiers. In Proceedings of the fifth annual workshop on Computational learning theory (pp. 144-152).

Breiman, L. (2001). Random forests. Machine learning, 45, 5-32.

Chen, H., & Shi, Z. (2020). A spatial-temporal attention-based method and a new dataset for remote sensing image change detection. Remote Sensing, 12(10), 1662.

Du, Z., Li, X., Miao, J., Huang, Y., Shen, H., & Zhang, L. (2023). Concatenated deep learning framework for multi-task change detection of optical and sar images. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing.

Fang, S., Li, K., Shao, J., & Li, Z. (2021). SNUNet-CD: A densely connected Siamese network for change detection of VHR images. IEEE Geoscience and Remote Sensing Letters, 19, 1-5.

Ferraris, V., Dobigeon, N., Wei, Q., & Chabert, M. (2017). Robust fusion of multiband images with different spatial and spectral resolutions for change detection. IEEE Transactions on Computational Imaging, 3(2), 175-186.

Fetai, B., Grigillo, D., & Lisec, A. (2022). Revising cadastral data on land boundaries using deep learning in image-based mapping. ISPRS International Journal of Geo-Information, 11(5), 298.

Gong, M., Zhao, J., Liu, J., Miao, Q., & Jiao, L. (2015). Change detection in synthetic aperture radar images based on deep neural networks. IEEE transactions on neural networks and learning systems, 27(1), 125-138.

Gong, M., Yang, Y., Zhan, T., Niu, X., & Li, S. (2019). A generative discriminatory classified network for change detection in multispectral imagery. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 12(1), 321-333.

Guo, Haonan, et al. "DeepCL: Deep Change Feature Learning on Remote Sensing Images in the Metric Space." arXiv preprint arXiv:2307.12208 (2023).

Goodchild, M. F., & Glennon, J. A. (2010). Crowdsourcing geographic information for disaster response: a research frontier. International Journal of Digital Earth, 3(3), 231-241.

He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 770-778).

Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 4700-4708).

Huang, G., Liu, S., Van der Maaten, L., & Weinberger, K. Q. (2018). Condensenet: An efficient densenet using learned group convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 2752-2761).

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. Advances in neural information processing systems, 25.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. nature, 521(7553), 436-444.

Li, X., Du, Z., Huang, Y., & Tan, Z. (2021). A deep translation (GAN) based change detection network for optical and SAR remote sensing images. ISPRS Journal of Photogrammetry and Remote Sensing, 179, 14-34.

Liu, S., Chen, T., Chen, X., Chen, X., Xiao, Q., Wu, B., ... & Wang, Z. (2022). More convnets in the 2020s: Scaling up kernels beyond 51x51 using sparsity. arXiv preprint arXiv:2207.03620.

Lyu, H., Lu, H., & Mou, L. (2016). Learning a transferable change rule from a recurrent neural network for land cover change detection. Remote Sensing, 8(6), 506.

Massarelli, C. (2018). Fast detection of significantly transformed areas due to illegal waste burial with a procedure applicable to Landsat images. International journal of remote sensing, 39(3), 754-769.

Patterson, J., & Gibson, A. (2017). Deep learning: A practitioner's approach. " O'Reilly Media, Inc.".

Paul, J. (2022, December). Change Detection by Deep Learning Models. In 2022 IEEE International Women in Engineering (WIE) Conference on Electrical and Computer Engineering (WIECON-ECE) (pp. 323-326). IEEE.

Radhika, K., & Varadarajan, S. (2018). A neural network based classification of satellite images for change detection applications. Cogent Engineering, 5(1), 1484587.

Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 2818-2826).

Sharma, A., Liu, X., Yang, X., & Shi, D. (2017). A patch-based convolutional neural network for remote sensing image classification. Neural Networks, 95, 19-28.

Tan, M., & Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In International conference on machine learning (pp. 6105-6114). PMLR.

Wang, Q., Yuan, Z., Du, Q., & Li, X. (2018). GETNET: A general end-to-end 2-D CNN framework for hyperspectral image change detection. IEEE Transactions on Geoscience and Remote Sensing, 57(1), 3-13.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Makine Öğrenmesi Algoritmaları ile Toplu Gayrimenkul Değerlemede Aykırı Veri Belirleme Yöntemlerinin İncelenmesi

**Aysun Daşdemir[*1], Süleyman Şişman[2], Arif Çağdaş Aydınoğlu[3]**

*Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği, Kocaeli, Türkiye*

**Anahtar Kelimeler**
Coğrafi Bilgi Sistemleri,
Aykırı Veri Belirleme,
Makine Öğrenmesi,
Toplu Gayrimenkul Değerleme,
Rastgele Orman

**ÖZET**

Gayrimenkul değerleme sürecinde aykırı veriler, modelin doğruluğu ve güvenilirliği üzerinde önemli bir etkiye sahiptir. Bu nedenle, gayrimenkul değerlemesinde aykırı verilerin doğru bir şekilde tespit edilip işlenmesi, modelin başarısını artırmak ve daha güvenilir sonuçlar elde etmek açısından kritik öneme sahiptir. Bu çalışmada, İstanbul ilinin Tuzla ve Pendik ilçesine ait piyasa örneklemleri temin edilmiştir. Örneklemler coğrafi analizlerle desteklenmiştir. Elde edilen gayrimenkul değer veri setinde aykırı değerlerin tespiti için Z-Skor ve Boxplot ve olmak üzere 2 farklı yöntem kullanılmıştır. Elde edilen optimize veri setleri eğitim ve test verisi olarak ayrılmıştır. Eğitim verileri kullanılarak Rastgele Orman makine öğrenme algoritması ile toplu gayrimenkul değerleme modelleri geliştirilmiştir. Model performansları, test verileri üzerinde MAE, MAPE, MSE, RMSE ve $R^2$ metrikleri kullanılarak değerlendirilmiştir. Sonuçlar değerlendirildiğinde; MAPE (12,933) ve $R^2$ (0,70) metriklerine göre Boxplot yönteminin, MAE (0,04685), MSE (0,00434) ve RMSE (0,6587) metriklerine göre Z-Skor yönteminin daha iyi performans sergilediği tespit edilmiştir. Bu bulgular çalışmanın aykırı veri temizleme yöntemlerinin model doğruluğu ve karar destek sistemlerinin güvenilirliği üzerinde kritik bir etkisi olduğunu ortaya koymuştur. Makine öğrenmesi algoritmaları ile toplu gayrimenkul değerleme süreçlerinde aykırı değer yönetimi, modele özgü ve dikkatle uygulanması gereken önemli bir adımdır.

# Examining Outlier Data Detection Methods in Mass Real Estate Valuation with Machine Learning Algorithms

**Keywords**
Geographic Information Systems,
Outlier Data Detection,
Machine Learning,
Mass Real Estate Valuation,
Random Forest

**ABSTRACT**

In the real estate valuation process, outlier data has a significant impact on the accuracy and reliability of the model. Therefore, correctly detecting and handling outlier data in real estate valuation is critical for enhancing model success and obtaining more reliable results. In this study, market samples from the Tuzla and Pendik districts of Istanbul were collected. The market samples were supported by geographic analyses. Outlier detection methods such as Z-Score and Boxplot were applied to the real estate value dataset obtained. The optimized datasets were then split into training and test datasets. Using the training data, mass real estate valuation models were developed with the Random Forest machine learning algorithm. Model performances were evaluated on the test data using metrics such as MAE, MAPE, MSE, RMSE, and $R^2$. Evaluating the results, it was found that the Boxplot method performed better according to MAPE (12.933) and $R^2$ (0.70), while the Z-Score method showed better performance according to MAE (0.04685), MSE (0.00434), and RMSE (0.6587). These findings highlight that outlier data detection methods have a critical impact on model accuracy and the reliability of decision support systems. Outlier management in mass real estate valuation processes using machine learning algorithms is a crucial step that must be applied specifically and carefully to the model.

[*] **Sorumlu Yazar**

*(a.dasdemir2021@gtu.edu.tr) ORCID ID 0009-0000-2994-4222
(ssisman@gtu.edu.tr) ORCID ID 0000-0003-4912-9027
(aydinoglu@gtu.edu.tr) ORCID ID 0000-0003-4912-9027

**Kaynak Göster (APA):**

Daşdemir A., Şişman S., Aydınoğlu A.Ç. (2025). Makine Öğrenmesi Algoritmaları ile Toplu Gayrimenkul Değerlemede Aykırı Veri Belirleme Yöntemlerinin İncelenmesi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Gayrimenkul varlıklar, barınma ihtiyacının ötesinde yatırım aracı olarak ekonomik ve sosyal açıdan büyük önem taşımaktadır (Enemark, 2004. Artan kentleşme ile birlikte konut talebi ve fiyatları yükselmekte, bu da değerleme süreçlerinde doğruluk, hız ve otomasyon ihtiyacını artırmaktadır. Sürdürülebilir ve şeffaf bir piyasa için bu süreçlerin güncel ve bilimsel verilerle desteklenmesi gerekmektedir (Ertaş, 2019).

Bu kapsamda gayrimenkul piyasasının istikrarlı bir yapıya ulaşması ve şeffaflığın sağlanması açısından makine öğrenmesi temelli değerleme sistemlerinin kullanımı artmaktadır (Ertaş, 2019). Ancak, sıkça karşılaşılan aykırı veri sorunları, doğruluk oranlarını olumsuz etkileyip karar alıcıları yanıltmaktadır (Leys et al., 2019). Sonuç olarak, aykırı değerlerin tespit edilmesi ve yönetilmesi sürecinde farklı yöntemler ve tanımlar geliştirilmiş olup, bu çeşitlilik elde edilen sonuçlarda farklılıklara yol açmaktadır. Bu durum, araştırma süreçlerinde hangi yöntemin hangi veri türü için daha etkili olduğu konusunda belirsizlikler yaratmaktadır.

Bu bağlamda bu çalışmanın temel amacı, değerleme veri setleri içerisindeki aykırı verilerin Boxplot (IQR) ve Z-Skor ve yöntemleri ile tespit edilmesi ve bu yöntemlerin Rastgele Orman gibi makine öğrenmesi algoritmaları ile geliştirilecek değerleme modellerindeki performans değişimlerinin incelenmesidir.

## 2. YÖNTEM

Bu araştırmada uygulanan çalışma metodolojisi, sürecin aşamalarını ve kullanılan yöntemleri gösterecek şekilde Şekil 1' de verilmiştir.

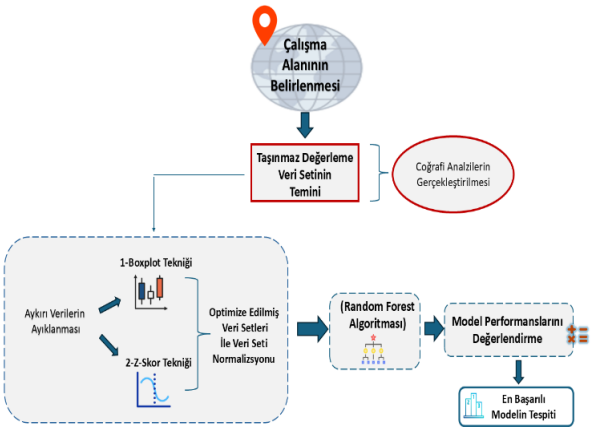


**Şekil 9.** Çalışma Metodolojisi

### 2.1. Çalışma Alanı ve Veri Setleri

İstanbul ilinin Anadolu yakasında bulunan Pendik ve Tuzla ilçelerinde bulunan toplam 44 mahalle çalışma alanı olarak belirlenmiştir (Şekil 2). Çalışma kapsamında konumsal, mahalli, bağımsız bölüm ve bina özelliklerinden oluşan veri kümesi oluşturulmuştur. Konumsal veriler İBB Açık Veri Portalı'ndan, nüfus verileri TÜİK'ten, sosyo-ekonomik gelişmişlik verileri Sanayi ve Teknoloji Bakanlığı raporlarından, arsa rayiç değerleri ise e-Devlet üzerinden temin edilmiştir. 31.12.2023 tarihli 37.269 piyasa örneği, ENDEKSA firmasından temin edilmiştir. Konumsal özellikler ise ArcGIS Pro 3.3. yazılımı ile gerçekleştirilen coğrafi analizler sonucu elde edilmiştir.

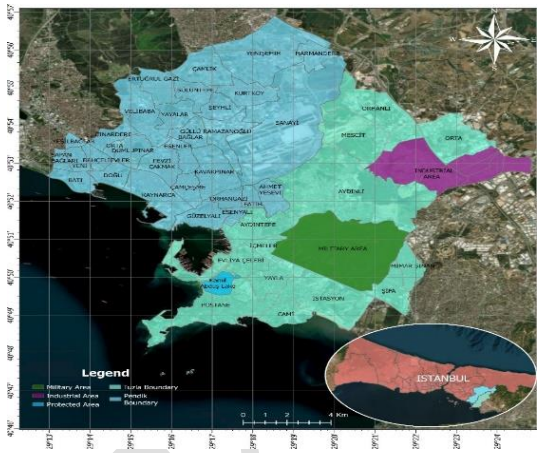


**Şekil 10** . Çalışma Alanının Belirlenmesi.

### 2.2. Aykırı Veri Belirleme Yöntemleri

Boxplot, Tukey (1977) tarafından geliştirilen ve veri analizlerinde sık kullanılan grafik tabanlı bir aykırı değer tespit yöntemidir (Seo, 2006). Ortalama ve standart sapmaya dayanmadığı için çarpık dağılımlarda da etkilidir. Boxplot, veri setindeki minimum, maksimum, medyan, 1. çeyrek (Q1) ve 3. çeyrek (Q3) değerleri üzerinden dağılımı görselleştirir.

$$Alt\ Sınır = Minimum = Q1 - 1.5 \times IQR \quad (1)$$

$$Üst\ \ Sınır = Maximum = Q3 + 1.5 \times IQR \quad (2)$$

Bu sınırların dışında kalan veriler aykırı değer olarak kabul edilir (Sim, Gan, & Chang, 2005).

Z-Skoru ise bir gözlemin veri kümesindeki ortalamadan kaç standart sapma uzaklıkta olduğunu gösteren bir ölçüttür. Normal dağılım varsayımında, Z-skoru standart normal dağılıma uyar ve şu formülle hesaplanır:

$$Z - Score = \frac{x - \mu}{\sigma} \quad (3)$$

Burada μ ortalama, σ ise standart sapma değerlerini ifade etmektedir. Genellikle |Z|> 3 olan gözlemler aykırı kabul edilir, ancak analiz amacına bağlı olarak eşik değeri farklı seviyelerde belirlenebilir (Seo & Marsh, 2006).

### 2.3. Rastgele Orman Algoritması

Random Forest, Breiman tarafından sınıflandırma ve regresyon problemleri için geliştirilen gözetimli bir makine öğrenmesi algoritmasıdır (Breiman, 2001). Algoritma, eğitim verilerinden rastgele örneklenen alt kümeler ve öznitelikler ile bağımsız karar ağaçları oluşturur. Her ağacın çıktısı birleştirilerek nihai tahmin elde edilmektedir (Breiman, 2001).

## 3. BULGULAR

### 3.1. Boxplot ve Z-Skor Yöntemleri ile Aykırı Veri Belirleme

Gayrimenkul değerleme veri seti üzerinde Boxplot ve Z-Skor yöntemleri ile aykırı veriler tespit edilmiştir. Aykırı veriler oda sayısı kategorik değişkenine göre alan

ve birim değer kriterleri üzerinden olmak üzere 2 aşamalı analizler sonucu elde edilmiştir Çalışma kapsamında uygulanan aykırı veri tespit tekniklerinin sonuçları, farklı yöntemlerin veri seti üzerinde farklı etkiler yarattığını göstermektedir. Boxplot yöntemi ile 3810 aykırı veri tespit edilirken, eşik değerinin 3 olarak kullanıldığı Z-Skoru yöntemi ile bu sayı 943' e düşmüştür. Uygulanan her iki yöntem için elde edilen aykrı veriler, veri sertlerinden toplu gayrimenkul değerleme modelleri geliştirmek amacıyla temizlenmiştir. Temizlenmiş veri setleri toplu gayrimenkul değerleme modelleri geliştirmek ve modelleme performansını değerlendirmek üzere eğitim ve test setlerine ayrılmıştır (Şekil 3).

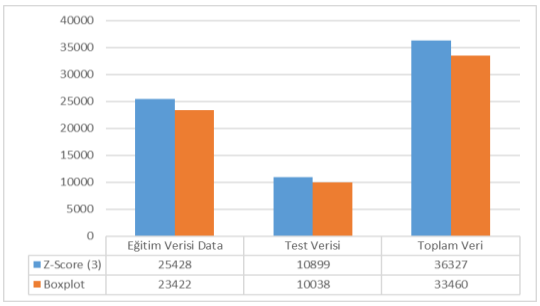


**Şekil 3.** Eğitim ve Test Veri Dağılımı

### 3.2. Rastgele Orman Algoritması ile Toplu Gayrimenkul Değerleme

Veri setleri içerisindeki birim ve ölçek farklılıklarını gidermek amacıyla veriler standardize edilmiştir Rastgele Orman algoritması için en iyi parametre değerleri belirlenerek eğitim veri seti ile değerleme modelleri geliştirilmiştir. Modellerin performansı MAE, MAPE, MSE, RMSE ve $R^2$ metrikleri ile test veri setleri üzerinden ayrı ayrı değerlendirilmiştir (Çizelge 1). Z-Skor yöntemi, Boxplot yöntemine kıyasla daha düşük MAE, MSE ve RMSE değerleri sunarak modelin mutlak ve karesel hata düzeyini azaltmada daha başarılı olmuştur. Öte yandan, Boxplot yöntemi, daha düşük MAPE değeri ve daha yüksek $R^2$ oranı ile modelin açıklayıcılığını ve genel doğruluk seviyesini bir miktar daha iyi korumuştur. Tahmin hatalarının minimize edilmesinin ön planda olduğu gayrimenkul değerleme uygulamalarında Z-Skor yöntemi tercih edilebilirken, modelin açıklama gücünü koruma amacının olduğu durumlarda Boxplot yöntemi de uygun bir alternatif sunmaktadır.

**Çizelge1.** Model Performans Değerlendirme Sonuçları

| Yöntem | MAE | MAPE | MSE | RMSE | $R^2$ |
|---|---|---|---|---|---|
| Boxplot | 0,04906 | 12,933 | 0,00451 | 0,06715 | 0,70 |
| Z-Skor | 0,04685 | 13,776 | 0,00434 | 0,06587 | 0,69 |

## 4. SONUÇ

Gayrimenkul değerleme sürecinde, aykırı verilerin belirlenip uygun şekilde işlenmesi, model doğruluğu ve güvenilir piyasa analizleri için kritik öneme sahiptir. Bu nedenle aykırı değer tespiti, veri ön işleme aşamasının önemli bir parçasıdır. Bu çalışmada Boxplot ve Z-Skor-3 yöntemleri ile belirlenen aykırı verilerin model performansına etkileri karşılaştırılmıştır. Boxplot yöntemi, veri dağılımı hakkında önceden varsayım yapmadan çalışabilmesi avantajı sunarken; Z-Skor yöntemi düşük hata (MAE, MSE, RMSE) değerleri ile daha başarılı sonuçlar üretmiştir. Ancak, Boxplot yöntemi daha düşük MAPE ve daha yüksek $R^2$ değerleriyle modelin açıklayıcılığını daha iyi korumuştur. Her iki yöntem de dikkatli bir şekilde veri setinin özelliklerine ve amaca uygun olarak seçilmelidir. Gayrimenkul değerleme süreçlerinde aykırı değer yönetimi, modele özgü ve dikkatle uygulanması gereken önemli bir adım olduğu göz önünde bulundurulmalıdır.

**TEŞEKKÜR**

Bu çalışma TÜBİTAK tarafından desteklenen 122R021 nolu 1001 projesi kapsamında gerçekleştirilmiştir.

**Yazar Katkı Oranı**

**Aysun Daşdemir:** Yazılım, Görselleştirme, Literatür Taraması, Yazım, **Süleyman Şişman:** Düzenleme, Kavramsallaştırma, Veri Analizi, Modelleme **Arif Çağdaş Aydınoğlu:** Fikir, Kavramsallaştırma Metodoloji.

**KAYNAKÇA**

Breiman, L. (2001). Random forests. Machine Learning, 45(1), 5–32. https://doi.org/10.1023/A:1010933404324

Enemark, S. (2004). Building land information policies. In UN, FIG, PC IDEA Inter-regional Special Forum on The Building of Land Information Policies in the Americas (pp. 1–20). Aguascalientes, Mexico.

Ertaş, M. (2019). Education for real estate valuation in Turkey. International Journal of Engineering Geosciences, 4(1), 8–15.

Leys, C., Delacre, M., Mora, Y. L., Lakens, D., & Ley, C. (2019). How to classify, detect, and manage univariate and multivariate outliers, with emphasis on pre-registration. International Review of Social Psychology, 32(1).

Sim, C. H., Gan, F. F., & Chang, T. C. (2005). Outlier labeling with boxplot procedures. Journal of the American Statistical Association, 100(470), 642–652. https://doi.org/10.1198/016214504000001326

Seo, S. (2006). A review and comparison of methods for detecting outliers in univariate data sets (Ph.D. dissertation). University of Pittsburgh, Pittsburgh, PA.

Seo, S., & Marsh, G. M. (2006). A review and comparison of methods for detecting outliers in univariate data sets (Ph.D. dissertation). University of Pittsburgh.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Konut Şantiyelerinde 3B Coğrafi Bilgi Sistemi Oluşturulması

**Kenan Berke Babaoğlu*[1], Mustafa Ümit Gümüşay[1]**

*Alanya Alaaddin Keykubad Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Antalya, Türkiye*

**Anahtar Kelimeler**
Şantiye,
3 Boyut,
Veritabanı,
BIM,
CBS

**ÖZET**

Bu çalışma, konut şantiyelerinde üç boyutlu (3B) Coğrafi Bilgi Sistemleri (CBS) ve Bina Bilgi Modellemesi (BIM) entegrasyonunun sağladığı katkıları ve pratik uygulamalarını incelemektedir. Şantiyelerde bilgi sistemlerinin kurulması, Coğrafi Bilgi Sistemleri temellerini kullanarak yapının içerisinde ve bulunduğu konuma bağlı tüm mekansal özellikleri 3B BIM verisi ile detaylı bir şekilde analiz etmeyi ve tüm yapı bileşenleri hakkında bilgiye anlık erişimi mümkün kılar. Gerçekleştirilen uygulamalar sonucunda, 3B modellerin proje planlamasında, imalat süreçlerinin takibinde, hata tespitinde ve iş güvenliği yönetiminde önemli iyileştirmeler sağladığı gözlemlenmiştir. Ayrıca, risk analizlerinin 3B ortamda görselleştirilmesi, sahadaki güvenlik önlemlerinin etkinliğini artırmıştır. Elde edilen bulgular, 3B Coğrafi Bilgi Sistemlerinin konut şantiyelerinde sadece proje süresince değil, aynı zamanda yapıların tüm yaşam döngüsü boyunca sürdürülebilir veri yönetimine ve dijital arşiv oluşturmaya önemli katkılar sunduğunu göstermektedir. Bu çerçevede, gelecekte yapay zeka destekli veri analizi ve sahadan gerçek zamanlı veri toplama sistemleriyle entegrasyonun, bu sistemlerin etkinliğini daha da artırabileceği öngörülmektedir.

# Establishment of a 3D Geographic Information System in Residential Construction Sites

**Keywords**
Construction Site,
3 Dimensions,
Database,
BIM,
GIS

**ABSTRACT**

This study investigates the contributions and practical applications of integrating three-dimensional (3D) Geographic Information Systems (GIS) and Building Information Modeling (BIM) in residential construction sites. Establishing information systems on construction sites enables detailed analysis of all spatial features within a building and its location, providing instant access to comprehensive information about all building components through the use of GIS fundamentals and 3D BIM data. The conducted applications demonstrated significant improvements in project planning, monitoring of construction processes, error detection, and occupational safety management through the use of 3D models. Furthermore, visualizing risk analyses in a 3D environment has enhanced the effectiveness of on-site safety measures. The findings indicate that 3D Geographic Information Systems contribute not only during the construction phase but also throughout the entire building lifecycle by supporting sustainable data management and digital archiving. In this context, it is anticipated that future integration with artificial intelligence-supported data analysis and real-time data collection technologies will further enhance the effectiveness and value of these systems in construction site management.

## 1. GİRİŞ

Şantiyelerde 3B Coğrafi Bilgi Sistemleri kullanımı, yapımına başlanacak ya da tamamlanmış bir yapı üzerinde bulunan ve bulunduğu konuma dayalı mekansal veri analizi yapmamızı sağlar. Yapının bulunduğu konuma bağlı arazinin topografik özelliklerinin ve yapı içerisinde bulunan tüm yapı elemanlarının ilişkilerini dijital ortamda üç boyutlu(3B) olarak modellenmesi ve yönetilmesidir.

3B CBS ile bir konut şantiyesinde yapının arazi üzerindeki yerleşimi, altyapı sistemleri, çevresel etkiler, mimari ve statik yapı elemanları hakkında bilgileri gerçek konumlarında, ölçekli ve görsel olarak analiz

* **Sorumlu Yazar**
*(e-mail) ORCID ID 0009-0008-5891-2674
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**
Babaoğlu K B & Gümüşay M Ü (2025). Konut Şantiyelerinde 3B Coğrafi Bilgi Sistemi Kurulması, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

edilebilir. Şantiyede inşa edilecek ya da inşa edilen yapının projeleri baz alınarak hazırlanan Yapı Bilgi Modellemesi (BIM) Coğrafi Bilgi Sistemleri ile entegre edildiği durumda konumsal ve yapısal olarak birlikte değerlendirilebilir.

3B CBS şantiyelerde hem planlama, uygulama ve sonuç sürecinde yüksek doğruluk ve gerçekleklik sağlayarak daha güvenli ve doğru bilgiye ulaşmamızı sağlar.

## 2. YÖNTEM

3B BIM verilerini elde edip dijital ortama aktarmak için Coğrafi Bilgi Sistemi kurulacak yapı belirlendikten sonra mimari ve statik projeler yardımı ile Revit programı ile betonarme elemanlarının yanı sıra mimaride yer alan duvar, kapı, pencere gibi detaylar doğru ölçülerinde çizilerek modelleme tamamlanır.

Şekil.1 de Antalya ili Alanya İlçesi Avsallar mahallesinde yapımı süren New Level Premium konut şantiyesine ait yapının gerçek görüntüsü ve Revit programında çizilen 3B modeli gösterilmiştir.

### 2.1. BIM ve CBS Verilerinin Entegrasyonu

Revit'te hazırlanan 3B modeli ArcGIS Pro üzerinde coğrafi 3B mekansal veri hazırlamak için kullanılan yöntem BIM ve GIS entegrasyonu esasına dayanır. Revit dosyası içerisindeki katmanları ayrı ayrı ArcGIS Pro'da katman olarak açılarak model 3 boyutlu olarak sahneye eklenir.

Coğrafi olarak doğru koordinatlara taşınan model için veritabanı oluşturmamız mümkün hale gelir. Oluşturulan veritabanı içerisine her katman ve her obje eklendikten sonra yapıya ve yapının üzerindeki tüm elemanlara bilgiler girilerek sorgulanabilir hale gelir.

3B model üzerinde ArcGIS Pro'da görüş analizleri, modeli kesitlere ayırma, gölgeleme analizi, bakış hattı, kazı/dolgu hacmi ve bina çevresi ilişkileri gibi bir çok mekansa analiz araçları kullanılabilir.



**Şekil 1.** Revit üzerinden örnek 3B gösterim.

## 3. BULGULAR

3B olarak oluşturulan bilgi sistemleri yapının yapım sürecini anlık takip etmeyi ve yapıdalardaki gelişmeleri bilgi sistemine kayıt ederek iş akışı ve programlarını koordine etmeyi kolaylaştırdı. Hazırlanan model arazi üzerinde görüntülendiğinde proje başında bulunduğu konumdan ötürü oluşabilecek sorunlar öngörülebilir hale geldi. Şekil.2 de gösterildiği gibi proje koordinatlarına uygun olarak arazi üzerinde gösterimi sağlanmış olup tüm çevresel faktörleri ile birlikte görünür hale gelmiştir.

3B model tabanlı oluşturulan Coğrafi Bilgi Sisteminde iş tekrarları ve gecikmeler azaldı ve bundan ötürü maliyetler önden daha kolay hesaplanarak iş tekrarlarının oluşmasının önüne geçmiş oldu. Çevresel faktörlere göre iş güvenliği sağlığı konusunda önlem alınması gereken alanlar önceden daha kolay tespit edilebiilir hale geldi.

Mevcut arazi üzerinde oluşan 3B hazır görüntü üzerinden incelenen proje içerisinde bulunan paydaşların arasındaki iletişim kabiliyeti görsel olarak güçlenmiş oldu. Anlık olarak kayıt edilen veriler ile yapıya ait tüm bilgiler bir arşiv gibi saklandı. Yapı inşaasında yeni işe başlayacak kişiler için adaptasyon sürecini hızlandırma açısından önemli bir kaynak oluşturdu.

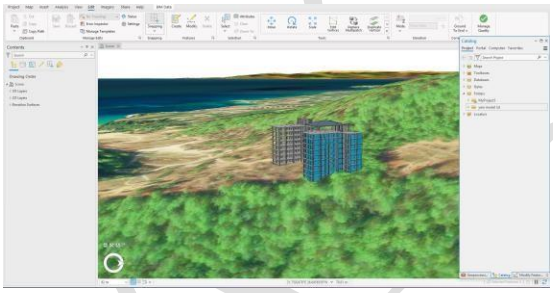

**Şekil 2. ArcGIS Pro Uygulamasındaki Görünüm**

## 4. TARTIŞMA

Bu çalışmada konut şanyiyelerinde 3B Coğrafi Bilgi Sistemlerinin kullanılmasına ilişkin elde edilen bulgular, teknolojik entegrasyonun inşaat sektörüne sağladığı katkıları ortaya koymuştur. Ancak elde edilen olumlu sonuçlara rağmen, bazı sınırlamalar ve geliştirme alanları da tespit edilmiştir.

Sistemin etkin kullanımı için şantiye personelinin yeterli eğitim almasına bağlıdır. Özellikle saha ekiplerinin teknoloji ile adaptasyonunun hızlı olması sistemi hızlandıracaktır, aksi takdirde sistemde gecikmeler yaşanabilir.

3B Coğrafi bilgi sistemlerinin şantiye yönetimine sağladığı faydalar açıkça ortaya çıkmıştır; ancak etkinliklerin artması için şantiyelerde bu sistemi yönetecek bilgili bir yönetici ve bu sistemde yer alacak kişiler için eğitim ve uygulamalarının yaygınlaştırılması gerektiği ve veri akış sürecini hızlandırma protokollerinin geliştirilmesi gerektiği değerlendirilmektedir.

## 5. SONUÇ

Bu çalışma kapsamında konut şantiyelerinde üç boyutlu (3B) Coğrafi Bilgi Sistemlerinin kurulumu ve kullanımının, şantiye süreçleri üzerindeki etkileri araştırılmıştır. Bulgular ışığında, 3B Coğrafi Bilgi Sistemlerinin şantiye yönetimi, maliyet kontrolü, iş güvenliği ve veri bütünlüğü alanlarında önemli avantajlar sağladığı ortaya konulmuştur.

Özellikle 3B model destekli yönetim uygulamalarının, sahadaki görselleştirme ve takip imkânlarını geliştirdiği (Eastman et al., 2011), imalat hatalarını azaltarak kaliteyi artırdığı (Azhar, 2011) ve şantiye süreçlerinde karar alma mekanizmalarını hızlandırdığı (Succar, 2009) uluslarası literatürde de

doğrulanmıştır. Ulusal çalışmalarda da benzer şekilde, 3B model kullanımının maliyet ve zaman yönetimi üzerindeki olumlu etkileri vurgulanmaktadır (Kivrak & Arslan, 2017).

Ancak, literatürde belirtildiği üzere (Hartmann, Gao & Fischer, 2008; Yılmaz & Öztürk, 2020), 3B bilgi sistemlerinin etkili kullanılabilmesi için şantiye çalışanlarının teknolojiye adaptasyonunun sağlanması kritik öneme sahiptir. Saha personelinin eğitimi ve sistemlerin kullanıcı dostu arayüzlerle desteklenmesi gerekliliği, hem ulusal hem de uluslararası araştırmalarda vurgulanmaktadır (Demirkan & Öktem, 2008).

Veri yönetimi açısından ise, yapı yaşam döngüsü boyunca kullanılabilecek dijital modellerin oluşturulması büyük fırsatlar sunmaktadır (Volk, Stengel & Schultmann, 2014). Ancak, veri güvenliği, uzun vadeli saklama stratejileri ve standartlaşma eksiklikleri henüz tam anlamıyla çözümlenememiştir (Succar, 2009; Arayici et al., 2012).

Sonuç olarak, bu çalışma, konut şantiyelerinde 3B Coğrafi Bilgi Sistemlerinin uygulanmasının, projelerin verimliliğini, güvenliğini ve sürdürülebilirliğini artırmada güçlü bir araç olduğunu ortaya koymuştur. Gelecek çalışmalarda, yapay zeka destekli veri analizi (Biljecki et al., 2015) ve sahadan gerçek zamanlı veri toplama (Cheng & Kumar, 2012) gibi teknolojilerle entegrasyonun, 3B Coğrafi Bilgi Sistemlerinin etkinliğini daha da artıracağı değerlendirilmektedir.

## TEŞEKKÜR

Bu sistemin kurulması için çalışmalara yön veren Alanya Alaaddin Keykubad Üniversitesi İnşaat Mühendisliği Bölümü başkanı Prof. Dr. Mustafa Ümit GÜMÜŞAY'a teşekkür ederim.

## KAYNAKÇA

Arayici, Y., Coates, P., Koskela, L., Kagioglou, M., Usher, C., & O'Reilly, K. (2012). Technology adoption in the BIM implementation for lean architectural practice. Automation in Construction, 20(2), 189–195.

Azhar, S. (2011). Building Information Modeling (BIM): Trends, Benefits, Risks, and Challenges for the AEC Industry. Leadership and Management in Engineering, 11(3), 241–252.

Biljecki, F., Ledoux, H., & Stoter, J. (2015). Generating 3D city models without elevation data. Computers, Environment and Urban Systems, 48, 1–18.

Cheng, T., & Kumar, S. (2012). Real-time 3D data capture for construction progress monitoring. Journal of Computing in Civil Engineering, 26(4), 541–552.

Demirkan, H., & Öktem, D. (2008). İnşaat sektöründe bilişim teknolojilerinin kullanımına yönelik bir araştırma. Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi, 23(4), 755–762.

Eastman, C., Teicholz, P., Sacks, R., & Liston, K. (2011). BIM Handbook: A Guide to Building Information Modeling for Owners, Managers, Designers, Engineers and Contractors. (2nd ed.). Wiley.

Hartmann, T., Gao, J., & Fischer, M. (2008). Areas of Application for 3D and 4D Models on Construction Projects. Journal of Construction Engineering and Management, 134(10), 776–785.

Kivrak, S., & Arslan, G. (2017). Şantiye Yönetiminde Bina Bilgi Modellemesi (BIM) Kullanımı: Fırsatlar ve Engeller. Uluslararası İnşaat Yönetimi Kongresi, 1(1), 45–54.

Sacks, R., Radosavljevic, M., & Barak, R. (2013). Requirements for building information modeling based lean production management systems for construction. Automation in Construction, 29, 64–76.

Succar, B. (2009). Building information modelling framework: A research and delivery foundation for industry stakeholders. Automation in Construction, 18(3), 357–375.

Volk, R., Stengel, J., & Schultmann, F. (2014). Building Information Modeling (BIM) for existing buildings — Literature review and future needs. Automation in Construction, 38, 109–127.

Yılmaz, H., & Öztürk, A. (2020). İnşaat Sektöründe BIM Uygulamalarının Değerlendirilmesi: Türkiye Örneği. Uluslararası Doğu Anadolu Fen Mühendislik ve Tasarım Dergisi, 2(2), 85–94.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# 3 Boyutlu Coğrafi Verilerden OGC Standardı 3D Tiles'ların Otomatik ve Hiyerarşik Olarak Oluşturulması

**Rümeysa. Kabakcı*[1], Talha Öztürk[1], Harun Uğuz[2], Hakan Şahin[1]**

[a]*MSB Harita Genel Müdürlüğü, Askeri Coğrafya Dairesi Başkanlığı, 06100, Dikimevi, Ankara*
[b]*Konya Teknik Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Bilgisayar Mühendisliği Bölümü, Konya, Türkiye*

**Anahtar Kelimeler**
3D Tiles,
Hiyerarşik Bölümleme,
3D Coğrafi Veri,
Optimized QuadTree

**ÖZET**

Günümüzde Coğrafi Bilgi Sistemleri (CBS), mekânsal verilerin analizinde ve yönetiminde kritik bir rol oynamaktadır. Artan veri miktarı ve kullanıcı talepleri doğrultusunda, geleneksel iki boyutlu haritaların ötesine geçilerek üç boyutlu veri kullanımı giderek yaygınlaşmaktadır. Ancak, büyük ölçekli ve karmaşık üç boyutlu verilerin depolanması, işlenmesi ve etkili bir şekilde sunulması önemli zorluklar barındırmaktadır. Bu bağlamda, Open Geospatial Consortium (OGC) tarafından geliştirilen 3D Tiles standardı, bu tür verilerin hiyerarşik olarak düzenlenmesini ve parçalara ayrılarak daha verimli bir biçimde iletilmesini mümkün kılmaktadır. Bu çalışmada, üç boyutlu coğrafi verilerin OGC'nin 3D Tiles standardına otomatik ve hiyerarşik bir şekilde dönüştürülmesini sağlayan bir yöntem geliştirilmiştir. Önerilen uygulama, açık kaynaklı yapısıyla dikkat çekmekte ve veri yoğunluğuna göre herhangi bir manuel müdahale gerektirmeksizin hiyerarşik bölümleme gerçekleştirebilmektedir. Bölümleme algoritmaları olarak QuadTree, Octree, Kd-Tree, R-Tree ve bu çalışmaya özgü geliştirilen Optimized QuadTree yöntemleri değerlendirilmiştir. Elde edilen çıktıların oluşturulma süresi, dosya boyutu ve ağaç yapısı bakımından karşılaştırılması yapılarak en uygun algoritma belirlenmiştir. Sunulan çözüm, büyük hacimli 3B coğrafi verilerin etkin yönetimi ve görselleştirilmesi açısından literatüre anlamlı bir katkı sunmakta; özellikle kentsel planlama ve dijital ikiz uygulamaları gibi alanlarda önemli bir referans niteliği taşımaktadır.

# Creating OGC Standard 3D Tiles Automatic and Hierarchically From 3D Geographical Data

**Keywords**
3D Tiles,
Hierarchical Partitioning,
3D Geographic Data,
Optimized QuadTree

**ABSTRACT**

Nowadays, Geographic Information Systems (GIS) play a critical role in the analysis and management of spatial data. With the increasing volume of data and rising user demands, the use of three-dimensional data has become increasingly widespread, moving beyond traditional two-dimensional maps. However, the storage, processing, and effective presentation of large-scale and complex 3D data pose significant challenges. In this context, the 3D Tiles standard developed by the Open Geospatial Consortium (OGC) enables the hierarchical organization and partitioning of such data for more efficient delivery. In this study, a method has been developed to automatically and hierarchically convert three-dimensional geographic data into the OGC's 3D Tiles standard. The proposed application stands out with its open-source structure and can perform hierarchical partitioning without requiring any manual intervention, depending on data density. Partitioning algorithms such as QuadTree, Octree, Kd-Tree, R-Tree, and a custom-developed Optimized QuadTree specific to this study have been evaluated. The outputs were compared in terms of generation time, file size, and tree structure to determine the most suitable algorithm. The presented solution provides a meaningful contribution to the literature in terms of effective management and visualization of large-volume 3D geographic data and serves as an important reference, particularly in fields such as urban planning and digital twin applications.

* **Sorumlu Yazar**

*(rumeysa.kabakci@harita.gov.tr) ORCID ID 0009-0001-0538-2568
(talha.ozturk@harita.gov.tr) ORCID ID 0009-0000-3376-4814
(huguz@ktun.edu.tr) ORCID ID 0000-0003-4617-202X
(hakan.sahin@harita.gov.tr) ORCID ID 0009-0003-8483-3113

**Kaynak Göster (APA):**

Kabakcı R, Öztürk T, Uğuz H. & Şahin H (2025). 3 Boyutlu Coğrafi Verilerden OGC Standardı 3D Tiles'ların Otomatik ve Hiyerarşik Olarak Oluşturulması, Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

3B coğrafi verilerin etkili yönetimi ve sunumu, günümüzün mekânsal veri ihtiyaçlarını karşılamada temel rol oynamaktadır. Özellikle akıllı şehir uygulamaları, dijital ikiz sistemleri ve web tabanlı CBS çözümleri, büyük hacimli 3B verilerin verimli şekilde işlenmesini zorunlu kılmaktadır. Bu gereksinim, yalnızca verilerin depolanmasını değil, aynı zamanda kullanıcıya hızlı ve detaylı biçimde sunulmasını da kapsamaktadır. OGC tarafından geliştirilen 3D Tiles standardı, 3B verilerin çevrimiçi ve hiyerarşik olarak sunulması için önemli bir çözüm sunmaktadır. Ancak bu formata veri dönüşümü, veri setinin boyutu ve karmaşıklığına bağlı olarak zorlu bir süreçtir. Bu çalışmada, hem veri yapılarının bu süreçteki rolü hem de geliştirilen yazılım sistemi detaylandırılmaktadır.

## 2. YÖNTEM

Geliştirilen sistem, üç ana bileşenden oluşmaktadır: veri hazırlama modülü, dönüşüm programı ve görselleştirme arayüzü. Veri hazırlama modülü, CAD ya da fotogrametrik yöntemlerle elde edilen 3B verileri analiz ederek format dönüşümüne hazır hâle getirir. Dönüşüm programı, JavaScript diliyle geliştirilmiş olup, OBJ ve CityGML formatlarını okuyarak 3D Tiles yapılarına dönüştürebilmektedir. Bu program içerisinde farklı algoritmalar (QuadTree, Octree vb.) modül olarak entegre edilmiştir. Her algoritmanın parametreleri kullanıcı tarafından ayarlanabilmektedir. Görselleştirme arayüzü ise CesiumJS kütüphanesi kullanılarak web tabanlı olarak sunulmuştur. Kullanıcı, hiyerarşik 3B verileri etkileşimli olarak inceleyebilmekte, katmanlar arasında geçiş yapabilmekte ve farklı çözünürlüklerde detayları analiz edebilmektedir.

### 2.1. 3D Model Dönüştürme Süreci

3D veri setleri, fotogrametri yöntemiyle oluşturulan .obj, .mtl ve .png formatlarında elde edilmiştir. Bu dosyalar, açık kaynaklı obj23dtiles kütüphanesi kullanılarak 3D Tiles formatına dönüştürülmüştür. Bu dönüşümle birlikte geometrik veriler b3dm dosya formatında ve yapı tanımlayıcıları tileset.json formatında hazırlanmıştır. Sürecin görsel şeması Şekil 1'de sunulmaktadır.

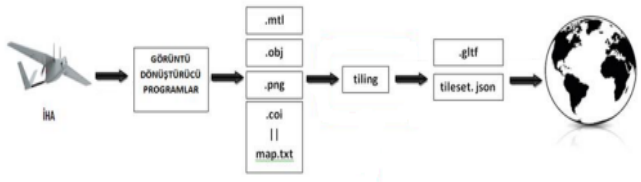


**Şekil 1.** 3D Tiles Süreci

### 2.2. Bölümleme Algoritmaları

Şekil 1'de gösterilen adımlar izlenerek dönüştürülen veri setleri, geometrik yoğunluklarına göre hiyerarşik biçimde parçalara ayrılmış; bu süreçte kullanılan bölümleme algoritmaları aşağıda açıklanmıştır.

**QuadTree**

QuadTree, iki boyutlu uzayı dört eş parçaya ayırarak çalışan hiyerarşik bir veri yapısıdır. Her bir düğüm, dört child düğüme sahip olacak şekilde dallanır. Bu algoritma, özellikle veri dağılımının homojen olduğu bölgelerde etkin çalışmaktadır. Bölgeleme sırasında, her alt bölgenin içinde kalan veri sayısı belirli bir eşik değeri aşmadığında bölme işlemi sonlandırılır.

**Octree**

Octree algoritması, 3B uzayı sekiz eş parçaya böler. Bu algoritma, hacimsel veri dağılımını hesaba kattığı için özellikle Lidar ve hacimsel yapı analizlerinde tercih edilmektedir. Uygulama sırasında bölme işlemi, kümenin hacim merkezine göre yapılır ve her yeni düğümde tekrar sekizli bölme işlemi uygulanır.

**Kd-Tree**

Kd-Tree, k boyutlu veriler için geliştirilmiş bir bölme yapısıdır. Bu çalışmada, veri noktalarının yoğunluklarına göre x, y ve z eksenlerinde sıralama yaparak ve ortadan ikiye bölerek iteratif olarak uygulanmıştır. Dallanma her düğümde dönüşümlü olarak bir sonraki eksende yapılır.

**R-Tree**

R-Tree, mekansal veri yapılarında yaygın olarak kullanılan bir algoritmadır. Verileri kapsayan minimum dikdörtgenleri kullanarak indeksleme yapar. Bölme işlemi, veri kümesinin alan veya hacim açısından en verimli şekilde ayrılmasını sağlar. Her bir düğüm, veri yoğunluğuna bağlı olarak iki child düğüme bölünür ve yapının dengede kalması sağlanır.

**Optimized QuadTree**

Bu çalışmada önerilen Optimized QuadTree algoritması, geleneksel QuadTree yapısının veri yoğunluğu dikkate alınarak iyileştirilmiş bir versiyonudur. Buradaki temel fark, bölme noktalarının sabit ortalardan değil, bölgedeki noktaların x ve y koordinat ortalamalarına göre belirlenmesidir. Bu sayede, veri yoğunluğunun fazla olduğu bölgelerde daha küçük ve detaylı bölümler oluşturulmuş, böylece daha hassas bir tile yapısı elde edilmiştir.

Bu algoritmanın ilk adımı kök düğümün oluşturulmasıyla başlar. Daha sonra veri, noktaların homojenlik düzeyine göre dört alt bölgeye ayrılır. Her bölgedeki veri sayısı belirli bir eşik değeri geçmiyorsa alt bölme yapılmaz, aksi durumda iteratif olarak detaylandırma devam eder.

## 3. BULGULAR

Testler, üç farklı veri seti üzerinde yapılmıştır: küçük ölçekli bina modeli (50 yapı), orta ölçekli ilçe modeli (500+ yapı) ve büyük ölçekli şehir modeli (5000+ yapı). Octree yapısı büyük veri setinde ayrıntılı bölümleme sağlarken, işlem süresi ve bellek kullanımı açısından verimsiz bulunmuştur. R-Tree yapısı ise geometrik yoğunluğa bağlı olarak tutarsız performans sergilemiştir. Optimized QuadTree algoritması, veri yükleme süresini ortalama %30 oranında kısaltmış, görsel bütünlüğü bozmadan yüksek çözünürlükte sunum sağlamıştır. Ayrıca kullanıcı geri bildirimleri doğrultusunda modül yapısı ve hata ayıklama sistemleri yazılıma entegre edilmiştir.

Çalışmada İzmir Narlıdere, Hakkari Biçer ve Ankara Çankaya bölgelerine ait veri setleri üzerinden yapılan testlerde her algoritmanın başarısı ölçülmüştür.

Şekil 2'deki tabloda özet performans verilerini sunmaktadır.

| Algoritma | Ortalama Süre (s) | Dosya Boyutu (MB) | Tile Sayısı | Derinlik | SSE Durağanlığı |
|---|---|---|---|---|---|
| QuadTree | 31.2 | 22.5 | 1200 | 4 | Orta |
| Octree | 36.4 | 25.8 | 1400 | 5 | Yüksek |
| Kd-Tree | 29.1 | 24.1 | 1250 | 5 | Düşük |
| R-Tree | 27.6 | 21.9 | 1180 | 4 | Orta |
| Optimize QuadTree | 23.3 | 18.4 | 1020 | 4 | Yüksek |

**Şekil 2**. Veri setlerine göre algoritmaların özet performansı

Görselleştirme sırasında Optimized QuadTree algoritmasının hem düşük gecikme süreleri hem de pürüzsüz tile geçişleri sağladığı gözlemlenmiştir. Ayrıca, Cesium ortamında yükleme süresi ve render maliyetinde de ciddi oranda azalma kaydedilmiştir.

## 4. TARTIŞMA

3B verilerin bölümlenmesi ve hiyerarşik yapılandırılması için kullanılan algoritmalar arasında QuadTree, Octree, Kd-Tree ve R-Tree öne çıkmaktadır. QuadTree, iki boyutlu düzlemlerde yaygın olarak kullanılan bir yapıdır ve 3B verilere uygulanması sadeleştirilmiş işlem avantajı sağlar. Octree ise hacimsel bölümleme yapısı sayesinde özellikle detaylı modellerde daha isabetli sonuçlar sunmaktadır. Kd-Tree, veri arama sürelerini optimize ederken, R-Tree, özellikle çokgen ve yüzey temelli verilerde başarılı performans göstermektedir. Bu yapıların her biri farklı senaryolarda avantaj sağlamaktadır. Ancak, yüksek hacimli 3B şehir modellerinde Optimized QuadTree algoritması ile daha az bellek kullanımı ve daha hızlı yükleme süreleri elde edilmiştir. Özellikle geometrilerin yoğun olduğu bölgelerde, bu algoritma daha dengeli ve verimli bir bölümleme sağlamaktadır.

## 5. SONUÇ

Bu çalışma, 3B coğrafi verilerin hiyerarşik yapılarla yönetilmesi ve OGC 3D Tiles standardına dönüştürülmesinde, algoritma seçimlerinin sistem performansını doğrudan etkilediğini göstermektedir. QuadTree ve türevi algoritmaların büyük veri setlerinde etkili sonuçlar üretmesi, bu yapıların dönüşüm sistemlerine entegre edilmesini cazip hale getirmiştir. Yazılım mimarisinin modülerliği sayesinde geliştirilebilirlik ve entegrasyon kolaylaşmıştır. İleriki çalışmalar için önerilen konular; yapay zekâ destekli bölümleme, bulut tabanlı sunucularla entegrasyon ve kullanıcı dostu arayüz tasarımlarıdır.

## TEŞEKKÜR

Bu çalışma, Konya Teknik Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Bilgisayar Mühendisliği Bölümü bünyesinde yürütülen 3 Boyutlu Coğrafi Verilerden OGC Standardı 3D Tiles'ların Otomatik ve Hiyerarşik Olarak Oluşturulması kapsamında gerçekleştirilmiştir.

## Yazar Katkı Oranı

Çalışmaya birinci yazar %80 oranında, ikinci yazar %10, üçüncü yazar %5 ve dördüncü yazar %5 oranında katkı sağlamıştır.

## KAYNAKÇA

Benner, J., Geiger, A., Gröger, G., Häfele, K.-H., & Löwner, M.-O. (2013). Enhanced LOD concepts for virtual 3D city models. ISPRS annals of the photogrammetry, remote sensing and spatial information sciences, 2, 51-61

Cozzi , P., & Lilley, S. (2022). 3D Tiles Specification Open Geospatial Consortium, https://docs.ogc.org/cs/22-025r4/22-025r4.html [Ziyaret Tarihi : 01 Ocak 2022

Gaillard, J., Vienne, A., Baume, R., Pedrinis, F., Peytavie, A., & Gesquière, G. (2015). Urban data visualisation in a web browser. Proceedings of the 20th International Conference on 3D Web Technology

Hillmann, M., Igelbrink, F., & Wiemann, T. (2022). Computing Arbitrarily Large Meshes with Level-Of Support for Cesium 3d Tiles. ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 48, 109-116.

Usta, Z. (2021). The design and development of a web-based 3D geographic information management framework.

Yang, X., Huo, L., Shen, T., Wang, X., Yuan, S., & Liu, X. (2024). A large-scale urban 3D model organisation method considering spatial distribution of buildings. IET Smart Cities, 6(1), 54-64.

Zhan, W., Chen, Y., & Chen, J. (2021). 3D Tiles-Based High-Efficiency Visualization Method for Complex BIM Models on the Web. ISPRS International Journal of Geo-Information, 10(7), 476.

© Kabakcı R., Öztürk T., Uğuz H., Şahin H. 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Arazi Yüzey Sıcaklığı ve Kentsel Isı Adası Değişimlerinin Uzaktan Algılama ve CBS Kullanılarak Analizi: Ankara Altındağ İlçesi Örneği

**Mine Kaya*[1], Nida Çelik Şimşek[2]**

[1] *Milli Savunma Bakanlığı, Harita Genel Müdürlüğü, Fotogrametri Dairesi, Ankara, Türkiye*
[2] *Yozgat Bozok Üniversitesi, Mühendislik Mimarlık Fakültesi, Şehir ve Bölge Planlama Bölümü, Yozgat, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Kentsel Isı Adası
CBS,
Sürdürülebilirlik

**ÖZET**

Sürdürülebilir kentsel gelişmeyi sağlayabilmek için iklim değişimine duyarlı kent planlarının hazırlanması gündemde olan bir konudur. Şehirlerin ısıl konforunun iyileştirilmesi ve çevre dostu kentsel planlama için iklim değişikliğine etki eden parametrelerin mekansal olarak izlenmesi ve analiz edilerek iklime duyarlı mekansal planlama stratejilerinin geliştirilmesi gerekmektedir. Bunun için uydu görüntüleri ve coğrafi bilgi sistemleri araçları, normalize edilmiş fark bitki indeksi (NDVI), arazi yüzey sıcaklığı (LST) ve kentsel ısı adası (UHI) gibi göstergelerin mekansal dağılımlarının analiz edilebilmesine olanak sağlamaktadır. Bu çalışmanın amacı, zaman içinde değişen yapılaşmış kentsel çevrenin arazi yüzey sıcaklığını ne ölçüde değiştirdiğini belirleyerek kentsel ısı adası değişimlerini izlemektir. Bunun için farklı kentsel kullanımları barındıran ve kentsel gelişme açık bir yerleşim bölgesi olan Ankara ili Altındağ ilçesi seçilmiştir. Çalışma alanının NDVI, LST ve UHI haritaları 2008 ve 2024 yıllarına ait Lansat-5 ve Landsat-8 uydu görüntüleri kullanılarak Coğrafi Bilgi Sistemi (CBS) yazılımı olan ArcMap 10.8 programında oluşturulmuştur. Buna göre, kentleşme ve insan faaliyetlerinin yüzey sıcaklığı ve kentsel ısı adası etkisi üzerinde artıcı etki yaratması beklenirken, azalan LST ve UHI değerleriyle karşılaşılmıştır. Bölgedeki arazi kullanımı ve mekansal planlama çalışmalarının zamansal bir değerlendirmesi yapıldığında, yeşil alan miktarındaki artışın bu duruma pozitif bir etki sağladığı değerlendirilmektedir. Bu çalışma göstermektedir ki, yeşil altyapıyı ön plana çıkaran mekansal planlama çalışmalarının devam ettirilmesi sürdürülebilir
ve iklim değişikliğine duyarlı kentleşme açısından kritik öneme sahiptir.

# Analysis of Land Surface Temperature and Urban Heat Island Changes Using Remote Sensing and GIS: A Case Study of Ankara Altındağ District

**Keywords**
Remote Sensing,
Urban Heat Island,
GIS,
Sustainability

**ABSTRACT**

Preparing climate change-sensitive urban plans to ensure sustainable urban development is a prominent issue. To improve the thermal comfort of cities and promote environmentally friendly urban planning, it is necessary to monitor and analyze climate change-affecting parameters spatially and develop climate-sensitive spatial planning strategies. For this purpose, satellite images and Geographic Information Systems (GIS) tools enable the analysis of the spatial distribution of indicators such as the Normalized Difference Vegetation Index (NDVI), Land Surface Temperature (LST), and Urban Heat Island (UHI). This study aims to monitor urban heat island changes by determining the extent to which the changing built urban environment alters land surface temperature over time. For this purpose, the Altındağ district of Ankara, a settlement area with diverse urban land uses and open to urban development, was selected. NDVI, LST, and UHI maps of the study area were created in ArcMap 10.8, a Geographic Information System (GIS) software, using Landsat-5 and Landsat-8 satellite images from 2008 and 2024. Accordingly, while urbanization and human activities were expected to have an increasing effect on surface temperature and the urban heat island effect, decreasing LST and UHI values were observed. When a temporal evaluation of land use and spatial planning studies in the region is carried out, it is assessed that the increase in the amount of green space has a positive effect on this situation. This study demonstrates that continuing spatial planning efforts that prioritize green infrastructure is of critical importance
for sustainable and climate change-sensitive urbanization.

* **Sorumlu Yazar**

*(mine.kaya@harita.gov.tr) ORCID ID 0009-0003-9358-7591
(nida.c.simsek@bozok.edu.tr) ORCID ID 0000-0001-8033-2459

**Kaynak Göster (APA):**

Kaya M & Şimşek N Ç (2025). Arazi Yüzey Sıcaklığı ve Kentsel Isı Adası Değişimlerinin Uzaktan Algılama ve CBS Kullanılarak Analizi: Ankara Altındağ İlçesi Örneği, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Günümüzde dünya nüfusunun %55'i şehirlerde yaşamakta ve bu oranın 2050'ye kadar %68'e ulaşması beklenmektedir (UN, 2018). Kentleşmenin devam etmesi durumunda, dünyadaki birçok şehrin iklim değişikliği konusunda olumsuz etkileneceği vurgulanmaktadır (UN-Habitat, 2024). Dünya ortalama yüzey sıcaklığının artışının iklim değişikliğinin önemli gösterglerinden biri olduğu bildirilmektedir (NASA, 2025). İklim değişikliği temel olarak nüfus artışı, sanayileşme, kentleşme ve kaynakların aşırı kullanımı tarafından tetiklenmektedir (Aksöz ve Çelik, 2023).

Kentleşme süreçleri, kentsel ısı adası (UHI) etkisini artırmaktadır. Bu etki, kentsel alanlardaki sıcaklıkların çevre bölgelere göre yükselmesiyle karakterize edilir ve çevresel kalite, insan sağlığı ve kentsel sürdürülebilirlik üzerinde önemli etkilere sahiptir (Duymuş vd., 2024). KIA etkisi, kentsel yayılma, yapı malzemeleri ve insan kaynaklı ısı emisyonları gibi çeşitli faktörlerden kaynaklanmaktadır (Jain ve Sarkar, 2017). Yalçın (2025)'a göre KIA iklimsel çevresel bir sorun sorundur, Kentsel alanlarda iç ve dış termal konforun bozulması gibi olumsuz durumlara neden olmaktadır (Yılmaz ve Öztürk, 2023) ve kentsel mekandaki hava kalitesine ve insan sağlığına doğrudan olumsuz etkide bulunmaktadır (Değerli, 2023). Isı adası tespiti, sürdürülebilir kentleşme için önemli görülmektedir (Tzavali vd., 2015; Filho vd., 2021). Arazi Yüzey Sıcaklığı (LST-Land Surface Tempurature), arazi ve atmosfer arasındaki etkileşimi yarattığı için UHI oluşumu açısından önemli bir parametredir (Değerli, 2023) uzaktan algılama yöntemleri kullanılarak büyük ölçeklerde hesaplanabilmektedir (Venkatraman vd., 2024). Uzaktan algılama uydularında bulunan termal bantlar aracılığıyla, incelenen sahalara ait LST değerleri, yüksek doğruluk ve yeterli konumsal çözünürlükte elde edilebilmektedir (Uyar ve İban, 2024).

Bu çalışmanın amacı, zaman içinde değişen yapılaşmış kentsel çevrenin arazi yüzey sıcaklığını ne ölçüde değiştirdiğini belirleyerek UHI'nın farklı yıllardaki değişimini karşılaştırmaktır. Bunun için farklı kentsel kullanımları barındıran ve kentsel gelişme açık bir yerleşim bölgesi olan Ankara ili Altındağ ilçesi seçilmiştir. Çalışma alanının LST ve UHI'sı 2008 ve 2024 yıllarına ait Lansat-5 ve Landsat-8 uydu görüntüleri kullanılarak Coğrafi Bilgi Sistemi (CBS) yazılımı olan ArcMap 10.8 programında oluşturulmuştur. Buna göre 2008 ve 2024 yılları arasında meydana gelen kentteki değişimlere bağlı olarak ortaya çıkan yüzey sıcaklığı, arazi örtüsü farklılıkları ve kentsel ısı adasının bu yıllar arasındaki değişimi tespit edilmiştir.

## 2. YÖNTEM

Arazi Yüzey sıcaklığı (LST) ve Normalize Edilmiş Fark Bitki İndeksi (NDVI), Kentsel Isı Adası (UHI) ölçülmesinde kullanılan yöntemlerdir. Araştırmada Arcgis 10.8 yazılımı kullanılmıştır. Kentsel ısı adasıyla ilgili daha önce yapılmış akademik çalışmalardan, yerli yabancı makalelerden, kitaplardan, dergilerden ve internet ortamında elde edilecek verilerden yardımcı materyal olarak faydalanılmıştır.

Çalışma kapsamında uydu seçimi ve görüntü temini olarak; 27 Temmuz 2008 LANSAT-5 (TM) uydu görüntülerinin termal bantı (bant6) LST değerinin belirlenmesinde, yakın kızılötesi (bant 3 ve bant 4) NDVI değerinin hesaplanmasında ve 31 Temmuz 2024 LANSAT-8 (OLI/TIRS) uydu görüntülerinin termal bantı (bant 10) LST değerinin belirlenmesinde, yakın kızılötesi (bant 4 ve bant5 ) ve kırmızı bantları ise NDVI değerinin hesaplanmasında kullanılmıştır. Altlık olarak ve analizlerin doğruluğunu sınamak için 2008 ve 2024 yıllarına ait Harita Genel Müdürlüğünden alınan ortofoto görüntüler kullanılmıştır.

Analiz kısmında 2008 ve 2024 yıllarına ait Lansat görüntülerinden LST, NDVI ve UHI analizi yapılmıştır ve değerlendirme yapılırken aynı yıllara ait ortofoto görüntülerle karşılaştırılması yapılmıştır.

### 2.1. Çalışma Alanı

Altındağ ilçesi, İç Anadolu Bölgesi'nin Kuzey batısındaki Yukarı Sakarya Bölümü'nde yer alır. Ankara kent merkezinin kuzeydoğu kısmını kapsar. Kuzeyinde Çubuk ve Pursaklar, batısında Keçiören ve Yenimahalle, güneyde Mamak, güneybatısında Çankaya, doğusunda Akyurt ve Elmadağ ilçeleri bulunmaktadır. Ankara Ovası Çubuk ve Akıncı Ovası arasındaki engebeli arazide kurulmuştur. Yüzölçümü 157,47 kilometre karedir. Yüzölçümünün %31'i dağlık, %6'sı ova, %3'ü de dalgalı araziden oluşmaktadır. Denizden yüksekliği 850 metredir. TUİK (2024) verilerine göre 412,267 kişidir. 26 mahalleden oluşmaktadır.

### 2.2. Yapılan Analizler

#### 2.2.1. NDVI Analizi

Kentsel alanlarda bitki örtüsü, UHI etkisini hafifletmek için kullanılır. Normalize edilmiş fark bitki örtüsü ölçümü (NDVI), uzaktan algılama yöntemlerini kullanarak bitki örtüsünün oranını değerlendirmek için önemli bir ölçüttür. Bu analiz, yakın kızılötesi (NIR) ve kırmızı ışık yansıtma değeri arasındaki farkı hesaplayarak bitki örtüsünün yoğunluğunu belirler. Yüksek NDVI değeri bitki örtüsünün daha yoğun olduğu sonucunu elde ederken, düşük değer bitki örtüsünün az ve cılız olduğunu gösterir. NDVI ölçeği -1 +1 arasında değişir (Venkatraman vd., 2024).

NDVI = (NIR − Red)/(NIR + Red)

Landsat 4–5 verilerini kullanarak **Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI):**

NDVI = (Band 4 − Band 3)/(Band 4 + Band 3) Landsat 8

verileri kullanılarak **Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI):**

NDVI=(Band 5−Band 4)/(Band 5+Band 4)

#### 2.2.2. LST Analizi

Arazi Yüzey Sıcaklığı (LST), CBS ve Uzaktan algılama yöntemleri ile belirlenen yeryüzünün yüzey sıcaklığını

ifade eder (Venkatraman vd., 2024). Uydulardan alınan termal ve kızılötesi bantlar ile kentsel ve doğal alanlardaki sıcaklık değişimleri geniş ölçekte ölçülebilir. LST verileri analiz edilerek kentsel ısı adaları tespit edilebilir.
Landsat 4–5 TM verileri kullanılarak **Arazi Yüzey Sıcaklığı (LST)** analiz etmek için aşağıdaki denklemler kullanılır:
Dijital sayıların (DN) spektral ışınıma (L) dönüştürülmesi için kullanılan denklem (Termal Bant 6 analizinde kullanılır):

$$L=((Lmax-Lmin)/DNmax)*Band+Lmax$$

Spektral ışınım sıcaklığa kelvin (Tb) formatında dönüştürüldükten sonra, bu sıcaklık değerlendirilir ve analiz edilir.

$$Tb = K2/((k1/L\lambda)+1)$$

LST hesaplamasının son adımı, Kelvin'den Celcius'a dönüşüm yapılarak LST hesaplanır.

$$LST = Tb - 273.15$$

Landsat 8 verileri kullanılarak Arazi Yüzey Sıcaklığı (LST) analiz etmek için aşağıdaki denklemler kullanılır:

Termal bant 10 kullanılarak ilk olarak spektral ışınım (L), dijital sayıların (DN) dönüşümü ile incelenir.

$$L = ((L\ max - L\ min)/ DN\ max) * band10 + Lmin$$

LST hesaplaması için Kelvin'den Celsiuc'a dönüşüm yapmak için:

$$LST= (K2/(Ln(k1\ L\lambda)+1)) - 273.15$$

### 2.2.3. UHI Analizi

CBS ve Uzaktan Algılama yöntemleri ile Kentsel Isı Adası etkilerini araştırmak ve değerlendirmek olarak tanımlanmaktadır. Kara Yüzey sıcaklığı (LST) verileri analiz edildikten sonra kentsel ve kentsel olmayan alanlardaki sıcaklık farkları alınır. Sürdürülebilir şehir planları oluşturmak için, araştırmacı ve şehir plancılarına kentsel ısı adası etkisinin belirlenmesi hayati öneme sahiptir (Venkatraman vd., 2024). UHI, aşağıdaki formül kullanılarak, önceden oluşturulan LST verisi ile hesaplanır (Rahman vd., 2022).

$$UHI = (T_s - T_{mean})/ SD$$

Burada, $T_s$ LST'yi , $T_{mean}$ LST ortalamasını, SD ise LST'nin standart sapmasını ifade etmektedir.

## 3. BULGULAR

Çalışma alanı olan Ankara ili Altındağ ilçesi 2008- 2024 yılları için oluşturulan NDVI Şekil 1-2, LST Şekil 3- 4 ve UHI analizleri Şekil 5-6'da görülmektedir.
Araştırmada bitki örtüsüne sahip alanları daha net bir şekilde göstermek amacıyla bitki örtüsü analizi (NDVI) yapılmıştır. Bitki örtüsü analiz sonuçları incelendiğinde (Şekil 1 ve Şekil 2) 2008 yılında yapılan analizde yeşil alanların çok az olduğu görülmektedir. Bunlar; Aydınlıkevler Mahallesin-Altınpark, Kale Mahallesi- Ankara Evi Parkı, Gültepe Mahallesi-Cebeci Asri Mezarlığı, Baraj Mahallesi-Çubuk Barajı ve Çubuk deresi boyunca uzanan alanlar göze çarpmaktadır.
2008 yılında var olan parklara ek olarak 2024 yılında yapılan Zübeyde Hanım Mahallesi- Başkent Millet Bahçesi, Beşikkaya Mahallesi- Altınköy Açık Hava Müzesi, Battalgazi Mahallesi- Emirhan Yalçın Parkı- Hacı Bektaş Veli Parkı ve Tonyukuk Parkı ve bunların dışında ilçe genelindeki yeşil alandaki artış NDVI değerini arttırdığı görülmektedir.

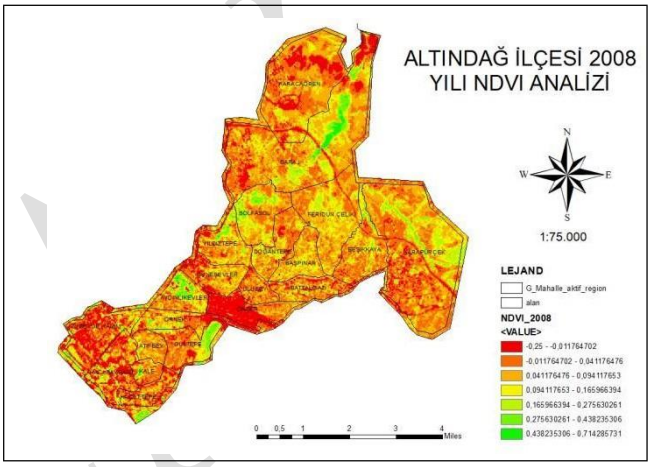


**Şekil 1.** 2008 Yılı NDVI Analizi Haritası

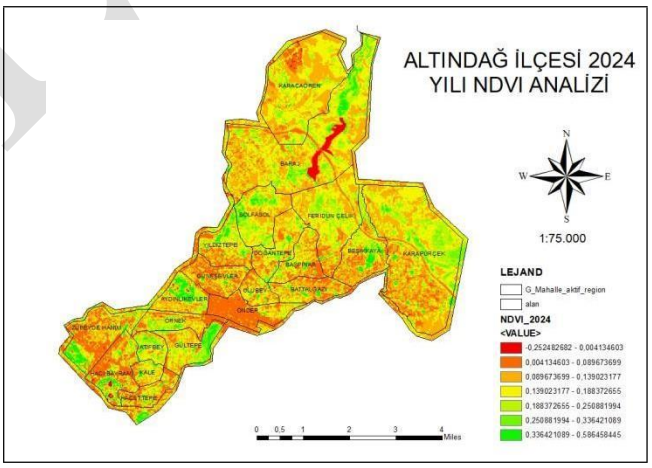


**Şekil 2.** 2024 Yılı NDVI Analizi Haritası

Lansat TM görüntüsünün 6. Bandı ve OLI/TIRS görüntüsünün 10. Bandı kullanılarak 2008 ve 2024 yıllarına ait yüzey sıcaklıkları incelendiğinde (Şekil 3 ve Şekil 4):
2008 yılında Altındağ ilçesinde temmuz ayında en düşük yüzey sıcaklığı 10.44 °C, en yüksek yüzey sıcaklığı
41.83 °C'dir. Harita incelendiğinde; Ankara Evi Parkı, Altınpark, Cebeci Asri Mezarlığı ve Çubuk Barajı alanı en düşük yüzey sıcaklığına sahip alanlardır. Altındağ ilçesinin kuzeyinde kalan alanlar henüz yerleşime açılmamış ve herhangi bir yeşil alanın bulunmadığı alanlar yüzey sıcaklığının en yüksek olduğu alanlardır. 2008 yıllarında sıcaklık 31°C ve 33°C arasında yoğunlaşmaktadır.

2024 yılına ait LST analizi incelendiğinde yüzey sıcaklığı en düşük 13°C, en yüksek 34.58°C arasındadır. Yüzey sıcaklıkları genel anlamda 19,14°C ve 24,94°C arasında olduğu görülmektedir. 2024 yıllında Altındağ ilçesi daha düşük yüzey sıcaklığına sahiptir. Kentin kuzeyinde yerleşimin olmadığı alanlar en yüksek yüzey sıcaklığına sahip alanlardır.

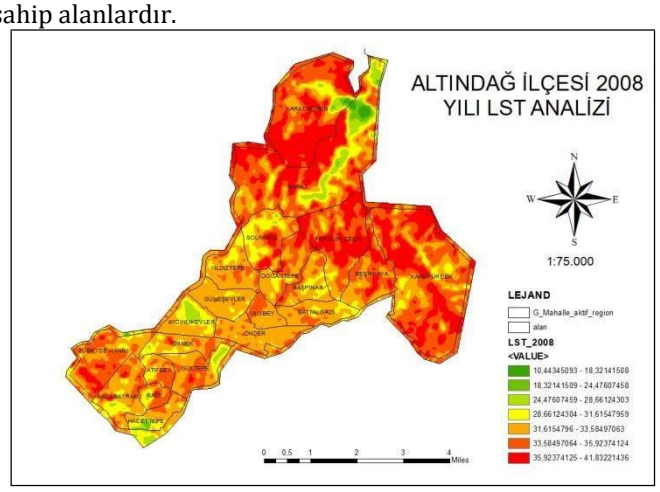


**Şekil 3.** 2008 Yılı LST Analizi Haritası

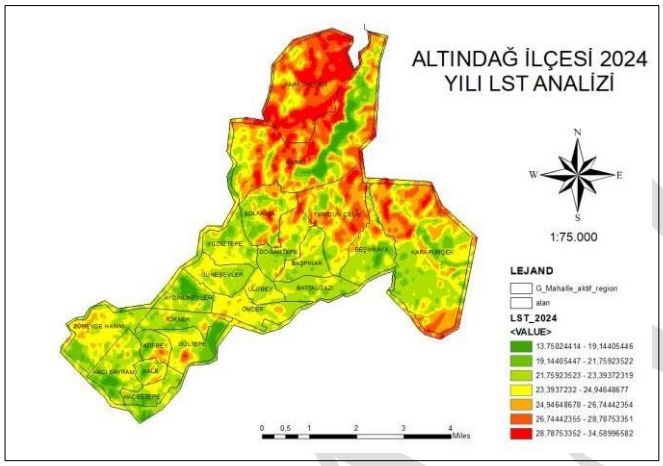


**Şekil 4.** 2024 Yılı LST Analizi Haritası

Altındağ ilçesinde 2008 ve 2024 yıllarına ait yapılan UHI analiz çalışmaları Şekil 5 ve Şekil 6 da gösterilmiştir. Kırmızı renkler kentsel ısı adası etkisi görülen alanları, yeşil renkler etkinin görüldüğü daha düşük alanları göstermektedir. 2008 yılında yapılan analize bakıldığında en sıcaklık düşük 1.50°C en yüksek sıcaklık 29.8°C'dir. Kent geneline baktığımızda orta düzeyde UHI etkisine sahiptir. Kentin kuzey ve kuzey doğusunda kalan alanlarda ise yüksek UHI etkisi olduğu görülmektedir.

2024 yılına ait analizler incelendiğinde en düşük 4.49°C en yüksek 25.33°C'dir kent genelinde 4.49-15.69°C arasında UHI etkisi vardır. Kentin kuzey bölgesinde yüksek UHI etkisi olduğu görülmektedir. İlçe geneline bakıldığında Kentsel Isı Adası (UHI) etkisi 2008 yılına göre nispeten azalmıştır.

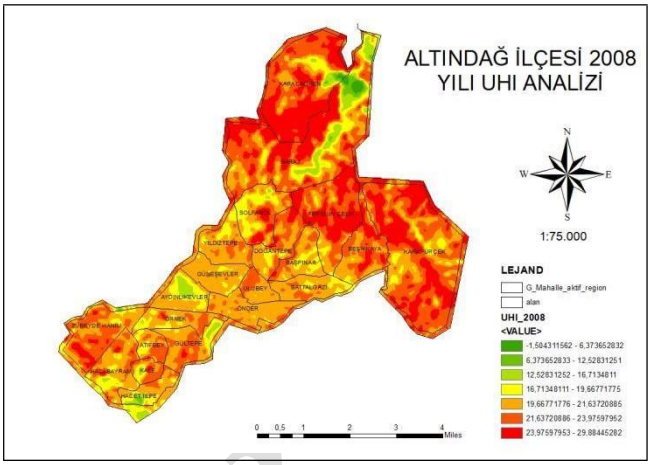


**Şekil 5.** 2008 Yılı UHI Analizi Haritası

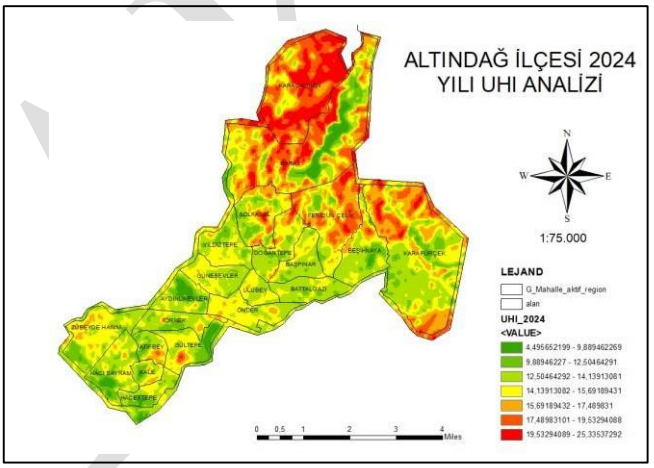


**Şekil 6.** 2024 Yılı UHI Analizi Haritası

Yapılan analizler doğrultusunda ulaşılan sonuçların doğruluğunu konumsal olarak kontrol etmek amacıyla çalışma yılları olan 2008 ve 2024 yıllarına ait ortofoto görüntülerden faydalanılmıştır.

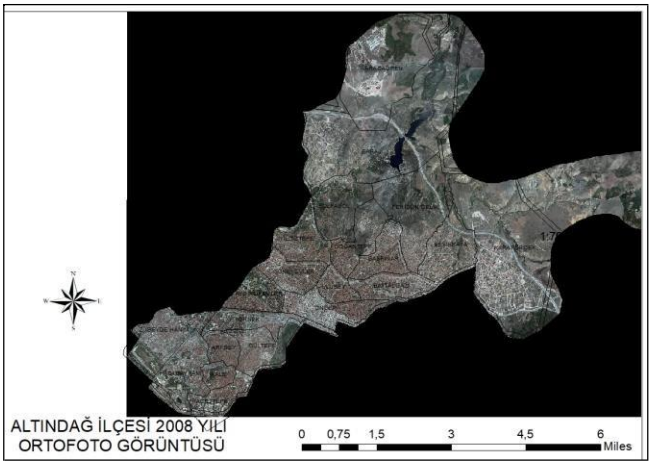


**Şekil 7.** 2008 Yılı Ortofoto Görüntüsü

Isı Adası etkisini düşürmekte önemli rol oynadığı görülmektedir.

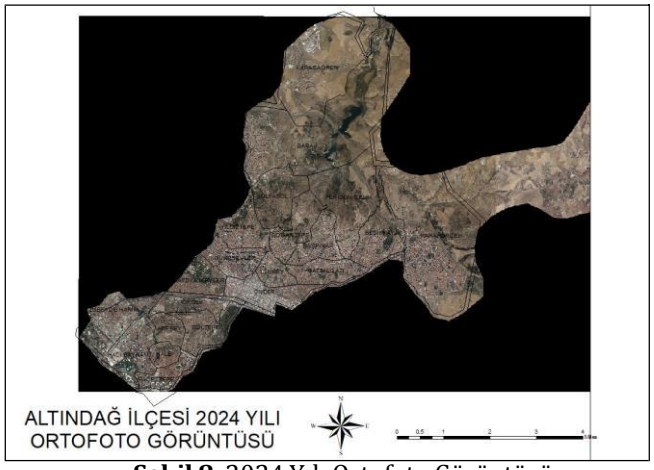


**Şekil 8.** 2024 Yılı Ortofoto Görüntüsü

## 4. TARTIŞMA

Bu çalışmada, 2008 ve 2024 yıllarına ait NDVI verileri karşılaştırılarak, bitki örtüsü yoğunluğunda meydana gelen değişimler analiz edilmiştir. Elde edilen bulgulara göre, 2024 yılında NDVI değeri yüksek olan alanlarda 2008 yılına kıyasla belirgin bir artış gözlemlenmiştir. Bu artış, çeşitli çevresel, iklimsel ve insan kaynaklı faktörlerin etkisiyle açıklanabilir. NDVI değeri düşük alanlarda yoğun yapılaşmanın olduğu alanlar ve bitki örtüsü az ya da hiç olmayan çıplak yüzeylerin olduğu görülmektedir. Çalışma alanında LST değerleri analiz edildiğinde ise 2024 yılında daha düşük kara yüzey sıcaklığının yaşandığı gözlemlenmiştir. Bununla birlikte bölgenin kuzeyinde kalan, bitki örtüsü olarak zayıf ve yapılaşmanın olmadığı Karacaören mahallesinde LST değeri yüksek çıkmıştır. Birçok çalışma, sıcak mevsimlerde NDVI ile LST arasında güçlü bir negatif korelasyon olduğunu ve yüksek bitki örtüsü yoğunluğuna sahip alanların daha düşük yüzey sıcaklıkları sergilediğini göstermektedir (Sun ve Kafatos, 2007; Guha vd., 2020; Marzban vd., 2018). Bu doğrultuda sonuçlar tutarlı görünmektedir.

Öte yandan Lu vd., (2009)'ne göre, yapılaşmış çevre, geçirimsiz yüzey nedeniyle kentsel sıcaklık artışına ve böylece daha yüksek LST değerlerinin oluşmasına neden olmaktadır ve kentleşme LST artışının temel nedenlerinden biri olarak görülmektedir (Zwolska vd., 2024). Ancak çalışma alanında kentsel alanlar zaman içinde artış göstermesine rağmen 2024 yılında ölçülen LST değerleri 2008 yılından daha düşüktür. 2008 ve 2024 yıllarına ait ortofotolar incelendiğinde kentleşmenin arttığı beraberinde kullanılan yeşil alan miktarının da doğru orantılı bir şekilde arttığı görülmüştür. Bu doğrultuda yapılan LST ve NDVI analizleri ortofoto görüntüler ile eşleştirildiğinde LST değerlerinin ve Kentsel Isı Adası etkisinin azalmasında kentte artan yeşil alan miktarının etkili olduğu görülmektedir.

UHI değeleri incelendiğinde ise, 2024 yılında UHI bölgelerinde değişimler görülmüştür. 2008 yılından 2024 yılına kentsel ısı adası etkisinde azalma olduğu sonucuna ulaşılmıştır. Baraj Mahallesinde bulunan Çubuk Barajı ve kollarının bulundukları alanda Kentsel

## 5. SONUÇ

Çalışma alanı 2008 yılı 2024 yılı arasında geçen 16 yıllık süreç içerisinde kentleşme anlamında yoğun değişikliğe uğramıştır. Kentleşme ve insan faaliyetlerinin yüzey sıcaklığı ve kentsel ısı adası etkisi üzerinde artıcı etki yaratması beklenirken, azalan LST ve UHI değerleriyle karşılaşılmıştır. Bölgedeki arazi kullanımı ve mekansal planlama çalışmalarının zamansal bir değerlendirmesi yapıldığında, yeşil alan miktarındaki artışın bu duruma pozitif bir etkide bulunduğu açıktır.

Yeşil alanlar kentsel sıcaklıkları düşürmede etki olduğundan, yeşil altyapıyı ön plana çıkaran mekansal planlama çalışmalarının devam ettirilmesi gerekmektedir. Su kütlelerinin varlığı kara yüzey sıcaklığını düşürmede etkili olduğundan, özellikle kentsel gelişme alanlarının çevresindeki su kaynaklarının korunması önemlidir. Planlama sınırında olan ancak henüz yapılaşmamış alanlar, boş araziler, boş toprak yüzeyleri, düzensiz bitki örtüsüne sahip araziler LST değerlerini artırdığından, yüzey sıcaklığını düşürmek ve termal konfora katkı sağlamak için bu alanların imar planlamasına dahil edilinceye kadar ağaçlandırılması sağlanmalıdır. Kent içinde ise özellikle geniş alanlar kaplayan ve çöküntü alanı haline dönüşmüş sağlıksız yapılar temizlenmeli ve çevre dostu, enerji verimli ve sürdürülebilir binalara dönüştürülmelidir.

**TEŞEKKÜR**

Ortofoto görüntülerine konusunda desteklerinden dolayı Harita Genel Müdürlüğüne teşekkür ederiz.

**Yazar Katkı Oranı**

Çalışmaya yazarlar eşit oranda katkı sağlamıştır.

**Çıkar Çatışması/Çakışması**

Çalışmada yazarlar arasında çıkar çatışması bulunmamaktadır.

**Araştırma ve Yayın Etiği Beyanı**

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

**KAYNAKÇA**

Aksöz, F. & Çelik A. (2023). Küresel İklim Değişikliğine Karşı Dirençli Kent Yönetişimi. Uluslararası Sosyal Siyasal ve Mali Araştırmalar Dergisi. 3(2).

Değerli, B.Ç. (2023). Kentsel Peyzaj Planlamada Isi Adasi Oluşumunun Uzaktan Algilama Yönetİmİ İle Analİzİ; Samsun Örneğİ. (Doktora Tezi), Kastamonu Üniversitesi, Kastamonu.

Duymuş, H., Seyhan, S., Özenen Kavlak, & M., Çabuk, A. (2025). Kentsel Isı Adası Etkisinin Mekânsal ve Zamansal Değişimlerle İlişkisi: Sistematik Bir Literatür Analizi. Journal of Anatolian Environmental and Animal Sciences, 10(1), 1-14. https://doi.org/10.35229/jaes.1596060

Filho, W. L., Al-Amin, A. Q., Nagy, G. J., Azeiteiro, U. M., Wiesböck, L., Ayal, D. Y., ... & Chiappetta Jabbour, C. J. (2018). A comparative analysis of climate-risk and extreme event-related impacts on well-being and health: Policy implications. International journal of environmental research and public health, 15(2), 331.

Guha, S., Govil, H., & Diwan, P. (2020), Monitoring LST-NDVI Relationship Using Premonsoon Landsat Datasets, Advances in Meteorology. https://doi.org/10.1155/2020/4539684

Jain, G. & Sarkar, S. (2017). Urban Heat Island: Causes, Effects & Mitigating Strategies. Environmental Science, Engineering.

Lu, Y., Feng, X., Xiao, P., Shen, C., & Sun, J. (2009) Urban heat island in summer of Nanjing based on TM data. In: Proceedings of the 2009 joint urban remote sensingevent,Shanghai,China.https://doi.org/10.1109/URS.2009.5137628

Marzban, F., Sodoudi, S., & Preusker, R. (2017). The influence of land-cover type on the relationship between NDVI–LST and LST-Tair. International Journal of Remote Sensing, 39(5), 1377–1398. https://doi.org/10.1080/01431161.2017.1402386 NASA, 2025. Evidence [Erişim tarihi: 10.04.2025]. https://science.nasa.gov/climate- change/evidence/

Rahman, M. N., Rony, M. R. H., Jannat, F. A., Chandra Pal, S., Islam, M. S., Alam, E., & Islam, A. R. M. T. (2022). Impact of Urbanization on Urban Heat Island Intensity in Major Districts of Bangladesh Using Remote Sensing and Geo-Spatial Tools. Climate, 10(1), 3. https://doi.org/10.3390/cli10010003

Sun, D & Kafato, M. (2007). Note on the NDVI-LST relationship and the use of temperature-related drought indices over North America. Geophysical Research Letters, 34, doi:10.1029/2007GL031485

Tzavali, A., Paravantis, J. P., Mihalakakou, G., Fotiadi, A., & Stigka, E. (2015). "Urban heat island intensity: A literature review". Fresenius Environmental Bulletin, 24(12b), 4537-4554.

UN, 2018. 2018 Revision of World Urbanization Prospects. [Erişim tarihi: 25.03.2025], https://www.un.org/uk

UN-Habitat, 2024. United Nations Human Settlements Programme. Cities and Climate Action. World Cities Report 2024. [Erişim tarihi: 20.03.2025], https://unhabitat.org/sites/default/files/2024/11/wcr2024_-_full_report.pdf

Uyar, S., & İban, M. C. (2024). NDVI ve LST Faktörlerinin Kentsel Alanlarda Gayrimenkul Değeri Üzerindeki Etkisinin Araştırılması: Ankara, İstanbul, İzmir ve Mersin Örneği. Türk Uzaktan Algılama Ve CBS Dergisi,5(2),158-171.

https://doi.org/10.48123/rsgis.1423218 Venkatraman S, Kandasamy V, Rajalakshmi J,

Sabarunisha Begum S, & Sujatha M. (2024). Assessment of urban heat island using remote sensing and geospatial application: A case study in Sao Paulo city, Brazil, South America, Journal of South American Earth Sciences, (134). https://doi.org/10.1016/j.jsames.2023.104763

Yalçın, M. (2025). İklİm Değİşİklİğİ Ve Kent: Kentsel Isi Adalarinin Küresel İklİm Değİşİklİğİne Etkİsİ, Gazİantep Örneğİ. (Yüksek Lisans Tezi), Gaziantep Üniversitesi, Gaziantep.

Yılmaz, D.&Öztürk, S. (2023). "Kentsel Isı Adası Etkisinin Sistematik Bir İncelemesi: Kentsel Form, Peyzaj ve Planlama Stratejileri". Çevre, Şehir ve İklim Dergisi. Yıl: 2. Sayı: 4. ss. (302-323)

Zwolska, A., Półrolniczak, M. & Kolendowicz, L. (2024). Urban growth's implications on land surface temperature in a medium-sized European city based on LCZ classification. Sci Rep 14, 8308. https://doi.org/10.1038/s41598-024-58501-0

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Çok Zamanlı SAR ve Optik Verilerin Entegrasyonu ile Çeltik Bitki Boyu Analizi ve Ürün Deseni Sınıflandırması

**Mert Alpat1, Meriç Bektaş1, Çağlar Bayık*1, Ömer Gökberk Narin2, Aliihsan Şekertekin3, Mustafa Üstüner4, Mustafa Tolga Esetlili5, Füsun Balık Şanlı6, Yusuf Kurucu5, Saygın Abdikan7**

*[1]Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Zonguldak, Türkiye*
*[2]Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Afyonkarahisar, Türkiye*
*[3]Iğdır Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Mimarlık ve Şehir Planlama Bölümü, Iğdır, Türkiye*
*[4]Samsun Üniversitesi, Özdemir Bayraktar Havacılık ve Uzay Bilimleri Fakültesi, İklim Bilimi ve Meteoroloji Mühendisliği Bölümü, Samsun, Türkiye*
*[5]Ege Üniversitesi, Ziraat Fakültesi, Toprak Bilimi ve Bitki Besleme Bölümü, İzmir, Türkiye*
*[6]Yıldız Teknik Üniversitesi, İnşaat Fakültesi, Harita Mühendisliği Bölümü, İstanbul, Türkiye*
*[7]Hacettepe Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Ankara, Türkiye*

**Anahtar Kelimeler**
Çeltik
Bitki Boyu
Ürün Sınıflandırması
Sentinel-1
Sentinel-2

**ÖZET**

Çeltik bitkisi, dünyada en çok tüketilen ürünlerden biridir ve bitki boyu, büyümenin en önemli göstergesidir. Bu çalışmada ilk olarak Gönen 'de arazi ölçümü ile elde edilen çeltik bitkisi boyu ile çok zamanlı Sentinel-1 (S1) ve Sentinel-2 (S2) verileri arasındaki ilişki incelenmiştir. Arazi çalışmaları kapsamında bitki boyu ölçümleri farklı büyüme evrelerinde düzenli aralıklarla gerçekleştirilmiştir. İkinci olarak buğday, çeltik ve mısır dahil olmak üzere ürün türleri için Rastgele Orman (RO) algoritması kullanılarak arazi örtüsü sınıflandırması gerçekleştirilmiştir. Sınıflandırmada kullanılan veri setine, S2 kaynaklı yedi farklı bant ve S1 kaynaklı geri saçılım katsayıları dahil edilmiştir. Boy için en güçlü ilişki, r = 0,81 korelasyon katsayısı ile Radar Bitki İndeksi (RVI) ve Yer Yüzeyi Su İndeksi (LSWI) entegre edildiğinde bulunmuştur. Sınıflandırma doğruluğuna bakıldığında en yüksek doğruluk VH polarizasyonu ve LSWI entegrasyonundan %84,2 olarak elde edilmiştir. Sonuçlar, hem doğru boy tahmini hem de etkili arazi örtüsü sınıflandırması için SAR ve optik verilerin birleştirilmesinin potansiyelini vurgulamaktadır.

# Multi-Temporal Integration of SAR and Optical Data for Rice Crop Height Estimation and Crop Pattern Classification

**Keywords**
Paddy rice
Crop height
Crop classification
Sentinel-1
Sentinel-2

**ABSTRACT**

Rice plant is one of the most widely consumed products in the world, and plant height is one of the most important indicators of growth. In this study, the relationship between rice plant height obtained from field measurements in Gönen and multi-temporal Sentinel-1 (S1) and Sentinel-2 (S2) data was investigated in the first stage. In the field campaign, plant height measurements were taken at regular intervals during different growth stages to ensure data diversity. In the second stage, land cover classification was performed using the Random Forest (RF) algorithm for crop types including wheat, rice, and maize. A total of seven spectral bands derived from S2 and backscatter coefficients from S1 were included in the classification dataset. The strongest correlation for plant height was obtained when the Radar Vegetation Index (RVI) and Land Surface Water Index (LSWI) were integrated, and the correlation coefficient was found to be r = 0.81. The highest classification accuracy (84.2%) was obtained by the integration of VH polarization and LSWI indices. The results emphasize the potential of combining SAR and optical data for both accurate plant height estimation and effective land cover classification.

* **Sorumlu Yazar**

(mert.alpat@fbe.karaelmas.edu.tr) ORCID ID 0009-0008-1375-6444
(meric.bektas@fbe.karaelmas.edu.tr) ORCID ID 0009-0009-4710-6842
*(caglarbayik@beun.edu.tr) ORCID ID 0000-0001-6606-3272
(gokberknarin@aku.edu.tr) ORCID ID 0000-0002-9286-7749
(aliihsan.sekertekin@igdir.edu.tr) ORCID ID 0000-0002-4715-5160
(mustafa.ustuner@samsun.edu.tr) ORCID ID 0000-0003-0553-2682
(tolga.esetlili@ege.edu.tr) ORCID ID 0000-0002-8095-4247
(fbalik@yildiz.edu.tr) ORCID ID 0000-0003-1243-8299
(yusuf.kurucu@ege.edu.tr) ORCID ID 0000-0002-8267-4847
(sayginabdikan@hacettepe.edu.tr) ORCID ID 0000-0002-3310-352X

**Kaynak Göster (APA):**

Alpat M, Bektaş M, Bayık Ç, Narin Ö G, Şekertekin A, Üstüner M, Esetlili T, Balık Şanlı F, Kurucu Y & Abdikan S (2025). Çok Zamanlı SAR ve Optik Verilerin Entegrasyonu ile Çeltik Bitki Boyu Analizi ve Ürün Deseni Sınıflandırması, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

TUFUAB

## 1. GİRİŞ

Günümüzde uzaktan algılama teknolojisi, tarımsal yönetim için vazgeçilmez ve geniş alanlardan düşük maliyetli bilgi edinmek için en kullanışlı araç olmuştur (Huang vd., 2016). Artan nüfus ve iklim değişikliğine bağlı tarım alanlarının azalması, gıda güvenliğini sağlamanın önemini arttırmakta ve bu da gıda üretim verimliliğinde iyileştirmeler yapılmasını zorunlu kılmaktadır. Bunu sağlamanın en temel yolu, ürün durumu ve arazi örtüsü ile ilgili doğru ve zamanında bilgilere ulaşmaktır (Luo vd., 2015).

Önemli bir parametre olan bitki boyu; bitki büyümesi, genel sağlık hakkında bilgi verirken, verim tahmininde de önemli bir rol oynamaktadır (Abdikan vd., 2023; Narin vd., 2024; Bazrafkan. vd., 2025). Geleneksel bitki boyu ölçümü yoğun emek ve zaman gerektiren yöntemler olmasının yanında geniş alanlar için pratik değildir (Zhang vd., 2024). Uzaktan algılama, özellikle Sentetik Açıklıklı Radar (SAR) ve optik verileri beraber kullanıldığında, etkili ve doğru bitki boyu tahmini için uygulanabilir bir alternatif sunmaktadır (Abdikan vd., 2024). SAR algılayıcıları, bitki boyu ve yoğunluğu ile ilgili bilgiler sağlarken optik algılayıcılar bitki sağlığı, klorofil içeriği ve örtü ile ilgili olan spektral yansıma bilgilerinin tahmininde kullanılmaktadır. SAR ve optik verilerin entegrasyonu, her iki algılayıcının güçlü yanlarını kullanarak bitki boyu tahmininin doğruluğunu ve sağlamlığını artırmaktadır (Fieuzal ve Baup, 2021).

Çok zamanlı optik ve SAR verilerinin, yüksek boyutlu verileri ve karmaşık ilişkileri işlemede etkili olan Rastgele Orman (RO) algoritmasıyla birleştirilmesi, her iki veri türünün güçlü yanlarından yararlanarak ürün sınıflandırmasına güçlü bir yaklaşım sunmaktadır. Bu yaklaşım, ürün türü tanımlamasında ve tarımsal izlemede gelişmiş doğruluk sağlamaktadır (Orynbaikyzy vd., 2020). Optik veriler spektral bilgi sağlarken, SAR verileri örtü yapısına, nem içeriğine ve hacmine duyarlıdır ve bulut örtüsünden daha az etkilenmektedir (Inglada vd., 2016). Normalize Fark Bitki İndeksi (NDVI), Normalize Fark Bitki İndeksi (Kırmızı Kenar Bandı) (NDVIred), Yeşil Normalize Fark Bitki İndeksi (GNDVI), LSWI, Klorofil Kırmızı Kenar İndeksi (Clre) ve Gelişmiş Bitki İndeksi (EVI) gibi bitki örtüsü endekslerinin zaman serilerini ve SAR verilerinden VH ve VV polarizasyonlarındaki geri saçılımları kullanarak araştırmacılar ürün gelişiminin zamansal dinamiklerini yakalayabilmektedir (Htitiou vd., 2020).

Bu çalışmanın amacı, Sentinel-1 ve Sentinel-2 verilerinden üretilmiş indeksler ile çeltik bitki boyu ilişkisini belirlemek ve bu indekslerinden zaman serili görüntü yığınları oluşturularak tarımsal ürün ve arazi kullanım türlerinin sınıflandırılmasıdır.

## 2. YÖNTEM

### 2.1. Çalışma alanı

Çalışma, 2024 yılında Türkiye'nin kuzeybatısında yer alan Balıkesir'in Gönen ilçesinde gerçekleştirilmiştir (Şekil 1). Gönen, ılıman kışlar, uzun ve kurak yazlar ile Akdeniz iklimine sahip bir coğrafyadır. İlçesi, Gönen havzasının merkezinde yer almakta olup, Gönen Deresi çevredeki tarım arazilerine sulama sağlamaktadır. Gönen Deresi ve iklim koşulları, tarım faaliyetlerini bu bölgede en önemli geçim kaynağı haline getirmiştir. Ancak tüm ürünler arasında çeltik, bölge ekonomisinin en önemli ürünüdür (Öztürk ve Akçay, 2010).

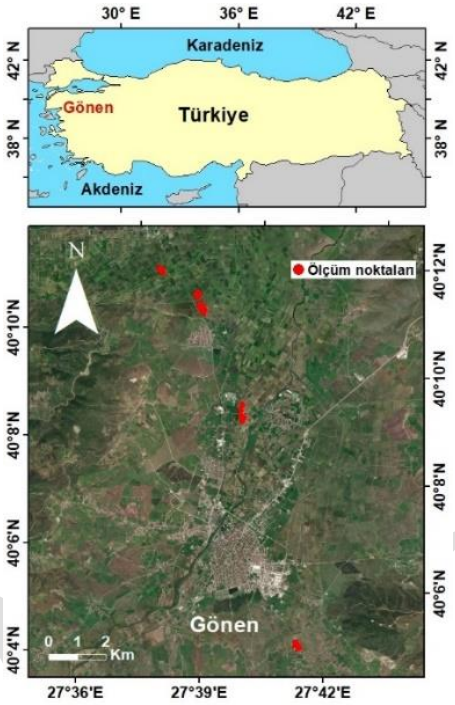


**Şekil 1.** Çalışma alanı.

### 2.2. Sentinel-1 ve Sentinel-2 verileri

Çalışma kapsamında S1 ve S2 uydu görüntülerinin yanı sıra bitki büyüme evrelerine ait çeltik bitki boyu ölçümleri kullanılmıştır. Saha çalışmaları sonucunda toplam 412 bitki boyu ölçülmüştür. Çeltik bitki boyunun uzaktan algılama verileriyle ilişkisini incelemek amacıyla dört farklı arazi çalışması dönemine karşılık gelen uydu görüntüleri kullanılmıştır. Çalışmanın ikinci aşamasında, bitki desenini sınıflandırmak amacıyla 1 Nisan 2024-31 Ekim 2024 tarihleri arasındaki tüm S1 ve bulutsuz S2 görüntülerinden zaman serisi oluşturularak çok bantlı yığın (stack) veri setleri elde edilmiştir.

Avrupa Uzay Ajansı (ESA) tarafından ücretsiz sağlanan S1 ve S2 verilerinden S1 SAR verileri Seviye-1 Zemin Menzili Tespit Edilen (GRD) formatında elde edilmiştir. Tüm görüntüler, yükselen yörüngede olup düşey-düşey (VV) ve düşey-yatay (VH) polarimetrik verilerdir. Açık kaynaklı Sentinel Uygulama Platformu (SNAP) (SNAP, 2024) yazılımı, 10 m mekansal çözünürlükte GRD görüntülerinden geri saçılım katsayılarını (σ°) çıkarmak için kullanılmıştır. Ön işleme adımları şu şekildedir: i) hassas yörünge düzeltmesi, ii) termal gürültü giderme, iii) GRD sınır gürültüsünün giderilmesi, iv) radyometrik kalibrasyon, v) 3x3 Lee Sigma filtresi, vi) geometrik düzeltme ve vii) denklem 1'i kullanarak geri saçılım katsayısının (σ°) doğrusal değerlerinden dönüştürülen dB değerlerinin hesaplanması.

$$\sigma_{dB} = 10 \cdot \log_{10}(\sigma^{\circ}) \quad (1)$$

S2 verileri ise bulutsuz olarak elde edilmiş ve Google Earth Engine (GEE) platformu kullanılarak işlenmiştir (Gorelick, 2017). GEE kataloğundan atmosferik olarak düzeltilmiş S2 L2A verisi kullanılmış ve 10 m mekansal çözünürlükte kullanılmıştır.

Bitki boyu uzaktan algılama verileri ilişkisi ve sınıflandırma işlemleri için S1 verilerinden VV ve VH geri saçılım değerleri ile RVI indeksi; S2 verilerden NDVI, NDVIred, GNDVI, LSWI, Clre ve EVI gibi bitki indeksleri türetilmiştir (Çizelge 1).

**Çizelge 1.** Çalışmada kullanılan indekslerin listesi.

| Algılayıcı | İndeks | Eşitlik |
|---|---|---|
| **S1** | **RVI** | $\frac{4\sigma^{\circ}_{VH}}{\sigma^{\circ}_{VV}+\sigma^{\circ}_{VH}}$ |
| **S2** | **NDVI** | $\frac{(\mathrm{NIR}-\mathrm{Red})}{(\mathrm{NIR}+\mathrm{Red})}$ |
| | **NDVIred** | $\frac{(\mathrm{NIR}-Red_{edge})}{(\mathrm{NIR}+Red_{edge})}$ |
| | **GNDVI** | $\frac{(\mathrm{NIR}-\mathrm{Green})}{(\mathrm{NIR}+\mathrm{Green})}$ |
| | **LSWI** | $\frac{(\mathrm{NIR}-\mathrm{SWIR})}{(\mathrm{NIR}+\mathrm{SWIR})}$ |
| | **Clre** | $(\mathrm{NIR}/Red_{edge})-1$ |
| | **EVI** | $\frac{2.5(\mathrm{NIR}-\mathrm{Red})}{(\mathrm{NIR}+6\mathrm{Red}-7.5\mathrm{Blue}+1)}$ |

### 2.3. Rastgele Orman

Bu çalışmanın ikinci aşamasında, Google Earth Engine (GEE) platformu kullanılarak 17 adet S1 ve 17 adet S2 görüntülerinden çeşitli bitki örtüsü ve radar endeksleri türetilmiştir. Bu endeksler, zaman serileri oluşturmak ve her endeks için çok bantlı yığılmış veri kümeleri üretmek için kullanılmıştır. Bu endekslerin zamansal dinamikleri, korelasyon analizi yoluyla tarlada ölçülen bitki boyuyla ilişkili olarak analiz edilirken, yığılmış veri kümeleri aynı zamanda arazi örtüsü sınıflandırması için de kullanılmıştır. Bu indeksler, sınıfların spektral farklılıklarını yansıtarak sınıflandırma başarımına katkı sağlamıştır. Çalışmada buğday, çeltik, İtalyan çavdarı, mera, mısır, orman ve kentsel alanlar olmak üzere toplam yedi sınıf tanımlanmıştır. Sınıflandırma işleminde, yer gerçekliği verisinin %70'inin eğitim verisi olarak, kalan %30'u ise test verisi olarak kullanılmıştır. Çalışma kapsamında, topluluk öğrenme algoritmalarından olan RO algoritması kullanılmıştır. Ağaç tabanlı yöntemlerden olan RO algoritması, robust yapısı, diğer makine öğrenme algoritmalarına kıyasla daha az parametreye sahip olması ve hızlı işlem kapasitesi nedeniyle bu çalışma kapsamında tercih edilmiştir. (Orynbaikyzy vd., 2020). RO algoritması için ağaç sayısı ve m değişkeni parametrelerinin belirlenmesi gerekmektedir. Sınıflandırma sonuçları, ürün türleri ve arazi örtüsü kategorileri arasında net mekansal desenler ortaya koyarak, sınıflandırma doğruluğunu artırmak için zamansal bilgileri dahil etmenin faydalarını vurgulamıştır.

## 3. BULGULAR ve TARTIŞMA

İlk olarak çeltik bitki boyunun uzaktan algılama verileriyle ilişkisinin analizi için SAR ile optik verilerinin katkısı için birkaç iki değişkenli kombinasyon test edilmiştir. RVI, VH ve EVI gibi indeksler bitki boyu ile ortalama üzeri korelasyonlar gösterirken, ikili değişkenler bu ilişkileri belirgin şekilde güçlendirmiştir. Örneğin, RVI+LSWI kombinasyonu,(yani yığın hale getirilmesi (stack)) 0,81'lik bir sonuç ortaya çıkarmış ve değişkenlerin tekil kullanımına kıyasla açık bir iyileşme olduğunu göstermiştir (Çizelge 2). Özellikle, RVI tabanlı kombinasyonlar diğerlerinden sürekli olarak daha iyi performans göstermiş ve tarımsal izlemede yapısal bir gösterge olarak önemini vurgulamıştır.

**Çizelge 2.** Ürün boyu ile seçilen indeksler arasındaki korelasyon değerleri.

| İndeksler | Pearson korelasyon katsayısı (r) | İndeksler | Pearson korelasyon katsayısı (r) |
|---|---|---|---|
| **NDVI** | 0,09 | **VV** | -0,21 |
| **NDVIred** | 0,22 | **RVI** | 0,76 |
| **GNDVI** | 0,35 | **RVI+EVI** | 0,80 |
| **LSWI** | 0,40 | **VH+LSWI** | 0,67 |
| **Clre** | 0,04 | **RVI+GNDVI** | 0,80 |
| **EVI** | 0,42 | **VH+NDVIred** | 0,66 |
| **VH** | 0,65 | **RVI + LSWI** | **0,81** |

İndekslerin tek kullanımında sınıflandırma sonuçları NDVIred, GNDVI ve LSWI için nispeten yüksek doğruluklar ortaya koymuştur. İndeks entegrasyonuna ise en yüksek performans VH+LSWI ve VH+NDVIred ile elde edilmiştir (Çizelge 3). Bu sonuçlar indekslerin entegrasyonunun sınıflandırma doğruluğuna olumlu katkıda bulunduğunu göstermektedir.

**Çizelge 3.** Seçilen indekslerin sınıflandırma doğruluğu.

| İndeksler | Doğruluk (%) | Kappa | F1-skor (%) |
|---|---|---|---|
| **NDVI** | 83,0 | 0,715 | 51,2 |
| **NDVIred** | 83,4 | 0,708 | 53,2 |
| **GNDVI** | 83,1 | 0,704 | 51,8 |
| **LSWI** | 83,1 | 0,708 | 53,5 |
| **Clre** | 83,0 | 0,711 | 53,9 |
| **EVI** | 82,3 | 0,708 | **54,8** |
| **VH** | 80,9 | 0,665 | 32,3 |
| **VV** | 79,7 | 0,650 | 36,8 |
| **RVI** | 75,8 | 0,599 | 32,6 |
| **RVI+EVI** | 81,7 | 0,697 | 47,5 |
| **VH+LSWI** | **84,2** | **0,723** | 52,6 |
| **RVI+GNDVI** | 82,1 | 0,701 | 46,9 |
| **VH+NDVIred** | 83,8 | 0,721 | 46,9 |
| **RVI + LSWI** | 83,1 | 0,713 | 52,7 |

RVI ile bitki boyu arasında gözlemlenen güçlü korelasyon, RVI'nin bitki örtüsü hacmi ve biyokütlesindeki zamansal değişiklikleri yakalama yeteneğinden kaynaklanmaktadır. Buna karşılık, VV geri saçılımı ile negatif korelasyon, artan bitki yoğunluğuyla azalan yüzey saçılımına olan duyarlılığıyla açıklanabilir. Yine de RVI, benzer yapısal özelliklere sahip ürün tipleri arasında sınırlı ayırt edici gücü nedeniyle nispeten düşük sınıflandırma doğruluğu sağlamıştır. Bu, biyofiziksel değişkenlerle yüksek korelasyonun mutlaka gelişmiş sınıflandırma performansına dönüşmediğini göstermektedir.

## 4. SONUÇ

Bu çalışmada ürün boyu tahmini ve ürün sınıflandırması için çok zamanlı Sentinel-1 ve Sentinel-2 verilerinin entegrasyonunun getirdiği katkılar araştırılmıştır. Bu entegrasyon ile iki uygulama için

tatmin edici sonuçlar ortaya çıkmıştır. Ancak, özellikle sınıflandırmada mısır ve İtalyan çimi gibi ürün sınıfları için daha düşük doğruluk gözlemlenmiştir. Bu doğruluk düşüklüğünü gidermek amacıyla, zaman serisi verilerle daha etkili çalışan Derin Sinir Ağları (DNN), Konvolüsyonel Sinir Ağları (CNN) ve XGBoost gibi gelişmiş makine öğrenimi yöntemlerinin kullanımı değerlendirilecektir. Bu bulgular, çok zamanlı SAR ve optik veri entegrasyonunun tarım çalışmaları için önemli bir potansiyele sahip olduğunu göstermişti.

## TEŞEKKÜR

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 222N088 numaralı proje, Bulgaristan Bilimler Akademisi (BAS) tarafından IC-TR/9/2023-2025 numaralı proje ve Hacettepe Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi'ne tarafından FHD-2024-21386 numaralı proje kapsamında desteklenmiştir. Yazarlar, destekleri için TÜBİTAK, BAS ve Hacettepe Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi'ne teşekkürlerini sunarlar.

### Yazar Katkı Oranı

Tüm yazarlar çalışmaya eşit katkı sunmuştur.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

## KAYNAKÇA

Abdikan, S., Sekertekin, A., Narin, O. G., Delen, A., & Sanli, F. B. (2023). A comparative analysis of SLR, MLR, ANN, XGBoost and CNN for crop height estimation of sunflower using Sentinel-1 and Sentinel-2. Advances in space research, 71(7), 3045-3059.

Abdikan, S., Ganeva, D., Narin, O. G., Sekertekin, A., Dimitrov, Z., Bayik, C., ... & Kurucu, Y. (2024, October). Exploring Sentinel-1 and Sentinel-2 time series sensitivity to rice height. In 2024 IEEE International Workshop on Metrology for Agriculture and Forestry (MetroAgriFor) (pp. 672-676). IEEE.

Bazrafkan, A., Worral, H., Bandillo, N., & Flores, P. (2025). Accurate plant height estimation in pulse crops through integration of LiDAR, multispectral information, and machine learning. Remote Sensing Applications: Society and Environment, 37, 101517. doi: 10.1016/j.rsase.2025.101517

Fieuzal, R., & Baup, F. (2016). Estimation of leaf area index and crop height of sunflowers using multi-temporal optical and SAR satellite data. International Journal of Remote Sensing, 37(12), 2780-2809. doi: 10.1080/01431161.2016.1176276

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. Remote Sensing of Environment, 202, 18-27. doi: 10.1016/j.rse.2017.06.031

Huang, Y., Thomson, S. J., Brand, H. J., & Reddy, K. N. (2016). Development and evaluation of low-altitude remote sensing systems for crop production management. International Journal of Agricultural and Biological Engineering, 9(4), 1-11. doi: 10.3965/j.ijabe.20160904.2010

Htitiou, A., Boudhar, A., Lebrini, Y., & Benabdelouahab, T. (2020). Deep learning-based reconstruction of spatiotemporally fused satellite images for smart agriculture applications in a heterogeneous agricultural region. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 44, 249-254. doi: 10.5194/isprs-archives-XLIV-4-W3-2020-249-2020

Inglada, J., Vincent, A., Arias, M., & Marais-Sicre, C. (2016). Improved early crop type identification by joint use of high temporal resolution SAR and optical image time series. Remote Sensing, 8(5), 362. doi:10.3390/rs8050362

Luo, S., Wang, C., Xi, X., Zeng, H., Li, D., Xia, S., & Wang, P. (2015). Fusion of airborne discrete-return LiDAR and hyperspectral data for land cover classification. Remote Sensing, 8(1), 3. doi:10.3390/rs8010003

Narin, O. G., Bayik, C., Sekertekin, A., Madenoglu, S., Pinar, M. O., Abdikan, S. A. Y. G. I. N., & Balik Sanli, F. (2024). Crop height estimation of wheat using sentinel-1 satellite imagery: Preliminary results. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 48, 267-273.

Orynbaikyzy, A., Gessner, U., Mack, B., & Conrad, C. (2020). Crop type classification using fusion of Sentinel-1 and Sentinel-2 data: Assessing the impact of feature selection, optical data availability, and parcel sizes on the accuracies. Remote Sensing, 12(17), 2779. doi: 10.3390/rs12172779

Öztürk, D., & Akçay, Y. (2010). Güney Marmara Bölgesinde çeltik üretiminin genel bir değerlendirmesi. Journal of Agricultural Faculty of Gaziosmanpaşa University (JAFAG), 2010(2), 61-71.

SNAP - ESA Sentinel Application Platform v9, http://step.esa.int

Zhang, B., Li, K., Zhang, F., Shao, Y., Wang, D., & Lou, L. (2024). Rice Height Estimation with Multi-Baseline PolInSAR Data and Optimal Detection Baseline Combination Analysis. Remote Sensing, 16(2), 358. doi:10.3390/rs16020358

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Sınıf Dengesizliği Probleminde U-Net++ ve U-Net3+ Mimari Performanslarının Analizi

**Süheyla Piltan Altaş*[1], Fevzi Karslı[2],**

[1,]*Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Trabzon, Türkiye*
[2]*Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Trabzon, Türkiye*

**Anahtar Kelimeler**
U-Net ++,
U-Net 3+,
Yol Çıkarımı,
Derin Öğrenme

**ÖZET**

Hava görüntülerinden otomatik yol çıkarımı bilgisayarlı görme, şehir planlaması, Coğrafi Bilgi Sistemleri (CBS), trafik denetleme, otonom sürüş, ulaşım planlama gibi birçok alanda yayın olarak kullanılmaktadır. Görüntülerde arka planın baskın olması, düşük çözünürlüklü verilerde detayların kaybolması, yol sınıfına benzer spektral özellik gösteren çevresel etkenlerin varlığı, yol tip ve şekillerinin çeşitliliği karşılaşılan temel zorluklardan bazılarıdır. Farklı problemlere ilişkin geliştirilen derin öğrenme mimarileri ile yol çıkarımı üzerine gerçekleştirilen çalışmalar son yıllarda hız kazanmıştır. Ancak gerçekleştirilen çalışmalar göstermiştir ki, özellikle sınıf dengesizliği problemi seçilen modelin eğitim sürecini olumsuz etkilemektedir. Veri setlerindeki sınıfların dağılımı, derin öğrenme mimarilerinin başarısını etkilemektedir. Bu çalışmada, Massachusetts Yolları Veri Seti üzerinde U-Net mimarisi temel alınarak geliştirilen U-Net++ ve U-Net 3+ mimarileri eğitilmiş, model başarıları doğruluk, hassasiyet, duyarlılık, F1 skoru ve IoU performans metrikleri ile irdelenmiştir. U-Net ++ stabil öğrenme süreci ile daha iyi performans göstererek yol tespitinde U-Net 3+ mimarisinden daha yüksek başarı sağlamıştır.

# Analysis of U-Net++ and U-Net3+ Architectural Performances in Class Imbalance Problem

**Keywords**
U-Net ++,
U-Net 3+,
Road Extraction,
Deep Learning

**ABSTRACT**

Automatic road extraction from aerial imagery is widely used in many fields such as computer vision, urban planning, Geographic Information Systems (GIS), traffic monitoring, self-driving, and transport planning. Some of the main difficulties encountered are the dominance of the background in the images, the loss of details in low resolution data, the presence of environmental factors with similar spectral characteristics to the road class, and the diversity of road types and shapes. Studies on road extraction with deep learning architectures developed for different problems have increased in recent years. However, studies have shown that especially the problem of class imbalance negatively affects the training process of the selected model. The distribution of classes in data sets affects the success of deep learning architectures. In this study, U-Net++ and U-Net 3+ architectures developed based on the U-Net architecture were trained on the Massachusetts Roads Dataset, and model performance was analysed with accuracy, precision, recall, F1 score and IoU performance metrics. U-Net ++ outperformed U-Net 3+ in road detection, showing better performance with a stable learning process.

## 1. GİRİŞ

Son yıllarda uzaktan algılama teknolojisindeki gelişmeler, yüksek çözünürlüklü hava görüntüleri üzerine çalışmaları arttırmıştır (Liu vd., 2021). Bu görüntüler, küçük objelerin dahi yüksek doğruluk ve hassasiyette tespitini mümkün kılmaktadır.

Yollar bir kentin temel unsurlarından biridir. Yol tespitine ilişkin geçmişten günümüze geliştirilen pek çok geleneksel yöntem mevcuttur. Bu yöntemler derin öğrenme tabanlı yöntemlere kıyasla daha fazla manuel müdahaleye gereksinim duymaktadır. Bu gereksinim algoritmaların veri tipine bağımlılıkları ile sonuçlanmaktadır ve genelleştirme kabiliyetlerini sınırlandırmaktadır. Ayrıca kullanıcı bağımlı süreçler tecrübe farklılıklarından kaynaklı hatalara açıktır.

Bilgisayar teknolojisindeki gelişmeler güçlü sistemleri beraberinde getirmiştir. Derin öğrenme

* **Sorumlu Yazar**
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**
Piltan Altaş S & Karslı F (2025). Sınıf Dengesizliği Probleminde U-Net++ ve U-Net3+ Mimari Performanslarının Analizi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

tabanlı mimariler eğitim aşamasında verinin en iyi gösterimine ulaşmayı hedeflerler (Chollet, 2021). Bu mimariler genelleştirilebilir olmaları ve otomasyon özellikleri ile öne çıkmaktadırlar. Ancak bu mimarilerin zaman zaman veri sınıfları arası denge, veri kalitesi ve sayısı, yüksek hesaplama maliyetleri başta olmak üzere karşılaştıkları birtakım zorluklar bulunmaktadır.

Bu çalışmada evrişimli sinir ağı temelli U-Net (Ronneberger vd., 2015) mimarisinden esinlenerek tasarlanan U-Net++ (Zhou vd., 2018) ve U-Net 3+ (Huang vd., 2020) mimarilerinin yüksek çözünürlüklü hava görüntüleri üzerinden yol çıkarım performansları irdelenmiştir. Analizler açık bir veri seti olan Massachusetts Yolları Veri Seti (Mnih, 2013) üzerinde gerçekleştirilmiştir. Veri seti yoğun arka plan bilgisi ile yol sınıfına ait oldukça sınırlı bilgi içermektedir. Ayrıca kentsel ve kırsal alanlara ait hava görüntüleri ile farklı yol tiplerinin bir arada analizini mümkün kılmaktadır. Çalışma kapsamında model başarıları doğruluk, hassasiyet, duyarlılık, F1 skoru ve IoU performans metrikleri ile irdelenmiş, dengesiz sınıflara sahip veri setinin eğitim sürecine etkisi araştırılmıştır.

## 2. YÖNTEM

### 2.1. U-Net ++ ve U-Net 3+ Mimarileri

Klasik U-Net mimarisinde kodlayıcı – kod çözücü bloklar arasında atlama bağlantıları bulunur. Ancak bu bağlantılar özellik haritaları arası bilgi kayıplarına neden olabilir. 2018 yılında yayınlanan çalışmada (Zhou vd., 2018) kodlayıcı-kod çözücü bloklar arasına bir ağ yapısı ile entegre edilen iç içe yoğun atlama bağlantılarının söz konusu semantik bilgi kaybını azalttığı tespit edilmiş ve U-Net++ adı verilen yeni bir mimari tasarım tanıtılmıştır.

U-Net 3+, U-Net++ mimarisini temel alan bir mimaridir. Araştırmacılar (Huang vd., 2020), U-Net++ mimarisinin yoğun yapısını geliştirerek kodlayıcı – kod çözücü arası tam ölçekli atlama bağlantısı yapısını tanıtmışlardır. Farklı çözünürlükteki özellik haritalarına ait bilgilerin bir arada kullanımının yalnızca doğruluk performansını değil, azaltılmış ağ parametreleri ile hesaplama verimliliğini de arttırdığını belirtmişlerdir. Ayrıca geliştirilen model ara katmanları öğrenme sürecine katarak eğitim sürecini geliştirmektedir.

### 2.2. Veri Seti

Uygulamada Massachusetts Yolları Veri Seti kullanılmıştır. Kırsal ve kentsel alanları içeren görüntüler, farklı yol tiplerinin bir arada analizini mümkün kılmaktadır. Yol sınıflandırması tabanlı veri setlerinde olduğu gibi, bu veri setinde de yoğun bir arka plan bilgisi mevcuttur.

### 2.3. Performans Metrikleri

Model performanslarının analizinde kullanılan metrikler verilmiştir:

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$\text{Hassasiyet} = \frac{TP}{TP+FP} \quad (2)$$

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (3)$$

$$\text{F1 Skoru} = \frac{2 \times \text{Hassasiyet} \times \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}} \quad (4)$$

$$\text{IoU} = \frac{\text{Örtüşme Alanı}}{\text{Birleşme Alanı}} \quad (5)$$

Burada TP doğru pozitif, TN doğru negatif, FP yanlış pozitif ve FN yanlış negatif değerlerini temsil etmektedir.

İlave olarak, U-Net++ ve U-Net 3+ mimarileri ile gerçekleştirilen eğitim süreleri kaydedilerek model verimlilikleri analiz edilmiştir.

### 2.4 Yapılan Çalışmalar

Veri seti 256×256 piksellik alanlara ayrılarak mimariye uygun hale getirilmiş; 2000 eğitim, 250 doğrulama ve 250 test olmak üzere toplam 2500 görüntü ile yeniden oluşturulmuştur.

Mimari eğitimleri Python ortamında Tensorflow ve Keras kütüphaneleri ile GTX 1060 grafik kartı üzerinde gerçekleştirilmiştir.

Eğitimlerde Adam optimizer kullanılmış, öğrenme oranı 0.0001, batch boyutu 4 olarak seçilmiştir. Erken durdurma sınırı 10 epok, başlangıç epoğu 100 epoktur. Kayıp fonksiyonu olarak özellikle dengesiz veri setleri için önerilen İkili Çapraz Entropi ve Dice kayıp fonksiyonları sırası ile 0.7 ve 0.3 oranında ağırlıklandırılarak bir arada kullanılmıştır.

## 3. BULGULAR

Modellerin test verileri ile analizi sonucu performans metrikleri çıktıları Çizelge 1'de verilmiştir.

**Çizelge1.** Performans metrikleri.

| Metrikler | U-Net++ | U-Net 3+ |
|---|---|---|
| Doğruluk | 0.9848 | **0.9850** |
| Hassasiyet | 0.7131 | **0.7475** |
| Duyarlılık | **0.7246** | 0.6674 |
| F1 Skoru | **0.7188** | 0.7052 |
| IoU | **0.5611** | 0.5446 |
| Eğitim Süresi (dakika) | **81.88** | 127.00 |

Model eğitim sürecine ilişkin epok – kayıp grafikleri U-Net++ ve U-Net 3+ mimarileri için ayrı ayrı verilmiştir (Şekil 1).

U-Net++ ve U-Net 3+ modellerinin performans görselleştirmeleri Şekil 2'de verilmiştir. İlk sütunlar test görüntüleri ve etiketleri ile, ikinci sütunlar ise test görüntüleri üzerinde gerçekleştirilen model tahminleri ile oluşturulmuştur.

## 4. TARTIŞMA

Performanslara ilişkin Çizelge 1 incelendiğinde duyarlılık, F1 skoru ve IoU metriklerinde U-Net++'ın daha üstün performans gösterdiği saptanmıştır. Doğruluk ve hassasiyet metriklerinde ise U-NET 3+ daha üstün performans göstermiştir. Ayrıca U-Net 3+'ın eğitim süresi, diğer mimariye kıyasla çok daha uzun sürmüştür.

Eğitim süreçlerine ilişkin kayıplar incelendiğinde (Şekil 1) U-NET ++ mimarisinin 16. epokta minimum doğrulama kaybı skoruna ulaştığı görülmüştür. Her iki

eğitimde doğrulama ve eğitim kayıpları genel olarak azalma eğiliminde olmuştur. Ancak U-Net 3+ mimarisinde doğrulama kayıpları 6-14. epoklar arası dalgalı seyir izlerken, U-Net ++ durma noktasına kadar stabil şekilde azalma eğilimi göstermiştir.

Genel olarak U Net ++'ın U-Net 3+'a göre daha kararlı bir öğrenme süreci geçirdiği söylenebilir.

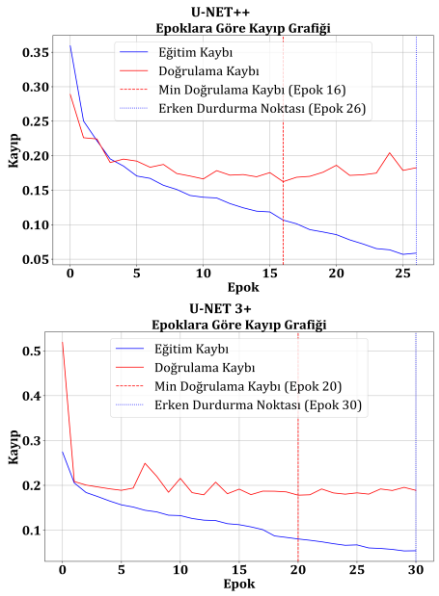


**Şekil 1.** Mimari eğitim süreçlerine ilişkin epok-kayıp grafikleri.

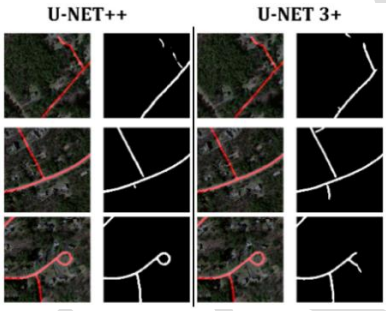


**Şekil 2.** U-Net++ ve U-Net3+ tespit performansları

Şekil 2 incelendiğinde U-Net++ mimarisinin diğer mimariye göre özellikle ağaçlık alanlarda yol tespitinde zorlandığı görülmüştür. Ancak U-Net 3+ da yol ile benzer spektral özellik gösteren bölgelerde yanlış pozitifler üretmiştir. Kıvrımlı yol yapılarında ise genel olarak U-Net++ daha yüksek sınıflandırma performansı ile öne çıkmaktadır.

## 5. SONUÇ

Veri seti sınıfları arası dengesiz dağılım, derin öğrenme mimarilerini performansını etkileyen temel unsurlardan biridir. Hava görüntülerinden yol tespiti uygulamaları görüntülerin yoğun arka plan içermesi, yol sınıfının ince ve şekilsiz yapısı, benzer spektral özellik gösteren nesneler ile yaşanan sınıf karmaşası gibi unsurlardan dolayı zorlu bir problemdir.

Bu çalışmada U-Net'in gelişmiş versiyonu olan U-Net++ ve U-Net 3+ mimarilerinin yol çıkarım performansları değerlendirilmiştir. Genel olarak U-Net ++ stabil öğrenme süreci ile daha iyi performans göstererek yol tespitinde yüksek başarı sağlamıştır.

Gelecek çalışmalarda değişken veri setleri üzerinde analizler gerçekleştirilerek farklı parametre değerlerinde mimarilerin davranışlarının kapsamlı bir şekilde irdelenmesi hedeflenmektedir.

### Yazar Katkı Oranı

Birinci yazar (Süheyla PİLTAN ALTAŞ): Mimarilerin tasarımı, model eğitimleri ve testleri, veri analizi, metin yazımı

İkinci yazar (Fevzi KARSLI): Sonuçların yorumlanması, metin düzenlemesi

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

### KAYNAKÇA

Chollet, F. (2021). Python ile Derin Öğrenme (2. Baskı). Buzdağı Yayınevi, Ankara.

Huang, H., Lin, L., Tong, R., Hu, H., Zhang, Q., Iwamoto, Y., ... & Wu, J. (2020, Mayıs). Unet 3+: A full-scale connected unet for medical image segmentation. ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 1055–1059. IEEE.

Liu, Z., Wang, M., Wang, F., & Ji, X. (2021). A residual attention and local context-aware network for road extraction from high-resolution remote sensing imagery. Remote Sensing, 13(24), 4958.

Mnih, V. (2013). Machine Learning for Aerial Image Labeling. (Doktora Tezi), University of Toronto, Kanada.

Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015, 18(3), 234–241. Springer.

Zhou, Z., Rahman Siddiquee, M. M., Tajbakhsh, N., & Liang, J. (2018). Unet++: A nested u-net architecture for medical image segmentation. Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop, DLMIA 2018, and 8th International Workshop, ML-CDS 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 20, 2018, Proceedings 4, 3–11. Springer International Publishing.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Bina Enerji Performansı Skoru Tahmini için Mekânsal Zekâ (GeoAI) Uygulama Analiz Araçlarının Geliştirilmesi

**Büşra Demirci [1], Süleyman Şişman[1], Arif Çağdaş Aydınoğlu[*1]**

[1]*Gebze Teknik Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği, Kocaeli, Türkiye*

**Anahtar Kelimeler**
Coğrafi Bilgi Sistemleri,
Makine Öğrenmesi,
Enerji Verimliliği,
Büyük Mekansal Veri

**ÖZET**

Son yıllarda teknolojinin hızla gelişmesiyle birlikte, uydu görüntüleri, insansız hava aracı (İHA) verileri ve sensör ağları gibi çeşitli kaynaklardan büyük hacimli mekânsal veriler üretilmektedir. Bu veri yoğunluğu, kentlerin sürdürülebilir şekilde yönetilebilmesi ve doğru karar destek sistemlerinin oluşturulması açısından büyük önem taşımaktadır. Ancak geleneksel analiz teknikleri, bu verilerin işlenmesi ve anlamlandırılması konusunda çoğu zaman yetersiz kalmaktadır. Bu noktada günümüzde, yapay zekâ destekli analiz yaklaşımları özellikle Coğrafi Bilgi Sistemleri (CBS) ile birlikte kullanıldığında mekânsal verilerin daha etkin analiz edilmesini sağlamakta; veriler arasındaki karmaşık ilişkileri çözümleyerek anlamlı tahminler yapılmasına imkân tanımaktadır. Makine öğrenmesi, doğal dil işleme gibi yapay zekâ teknikleri sayesinde geliştirilen öngörücü modeller, enerji verimliliği, çevresel sürdürülebilirlik ve şehir planlama gibi alanlarda stratejik kararların alınmasında etkili rol oynayan GeoAI (Mekânsal Zekâ) kavramının önemini arttırmıştır. Bu çalışma kapsamında; Arcpy kütüphanesinin CBS yeteneklerinin değerlendirilmesi, GeoAI algoritmalarıyla entegre çalışabilen ve makine öğrenmesinin regresyon modellerine hitap eden 7 adet analiz araçlarının geliştirilmesi ve şehirlerde enerji verimliliğini artırmaya yönelik bina enerji performansı skorlarını tahmin edebilen bir uygulamanın oluşturulması amaçlanmaktadır. Bu skorun doğru tahmin edilmesi, enerji tasarrufu potansiyelinin belirlenmesi ve kaynakların daha verimli kullanılmasına katkı sağlamaktadır.

# Development of Geospatial Intelligence (GeoAI) Application Analysis Tools for Building Energy Performance Score Prediction

**Keywords**
Geographic Information System,
Machine Learning,
Energy Efficiency,
Big Spatial Data

**ABSTRACT**

In recent years, with the rapid development of technology, large volumes of spatial data are being produced from various sources such as satellite images, unmanned aerial vehicle (UAV) data and sensor networks. This data density is of great importance for the sustainable management of cities and the creation of accurate decision support systems. However, traditional analysis techniques are often inadequate in processing and interpreting this data. At this point, artificial intelligence-supported analysis approaches, especially when used together with Geographic Information Systems (GIS), provide more effective analysis of spatial data; and enable meaningful predictions to be made by analyzing complex relationships between data. Predictive models developed thanks to artificial intelligence techniques such as machine learning and natural language processing have increased the importance of the GeoAI (Spatial Intelligence) concept, which plays an effective role in making strategic decisions in areas such as energy efficiency, environmental sustainability and urban planning. Within the scope of this study; It is aimed to evaluate the GIS capabilities of the Arcpy library, develop 7 analysis tools that can work integrated with GeoAI algorithms and address the regression models of machine learning, and create an application that can predict building energy performance scores to increase energy efficiency in cities. Accurate estimation of this score contributes to the determination of energy saving potential and more efficient use of resources.

[*] **Sorumlu Yazar**

(b.demirci2021@gtu.edu.tr) ORCID ID 0009-0005-3585-8992
(ssisman@gtu.edu.tr) ORCID ID 0000-0002-0924-1092
[*](aydinoglu@gtu.edu.tr) ORCID ID 0000-0003-4912-9027

**Kaynak Göster (APA):**

Demirci B, Şişman S, Aydınoğlu A Ç (2025). Mekânsal Zekâ (GeoAI) Uygulama Analiz Araçlarının Geliştirilmesi ve Bina Enerji Performansı Skoru Tahmin Uygulaması, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

TADUAK

## 1. GİRİŞ

Günümüzde mekânsal verilerin hacmi, uydu görüntüleri, İHA verileri ve sensör ağları gibi teknolojilerle hızla artmakta; bu durum, sürdürülebilir şehir yönetimi ve etkili karar destek sistemleri geliştirilmesini zorunlu kılmaktadır. Bu noktada, Coğrafi Bilgi Sistemleri (CBS) ile entegre çalışan yapay zekâ tabanlı yaklaşımlar, veri analizinde güçlü çözümler sunmaktadır (Li vd.,2024).

Python programlama dili ile ArcGIS platformunda geliştirilen 7 farklı araç kutusu da bu yaklaşıma katkı sunmayı hedeflemektedir (Sahin vd.,2020). Bu araçlar; aykırı değer tespiti (Sisman ve Aydinoglu, 2022), veri standardizasyonu (Kappal,2019), değişken seçimi (Wang, 2023) ve eğitim-test veri ayırma gibi ön işleme adımlarının yanı sıra GBM (Hao vd.,2024) ve XGBoost (Iban,2022) algoritmalarıyla regresyon modeli kurulmasını sağlamaktadır. Geliştirilen son araç ise MAE, MAPE, RMSE ve $R^2$ gibi metriklerle model performansını değerlendirmektedir (Alburshaid vd.,2024). Geniş veri setlerinin yönetimi, tahminleme modelleri ile bina enerji performansı gibi konularda kullanılabilecek bu araçlar, mekânsal zekâ uygulamalarının yaygınlaşmasına katkıda bulunmakta olup; ayrıca, yalnızca bina enerji skoru tahminiyle sınırlı kalmadan, diğer regresyon problemlerinde de esnek bir şekilde kullanılabilecek şekilde tasarlanmıştır.

## 2. YÖNTEM

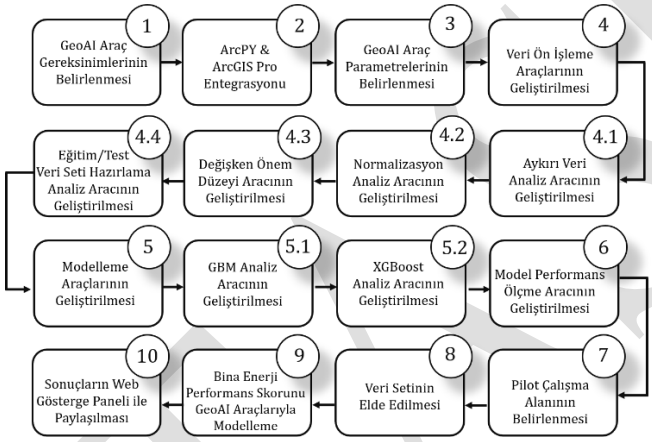


**Şekil 1.** Çalışma metodolojisi

### 2.1. GeoAI Analiz Araç Paketinin Geliştirilmesi

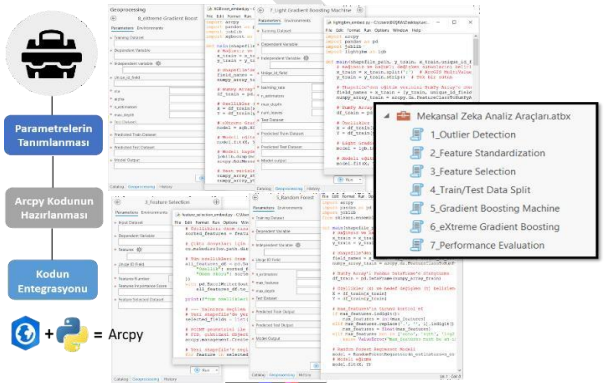


**Şekil 2.** Geliştirilen araç paketinin arayüzü

Analiz araç paketinin geliştirilmesinde çeşitli Python kütüphanelerinden yararlanılmıştır. Makine öğrenmesi tabanlı regresyon modelleri için Scikit-learn, sayısal hesaplamalar için NumPy, veri düzenleme ve dönüştürme işlemleri için Pandas kütüphaneleri kullanılmıştır. Ayrıca, model sonuçlarının görselleştirilmesi için Matplotlib ve Seaborn'dan faydalanılmıştır (Pedregosa vd.,2011).

ArcGIS platformunun avantajlarından biri, içinde yer almayan kütüphanelerin dışarıdan entegre edilebilmesidir. Bu sayede, XGBoost modeli için xgboost kütüphanesi sisteme eklenerek başarıyla çalıştırılmıştır. Dolayısıyla çalışmada ArcGIS platformunun Python ve ArcPy kütüphanesi ile diğer kütüphanelerin entegrasyonu sayesinde yenilikçi makine öğrenmesi tekniklerinin kullanılarak mekânsal zekâ odaklı çeşitli araç kutularının başarıyla geliştirilebildiği görülmüştür.

## 3. GeoAI ANALİZ ARAÇLARI İLE BİNA ENERJİ PERFORMANS SKORU TAHMİNİ

Günümüz şehirlerinde nüfusun artması ve hızlı sanayileşmenin etkisiyle enerjiye olan talep ve enerji tüketimi büyük ölçüde artmıştır. Özellikle binalarda tüketilen enerji miktarının giderek artması, binaların enerji performanslarının belirlenmesini kritik duruma getirmiştir. Bu amaçla çalışmanın geri kalanında, geliştirilen Mekânsal Zekâ (GeoAI) analiz araçları ile şehirlerde enerji verimliliğinin sağlanmasına yönelik bina enerji performans skoru tahmin uygulaması gerçekleştirilmiştir. Ülkemizde Çevre, Şehircilik ve İklim Değişikliği Bakanlığı tarafından 1 Ocak 2011 tarihinde yürürlüğe konulan ve binaların metrekare başına düşen yıllık enerji tüketimini belgeleyen Enerji Kimlik Belgesi (EKB) verileri, bu çalışma kapsamında pilot bölge olarak seçilen Tuzla ilçesi için Web Scraping ve Doğal Dil İşleme (NLP) teknikleri kullanılarak elde edilmiştir. İstanbul'un en doğusunda yer alan Tuzla, 2023 yılı itibarıyla 293.604 kişilik nüfusa ve 138 $km^2$ yüzölçümüne sahiptir. Güneyde Marmara Denizi'ne kıyısı bulunan ilçede 17 mahalle yer almaktadır. Çalışma kapsamında bu ilçede yer alan 4637 adet binaya ait Enerji Kimlik Belgesi parametreleri değerlendirilmiştir. Bu parametreler Bina Özellikleri, Bina Dış Yüzey Özellikleri, Yıllık Bina Enerji Tüketimi ve Bina Mekanik Özellikleri olmak üzere 4 ana kategoride incelenmiştir. Geliştirilen analiz araçları ile bina enerji veri ön işlemesi gerçekleştirilmiş, %70 Eğitim (3245) ve %30 Test (1392) oranlarında veri setleri oluşturulmuştur. Eğitim veri seti ile GBM ve XGBoost tahmin modelleri geliştirilmiş ardından bu modellerinin performansı değerlendirilmiştir.

## 4. SONUÇ

Bina Enerji Performans Oranı'nın bağımlı değişken, diğer 30 değişkenin ise bağımsız değişken olarak tanımlandığı tahmin modellerinin performansları, $R^2$, MAE, MAPE gibi metrikler kullanılarak değerlendirilmiştir. Elde edilen sonuçlar $R^2$ metriğine göre yorumlandığında; XGBoost algoritması 0.82 ile yüksek doğruluk oranını sağlamışken, GBM algoritması 0.78 ile XGBoost algoritmasına göre daha düşük başarıgöstermiştir (Şekil.3). XGBoost algoritması için

hiperparametre optimizasyonu ise n_estimators:150, eta:0.1, max_depth:7, gamma:0 şeklinde gerçekleştirilmiştir. Ayrıca, elde edilen tüm sonuçlar Web Gösterge Paneli aracılığıyla dinamikleştirilmiş görsel tekniklerle kullanıcıyla paylaşılmıştır (Şekil.4).

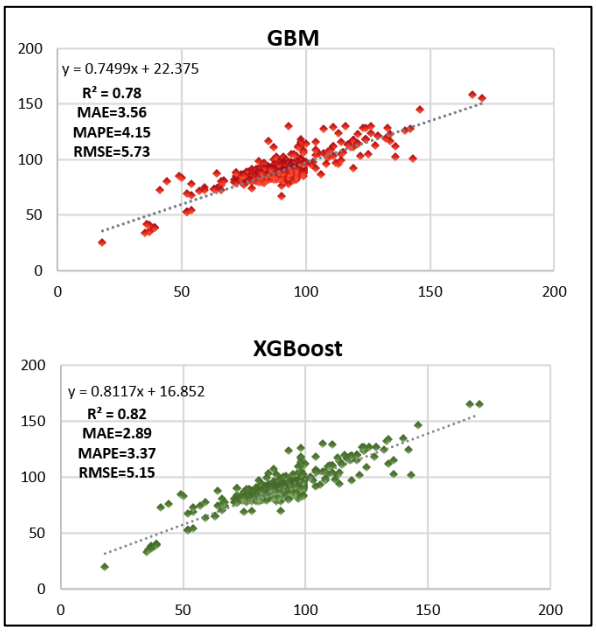


**Şekil 3.** Algoritmalarının regresyon grafikleri

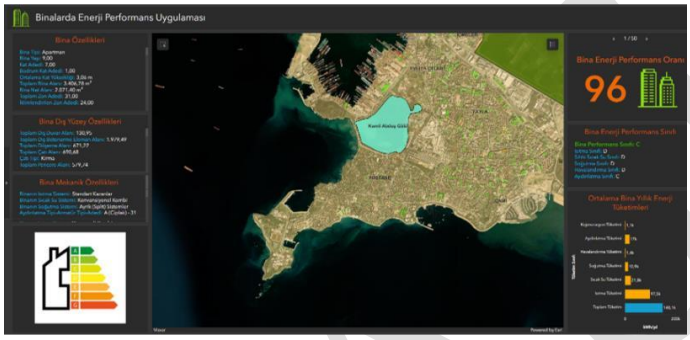


**Şekil 4.** Web Gösterge Paneli

## TEŞEKKÜR

Bu çalışma TÜBİTAK tarafından desteklenen 122R021 nolu 1001 projesi kapsamında gerçekleştirilmiştir.

## Yazar Katkı Oranı

**Büşra Demirci:** Yazılım, Görselleştirme, Literatür Taraması, Yazım **Süleyman Şişman:** Düzenleme, Kavramsallaştırma, Veri Analizi, Modelleme **Arif Çağdaş Aydınoğlu:** Fikir, Kavramsallaştırma, Metodoloji

## Çıkar Çatışması/Çakışması

Yazarlar, bu çalışmada bilinen ilgili herhangi bir finansal veya finansal olmayan çıkar çatışması olmadığını beyan eder.

## KAYNAKÇA

Alburshaid, E. A., & Al-Alawi, A. I. (2024, January). Forecasting Methods for the Real Estate Market: A Review. In 2024 ASU International Conference in Emerging Technologies for Sustainability and Intelligent Systems (ICETSIS) (pp. 472-477). IEEE.

Hao, Q., Zhang, T., Cheng, X., He, P., Zhu, X., & Chen, Y. (2024). GIS-based non-grain cultivated land susceptibility prediction using data mining methods. *Scientific Reports*, *14*(1), 4433.

Iban, M. C. (2022) An explainable model for the mass appraisal of residences: The application of tree-based Machine Learning algorithms and interpretation of value determinants. *Habitat international*, *128*, 102660.

Li, W., Arundel, S., Gao, S., Goodchild, M., Hu, Y., Wang, S., & Zipf, A. (2024) GeoAI for Science and the Science of GeoAI. *Journal of Spatial Information Science*, (29), 1-17.

Sahin, E. K., Colkesen, I., Acmali, S. S., Akgun, A., Aydinoglu, A. C. (2020) Developing comprehensive geocomputation tools for landslide susceptibility mapping: LSM tool pack. *Computers & geosciences*, *144*, 104592.

Sisman, S., Aydinoglu, A. C. 2022. "Improving performance of mass real estate valuation through application of the dataset optimization and Spatially Constrained Multivariate Clustering Analysis", *Land Use Policy*, *119*.

Wang, Z. (2023). Research on feature selection methods based on random forest. *Tehnički vjesnik*, *30*(2), 623-633.

Pedregosa, F.; Varoquaux, G.; Gramfort, A.; Michel, V.; Thirion, B.; Grisel, O.; Blondel, M.; Prettenhofer, P.; Weiss, R.; Dubourg, V.; et al. Scikit-learn: Machine learning in Python. J. Mach. Learn. Res. 2011, 12, 2825–2830. [CrossRef]

Kappal, S. (2019). Data normalization using median median absolute deviation MMAD based Z-score for robust predictions vs. min–max normalization. *London Journal of Research in Science: Natural and Formal*, *19*(4), 39-4

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Panoramik Görüntülerden Derin Öğrenme Segmentasyonu ile Gökyüzü Görünüm Faktörü Tahmini ve Kentsel Morfoloji ile Nicel İlişkisi

**Şükrü Burak Çetin**[1]

[1]*İstanbul Büyükşehir Belediyesi, Coğrafi Bilgi Sistemleri Müdürlüğü, İstanbul*

**Anahtar Kelimeler**
Gökyüzü Görünüm Faktörü (SVF),
Kentsel Morfoloji,
Derin Öğrenme,
Panoramik Görüntü Anaizi

**ÖZET**

Kent morfolojisi ile gökyüzü görüş faktörü (SVF) arasındaki ilişkiyi incelemek, şehirlerde güneş enerjisi potansiyelinin ve kentsel çevre kalitesinin değerlendirilmesinde önemli bir rol oynamaktadır. Bu araştırma makalesi, farklı kentsel formların SVF üzerindeki etkilerini değerlendiren bir yaklaşım sunmaktadır. İlk olarak, İstanbul Büyükşehir Belediyesi tarafından sağlanan 2017-2019 yıllarına ait farklı kamera bölgelerinden elde edilen 624.832 panorama görüntü parçası(2017-2019), 3D grafiklerde verimli bir şekilde işlenebilmesi ve düşük distorsiyon ile daha doğal bir çevre temsili sağlayan küp harita izdüşümüne (Cubemap Projection) dönüştürülmüştür. Ardından, bu küp harita izdüşümüne çevrilmiş panorama görüntüleri, küresel bir görüntüyü dikdörtgen bir formata dönüştürerek tüm açılardan eksiksiz bir görünüm sağlayan eşdikdörtgensel izdüşüme (Equirectangular Projection) dönüştürülmüştür. Son olarak da, bu panorama görüntüleri SVF'nin hesaplanabilmesi için balık gözü (fisheye) görüntülerine dönüştürülmüş ve Konvolüsyonel Sinir Ağları (CNNs) ve Üretken Çekişmeli Ağlar (GANs) yeteneklerine sahip olan Segment Anything Model 2 (SAM2) ile derin öğrenme temelli segmentasyon gerçekleştirilerek 156.208 panorama görüntüsü analiz edilmiştir. Görüntülerin 95.098'i Kadıköy ilçesinden, 61.110'u ise Fatih ilçesinden alınarak çalışma yürütülmüştür. SVF, bu görüntülerden elde edilen piksel istatistikleri yöntemiyle hesaplanmıştır. Analiz, SVF'nin çeşitli kentsel morfolojilere nasıl dağıldığını ve hangi kentsel yapıların daha yüksek veya daha düşük SVF değerlerine sahip olduğunu ortaya koymuştur. Elde edilen sonuçlar, yoğun yapılaşmış alanların daha düşük SVF değerlerine sahip olduğunu, açık alanların ise daha yüksek SVF değerlerine sahip olduğunu göstermiştir. Bu bulgular, kentsel planlama ve tasarım süreçlerinde SVF'nin dikkate alınmasının, güneş enerjisi verimliliğini ve kentsel yaşam kalitesini artırmak için kritik olduğunu göstermekte olup, bu araştırma, kentsel güneş enerjisi potansiyelinin ve çevresel kalitenin değerlendirilmesinde SVF'nin rolünü vurgulamaktadır.

# Sky View Factor Estimation from Panoramic Images via Deep Learning Segmentation and Its Quantitative Relationship with Urban Morphology

**Keywords**
Sky View Factor (SVF),
Urban Morphology,
Deep Learning,
Panoramic Image Analysis

**ABSTRACT**

Understanding the relationship between urban morphology and the Sky View Factor (SVF) is essential for assessing solar energy potential and environmental quality in urban areas. This study proposes an approach to evaluate the influence of varying urban forms on SVF. A total of 624,832 panoramic image segments from different camera regions, provided by the Istanbul Metropolitan Municipality (2017–2019), were initially converted to Cubemap Projection. This format enables efficient 3D rendering and offers a more natural environmental representation with reduced distortion. These Cubemap images were subsequently transformed into Equirectangular Projection, allowing for a complete panoramic view in a rectangular format. Finally, they were converted into fisheye images suitable for SVF calculation. Deep learning-based segmentation was performed using the Segment Anything Model 2 (SAM2), integrating Convolutional Neural Networks (CNNs) and Generative Adversarial Networks (GANs), resulting in the analysis of 156,208 panoramic images—95,098 from the Kadıköy district and 61,110 from the Fatih district. SVF values were derived through pixel-based statistical analysis. The findings revealed the spatial distribution of SVF across different urban morphologies, identifying which urban structures correspond to higher or lower SVF values. Specifically, densely built environments exhibited lower SVF values, while open spaces demonstrated higher SVF values. These results highlight the necessity of incorporating SVF considerations into urban planning and design to promote solar energy utilization and enhance environmental quality. Overall, this research underscores the pivotal role of SVF in the sustainable development of urban areas.

* **Sorumlu Yazar**

*(sukruburak.cetin@ibb.gov.tr) ORCID ID 0009-0002-7924-419X

**Kaynak Göster (APA):**

Çetin Ş B (2025). *Panoramik Görüntülerden Derin Öğrenme Segmentasyonu ile Gökyüzü Görünüm Faktörü Tahmini ve Kentsel Morfoloji ile Nicel İlişkisi*, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20

## 1. GİRİŞ

Güneş enerjisi potansiyelinin kentsel ölçekte değerlendirilmesi, sürdürülebilir şehir planlaması ve yenilenebilir enerji kullanımının artırılması açısından kritik bir öneme sahiptir. Bu değerlendirmede kullanılan başlıca parametrelerden biri olan Gökyüzü Görünürlük Faktörü (Sky View Factor - SVF), bir noktanın gökyüzüne olan açıklığını nicel olarak ifade eder ve kentsel yapının mekânsal yoğunluğu hakkında önemli bilgiler sunar. SVF, yalnızca güneş erişimini değil, aynı zamanda ısı adası etkisi, doğal aydınlatma ve hava kalitesi gibi çevresel göstergeleri de doğrudan etkiler.

Literatürde SVF'nin mekânsal dağılımının değerlendirilmesi için çeşitli yöntemler geliştirilmiştir. Özellikle LiDAR ve 3D modelleme tekniklerine dayalı çalışmalar kent yüzeylerinin ayrıntılı biçimde modellenmesine imkân tanırken, bu yöntemler çoğunlukla yüksek işlem gücü ve veri maliyetleri nedeniyle sınırlı uygulanabilirliğe sahiptir. Alternatif olarak, sokak görünümünden elde edilen panoramik görüntülerle SVF tahmini yapan görüntü işleme tabanlı yaklaşımlar da son yıllarda ön plana çıkmıştır. Bu yaklaşımlar, sahadan veri toplamadan SVF ölçümü yapabilme avantajı sayesinde büyük ölçekli analizlere olanak tanır.

Bu çalışma, İstanbul'un Kadıköy ve Fatih ilçelerinde 2017-2019 yılları arasında İstanbul Büyükşehir Belediyesi tarafından sağlanan 624.832 panoramik görüntüyü kullanarak, farklı kentsel biçimlerin SVF üzerindeki etkisini büyük veri ve yapay zekâ destekli bir yöntemle analiz etmeyi amaçlamaktadır. Görüntüler sırasıyla Cubemap ve Equirectangular projeksiyonlara dönüştürülmüş, ardından balık gözü (fisheye) formatına çevrilerek SVF hesaplamaları için uygun hale getirilmiştir. Görüntü segmentasyonu, Convolutional Neural Networks (CNN) ve Generative Adversarial Networks (GAN) mimarilerini birleştiren Segment Anything Model 2 (SAM2) kullanılarak gerçekleştirilmiştir. Toplamda 156.208 panoramik görüntü analiz edilmiş; bunların 95.098'i Kadıköy, 61.110'u ise Fatih ilçesine aittir. Piksel tabanlı analizler sonucunda SVF değerleri hesaplanmış ve yapı yoğunluğu, ile SVF arasında ters orantılı, sokak morfolojileri ile de doğrusal bir ilişki olduğu ortaya konmuştur. Bu bulgular, güneş ışığına erişimin kentsel form tarafından nasıl kısıtlandığını göstermekte ve SVF'nin kentsel tasarım kararlarında dikkate alınması gereken temel bir metrik olduğunu vurgulamaktadır.

## 2. YÖNTEM

Bu çalışmada, Gökyüzü Görünürlük Faktörü (SVF) tahmini için İstanbul Büyükşehir Belediyesi tarafından 2017-2019 yılları arasında toplanan yüksek çözünürlüklü panorama görüntüleri kullanılmıştır. Veriler, Figür 1'deki gibi Cyclomedia Panorama API üzerinden altı farklı kamera yönünü temsil eden Back-Left-Front-Right-Up-Down (B-L-F-R-U-D) formatında seviye 2 kalitesinde indirilmiştir.




**Figür 1:** Seviye 2 Panorama Görüntüleri

İlk olarak, bu altı yönlü görüntüler birleştirilerek Figür 2'deki gibi düşük distorsiyonlu bir çevresel temsile olanak tanıyan Cubemap projeksiyonu oluşturulmuştur. Ardından, Cubemap görüntüler Figür 3'deki gibi Equirectangular projeksiyona dönüştürülerek, 360 derece görüş sağlayan küresel bir görüntü formatı elde edilmiştir. Bu equirectangular görüntüler, Figür 4'teki gibi balık gözü (fisheye) projeksiyona çevrilerek SVF hesaplamaları için uygun hale getirilmiştir.

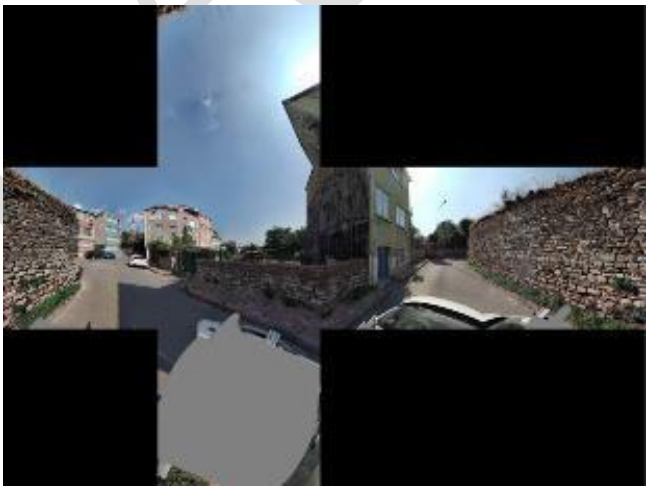

**Figür 2:** Cubemap Projeksiyonu

Fisheye görüntüler üzerinde gökyüzü segmentasyonu, Segment Anything Model 2 (SAM2) kullanılarak gerçekleştirilmiştir. Segmentasyon işlemi (Figür 4-C), görüntü üzerinde merkez, kuzey, güney, doğu ve batı yönlerini temsil eden ve aralarında 50 piksel mesafe bulunan beş farklı merkez piksel seçimi ile yapılmıştır.



**Figür 3:** Equirectangular Projeksiyonu



**A)** Equirectangular Projeksiyon 90°(Zenith)



**B)** Fisheye Projeksiyonu



**C)** Sam 2 Model Gökyüzü Tespiti

**Figür 4:** Fisheye(balıkgözü) Projeksiyonu ve Aşamaları

Segmentasyon sonrası gökyüzü alanı, her biri 10°'lik açıya sahip 36 eş dairesel bölgeye bölünerek (Figür 5) piksel yoğunluğu hesaplanmış ve bu değer tüm alanla normalize edilerek SVF değeri elde edilmiştir. Elde edilen SVF verileri, MapLibre kütüphanesi aracılığıyla interaktif bir ısı haritası formatında görselleştirilmiştir.

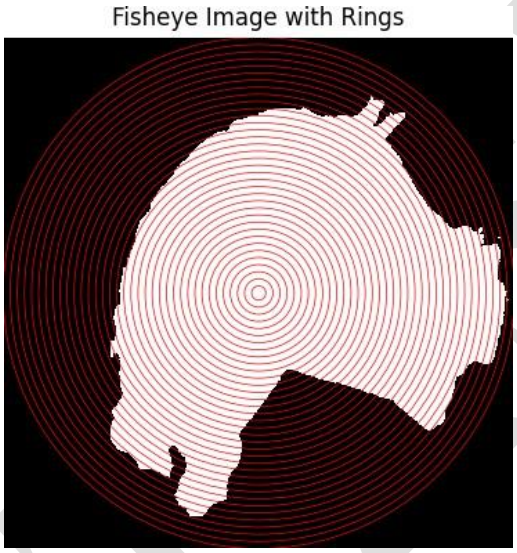


**Figür 5:** SVF Hesaplama Prensibi

Her panorama noktası için 10 metrelik buffer alanı tanımlanmış ve bu alanlar, İstanbul'un mevcut kent morfolojisi verileriyle (bina ayak izi, sokak eksenleri vb.)kesiştirilmiştir. Figür 6'daki gibi, kesişen alanlara göre eşdeğer dikdörtgen indeksi (ERI), uzama indeksi, binalar arası mesafe, bina bitişikliği, sokak doğrusallığı, sokak genişliği gibi morfolojik metrikler hesaplanmış ve her panorama noktası için ortalama değerler elde edilmiştir. Son olarak, bu morfolojik özelliklerin SVF ile olan ilişkileri nicel olarak incelenmiştir.

**Figür 6**: Kent Morfolojisi Değerlerinin SVF İle Olan Nicel İlişki Grafikleri

## 3. BULGULAR

Analiz edilen 156.208 panorama görüntüsünün

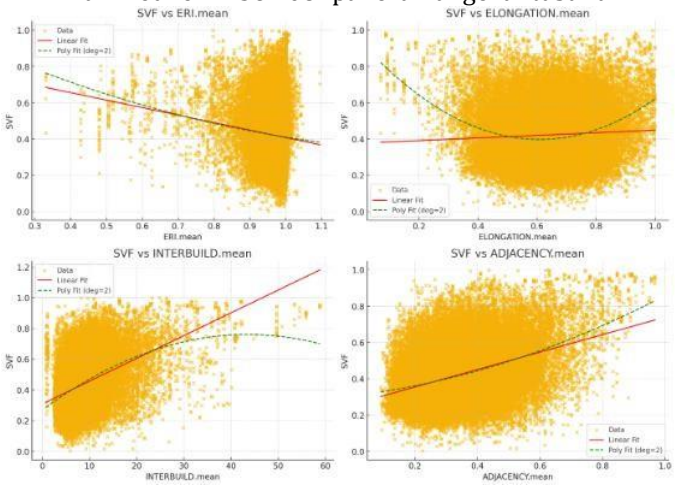


SVF değerleri ile kentsel morfoloji metrikleri arasında anlamlı ilişkiler saptanmıştır. Kadıköy (n=95.098) ve Fatih (n=61.110) ilçelerinde SVF dağılımı, yapı yoğunluğunun SVF üzerindeki etkisini açıkça göstermiştir. Özellikle, düşük SVF değerleri, yüksek yapı yoğunluğu, dar sokaklar ve yüksek bina bitişikliği olan alanlarda gözlemlenmiştir. Yüksek SVF değerleri, açık alanlara sahip, binalar arası mesafenin fazla olduğu ve sokakların daha geniş olduğu bölgelerde belirginleşmiştir. SVF ile ERI, Interbuild ve Adjacency metrikleri arasında negatif korelasyon, sokak genişliği ve sokak doğrusallığı ile pozitif korelasyon bulunmuştur.

Bu sonuçlar, SVF'nin kent morfolojisiyle doğrudan ilişkili olduğunu göstermekte ve bu faktörlerin kentsel ısı adası etkisi, güneşlenme süreleri ve çevresel konfor gibi unsurları etkileyebileceğini ortaya koymaktadır.Sokak morfolojisi ile Gökyüzü Görünürlük Faktörü (SVF) arasındaki ilişkiyi değerlendirmek amacıyla, SVF'yi bağımlı değişken, sokak doğrusallığı, genişliği ve açıklığı ise bağımsız değişkenler olarak kabul eden doğrusal ve polinomsal regresyon analizleri gerçekleştirilmiştir. Analiz sonuçları, sokak genişliğinin SVF ile en güçlü doğrusal korelasyona sahip olduğunu ortaya koymuştur ($R^2$ = 0.166, katsayı: +0.0072), bu da daha geniş sokakların gökyüzü görünürlüğünü artırdığını doğrulamaktadır. Sokak açıklığı, SVF ile pozitif ancak daha zayıf bir ilişki göstermiş ($R^2$ = 0.087, katsayı:
+0.287), polinomsal uyumda ise bu ilişki bir miktar iyileşerek doğrusal olmayan eğilimlere işaret etmiştir ($R^2$ = 0.110). Buna karşılık, sokak doğrusallığı ile SVF arasında anlamlı bir ilişki bulunamamış ($R^2$ = 0.019, katsayı: −0.344), bu da diğer kentsel faktörlerin SVF üzerindeki etkisinin daha belirgin olabileceğini göstermektedir. Bu bulgular, sokak genişliği veaçıklığının SVF'yi artırmada önemli rol oynadığını, ancak doğrusallığın bu bağlamda sınırlı bir açıklayıcı güce sahip olduğunu ortaya koymaktadır.

## 4. TARTIŞMA

Bu çalışmanın bulguları, sokak seviyesinden elde edilen panorama görüntüler ile SVF hesaplamasının mümkün olduğunu ve büyük veri ortamlarında yapay zekâ destekli segmentasyon yöntemlerinin kullanılabilirliğini göstermektedir. Derin öğrenme temelli segmentasyon, manuel yöntemlere kıyasla zaman ve kaynak açısından

daha verimli sonuçlar sunmuştur.

Literatürde sıklıkla kullanılan LiDAR ve 3D model tabanlı yaklaşımlar, yüksek donanım gereksinimleri ve sınırlı erişilebilirlik nedeniyle her zaman uygulanabilir olmamakta; bu nedenle panorama tabanlı yaklaşımlar, büyük ölçekli kentsel analizlerde avantaj sağlamaktadır. Ayrıca, SVF ile kent morfolojisi metrikleri arasındaki korelasyon, kentsel planlamada bu parametrelerin birlikte değerlendirilmesi gerektiğini vurgulamaktadır. Özellikle yapı yoğunluğunun azaltılması ve sokak genişliklerinin artırılması, SVF'nin artırılmasına katkı sunabilir ve bu da daha iyi güneşlenme, doğal havalandırma ve mikro iklim koşulları anlamına gelir.

## 5. SONUÇ

Bu çalışma, İstanbul'un iki farklı morfolojik karaktere sahip ilçesinde, panorama görüntülerden elde edilen SVF değerleri ile kent morfolojisi arasındaki ilişkiyi derin öğrenme temelli yöntemlerle analiz etmiştir. Sonuçlar, SVF'nin kentsel çevrenin mekânsal niteliklerinden doğrudan etkilendiğini ve bu nedenle kentsel tasarım kararlarında önemli bir metrik olarak değerlendirilmesi gerektiğini göstermektedir.

Bu metodoloji, farklı şehirler ve bölgelere kolayca uyarlanabilir olup, özellikle güneş enerjisi potansiyelinin haritalanması, mikro iklim analizi ve sürdürülebilir kentsel planlama süreçlerine entegre edilebilir. Gelecek çalışmalar, zaman serisi verileriyle SVF değişimlerinin izlenmesini ve farklı kent morfolojilerinin karşılaştırmalı analizini içerebilir.

## TEŞEKKÜR

Bu çalışmanın başarıyla tamamlanması, birçok kişi ve kuruluşun desteği ve yardımı olmadan mümkün olamazdı. İstanbul Büyükşehir Belediyesi Coğrafi Bilgi Sistemleri Daire Başkanı Rukiye Aydın Türktaş'a ve İstanbul Büyükşehir Belediyesi Coğrafi Bilgi Sistemleri Müdür Yardımcısı Nezahat Deniz Durnagöl'e özveriyle çalışmanın gerçekleşmesi için bu denli değerli verileri sağladıkları ve araştırma süreci boyunca verdikleri sürekli destek için içten teşekkürlerimizi sunarız. Onların çabaları ve katkıları bu çalışmanın başarısının ayrılmaz bir parçası olmuştur. Ayrıca, bu çalışmada yer alan ve geri bildirim ve görüşleriyle araştırmaya katkıda bulunan tüm katılımcılara da teşekkürlerimizi sunarız.

## KAYNAKLAR

Amidie, M., & Farhan, L. (2021). Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1), 1–74.

Borman, S., & Stevenson, R. L. (1999). Super-resolution from image sequences: A review. In *Proceedings of the Midwest Symposium on Circuits and Systems* (pp. 374–378).

Dong, C., Loy, C. C., He, K., & Tang, X. (2014). Learning a deep convolutional network for image super-resolution. In *European Conference on Computer Vision* (pp. 184–199).

Gawande, S. (2018). *Generative adversarial networks for single image super-resolution in microscopy images* (Master's Thesis), KTH Royal Institute of Technology, Stockholm.

Gazel Bulut, E. B. (2022). Çekişmeli Üretici Ağlar Kullanılarak Yer Gözlem Uydularından Süper Çözünürlüklü Görüntü Oluşturulması. (Yüksek Lisans Tezi), Hacettepe Üniversitesi Fen ve Mühendislik Bilimleri Enstitüsü, Ankara.

Ma, W., Pan, Z., Guo, J., & Lei, B. (2018). Super-resolution of remote sensing images based on transferred generative adversarial network. In *Proceedings of the IEEE International Geoscience and Remote Sensing Symposium (IGARSS)* (pp. 1148–1151), Valencia, Spain.

.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Yoğun Kazı Çalışması Yapılan Sahalarda Oluşan Heyelan Alanlarının M3C2 Çıktıları Kullanarak Belirlenmesi ve Sınırlandırılması

**Mehmet Güven Koçak*[1], Nilüfer Özdaş[1], Osman Sami Kırtıloğlu[1], Nevin Betül Avşar[1]**

[1]*İzmir Kâtip Çelebi Üniversitesi, Mühendislik-Mimarlık Fakültesi, Harita Mühendisliği Bölümü, İzmir, Türkiye*

**Anahtar Kelimeler**
Fotogrametri,
Nokta bulutu,
M3C2,
k merkezli öbekleme,
Heyelan

**ÖZET**

Açık maden işletmelerinde kazı çalışmaları sonucu yerçekimi etkisiyle toprak kaymaları meydana gelmekte ve bu durum çalışanlar için bir tehlike oluşturabilmektedir. İşletmenin çalışanlar açısından güvenliğinin temini için fotogrametrik yöntemlerden yararlanılabilir. Bu çalışmada; yoğun kazı çalışması yapılan bir maden sahasında meydana gelen heyelanların yayılım alanlarının, iki epoğa ait İHA görüntüleri kullanılarak sınırlandırılması için bir yaklaşım önerilmiştir. Her bir epoğa ait görüntüler fotogrametrik olarak değerlendirilmiştir. Elde edilen iki yoğun ham nokta bulutu herhangi bir ek işlem uygulanmaksızın doğrudan karşılaştırılmıştır. Karşılaştırma için günümüzde en çok tercih edilen M3C2 yaklaşımı kullanılmıştır. M3C2 ile karşılaştırma nokta bulutunun referans olarak alınan nokta bulutuna göre yer değiştirme vektörleri elde edilmiştir. Daha sonra M3C2 vektör bileşenleri kullanılarak yeni bir değişken türetilmiştir. 3B vektörün xy düzlemindeki yatay bileşeni vektörün normuna bölünerek bir oran bulunmuştur. Alanın tümü için elde edilen oran değerlerine k merkezli öbekleme algoritması uygulanarak heyelan alanlarının sınırları belirlenmiştir. Önerilen yöntemin doğruluğu ilgili konumlarda yapılan görsel karşılaştırmalarla test edilmiştir.

# Extraction and Delineation of Landslide Areas in Intense Excavation Sites Using M3C2 Outputs

**Keywords**
Photogrammetry,
Point cloud,
M3C2,
k-means clustering,
Landslide

**ABSTRACT**

As a result of excavation works in open mine operations, landslides occur due to the effect of gravity and this situation poses a danger to workers. Photogrammetric methods can be utilized to ensure the safety of the mine for the workers. In this study, an approach is proposed to delineate the extent of landslides in an intensively excavated mine site by using drone images of two epochs. The images of each epoch are evaluated photogrammetrically. Two dense raw point clouds are directly compared without any additional processing. For the comparison, the M3C2 approach, which is currently the most preferred one, was used. With M3C2, the displacement vectors of the compare point cloud with respect to the reference point cloud are obtained. A new variable was then derived using the M3C2 vector components. A ratio was found by dividing the horizontal component of the 3D vector in the xy plane by its norm. The boundaries of landslide areas were determined by applying the k-means clustering algorithm to the ratio values obtained for the entire area. The accuracy of the proposed method was tested by visual comparisons at the relevant locations.

* **Sorumlu Yazar**

*(mehmetguven.kocak@ikcu.edu.tr) ORCID ID 0000-0002-7992-5860
(nilufer.ozdas@ikcu.edu.tr) ORCID ID 0009-0007-3929-6813
(osmansami.kirtiloglu@ikcu.edu.tr) ORCID ID 0000-0003-2307-1787
(nevinbetul.avsar@ikcu.edu.tr) ORCID ID 0000-0001-7402-6201

**Kaynak Göster (APA):**

Koçak, MG, Özdaş, N, Kırtıloğlu, OS, Avşar, NB (2025). Yoğun Kazı Çalışması Yapılan Sahalarda Oluşan Heyelan Alanlarının M3C2 Çıktıları Kullanarak Belirlenmesi ve Sınırlandırılması, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

TASLAK

## 1. GİRİŞ

Bilindiği üzere jeodezik amaçlı izleme çalışmaları, cisimlerin kuvvet altında davranışlarını izlemek için yüksek doğruluk sağlaması nedeniyle tercih edilen yöntemlerden en önemlisidir. İncelenecek cismin boyutuna ve yayılımına bağlı olarak tesis edilecek jeodezik ağda farklı epoklarda yapılacak ölçmelerle cisimlerin yapmış olduğu kinematik hareket belirlenebilir. Burada hareketin olmadığı varsayılan sabit dayanak noktaları kullanılarak cisim noktalarının hareketi açıklanmaya çalışılır. Yüksek doğruluk sağlayan jeodezik yaklaşım; ekonomik anlamda yüksek maliyetlidir, hareketin izlenmesi amaçlanan sahada ve sahayı temsil etmek üzere tesis edilecek nokta sayısı sınırlıdır. Ayrıca ölçmelerin yapılacağı yüzey üzerinde ve çevresinde ölçmeleri gerçekleştirecek ekibin güvenliği önemli bir problem teşkil etmektedir. Örnek olarak açık maden işletmelerinde şev stabilitesi ve heyelanların izlenmesi ve haritalandırılması için jeodezik yöntemler kullanılması zaman, maliyet ve güvenlik gibi kısıtlar içermektedir (Tangadzani vd., 2024).

Son yıllarda İHA fotogrametrisi ile açık maden işletmelerinde haritalama ve izleme çalışmaları yukarıda sıralanan kısıtlara alternatif olarak genel kabul görmeye başlamıştır. Bu şekilde geniş alanlarda yüksek mekânsal ve zamansal çözünürlükte görüntüler elde edilerek hızlı ve uygun maliyetle nokta bulutları elde edilebilmektedir.

Bu çalışmada, bir açık maden sahasında farklı zamanlarda elde edilen İHA görüntülerinden üretilen nokta bulutları karşılaştırılarak oluşan heyelan alanlarının sınırlarının sayısal olarak belirginleştirilmesi hedeflenmiştir. Çalışmada fotogrametrik nokta bulutu verilerinin karşılaştırılmasında M3C2 (Multiscale Model to Model Cloud Comparison) yönteminden yararlanılmış, buradan elde edilen çıktılar k merkez öbekleme algoritmasında kullanılmıştır.

## 2. YÖNTEM

Çalışma kapsamında bir maden sahasında iki farklı epokta elde edilen İHA görüntüleri kullanılmıştır. İlgili saha 156 gün arayla DJI Phantom İHA'na monte 8.8 mm odak uzaklığına sahip FC6310S kamerası ile görüntülenmiştir. Görüntüler ortalama 6.0 cm yer örnekleme aralığı değerine sahiptirler. Her iki epoka ait görüntüler Agisoft yazılımı yardımıyla değerlendirilerek nokta bulutları elde edilmiştir (Agisoft LLC, 2018). Daha sonra iki nokta bulutu CloudCompare yazılımı eklentisi olan M3C2 ile karşılaştırılmıştır (CloudCompare, 2020). M3C2, alınan referans nokta bulutundan karşılaştırma nokta bulutuna değişim vektör bileşenlerinin hesaplanmasına olanak vermektedir (Lague at al., 2013). Değişim vektörünün yatay bileşeninin, vektörün M3C2 ile hesaplanan boyutuna oranı ile bulunan türetme değişken bu çalışmada heyelan konumlarının belirlenmesi için kullanılmıştır. Hesaplanan oranın istatistiksel olarak anlamlı olduğu konumlar belirlenmiştir (Koch, 1999). Test büyüklüklerinin hesabı için ihtiyaç duyulan varyans değerleri Koçak vd. (2025)'e göre belirlenmiştir.

Değişimin anlamlı olduğu konumlarda elde edilen oran değerlerine gözetimsiz öğrenme algoritması olan k merkezli öbekleme uygulanmıştır (Kaufman ve Rousseeuw, 1990). k öbek sayısı bu çalışma kapsamında deneysel bir yaklaşımla dört olarak belirlenmiştir.

## 3. BULGULAR

Analizler sonucunda, heyelan yaşanan noktaların yer değiştirme vektörlerinin büyüklükleri incelendiğinde çevreye kıyasla belirgin seviyede yüksek değerler aldığı gözlenmiştir. Örneğin, heyelan kümesindeki noktaların ortalama yatay hareket oranı, daha az değişim gösteren konumlara kıyasla anlamlı derecede yüksek çıkmıştır. Bu sayısal bulgu, heyelan bölgesinin özellikle yatay bileşenli hareketlerle ayrıştığını göstermektedir.

k merkezli öbekleme analizi, çalışma sahasındaki heyelan hareketlerini başarılı şekilde sınıflandırmıştır. Yüksek yatay hareket oranına sahip noktaların oluşturduğu küme (Şekil 1), heyelanın meydana geldiği konumları belirgin biçimde ortaya çıkarmıştır (Şekil 2). Öbekleme sonrası heyelan kümesine ait noktaların mekânsal dağılımı incelendiğinde, bu noktaların yoğunlaştığı alanın heyelan sınırları, görüntülerde ayırt edilebilen sınırlar ile büyük oranda örtüştüğü gözlenmiştir.

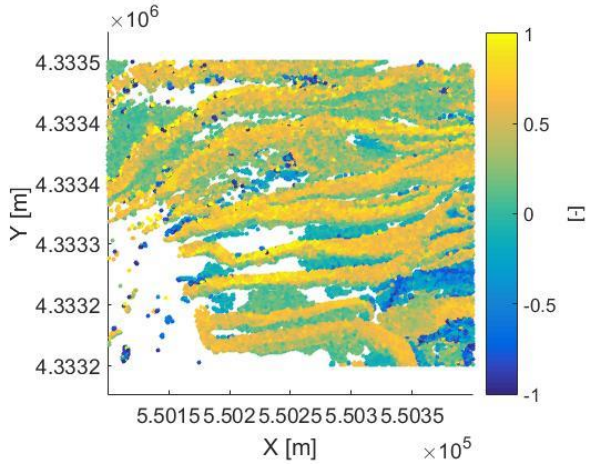


**Şekil 1.** Çalışma alanındaki M3C2 vektörü yatay bileşeninin M3C2 vektör normuna oranı haritası

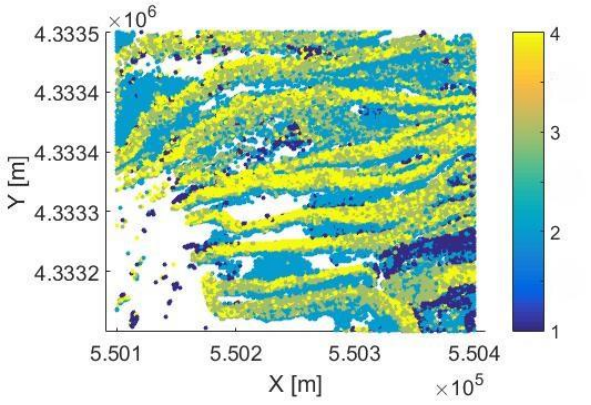


**Şekil 2.** k merkezli öbekleme sonucu (k = 4)

## 4. TARTIŞMA

Kullanılan oran metriği M3C2 ile elde edilen değişim vektörünün yatay bileşeninin baskın olduğu konumları

ortaya çıkarmak, belirginleştirmek amacıyla önerilmektedir. k merkezli öbekleme ise oran metriği değerleriyle oluşan örüntülerin objektif olarak sınıflandırılmasını sağlamaktadır. 4B nokta bulutu zaman serilerinde değişim desenlerini tespit etmede başarılı bulunduğu bildirilen k merkezli öbekleme algoritması (Winiwarter vd., 2023), bu çalışmada kullanılan veri setinde heyelan bölgelerinin güvenilir şekilde diğer bölgelerden ayrışmasını sağlamıştır. Önerilen yöntem henüz tek bir çalışma alanında gerçekleştirilebilmiş, sonuçların doğruluğu görsel olarak kontrol edilmiştir.

## 5. SONUÇ

Bu çalışmada, açık maden sahalarında şev stabilitesi ve heyelan oluşum alanlarının sınırlandırılması için İHA görüntüleriyle elde edilen 3B nokta bulutlarının fark analizine dayalı bir yaklaşım sunulmuştur. M3C2 algoritması ile elde edilen 3B yer değiştirme vektörlerinin yatay bileşenleri kullanılarak geliştirdiğimiz kümeleme temelli yöntem, kullandığımız çalışma alanı verilerine uygulandığında heyelan yaşanan bölgeleri hızlı ve yüksek doğrulukla sınırlayabilmiştir. Gelecekte, yöntemin farklı arazi tiplerinde ve farklı ölçeklerde uygulanarak test edilmesi planlanmaktadır. Yaklaşımın CBS tabanlı, etkin bir karar destek aracı olarak kullanılabileceği değerlendirilmektedir.

## TEŞEKKÜR

Yazarlar, bu makalede kullanılan İHA görüntülerine erişim sağlayan FİDES Mühendislik'e ve verilerin analizi için gerekli bilgisayar donanım ve yazılımını sağlayan İzmir Kâtip Çelebi Üniversitesi'ne teşekkürlerini sunar.

## Yazar Katkı Oranı

Tüm yazarlar çalışmaya eşit katkı sunmuşlardır.

## Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

## KAYNAKÇA

Agisoft LLC. (2018). PhotoScan (Version 1.4) [Computer software]. https://www.agisoft.com/

CloudCompare. (2020). CloudCompare (Version 2.12.2) [Computer software]. https://www.cloudcompare.org/

Kaufman, K., & Rousseeuw, P. J. (1990). Finding Groups in Data: An Introduction to Cluster Analysis, 342 pp., J. Wiley, New York.

Koch, K. R. (1999). Parameter Estimation and Hypothesis Testing in Linear Models. Springer Science & Business Media.

Koçak, MG., Özdaş, N., & Kırtıloğlu, OS. (2025). Visualization of M3C2 Outputs Obtained From an Open Pit Mine Field. Hakem incelemesinde

Lague, D., Brodu, N., & Leroux, J. (2013). Accurate 3D comparison of complex topography with terrestrial laser scanner: Application to the Rangitikei canyon (NZ). ISPRS Journal of Photogrammetry and Remote Sensing, 82, 10–26. https://doi.org/10.1016/j.isprsjprs.2013.04.009

Tangadzani, J. P., Paradzayi, C., & Muromo, T. G. (2024). Application of UAV-based Photogrammetry in Monitoring Slope Deformations in Open Pit Mining Environments: A Systematic Review. FIG Wroking Week, Accra, Ghana.

Winiwarter, L., Anders, K., Czerwonka-Schröder, D., & Höfle, B. (2023). Full four-dimensional change analysis of topographic point cloud time series using Kalman filtering. Earth Surface Dynamics, 11(4), 593-613.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Baz-Yükseklik Oranının, Uydu Görüntülerinden Üretilen Sayısal Yüzey Modeli Doğruluğuna Etkisi

**Ertuğrul Avşar*[1], Orhan Fırat[2], Gökhan Arasan[1], Hasan Güner[1]**

[1]*MSB Harita Genel Müdürlüğü, Ankara, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Fotogrametri,
Uydu Görüntüleri,
Sayısal Yüzey Modeli,
Görüntü İşleme,

**ÖZET**

Uzaktan algılama bilimi; tarım, ormancılık, kentsel planlama, askeri uygulamalar ve doğal afet yönetimi gibi birçok alanda yaygın olarak kullanılmaktadır. Uzaktan algılama platformları genel olarak yersel, hava ve uzay tabanlı olmak üzere üç gruba ayrılmaktadır. Bu platformlarda yer alan farklı algılayıcı sensörler aracılığıyla ortofoto, Sayısal Yüzey Modeli (SYM), radar verisi veya LiDAR gibi çeşitli coğrafi veriler elde edilebilmektedir. Teknolojideki hızlı gelişmeler sayesinde uzaktan algılama verilerinin bilgisayar ortamında işlenmesi daha hızlı ve verimli hale gelmiştir. Ayrıca coğrafi veri üretimi ve analiz süreçlerinin otomatikleştirilmesiyle zaman ve maliyet açısından önemli kazanımlar sağlanmıştır. Uydu görüntülerinden SYM, güncelliğini koruyan bir konu olarak farklı uygulamalar için temel coğrafi altlık sağlamaktadır. SYM'ler, uydu görüntülerinden görüntü eşleme yöntemleri kullanılarak üretilebilmekte olup, bu modellerin doğruluğu yapılacak araştırma ve analizler açısından kritik bir öneme sahiptir. Bu çalışmada, farklı çekim tarihleri ve farklı görüş açılarına sahip Göktürk-1 uydu görüntüleri kullanılarak, görüntü çekim anındaki baz mesafesi ile yükseklik oranı dikkate alınarak SYM'ler üretilmiş; baz/yükseklik (B/H) oranının SYM doğruluğu üzerindeki etkisi analiz edilmiştir.

# The Effect of The Base-to-Height Ratio on The Accuracy of Digital Surface Models Generated from Satellite Imagery

**Keywords**
Remote sensing,
Photogrammetry,
Satellite Imagery,
Digital Surface Model,
Image Processing

**ABSTRACT**

Remote sensing science is widely used in various fields such as agriculture, forestry, urban planning, military applications, and natural disaster management. Remote sensing platforms are generally classified into three main groups: ground-based, airborne, and space-based. These platforms are equipped with sensor systems that enable the acquisition of various types of geospatial data, such as orthophotos, Digital Surface Models (DSMs), radar data, and LiDAR. Thanks to rapid technological advancements, the processing of remote sensing data in computer environments has become faster and more efficient. Furthermore, the automation of geospatial data production and analysis processes has led to significant time and cost savings. The generation of DSMs from satellite imagery remains a current and relevant topic, providing a fundamental geospatial base for various applications. DSMs can be produced from satellite images using image matching techniques, and the accuracy of these models is critically important for subsequent research and analysis. In this study, DSMs were generated using Göktürk-1 satellite images acquired on different dates and with different viewing angles, considering the relationship between the baseline at the time of image acquisition and the height ratio. The effect of the baseline-to-height (B/H) ratio on DSM accuracy was analyzed.

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Avşar E, Fırat O, Gökhan Arasan G & Güner H (2025). Baz-Yükseklik Oranının, Uydu Görüntülerinden Üretilen Sayısal Yüzey Modeli Doğruluğuna Etkisi, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Sayısal Yüzey Modeli (SYM), yeryüzü üzerindeki tüm nesneleri (binalar, ağaçlar, yapılar vb.) içerecek şekilde yüzeyin üç boyutlu yüksekliğini temsil eden bir modeldir. SYM elde etme yöntemleri, farklı veri kaynakları ve teknolojilere dayanmaktadır. En yaygın yöntemlerden biri, uydu görüntülerinden veya hava fotoğraflarından stereo fotogrametri tekniğiyle yükseklik bilgisinin çıkarılmasıdır. Bunu yanı sıra LiDAR teknolojisi ise lazer darbeleriyle çok hassas nokta bulutu oluşturarak özellikle şehir ve orman gibi detaylı alanlarda yüksek doğruluklu SYM üretimi sağlar. Radar tabanlı InSAR yöntemi ise, hava koşullarından etkilenmeden geniş alanlarda yükseklik farklarını belirlemede kullanılmaktadır. Bu yöntemler; doğruluk, uygulama alanı ve maliyet gibi faktörler göz önüne alındığında kullanım amacına göre tercih edilmektedir.

Uydu görüntülerinden SYM üretiminde stereo bindirmeli görüntü çiftlerinin kullanılması ve uydu görüntülerine ait parametrelerin bilinmesi gerekmedir.

Yüksek çözünürlüklü uyduların esnek stereo görüntüleme yetenekleri sayesinde, baz-yükseklik oranı (base-to-height ratio, B/H) 0.5'den büyük olan güçlü stereo geometriler üretilebilmektedir. Uydu görüntüleme geometrisi, özellikle B/H oranı veya yakınsama açısı, SYM'lerin düşey doğruluğunun artırılmasında önemli rol oynamaktadır. Ancak, şehir alanlarında iki stereo görüntü arasındaki benzerliği artırmak ve eşleştirme aşamasını iyileştirmek için daha küçük B/H oranları tercih edilebilmektedir. Ayrıca, bu uyduların yönlendirme kabiliyetleri sayesinde aynı gün içinde aynı yörünge boyunca (in-track) stereo görüntüler elde edilebilir, bu da radyometrik farklılıkları azaltır ve eşleştirme işleminin başarı oranını artırır. Böylece, yüksek çözünürlüklü stereo verileri kısa tekrar ziyaret süreleriyle ve uygun maliyetle hızlıca elde edilebilir. (Aguilar, Saldaña ve Aguilar, 2013)

Yükseklik modelleri, önceden belirlenmiş standartlara ve kullanıcı gereksinimlerine uygun olmalıdır. Yükseklik modelinin kalitesi doğruluk ve morfolojik detay olan iki ana bileşeni içerir. Uydu verilerinin harita ürünlerinde kullanılabilmesi için, hassas yükseklik bilgisi içermesi büyük önem taşımaktadır. Optik uydu görüntülerine dayalı olarak oluşturulan SYM'lerin doğruluğu büyük ölçüde çözünürlüğüne, B/H oranına, görüntü kontrastına ve arazinin engebeliliğine bağlıdır. (Sefercik, Alkan, Büyüksalih ve Jacobsen, 2013)

Uygun çekim açısı ve çekim tarihe sahip stereo uydu görüntü çiftleri ile bu görüntülere ait rasyonel polinom katsayıları (Rational Polynomial Coefficients – RPC) kullanılarak görüntü eşleme yöntemleri sayesinde SYM üretmek mümkün olmaktadır.

Uydu görüntülerinde, üç boyutlu (3B) nesne uzayı konumları (X, Y, Z) ile bunlara karşılık gelen iki boyutlu (2B) görüntü uzayı konumları (x, y) arasındaki ilişkiyi kurmak için geometrik sensör modelleri kullanılmaktadır. Çok yüksek çözünürlüklü uydu görüntüleri için, araştırmacıların çoğu üç boyutlu fiziksel ya da kesin modeller veya görüntü uzayında, az sayıda yüksek doğruluğa sahip yer kontrol noktaları (YKN) ile iyileştirilen, yaygın olarak bilinen ve uydu sağlayıcıları tarafından sunulan RPC olan bu iki modelin kullanımını önermektedir. (Manuel A. Aguilar, Fernando J. Aguilar, María del Mar Saldaña, and Ismael Fernández)

Bu doğrultuda çalışmada 0.5 m siyah-beyaz (pankromatik) yüksek mekânsal çözünürlükte görüntü elde edebilen Göktürk-1 uydu görüntülerini kendi aralarında farklı kombinasyonlar ile B/H oranında hem sadece RPC parametreleri hemde YKN kullanılarak iki farklı yöntemde SYM'ler üretilmiş ve SYM'lerin doğrulukları kontrol edilmiş; ayrıca ortaya çıkan sonuçlar ile baz yükseklik oranı arasındaki ilişki irdelenmiştir.

## 2. YÖNTEM

Ankara il merkezinin batısında yer alan bir bölgede 6 adet (5 adet along-track, 1 adet across-track) Göktürk-
1 uydu görüntüsünden PCI Geomatica Banff ticari yazılımı ile farklı kombinasyonlarda ve farklı baz yükseklik oranlarında stereo uydu görüntü çiftleri oluşturulmuş, hem YKN'li, hem de yalnızca RPC parametreleri kullanılarak (Level4-L4) SYM'ler üretilmiştir. Üretilen veriler çeşitli test noktaları ile kontrol edilmiştir.

### 2.1. Görüntü Özellikleri ve Çiftlerinin Belirlenmesi

SYM üretimi için Çizelge 1'de tarih ve çekim açıları belirtilen Göktürk-1 uydu görüntüleri kullanılmıştır. Görüntüler 0.5 m pankromatik, 2 m multispektral (RGB+NIR) bantta mekansal çözünürlüğe sahiptir.

**Çizelge 1.** Çalışmada kullanılan Göktürk-1 görüntüleri.

| ID | Görüntü Tarihi (Gün,Ay,Yıl) | Görüntü Açısı (°) |
|---|---|---|
| 5245 | 27.07.2018 | 10 |
| 5310 | 27.07.2018 | 7 |
| 5250 | 13.04.2018 | 34 |
| 5402 | 13.04.2018 | 9 |
| 5452 | 13.04.2018 | 35 |
| 5229 | 06.07.2018 | 29 |

### 2.2. Farklı B/H Oranlarında Görüntü Çiftlerinden SYM Üretimi

Çalışmada kullanılmak üzere aynı alanı görüntüleyen 6 adet görüntü ile 3 görüntü çifti aynı yörünge hattında (along-track), 1 görütü çifti ise yakın yörünge (across-track) hattına sahip 4 farklı kombinasyonda çift olacak şekilde görüntü grupları oluşturulmuştur.

Oluşturulan görüntü grupları kendi içerisinde baz mesafesi, aynı yörünge özellikleri ve çekim tarihleri dikkate alınarak Çizelge 2'de gösterildiği gibi görüntü çiftlerine ayrılmıştır.

**Çizelge 2.** Görüntü grupları ve B/H oranları.

| Grup | Görüntü Çiftleri | Baz Mesafesi (km) | Yükseklik (km) | B/H |
|---|---|---|---|---|
| A | 5245-5310 | 171 | 680 | 0.3 |
| B | 5250-5402 | 494 | 680 | 0.7 |
| C | 5452-5229 | 755 | 680 | 1.1 |
| D | 5452-5250 | 837 | 680 | 1.2 |

CI Geomatica Banff yazılımı OrthoEngine modülünde (Rational Function) 4 farklı senaryoda 8 adet (4 adet L4A, 4 adet L4B) SYM üretimi yapılmıştır. Üretimler Universal Transverse Mercator (UTM) projeksiyonunda WGS84 datumunda koordinat sistemine sahiptir.

Projede her bir grupta 16 adet bağlama noktası (tie point) toplanmıştır. Bağlama noktaları tüm gruplarda x ve y eksenlerinde ± 0.5 piksel karesel ortalama hataya (KOH) sahiptir.

Ayrıca üretimlerinde bağlama noktaları ile beraber her bir gruptaki görüntüye 1 adet YKN tesisi yapılmıştır. SYM üretimlerinde uydu görüntülerinin sadece pankromatik bantları kullanılmış ve ilk olarak epipolar geometrileri oluşturularak Semi-global matching (SGM) çıkarım methodu ile 1 piksel örneklemde elipsoidal yükselik değerine sahip 0.5 m çözünürlüklü SYM'ler türetilmiştir.

### 2.3. Test Noktaları ile Karşılaştırma

Üretilen 8 farklı SYM için de hem üretim aşamasında kullanılan YKN hem de test noktaları, HGM tarafından Ultracam Eagle model geniş formatlı sayısal hava kameraları ile %80 ileri bindirme ve %30 yan bindirme oranlarına sahip ve 30 cm Yer Örnekleme Aralığında çekilmiş hava fotoğraflarından oluşturulan stereo modeller üzerinden elde edilen 3 boyutlu kontrol noktalarıdır. Kontrol noktalarının yatay konum doğruluğu ± 0.5 m, düşey konum doğruluğu ise ± 1 m'den daha iyidir.

Analizde kullanılan kontrol noktaları arazi yapısının değişmediği düz alanlardan toplanmıştır. Bina, ağaç veya yüksek yapı gibi detaylar kullanılmamıştır. Üretilen 8 adet SYM'nin doğruluk analizi 48 adet YKN ile KOH formülüne göre hesaplanmıştır.

## 3. BULGULAR

Yukarıda belirtilen 48 adet stereo hava fotoğraflarından elde edilen kontrol noktaları ile Çizelge
3 ve Çizelge 4'te gösterildiği üzere L4A ve L4B seviyesindeki SYM'lerin doğrulukları %90 güven aralığında hesaplanmıştır.

**Çizelge 3.** L4A YKN ile KOH hesabı.

| Grup | B/H | KOH(m) | LE90(m) |
|---|---|---|---|
| A | 0.3 | ±3.76 | ±6.18 |
| B | 0.7 | ±2.03 | ±3.34 |
| C | 1.1 | ±1.31 | ±2.16 |
| D | 1.2 | ±1.95 | ±3.21 |

**Çizelge 4.** L4B YKN ile KOH hesabı.

| Grup | B/H | KOH(m) | LE90(m) |
|---|---|---|---|
| A | 0.3 | ±1.77 | ±2.91 |
| B | 0.7 | ±1.14 | ±1.87 |
| C | 1.1 | ±0.87 | ±1.43 |
| D | 1.2 | ±0.99 | ±1.63 |

## SONUÇ

Hesaplanan KOH değerlerine göre B/H oranın SYM doğruluğu üzerindeki ilişkisi incelenmiş; öncelikle beklendiği üzere YKN kullanılarak üretilen SYM'lerin sadece RPC parametresi ile üretilen verilere göre daha iyi sonuçlar verdiği görülmüştür.

Bununla birlikte iki farklı yöntemle de üretilen SYM doğruluklarında; A, B ve C üretimleri ile doğru orantılı olarak artırılan B/H oranı ile veri doğruluğunda iyileşmeler görülmüştür.

Bu kapsamda B/H oranı dikkate alınarak yapılan üretimlerde literatürde de belirtildiği üzere 0.6 değer ve üzerine çıkıldığı durumlarda veri doğruluğunun arttığı görülmüştür.

Fakat düşük B/H (<0.6) oranlarında derinlik hassasiyeti düştüğü için yükseklik verisinde de hataların arttığı görülmüştür.

Bu doğrultuda ideal B/H oranları görüntü çiftlerinde görüntü eşleştirme algoritmalarının sağlıklı çalışmasını mümkün kıldığı, yeterli paralaks sağladığı ve dolayısıyla SYM üretiminde yüksek doğruluk elde edilmesine katkı sağladığı tespit edilmiştir.

Sonuç olarak Sayısal Yükseklik Modeli (SYM) üretiminde kullanılan stereo uydu görüntülerinin geometrik yapısını tanımlayan baz-yükseklik oranı (B/H oranı), modelin düşey doğruluğu açısından kritik bir parametre olup, uygun değer aralığında seçilmesi model kalitesini doğrudan etkilemektedir. B/H oranının düşük olması, paralaks farkının yetersiz kalmasına neden olarak özellikle engebeli arazilerde yükseklik duyarlılığını azaltmakta, buna karşılık çok yüksek oranlarda ise stereo görüntüler arasındaki perspektif farkını artırarak eşleştirme hatalarının oluşmasına ve fotogrametrik uyumsuzluklara yol açabileceği değerlendirilmektedir.

## KAYNAKÇA

Zhang, C., Fraser C. Generation Of Digital Surface Model From High Resolution Satellite Imagery. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. Vol. XXXVII. Part B1. Beijing, (2008)

Aguilar, A. M., Saldana, M. M., Aguilar, J. F. (2013) Generation and Quality Assessment of Stereo-

Extracted DSM from GeoEye-1 and WorldView-2 Imagery, IEEE Transactions On Geoscience And Remote Sensıng

Sefercik, U. G., Alkan, M., Büyüksalih, G., Jacobsen K. (2013) Generation And Validation Of High-Resolution DEMs From Worldview-2 Stereo Data, The Photogrammetric Record

Şıpka, T. (2014). Worldvıew-1 Stereo Uydu Verilerinden Üretilen Sayısal Yükseklik Modelinde Doğruluk Analizi. (Yüksek Lisans Tezi), İstanbul Teknik Üniversitesi, İstanbul

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU

https://tufuab2025.beun.edu.tr/

# Fotogrametrik Nirengi Dengeleme İşlemlerinde Farklı İterasyonlarda Yer Kontrol Noktası ve Detay Noktası Kullanımının Doğruluğa Etkilerinin Araştırılması

**Gökhan Şencan[1], Orhan Fırat[1], Ercan Emirzeoğlu [1]**

[1] *MSB Harita Genel Müdürlüğü, Ankara, Türkiye*

**Anahtar Kelimeler**
Fotogrametrik Nirengi,
Sayısal Hava Kamerası,
Yer Kontrol Noktası,
Detay Noktası,
Doğruluk,

**ÖZ**

Fotogrametrik nirengi yöntemiyle üretilen ortofoto haritaların doğruluğu, üretim sürecindeki birçok parametreye bağlıdır. Ortofoto üretim aşamalarından biri olan fotogrametrik nirengi işlemleri kapsamında gerçekleştirilen blok dengelemelerinde Yer Kontrol Noktası (YKN) ve/veya keskin detay noktası kullanılmaktadır. Bu çalışmada, fotogrametrik nirengi işlemlerinde YKN ile detay noktalarının kullanımının doğruluk üzerindeki etkileri araştırılmış; ayrıca 1:1.000 ve 1:5.000 ölçekli harita üretiminde yeterli doğruluğun sağlanabilmesi için gerekli minimum nokta sayısı ile bu noktalar arasındaki ideal mesafe belirlenmeye çalışılmıştır. Araştırma, 180 km$^2$'lik Kahramankazan bölgesinde yapılmıştır. Bu alanda, fotogrametrik nirengi blok yapısına uygun şekilde planlanan 30 YKN ve 146 detay noktasının koordinatları ölçülmüştür. %90 ileri ve %60 yan bindirme oranı ile 10 cm ve 30 cm yer örnekleme aralığında hava fotoğrafları çekilmiştir. YKN'ler ve detay noktaları ile farklı iterasyonda dengeleme işlemi yapılmıştır. 30 cm yer örnekleme aralığında, 1:5.000 ölçekli harita üretimi için 8 adet YKN'nin veya 8 adet detay noktasının dengelemede kullanılması durumunda ideal mesafe 5 km olarak hesaplanmıştır. Benzer şekilde, 10 cm yer örnekleme aralığında, 1:1.000 ölçekli harita üretimi için 18 adet YKN'nin veya 18 adet detay noktasının dengelemede kullanılması durumunda, ideal mesafe 3 km olarak hesaplanmıştır. Sonuçların, BÖHHBÜY ile ASPRS büyük ölçekli haritalar için doğruluk standardına uygun olduğu görülmüştür.

# Comparison of the Effects of Using Ground Control Point and Detail Point on Accuracy in Different Iterations of Photogrammetric Triangulation

**Keywords**
Photogrammetry
Triangulation,
Digital Aerial Camera,
Ground Control Point,
Detail Point,
Accuracy,

**ABSTRACT**

The accuracy of orthophoto maps produced using photogrammetric triangulation depends on many parameters in the production process. One of the stages in orthophoto production is photogrammetric triangulation, where block adjustments are made using Ground Control Points (GCPs) and/or sharp detail points. This study investigates the effects of using GCPs and detail points on accuracy in photogrammetric triangulation. Additionally, it aims to determine the minimum number of points required and the ideal distance between these points for achieving sufficient accuracy in the production of maps at scales of 1:1.000 and 1:5.000. The research was conducted in the 180 km$^2$ Kahramankazan region. In this area, the coordinates of 30 GCPs and 146 detail points were measured according to the photogrammetric triangulation block structure. Aerial photographs were taken with %90 forward and %60 side overlap at ground sampling intervals of 10 cm and 30 cm. Block adjustment was performed using GCPs and detail points in different iterations. At a 30 cm ground sampling interval, for 1:5.000 scale map production, using 8 GCPs or 8 detail points in the adjustment resulted in an ideal distance of 5 km. Similarly, at a 10 cm ground sampling interval, for 1:1.000 scale map production, using 18 GCPs or 18 detail points in the adjustment resulted in an ideal distance of 3 km. The results were found to meet the accuracy standards for large-scale maps set by BÖHHBÜY and ASPRS.

* **Sorumlu Yazar**

*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx
(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**

Şencan G, Fırat O & Emirzeoğlu E (2025). Fotogrametrik Nirengi Dengeleme İşlemlerinde Farklı İterasyonlarda Yer Kontrol Noktası ve Detay Noktası Kullanımının Doğruluğa Etkilerinin Araştırılması, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Uzaktan algılama sistemlerinin gelişmesiyle birlikte insan hayatını kolaylaştıran teknolojik gelişmelerle ortofoto harita üretim maliyetinin yersel yöntemlere göre daha düşük olması ve tüm topoğrafik yapının kolayca tespit edilebilmesi, yerleşim yerlerinin kolayca izlenmesiyle birlikte haritaların kolaylıkla güncellenmesi gibi sağladığı avantajlar nedeniyle topoğrafik haritalarda yerini almıştır. Ortofoto harita üretiminde fotogrametrik nirengi otomasyon sistemlerinin hız, maliyet ve doğruluk yönündeki avantajları nedeniyle harita üretiminde önemi artmaktadır. Gerçek zamanlı kinematik GPS (RTK GPS) tekniği ve IMU siteminden elde edilen verilerin fotogrametrik nirengi dengelemesinde kullanılmasıyla birlikte arazide Yer Kontrol Noktası (YKN) ihtiyacının azalması sayesinde fotogrametrik nirengide önemli gelişmeler sağlanmıştır.

Fotogrametrik nirengi işlemleri kapsamında gerçekleştirilen blok dengelemelerinde Yer Kontrol Noktası (YKN) ve/veya keskin detay noktası kullanılmaktadır. Yer Kontrol Noktalarının araziye tesisi hava fotoğrafı çekiminden önce gerçekleştirildiğinden, hava fotoğrafı çekimine kadar geçen süre zarfında tesis edilen noktaların tahrip olma olasılığı artacağından dolayı, hava fotoğrafı çekiminin kısa süre içerisinde yapılması önem arz etmektedir. Hava fotoğrafı çekiminin; başta meteorolojik koşullar olmak üzere çeşitli nedenlerden dolayı (sinyal karıştırması, öncelik arz eden diğer faaliyetler vb.) hemen yapılamaması ya da hiç yapılamaması durumunda tesis edilen YKN'lerin tahrip olma olasılığı ortaya çıkmakta ve bu durumda tahrip olan noktalardan dolayı zaman ve maliyet kaybı oluşmaktadır. Bu durumun önüne geçilmesi maksadıyla; hava fotoğrafı çekiminden önce ya da sonra yapılmasının mümkün olması, tahrip olma olasılıklarının YKN'lere kıyasla daha az olması ve tesis maliyeti gerektirmemesi nedeniyle YKN yerine detay noktası kullanılması alternatif bir yol olarak belirlenmiş ve bu yöntemin uygulamaya konulmasından önce bir fizibilite çalışması yapılmasının uygun olacağı değerlendirilmiştir.

Ayrıca bu çalışmada; 1:1.000 ve 1:5.000 ölçekli harita üretiminde fotogrametrik nirengi dengelemelerinde yeterli doğruluğun sağlanabilmesi için gerekli olan minimum nokta sayısı ile bu noktalar arasındaki ideal mesafe belirlenmeye çalışılmıştır.

Söz konusu fizibilite çalışması kapsamında, TUFUAB veri havuzu alanı olarak belirlenen 180 km$^2$ alana sahip Kahramankazan bölgesinde 30 adet yer kontrol noktası ve 146 adet detay noktasının koordinatları ölçülmüş ve %90 ileri, %60 yan bindirme oranına sahip, 10 cm ve 30 cm yer örnekleme aralığında hava fotoğrafı çekimi gerçekleştirilmiştir.

Arazide koordinatları ölçülen yer kontrol noktaları ve detay noktaları farklı iterasyonlarda kullanılarak fotogrametrik nirengi işlemleri gerçekleştirilmiş ve bu sayede YKN'ler yerine detay noktalarının kullanılmasının doğruluk üzerindeki ektileri ve km$^2$'ye düşen yaklaşık nokta sayısı ile noktalar arası yaklaşık mesafe araştırılmıştır.

## 2. YÖNTEM

### 2.1. Yer Kontrol Noktası ve Detay Noktalarının Planlanması ve Ölçümü

Fotogrametrik nirengi dengeleme işlemlerinde kullanılmak üzere, TUFUAB veri havuzu alanı olarak belirlenen 180 km$^2$ alana sahip Kahramankazan bölgesinde, 30 farklı bölgede 30 adet yer kontrol noktası ile 146 farklı bölgede 146 adet detay noktasının arazide ölçülmesi planlanmıştır (Şekil 1). Planlanan detay noktalarının yerleri 2024 yılında çekilen hava fotoğrafları ile üretilen ortofotolardan tespit edilmiştir.

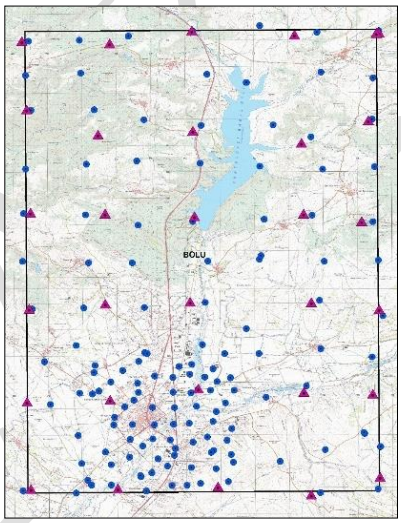


**Şekil 1.** Kahramankazan bölgesinde planlanan yer kontrol noktası ve detay noktalarının dağılımını gösteren grafik

Fotogrametrik nirengi dengeleme işlemlerinde ve yapılan kontrol işlemlerinde, Kahramankazan bölgesinde 30 adet YKN ve 146 adet detay noktası tesis edilmiştir. Noktaların konum bilgisi gerçek zamanlı kinematik GPS (RTK GPS) ile yatayda ± 1-3 cm, düşeyde ± 1-5 cm'den daha doğru olacak biçimde koordinatları ölçülmüş ve her bir noktaya ilişkin aşağıdaki örneğe uygun olarak detay krokisi hazırlanmıştır (Şekil 2).

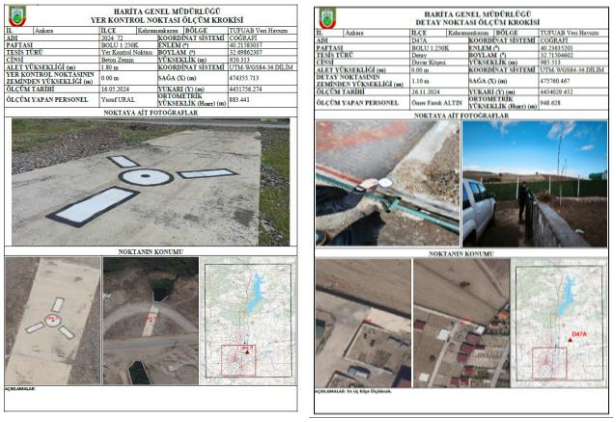


**Şekil 2.** YKN ve Detay krokisi örneği

### 2.2. Hava Fotoğrafı Çekim Planının Hazırlanması

Hava fotoğrafı çekiminde kullanılan Ultracam Eagle Mark3 (f:100 mm) sayısal hava kamerasına yönelik, 10 cm ve 30 cm yer örnekleme aralığında, %90 ileri, %60 yan bindirme oranına sahip olacak biçimde hava fotoğraflarının çekilmesi maksadıyla uçuş planı hazırlanmıştır (Şekil 3).

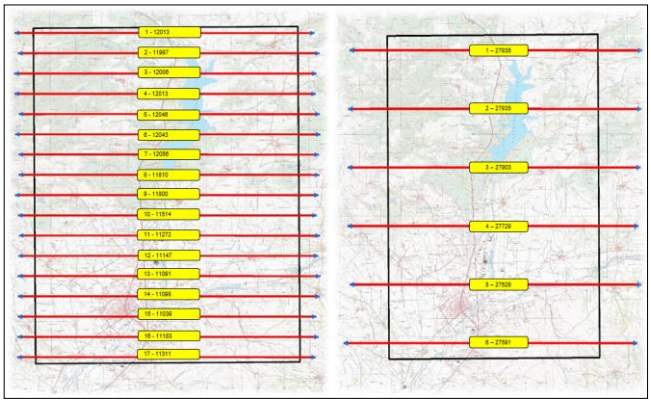

**Şekil 3.** Hava fotoğrafı çekim planı

Hazırlanan uçuş planına uygun olarak, Harita Genel Müdürlüğü hava fotoğrafı çekim uçağıyla, 2024 yılı Eylül ayında, 10 cm yer örnekleme aralığında, yaklaşık 11.500 ft (3500 m) yükseklikten 803 adet hava fotoğrafı ile 30 cm yer örnekleme aralığında yaklaşık 28.000 ft (8500 m) yükseklikten 120 adet hava fotoğrafı çekimi gerçekleştirmiştir (Şekil 4).

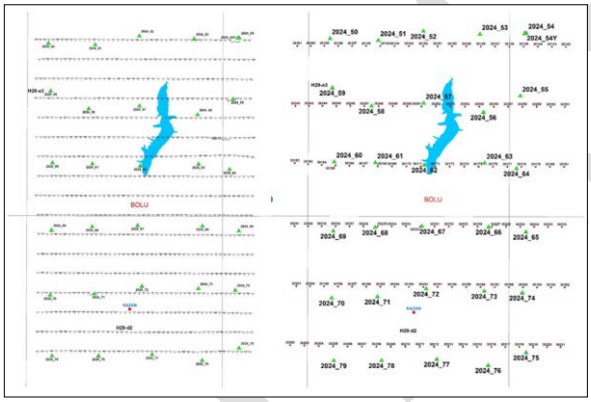

**Şekil 4.** Hava fotoğrafı çekim indeksi

### 2.3. Ham Hava Fotoğraflarının İşlenmesi

Hava fotoğrafı çekiminden sonra elde edilen Level-0 seviyesindeki ham görüntüler işlenerek Level-0 seviyesinden Level-2 seviyesine getirilmiştir. Daha sonra Level-2 seviyesindeki görüntülerin radyometrik düzeltmesi yapılarak fotogrametrik nirengi işlemlerinde kullanılabilen TIFF formatında Level-3 seviyesindeki sayısal hava fotoğrafı üretilmiştir (Şekil 5).

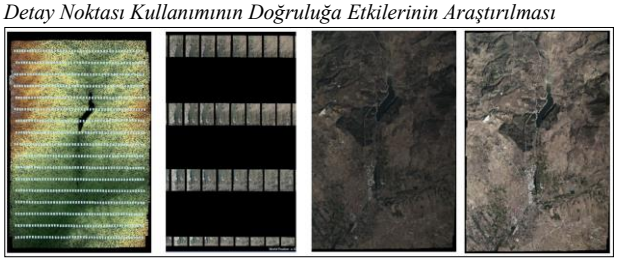

**Şekil 5.** Ham hava fotoğraflarının işlenmesi ve sayısal hava fotoğrafı

### 2.4. Ham GPS/IMU Verilerinin Çözümlenmesi

Hava fotoğrafı çekimi sırasında uçaktaki GPS/IMU cihazının ölçtüğü ham veriler, TUSAGA Aktif istasyon verileri ile çözümlenerek, her bir hava fotoğrafına ait yaklaşık yöneltme parametreleri (X, Y, Z, omega, phi ve kappa) hesaplanmıştır (Şekil 6).

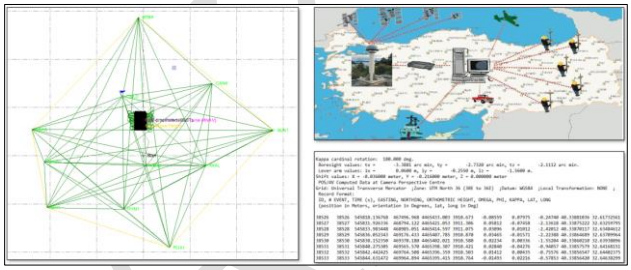

**Şekil 6.** GPS/IMU çözümü ve sonuçları

### 2.5. Fotogrametrik Nirengi Dengelemesi

Fotogrametrik dengeleme işlemlerinde 30 cm yer örnekleme aralığında çekilen hava fotoğrafları kullanılarak dengeleme yapılmıştır.

Dengeleme 1: Arazide ölçümü yapılan 30 adet yer kontrol noktası dengeleme kullanılmış ve 146 adet detay noktası kontrol noktası olarak seçilmiştir. Kontrol noktaları 3-sigma kuralına göre z yönündeki hata miktarı %99.7 sınırı içerisinde olmayan 2 adet detay noktası tespit edilmiş ve diğer dengeleme iterasyonlarınada dâhil edilmemiştir.

2024 yılında ölçülen 30 adet yer kontrol noktası kullanılarak fotogrametrik nirengi dengelemesi yapılmıştır ve 144 adet detay noktası kontrol noktası olarak seçilmiştir. (Şekil 7), elde edilen dengeleme sonuçları Tablo 1'de, kontrol noktalarının sonuçları Tablo 2'de, ve kontrol noktalarının hatasını gösteren grafik Şekil 8'de sunulmuştur.

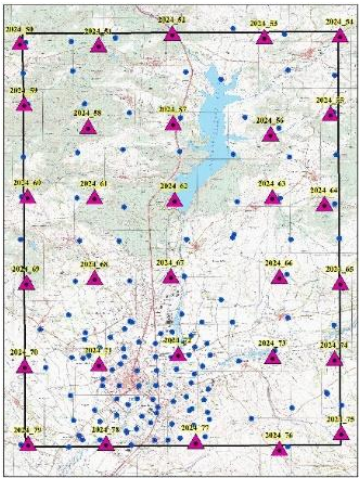

**Şekil 7.** Dengeleme-1'de kullanılan noktaların dağılımı

**Tablo 1.** Dengeleme-1'de elde edilen sonuçlar

| | X (m) | Y (m) | Z (m) |
|---|---|---|---|
| **Maksimum** | 0.11 | -0.14 | -0.43 |
| **Ortalama** | 0 | 0 | 0 |
| **Standart Sapma** | 0.05 | 0.06 | 0.19 |
| **KOH (x,y,z)** | **0.05** | **0.06** | **0.18** |
| **KOHr** | 0.07 | $\sqrt{[(KOHx)^2+(KOHy)^2]}$ | |
| **DOĞRULUKr (%95 Güven Aralığında)** | 0.12 | KOHr*1.7308 | |
| **DOĞRULUKz (%95 Güven Aralığında)** | 0.36 | KOHz*1.9600 | |

**Tablo 2.** Dengeleme-1'de elde edilen kontrol noktalarının sonuçları

| | X (m) | Y (m) | Z (m) |
|---|---|---|---|
| **Maksimum** | -0.42 | 0.58 | -1.49 |
| **Ortalama** | 0 | 0.04 | -0.10 |
| **Standart Sapma** | 0.15 | 0.20 | 0.51 |
| **KOH (x,y,z)** | **0.14** | **0.20** | **0.52** |
| **KOHr** | 0.25 | $\sqrt{[(KOHx)^2+(KOHy)^2]}$ | |
| **DOĞRULUKr (%95 Güven Aralığında)** | 0.43 | KOHr*1.7308 | |
| **DOĞRULUKz (%95 Güven Aralığında)** | 1.01 | KOHz*1.9600 | |

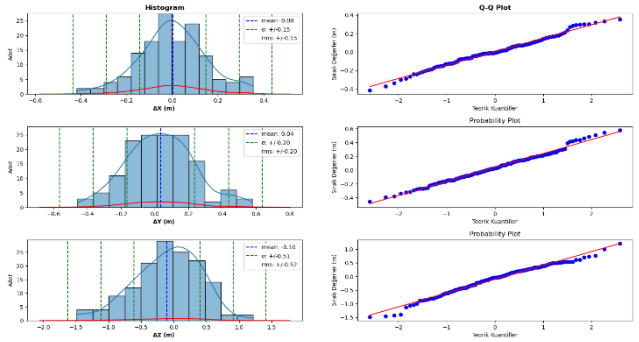


**Şekil 8.** Kontrol noktalarının hatalarını gösteren grafik

Dengeleme 3: 8 adet yer kontrol noktası kullanılarak fotogrametrik nirengi dengelemesi yapılmıştır. 22 adet YKN ve 144 adet detay noktası kontrol noktası olarak seçilmiştir (Şekil 9), elde edilen dengeleme sonuçları Tablo 3'te, kontrol noktalarının sonuçları Tablo 4'te, ve kontrol noktalarının hatasını gösteren grafik Şekil 10'da sunulmuştur.

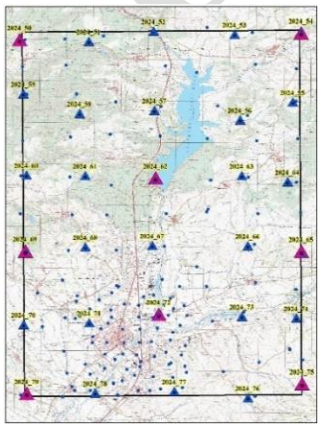

**Şekil 9.** Dengeleme-3'te kullanılan noktaların dağılımı

**Tablo 3.** Dengeleme-3'te elde edilen sonuçlar

| | X (m) | Y (m) | Z (m) |
|---|---|---|---|
| **Maksimum** | 0.16 | -0.23 | 0.37 |
| **Ortalama** | 0 | 0 | 0 |
| **Standart Sapma** | 0.09 | 0.14 | 0.27 |
| **KOH (x,y,z)** | **0.08** | **0.13** | **0.25** |
| **KOHr** | 0.15 | $\sqrt{[(KOHx)^2+(KOHy)^2]}$ | |
| **DOĞRULUKr (%95 Güven Aralığında)** | 0.26 | KOHr*1.7308 | |
| **DOĞRULUKz (%95 Güven Aralığında)** | 0.50 | KOHz*1.9600 | |

**Tablo 4.** Dengeleme-3'te elde edilen kontrol noktalarının sonuçları

| | X (m) | Y (m) | Z (m) |
|---|---|---|---|
| **Maksimum** | 0.49 | 0.72 | 1.66 |
| **Ortalama** | 0 | 0.04 | 0.07 |
| **Standart Sapma** | 0.18 | 0.25 | 0.53 |
| **KOH (x,y,z)** | **0.18** | **0.26** | **0.54** |
| **KOHr** | 0.31 | $\sqrt{[(KOHx)^2+(KOHy)^2]}$ | |
| **DOĞRULUKr (%95 Güven Aralığında)** | 0.54 | KOHr*1.7308 | |
| **DOĞRULUKz (%95 Güven Aralığında)** | 1.05 | KOHz*1.9600 | |

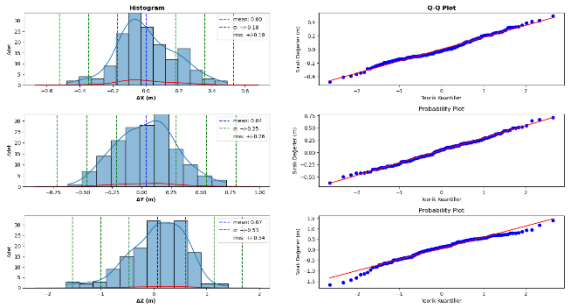


**Şekil 10.** Dengeleme noktalarının hatalarını gösteren grafik

Fotogrametrik nirengi dengeleme işlemlerinde farklı iterasyonlarda yer kontrol noktası ve detay noktası kullanılarak hesaplanan sonuçlar Tablo 5'te sunulmuştur.

**Tablo 5.** Blok dengeleme sonucunda kontrol noktalarının KOH değerleri

| Dengeleme No | Dengelemede Kullanılan Nokta Sayısı | Kontrol Noktası Sayısı | $KOH_X$ | $KOH_Y$ | KOHp Planimetrik | $KOH_Z$ | $\lvert\Delta X_{max}\rvert$ | $\lvert\Delta Y_{max}\rvert$ | $\lvert\Delta Z_{max}\rvert$ |
|---|---|---|---|---|---|---|---|---|---|
| 1 | 30 YKN | 144 Detay | **± 0.14** | **± 0.20** | **± 0.25** | **± 0.52** | 0.42 | 0.58 | 1.49 |
| 2 | 5 YKN | 25 YKN 144 Detay | ± 0.19 | ± 0.33 | ± 0.38 | **± 0.72** | 0.52 | 0.87 | 1.75 |
| 3 | 8 YKN | 22 YKN 144 Detay | **± 0.18** | **± 0.26** | **± 0.31** | **± 0.54** | 0.49 | 0.72 | 1.66 |
| 4 | 30 Detay | 30 YKN 114 Detay | ± 0.14 | ± 0.19 | ± 0.23 | ± 0.52 | 0.44 | 0.56 | 1.47 |
| 5 | 5 Detay | 30 YKN 139 Detay | ± 0.26 | ± 0.34 | ± 0.42 | **± 0.94** | 0.66 | 0.90 | 2.05 |
| 6 | 8 Detay | 30 YKN 136 Detay | **± 0.20** | **± 0.29** | **± 0.35** | **± 0.56** | 0.56 | 0.79 | 1.55 |

Fotogrametrik dengeleme işlemlerinde 10 cm yer örnekleme aralığında çekilen hava fotoğrafları kullanılarak dengeleme yapılmıştır.

Dengeleme 1: Arazide ölçümü yapılan 30 adet yer kontrol noktası dengeleme kullanılmış ve 146 adet detay noktası kontrol noktası olarak seçilmiştir. Kontrol noktaları 3-sigma kuralına göre z yönündeki hata miktarı %99.7 sınırı içerisinde olmayan 9 adet detay noktası tespit edilmiş ve diğer dengeleme iterasyonlarınada dâhil edilmemiştir.

2024 yılında ölçülen 30 adet yer kontrol noktası kullanılarak fotogrametrik nirengi dengelemesi yapılmıştır ve 137 adet detay noktası kontrol noktası olarak seçilmiştir. (Şekil 11), elde edilen dengeleme sonuçları Tablo 6'da, kontrol noktalarının sonuçları Tablo 7'de, ve kontrol noktalarının hatasını gösteren grafik Şekil 12'de sunulmuştur.

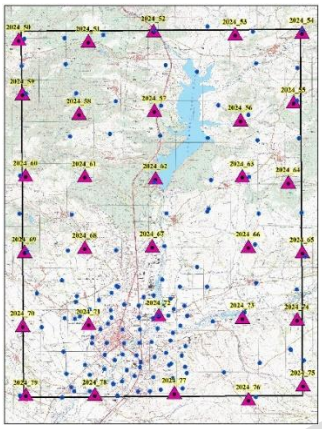

**Şekil 11.** Dengeleme-1'de kullanılan noktaların dağılımı

**Tablo 6.** Dengeleme-1'de elde edilen sonuçlar

| | X (m) | Y (m) | Z (m) |
|---|---|---|---|
| **Maksimum** | -0.11 | -0.10 | 0.18 |
| **Ortalama** | 0 | 0 | 0 |
| **Standart Sapma** | 0.05 | 0.05 | 0.08 |
| **KOH (x,y,z)** | **0.05** | **0.05** | **0.07** |
| **KOHr** | 0.07 | $\sqrt{[(KOHx)^2+(KOHy)^2]}$ | |
| **DOĞRULUKr (%95 Güven Aralığında)** | 0.12 | KOHr*1.7308 | |
| **DOĞRULUKz (%95 Güven Aralığında)** | 0.15 | KOHz*1.9600 | |

**Tablo 7.** Dengeleme-1'de elde edilen kontrol noktalarının sonuçları

| | X (m) | Y (m) | Z (m) |
|---|---|---|---|
| **Maksimum** | -0.44 | 0.31 | -0.49 |
| **Ortalama** | -0,01 | 0.03 | -0.03 |
| **Standart Sapma** | 0.09 | 0.11 | 0.16 |
| **KOH (x,y,z)** | **0.09** | **0.11** | **0.16** |
| **KOHr** | 0.14 | $\sqrt{[(KOHx)^2+(KOHy)^2]}$ | |
| **DOĞRULUKr (%95 Güven Aralığında)** | 0.25 | KOHr*1.7308 | |
| **DOĞRULUKz (%95 Güven Aralığında)** | 0.32 | KOHz*1.9600 | |

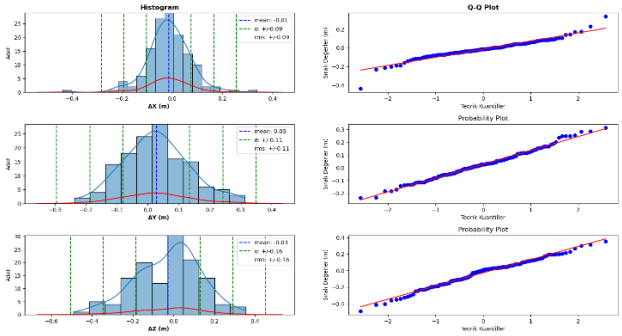

**Şekil 12.** Kontrol noktalarının hatalarını gösteren grafik

Dengeleme 6: 18 adet yer kontrol noktası kullanılarak fotogrametrik nirengi dengelemesi yapılmıştır. 12 adet YKN ve 137 adet detay noktası kontrol noktası olarak seçilmiştir (Şekil 13), elde edilen dengeleme sonuçları Tablo 8'de, kontrol noktalarının sonuçları Tablo 9'da, ve kontrol noktalarının hatasını gösteren grafik Şekil 14'de sunulmuştur.

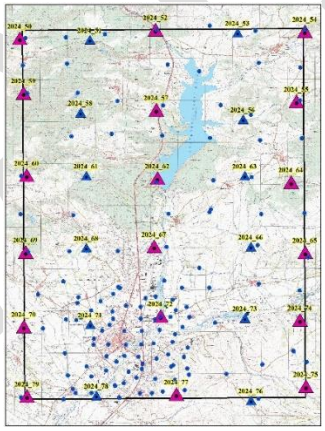

**Şekil 13.** Dengeleme-6'da kullanılan noktaların dağılımı

**Tablo 8.** Dengeleme-6'da elde edilen sonuçlar

| | X (m) | Y (m) | Z (m) |
|---|---|---|---|
| **Maksimum** | -0.12 | -0.12 | 0.20 |
| **Ortalama** | 0 | 0 | 0 |
| **Standart Sapma** | 0.06 | 0.07 | 0.10 |
| **KOH (x,y,z)** | **0.06** | **0.07** | **0.09** |
| **KOHr** | 0.09 | $\sqrt{[(KOHx)^2+(KOHy)^2]}$ | |
| **DOĞRULUKr (%95 Güven Aralığında)** | 0.16 | KOHr*1.7308 | |
| **DOĞRULUKz (%95 Güven Aralığında)** | 0.18 | KOHz*1.9600 | |

**Tablo 9.** Dengeleme-6'da elde edilen kontrol noktalarının sonuçları

| | X (m) | Y (m) | Z (m) |
|---|---|---|---|
| **Maksimum** | -0.48 | 0.32 | -0.49 |
| **Ortalama** | -0.03 | 0.03 | 0 |
| **Standart Sapma** | 0.10 | 0.12 | 0.16 |
| **KOH (x,y,z)** | **0.10** | **0.12** | **0.16** |
| **KOHr** | 0.16 | $\sqrt{[(KOHx)^2+(KOHy)^2]}$ | |
| **DOĞRULUKr (%95 Güven Aralığında)** | 0.27 | KOHr*1.7308 | |

| | | |
|---|---|---|
| **DOĞRULUKz (%95 Güven Aralığında)** | 0.31 | KOHz*1.9600 |

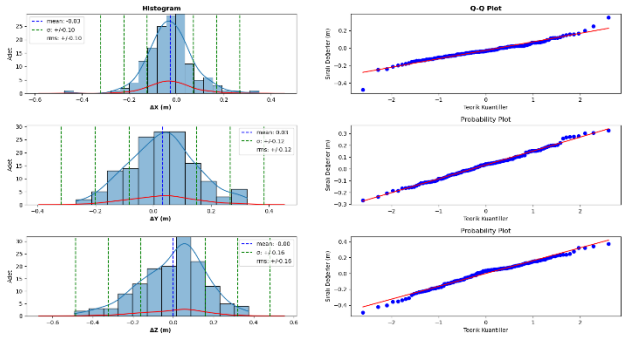


**Şekil 14.** Dengeleme noktalarının hatalarını gösteren grafik

Fotogrametrik nirengi dengeleme işlemlerinde farklı iterasyonlarda yer kontrol noktası ve detay noktası kullanılarak hesaplanan sonuçlar Tablo 10'da sunulmuştur.

**Tablo 10.** Blok dengeleme sonucunda kontrol noktalarının KOH değerleri

| Dengeleme No | Dengelemede Kullanılan Nokta Sayısı | Kontrol Noktası Sayısı | KOH X | KOH Y | KOHp Planimetrik | KOH Z | \|ΔX max\| | \|ΔY max\| | \|ΔZ max\| |
|---|---|---|---|---|---|---|---|---|---|
| 1 | 30 YKN | 137 Detay | ± 0.09 | ± 0.11 | ± 0.14 | ± 0.16 | 0.44 | 0.31 | 0.49 |
| 2 | 5 YKN | 25 YKN 137 Detay | ± 0.17 | ± 0.23 | ± 0.28 | ± 0.26 | 0.58 | 0.48 | 0.79 |
| 3 | 8 YKN | 22 YKN 137 Detay | ± 0.15 | ± 0.17 | ± 0.22 | ± 0.22 | 0.54 | 0.35 | 0.66 |
| 4* | 13 YKN | 17 YKN 137 Detay | ± 0.10 | ± 0.14 | ± 0.17 | ± 0.17 | 0.47 | 0.30 | 0.60 |
| 5* | 15 YKN | 15 YKN 137 Detay | ± 0.10 | ± 0.12 | ± 0.16 | ± 0.16 | 0.48 | 0.30 | 0.49 |
| 6 | 18 YKN | 12 YKN 137 Detay | ± 0.10 | ± 0.12 | ± 0.16 | ± 0.16 | 0.48 | 0.32 | 0.49 |
| 7 | 30 Detay | 30 YKN 107 Detay | ± 0.10 | ± 0.11 | ± 0.15 | ± 0.18 | 0.45 | 0.33 | 0.57 |
| 8 | 5 Detay | 30 YKN 132 Detay | ± 0.17 | ± 0.24 | ± 0.30 | ± 0.31 | 0.60 | 0.48 | 0.82 |
| 9 | 8 Detay | 30 YKN 129 Detay | ± 0.15 | ± 0.20 | ± 0.25 | ± 0.26 | 0.56 | 0.39 | 0.74 |
| 10 | 13 Detay | 30 YKN 124 Detay | ± 0.13 | ± 0.17 | ± 0.21 | ± 0.22 | 0.51 | 0.37 | 0.67 |
| 11 | 15 Detay | 30 YKN 122 Detay | ± 0.13 | ± 0.15 | ± 0.20 | ± 0.21 | 0.52 | 0.36 | 0.67 |
| 12 | 18 Detay | 30 YKN | ± 0.12 | ± 0.13 | ± 0.18 | ± 0.19 | 0.50 | 0.33 | 0.60 |

## 3. BULGULAR

Bu çalışmada, fotogrametrik nirengi dengelemelerinde farklı sayıda yer kontrol noktaları ve detay noktaları kullanılarak blok dengelemesi yapılmıştır. Farklı iterasyonlarda yapılan blok dengeleme sonucunda, denetleme noktalarının KOH değerlerine ilişkin istatistikler hesaplanmıştır.

Fotogrametrik dengeleme işlemlerinde 30 cm yer örnekleme aralığında çekilen hava fotoğrafları kullanılarak elde edilen dengeleme sonucu Tablo 11'de sunulmuş ve 10 cm yer örnekleme aralığında çekilen hava fotoğrafları kullanılarak elde edilen dengeleme sonucu Tablo 12'de sunulmuştur.

**Tablo 11.** Blok dengeleme sonucunda kontrol noktalarının KOH değerleri (30 cm)

| Dengeleme No | Dengelemede Kullanılan Nokta Sayısı | Kontrol Noktası Sayısı | KOH X | KOH Y | KOHp Planimetrik | KOH Z | \|ΔX max\| | \|ΔY max\| | \|ΔZ max\| |
|---|---|---|---|---|---|---|---|---|---|
| 3 | 8 YKN | - | ± 0.08 | ± 0.13 | ± 0.15 | ± 0.25 | 0.16 | 0.23 | 0.37 |
| 3-Kontrol | 8 YKN | 22 YKN 144 Detay | ± 0.18 | ± 0.26 | ± 0.31 | ± 0.54 | 0.49 | 0.72 | 1.66 |
| 6 | 8 Detay | - | ± 0.13 | ± 0.14 | ± 0.19 | ± 0.24 | 0.23 | 0.20 | 0.35 |
| 6-Kontrol | 8 Detay | 30 YKN 136 Detay | ± 0.20 | ± 0.29 | ± 0.35 | ± 0.56 | 0.56 | 0.79 | 1.55 |

**Tablo 12.** Blok dengeleme sonucunda kontrol noktalarının KOH değerleri (10 cm)

| Dengeleme No | Dengelemede Kullanılan Nokta Sayısı | Kontrol Noktası Sayısı | KOH X | KOH Y | KOHp Planimetrik | KOH Z | \|ΔX max\| | \|ΔY max\| | \|ΔZ max\| |
|---|---|---|---|---|---|---|---|---|---|
| 6 | 18 YKN | - | ± 0.06 | ± 0.07 | ± 0.09 | ± 0.09 | -0.12 | -0.12 | 0.20 |
| 6-Kontrol | 18 YKN | 12 YKN 137 Detay | ± 0.10 | ± 0.12 | ± 0.16 | ± 0.16 | 0.48 | 0.32 | 0.49 |
| 12 | 18 Detay | - | ± 0.06 | ± 0.08 | ± 0.10 | ± 0.08 | 0.12 | -0.14 | 0.17 |
| 12-Kontrol | 18 Detay | 30 YKN 119 Detay | ± 0.12 | ± 0.13 | ± 0.18 | ± 0.19 | 0.50 | 0.33 | 0.60 |

### a. Büyük Ölçekli Harita ve Harita Bilgisi Üretim Yönetmeliği (BÖHHBÜY)'ne göre:

BÖHHBÜY doğruluk standartlarında yer alan Tablo 13 incelendiğinde, ortofoto ve harita üretiminin 10 cm yer örnekleme aralığı için 1:1.000 ölçeğinde, 30 cm yer örnekleme aralığı için ise 1:5.000 ölçeğinde yapıldığı durumlarda, fizibilite çalışmasında elde edilen sonuçların Tablo 13'te gösterilen BÖHHBÜY standartlarında belirtilen değerlerden daha küçük olduğu görülmüştür. (BÖHHBÜY 2018).

**Tablo 13**. Büyük Ölçekli Harita ve Harita Bilgisi Üretim Yönetmeliği Standartları

| ÖLÇEK | $KOH_{X,Y}$ (±cm) | $KOH_{Planimetrik}$ $(\sqrt{KOH_X^2 + KOH_Y^2})$ (±cm) | $KOH_Z$ (±cm) |
|---|---|---|---|
| 1/1.000 | 14.62 | 20.68 | 19.44 |
| 1/5.000 | 44.46 | 62.88 | 59.13 |

### b. Amerikan Fotogrametri ve Uzaktan Algılama Derneği (ASPRS) Büyük Ölçekli Haritalar için Doğruluk Standardına göre:

ASPRS doğruluk standartları Tablo 14'e bakıldığında üretilecek ortofoto ve haritalar 1:1.000 ölçeğinde olduğunda Sınıf 1 derecelendirmede planimetrik doğruluk 0.25 m ve 1:5.000 ölçeğinde olduğunda ise 1.25 m olacağından dolayı fizibilite çalışmasında elde edilen sonuçların ASPRS standartlarında belirtilen değerlerden daha küçük olduğu görülmüştür (ASPRS 1998).

**Tablo 14**. Büyük Ölçekli Haritalar İçin ASPRS Doğruluk Standartları

| Sınıf 1 Planimetrik Doğruluk Sınırlama RMSE (m) | Harita Ölçeği |
|---|---|
| 0.0125 | 1:50 |
| 0.025 | 1:100 |
| 0.050 | 1:200 |
| 0.125 | 1:500 |
| 0.25 | 1:1.000 |
| 0.50 | 1:2.000 |
| 1 | 1:4.000 |
| 1.25 | 1:5.000 |
| 2.50 | 1:10.000 |
| 5 | 1:20.000 |

## 4. SONUÇLAR

Fotogrametrik nirengi dengelemesinde Kahramankazan bölgesinde 180 km²' lik alanda 30 cm yer örnekleme aralığında 1:5000 ölçeğinde harita üretimi için gerekli olan doğruluğu sağlamak için 8 adet yer kontrol noktası ölçülmesi ile elde edilen "Dengeleme 3" sonuçlarında karesel ortalama hata (KOH) değeri planimetrik olarak ± 0.15 m, düşeyde ± 0.25 m hesaplanmıştır. 22 adet YKN ve 144 adet detay denetleme noktası ile kontrol edilerek KOH değeri planimetrik olarak ± 0.31 m, düşeyde ± 0.54 m olarak hesaplanmıştır.edilerek KOH değeri planimetrik olarak ± 0.37 m, düşeyde ± 0.43 m olarak hesaplanmıştır.

8 adet detay noktası ölçülmesi ile elde edilen "Dengeleme 6" sonuçlarında karesel ortalama hata (KOH) değeri planimetrik olarak ± 0.19 m, düşeyde ± 0.24 m hesaplanmıştır. 30 adet YKN ve 136 adet detay denetleme noktası ile kontrol edilerek KOH değeri planimetrik olarak ± 0.35 m, düşeyde ± 0.56 m olarak hesaplanmıştır.

Fotogrametrik nirengi dengelemesinde Kahramankazan bölgesinde 180 km²' lik alanda 10 cm yer örnekleme aralığında 1:1000 ölçeğinde harita üretimi için gerekli olan doğruluğu sağlamak için 18 adet yer kontrol noktası ölçülmesi ile elde edilen "Dengeleme 6" sonuçlarında karesel ortalama hata (KOH) değeri planimetrik olarak ± 0.09 m, düşeyde ± 0.09 m hesaplanmıştır. 12 adet YKN ve 137 adet detay denetleme noktası ile kontrol edilerek KOH değeri planimetrik olarak ± 0.16 m, düşeyde ± 0.16 m olarak hesaplanmıştır.

18 adet detay noktası ölçülmesi ile elde edilen "Dengeleme 12" sonuçlarında karesel ortalama hata (KOH) değeri planimetrik olarak ± 0.10 m, düşeyde ± 0.08 m hesaplanmıştır. 30 adet YKN ve 119 adet detay denetleme noktası ile kontrol edilerek KOH değeri planimetrik olarak ± 0.18 m, düşeyde ± 0.19 m olarak hesaplanmıştır.

Sonuç olarak; 30 cm yer örnekleme aralığında, 1:5.000 ölçekli harita üretimi için yeterli doğruluğun sağlanabilmesi amacıyla, fotogrametrik nirengi bloğunda 8 adet YKN'nin veya 8 adet detay noktasının dengelemede kullanılması ve diğer noktaların kontrol noktası olarak değerlendirilmesi durumunda, yaklaşık 23 km²'de 1 nokta olacak şekilde, noktalar arası mesafenin ise yaklaşık 5 km olarak hesaplanmıştır. Benzer şekilde, 10 cm yer örnekleme aralığında, 1:1.000 ölçekli harita üretimi için yeterli doğruluğun sağlanabilmesi için, fotogrametrik nirengi bloğunda 18 adet YKN'nin veya 18 adet detay noktasının dengelemede kullanılması ve diğer noktaların kontrol noktası olarak kullanılması durumunda, yaklaşık 10 km²'de 1 nokta olacak şekilde, noktalar arası mesafenin ise yaklaşık 3 km olarak hesaplanmıştır. Fotogarametrik nirengi bloklarında kullanılan kontrol noktalarının (KOH) değeri planimetrik ve düşey olarak hesaplanmıştır.

Elde edilen sonuçların Büyük Ölçekli Harita ve Harita Bilgisi Üretim Yönetmeliği (BÖHHBÜY) ile ASPRS büyük ölçekli haritalar için doğruluk standardına uygun olduğu görülmüştür.

Çalışma planı olarak değerlendirme yapıldığında;

- 10 cm yer örnekleme aralığında 1/1000 ölçekli harita üretiminde yer kontrol noktası planlanması durumunda; Kahramankazan bölgesinde (180 km²) 18 adet YKN planlanması gerekmektedir.
- Detay noktası planlanması durumunda Kahramankazan bölgesinde blok yapısına göre "Dengeleme 6-12 (10cm)" de olduğu gibi planlama yapılması gerekmektedir. Ancak detay noktalarının hava fotoğrafında net olarak görünmeme olasılığından dolayı planlanan noktaların yakın çevresine yedek detay noktası planlanması yararlı olacaktır. Bu durumda blokta toplam 36 adet detay noktası planlanması gerekmektedir.
- 30 cm yer örnekleme aralığında 1/5000 ölçekli harita üretiminde yer kontrol noktası planlanması durumunda; Kahramankazan bölgesinde (180 km²) 8 adet YKN planlanması gerekmektedir.
- Detay noktası planlanması durumunda Kahramankazan bölgesinde blok yapısına göre "Dengeleme 3-6 (30cm)" da olduğu gibi planlama yapılması gerekmektedir. Ancak detay noktalarının hava fotoğrafında net olarak görünmeme olasılığından dolayı planlanan noktaların yakın çevresine yedek detay noktası planlanması yararlı olacaktır. Bu durumda blokta toplam 16 adet detay noktası planlanması gerekmektedir.
- Arazide yer kontrol noktası tesisi/ölçümü veya detay noktası ölçümünün yapılmasında; hava şartları, yapılacak ölçü yöntemi, noktaların konaklama noktasına uzaklığı, yol durumu ve noktaların birbirine olan uzaklığı aynı olacaktır.
- Yer kontrol noktasının intikal yapıldıktan sonra tesisi yaklaşık 30-45 dk sürmektedir. Yer kontrol noktası tesisi için boya, taş vs. kullanılmaktadır. Bir ekip günde yaklaşık 3-4 nokta tesis yapmaktadır.
- Detay noktası ölçümü intikal yapıldıktan sonra tesis olmadığı için ölçümü 10-15 dk sürmektedir. Bir ekip günde yaklaşık yedek noktalarla birlikte 6-8 nokta ölçmektedir.

Bu durumda;

- Yer kontrol noktası yerine detay noktası ölçülmesi durumunda günlük çalışma zamanı olarak %10 oranında azalabileceği ve maliyet açısından malzeme (boya vb.) kullanımının ortadan kalkacağı değerlendirilmektedir.
- Hava fotoğrafı çekiminin; başta meteorolojik koşullar olmak üzere çeşitli nedenlerden dolayı (sinyal karıştırması, öncelik arz eden diğer faaliyetler vb.) hemen yapılamaması ya da hiç yapılamaması durumunda olan bölgelerde detay noktası ölçümü planlamak ve hava fotoğrafı çekimi yapılması muhtemel olan paftalarda ise yer kontrol noktası tesisi yapmak uygun olacaktır.

**Yazar Katkı Oranı**

Yazarların makaleye eşit oranda katkı sağlamıştır.

**Çıkar Çatışması/Çakışması**

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

**KAYNAKÇA**

BÖHHBÜY (2018). Büyük Ölçekli Harita ve Harita Bilgisi Üretim Yönetmeliği.

ASPRS (1998). Amerikan Fotogrametri ve Uzaktan Algılama Derneği Büyük Ölçekli Haritalar için Doğruluk Standardı.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Fotogrametrik Verilerden Yarı-Otomatik Yöntemle Üretilen CityGML Modellerinin Çatı Tipine Göre Tam Otomatik Yöntemle Sınıflandırılması

**Hasan Onur Işık**[*1,2]

[1]*İstanbul Büyükşehir Belediyesi, İmar ve Şehircilik Dairesi Başkanlığı, Harita Şube Müdürlüğü, 34134, İstanbul.*
[2]*İstanbul Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Geomatik Mühendisliği, İstanbul, Türkiye.*

**Anahtar Kelimeler**
CityGML, Çatı Sınıflandırma, Python, 3B Bina Modeli, Geometrik Analiz

**ÖZET**

3 boyutlu kent modeli uygulamaları, Türkiye'de de hızla gelişen bir araştırma alanıdır. Bu modellerin üretiminde otomatik, yarı-otomatik ve manuel yöntemler kullanılmakta, özellikle büyük kentlerde otomatikleştirme süreçleri zaman ve iş gücü açısından avantaj sağlamaktadır. Son yıllarda yalnızca geometrik değil, öznitelik verilerinin de otomatik türetilmesine yönelik çalışmalar artmıştır. Bu kapsamda çatı tiplerinin iç topolojik ve geometrik özelliklere göre belirlenmesi güncel ve önemli bir konudur. Çatı tipleri, mekânsal analizler için kritik olup, sınıflandırmaları için çeşitli şemalar geliştirilmiştir. Bunlardan biri olan CityGML veri modelinde çatı türleri, sabit bir değer listesi yerine gml:CodeType olarak tanımlanmakta, ilgili kod listesi ise CityGML şeması dışında, SIG 3D adlı uluslararası bir uzman grubu tarafından önerilmektedir. Bu liste 14 farklı çatı tipini içermektedir. Bu çalışmada, İstanbul Büyükşehir Belediyesi tarafından yürütülen "İstanbul İl Sınırları İçerisinde, Fotogrametrik Yöntemle 1/1000 ve 1/5000 Ölçekli Revizyon Halihazır Harita, 1/1000 Ölçekli Gerçek Ortofoto Harita ve 3 Boyutlu Kent Modeli Üretim İşi" kapsamında yarı-otomatik yöntemle üretilen veriler kullanılarak Python yazılım dili ile çatıların tam otomatik olarak sınıflandırılmasına yönelik algoritmalar geliştirilmiştir.

# Automatic Roof Type Classification of CityGML Models Semi-Automatically Derived from Photogrammetric Data

**Keywords**
CityGML, Roof Classification, Python, 3D Building Model, Geometric Analysis

**ABSTRACT**

Applications of 3D city models are rapidly evolving as a research area in Turkey as well. Various methods—automatic, semi-automatic, and manual—are employed in the production of these models, with automation processes offering significant advantages in terms of time and labor, especially in large urban areas. In recent years, studies have increasingly focused not only on geometric aspects but also on the automatic derivation of semantic attributes. In this context, the classification of roof types based on internal topological and geometric characteristics has become a current and significant topic. Roof types are critical for spatial analysis, and various classification schemes have been developed for this purpose. In one of these schemes, the CityGML data model, roof types are defined using gml:CodeType instead of a fixed enumeration, and the corresponding code list is proposed by an international expert group known as SIG 3D, independent of the CityGML schema. This list includes 14 distinct roof types. In this study, algorithms were developed in the Python programming language for the fully automatic classification of roofs using semi-automatically produced data from the project titled "Production of 1/1000 and 1/5000 Scale Revised Base Maps, 1/1000 Scale True Ortho Photo Maps, and 3D City Model Within the Boundaries of Istanbul Province," carried out by the Istanbul Metropolitan Municipality.

## 1. GİRİŞ

3 boyutlu kent modeli uygulamaları dünya genelinde olduğu gibi Türkiye'de de gelişmekte olan bir araştırma ve uygulama alanıdır (Biljecki ve diğ., 2015, URL-1). Bu modellerin üretilme aşamalarında uygulanan otomatik, yarı-otomatik, prosedürel, manuel yöntemler gibi farklı yaklaşımlar kullanılmaktadır. Özellikle büyük kentlerdeki nesne yoğunlukları nedeniyle zaman ve iş gücü optimizasyonu sağlayacak olan otomatikleştirilmiş

* **Sorumlu Yazar**
*(e-mail) ORCID ID xxxx – xxxx – xxxx – xxxx

**Kaynak Göster (APA):**
Işık H O (2025). Fotogrametrik Verilerden Yarı-Otomatik Yöntemle Üretilen CityGML Modellerinin Çatı Tipine Göre Tam Otomatik Yöntemle Sınıflandırılması, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

üretim teknikleri modelleme yaklaşımlarında destekleyici bir yöntem olarak kullanılmaktadır. Son yıllarda yalnızca nesne geometrileri değil, aynı zamanda -bu alanda üretilen veri örnekleri ve uygulamalarının artması ile birlikte- bu nesnelere ait öznitelik verilerinin otomatik olarak türetilmesine yönelik çalışmalar da artış göstermektedir. Bununla birlikte çatı tiplerinin belirlenmesinin kent modelinin oluşturulmasının öncül bir süreci olarak tanımlandığı çalışmalar da bulunmakta ve bu belirleme sürecinin sonrasında model tabanlı, veri tabanlı ve hibrit yaklaşımlar dışında derin öğrenme odaklı modellemeler gerçekleştirilmektedir (Krafczek ve Jabari. ,2022).

Bir yönüyle de mevcut çalışmaların çoğunda çatı geometrileri yeniden yapılandırılmakta; ancak çatı tipi gibi semantik bilgilerin bir öznitelik olarak tanımlanması çoğu zaman ihmal edilmektedir (Biljecki & Dehbi, 2019). Meng ve diğ. (2023) ise kamuya ait veri tabanlarında çatı tipi verisinin en eksik üretilen bina özelliklerinden birisi olduğunu belirterek rüzgâr hassasiyet analizinde kullanımı için uydu görüntüleri üzerinden otomatik çatı tipleri belirlemek üzerine yapay zekâ destekli bir algoritma geliştirmişlerdir. Biljecki ve Dehbi (2019) ise yapı işlevi, fiziksel özellikleri, geometrisi ve çevresel bilgileri ile çatı tipi tahmin modeli önermiştir.

Literatürde gerçekleştirilmiş olan bu teknik yaklaşımlar ele alındığında, İstanbul gibi morfolojik olarak karmaşık yapı stoğuna sahip bir metropolde geometrinin tam otomatik olarak modellenmesi sınırlı kalabilmektedir. Yapılan çalışmalarda sınırlı sayıda çatı tiplerinin belirlenmesi ile birlikte, kent ve bina yerleşimi ve mülkiyet altyapısına ilişkin envanterler binaların otomatik modellenmesi yaklaşımlarını destekleyici unsurlardır. İstanbul'un özgün koşulları nedeniyle operatör destekli yaklaşımların olması model doğruluğunu artırmaktadır. Son yıllarda ülkemizin gerektirdiği mevzuat ve üretim yöntemleri sonucunda İstanbul'da yüksek geometrik doğruluğa sahip elde edilen vektör veriler bulunmaktadır. Bu bağlamda nesnelerin öznitelik verilerinin iç topolojik ve geometrik özelliklerinden yararlanarak türetilmesi örneklerinden birisi olan çatı tiplerinin otomatik üretimi güncel ve önemli bir konu olarak değerlendirilmiştir.

Çatı tipleri, birçok mekânsal analiz için öncül veri niteliği taşımakta ve bu nedenle sınıflandırmalarına yönelik olarak da çeşitli kategorileştirme şemaları geliştirilmektedir. Bu şemalardan biri kent modellerinin yaygın biçimde kullanılan veri modeli ve standardı olan CityGML çerçevesinde ele alınmaktadır. CityGML'de çatı tipleri (roofType), sabit bir değer listesi olarak değil, gml:CodeType veri türüyle tanımlanmakta olup, bu değerlere ilişkin önceden tanımlanmış değerler listesi oluşturan "codelist" CityGML şemasının dışında tanımlanmaktadır. Bu kod listesi, 3B kent ve arazi modelleri üzerine çalışan uluslararası bir uzman grubu olan Sig3D (URL-2) tarafından önerilmekte ve CityGML standardının eki olan Annex C'de örnek olarak sunulmaktadır. SIG 3D tarafından tanımlanan bu öneri kod listesi, 14 farklı çatı tipini içermektedir. Bu çalışmada, söz konusu çatı tiplerinin otomatik olarak belirlenmesi amaçlanmış olup, İstanbul Büyükşehir Belediyesi Harita Müdürlüğü tarafından yürütülmüş olan "İstanbul İl Sınırları İçerisinde, Fotogrametrik Yöntemle 1/1000 ve 1/5000 Ölçekli Revizyon Halihazır Harita, 1/1000 Ölçekli Gerçek Ortofoto Harita ve 3 Boyutlu Kent Modeli Üretim İşi" kapsamında üretilen veriler kullanılarak Python yazılım dili ile çatıların otomatik olarak sınıflandırılması yönelik algoritmalar geliştirilmiştir.

## 2. VERİ

Bu çalışmada kullanılan veriler, yukarıda bahsedilmiş olan iş kapsamında üretilmiş olan OGC'nin tanımladığı CityGML standartına (Gröger ve diğ., 2012) uygun üretilmiştir. XML tabanlı bir veri modeli olan CityGML içinde her bir bina <bldg:Building> alanı üst yapısı içerisinde binanın bileşenlerinin tanımlandığı alt alanlardan oluşur. Bu bileşenlerden bir tanesi de <bldg:RoofSurface> alanı altında tanımlanan çatı yüzeyleridir. Bu yapı içerisinde birden fazla yüzeyi tanımlamak için oluşturulan çokgenleri tanımlayan çokgen köşeleri dizisini içeren koordinat kümeleri yer almaktadır.

## 3. YÖNTEM

Bu çalışmada, CityGML formatındaki bina modellerinin çatı yüzeylerinin SiG3D tarafından belirtilen çatı tiplerine göre otomatik olarak sınıflandırılmasına yönelik Python programlama dili ile geliştirilen bir algoritma kullanılmıştır. Öncelikle GML dosyaları ayrıştırılarak her bina için <bldg:RoofSurface> etiketleri içerisindeki üç boyutlu koordinat verileri elde edilmektedir. Bu yüzeylerden çokgen biçimli çatılar için üçgenleme gerçekleştirilerek her bir üçgen yüzeyin normal vektörü hesaplanmıştır. Elde edilen normal vektörler, eğim (inclination) ve yönelim (azimuth) açılarına göre gruplanarak çatı yüzeyleri sınıflandırılmış; benzer yönelimli ve küçük alana sahip gruplar ise en yakın grupla birleştirilmiştir. Sınıflandırma sürecinde, eğim oranı, azimut yönleri, yüzey alan oranları ve ortak kenar kontrolü gibi mekânsal kriterler dikkate alınarak her binanın olması gereken çatı tipi belirlenmiş; sonuçlar 3B görselleştirme ile desteklenmiş ve Excel formatında raporlanmıştır.

### 3.1. GML Dosyalarının Ayrıştırılması (parsing)

Çalışmada kullanılan CityGML formatındaki binaların çatı geometrileri etree kütüphanesi ile ayrıştırılarak, XML hiyerarşisi üzerinde bldg:RoofSurface etiketine sahip elemanlar aracılığıyla tespit edilmiştir. Bu yüzeylerin geometrik tanımı, gml:posList etiketi altında üç boyutlu koordinatlar (X, Y, Z) biçiminde verilmiştir. Üçten fazla köşe noktasına sahip çokgen yüzeyler, bir bilimsel hesaplama kütüphanesi olan scipy kütüphanesinin mekânsal analiz modülü olan spatial kullanılarak Delaunay üçgenleme sınıfı yardımıyla kulak bulma (ear-clipping) yaklaşımıyla üçgenleştirilmiş ve her bir çatı yüzeyi alt üçgenlere ayrılmıştır. Ardından, analizlerin sağlıklı bir biçimde yürütülebilmesi amacıyla tüm çatı yüzey koordinatları en küçük X, Y ve Z değerleri referans alınarak normalize edilmiş; bu sayede hem görselleştirme hem de eğim ve yönelim temelli grup analizleri için tutarlı ve hızlı işlemleri mümkün hale getiren bir geometrik temel oluşturulmuştur.

### 3.2. Çatı Yüzeylerinin Geometrik Olarak Gruplandırılması

Çatı yüzeylerinin geometrik analizine yönelik ilk adım, her bir üçgensel yüzeyin yönünü tanımlayan normal vektörlerin hesaplanmasıdır. Bu işlem, üçgenin kenar vektörlerinin vektörel çarpım yöntemiyle normallerinin bulunması yoluyla gerçekleştirilir. Birbiriyle kesişerek açısal olarak yaklaşan normaller ilk gruplamaya tabi tutulur. Ardından, gruplanmış ortalama normaller aracılığıyla grup yüzeylerinin ortalama eğimi (inclination) ve yönelimi (azimuth) trigonometrik hesaplamalarla türetilmiştir. Eğim ve yönelim değerleri üzerinden benzer nitelik gösteren yüzeyler gruplandırılmış; gruplama işleminde yüzeylerin hem yönelimsel açı farkı (azimuth) hem de eğimsel açı farkı (inclination) belirli eşik değerleri (örneğin 10° eğim, 20° yönelim) altında kalması koşulu esas alınmıştır. Ayrıca, komşu yüzeylerin uzamsal kesişimi de dikkate alınarak, sadece benzer yönelimde değil aynı zamanda topolojik olarak bağlantılı yüzeylerin aynı gruba dahil edilmesi sağlanmıştır.

Çatı yüzeylerinin normallere göre gruplanmasının ardından ihmal edilebilir derecede küçük olan gruplar geometrik benzerlik ve mekânsal yakınlık ilkeleri göz önüne alınarak komşu gruplara dahil edilirler. Belirli eşik değerinin altında alana sahip olan yüzeylerin öklidyen uzaklıklarına göre yakınlıkları esas alınarak gruplandırılması sağlanır. Bu adımlar, çatı tipinin daha doğru ve homojen şekilde sınıflandırılabilmesi için kritik öneme sahiptir.

### 3.3. Çatı Tipi Sınıflandırma Algoritması

Çatı yüzeylerinin sınıflandırılması süreci SIG 3D CityGML çatı tipi kod listesi esas alınarak yüzey gruplarının eğim ve yönelim gruplandırma sonuçlarının analizine dayanmaktadır. Grupların sayılarına göre belirlenen algoritmalar ile yüzey gruplarının yüzey normallerinin karakteristikleri göz önüne alınarak gruplandırmalar gerçekleştirilmiştir.

### 3.4. Görselleştirme

Çatı yüzeylerinin analiz sonuçları matplotlib kütüphanesi kullanılarak üç boyutlu Poly3DCollection nesneleri aracılığıyla her bir grup farklı bir renk ile temsil edilerek kontrol edilmiştir. Ayrıca, her grup için ortalama normal vektörler de çizilerek yüzey eğimleri ve yönelimleri görsel olarak vurgulanmıştır. Böylece otomatikleştirme sürecinden kaynaklı hatalar mümkün olduğunca azaltılmaya çalışılmıştır. Görselleştirme sadece model geliştirme aşamasında kullanılmış olup verilerin değerlendirilmesi sürecinde kullanılmamıştır.

## 4. BULGULAR

Bu çalışma, Bölüm 3'te açıklanmış olan yöntem doğrultusunda geliştirilmiş olup, PyCharm geliştirme ortamı ve Python programlama dili kullanılarak, 11. Nesil Intel(R) Core(TM) i7-11800H @ 2.30GHz işlemciye ve 16 GB RAM'e sahip 64 bit mimarideki bir sistem üzerinde gerçekleştirilmiştir.

**Çizelge1.** Çatı tipi bazında sınıflandırma doğruluğu, eşleşme ve sapma oranları.

| Çatı Tipi | Toplam | Eşleşen | Eşleşmeyen | Manuel Sapma | Eşleşme (%) | Eşleşme (%) | Manuel Sapma (%) | En Yüksek Doğruluk (%) |
|---|---|---|---|---|---|---|---|---|
| 1000 | 1374 | 1099 | 275 | 264 | 79.99 | 20.01 | 19.21 | 99.20 |
| 1010 | 743 | 393 | 350 | 292 | 52.89 | 47.11 | 39.30 | 92.19 |
| 1020 | 5 | 3 | 2 | 0 | 60.00 | 40.00 | 0.00 | 60.00 |
| 1030 | 1173 | 1060 | 113 | 0 | 90.37 | 9.63 | 0.00 | 90.37 |
| 1040 | 539 | 437 | 102 | 0 | 81.08 | 18.92 | 0.00 | 81.08 |
| 1070 | 159 | 107 | 52 | 8 | 67.30 | 32.70 | 5.03 | 72.33 |
| 1080 | 44 | 38 | 6 | 0 | 86.36 | 13.64 | 0.00 | 86.36 |
| 1090 | 10 | 7 | 3 | 0 | 70.00 | 30.00 | 0.00 | 70.00 |
| 1110 | 2 | 2 | 0 | 0 | 100.00 | 0.00 | 0.00 | 100.00 |
| 1130 | 213 | 152 | 61 | 5 | 71.36 | 28.64 | 2.35 | 73.71 |
| Toplam | 4262 | 3298 | 964 | 569 | 77.38 | 22.62 | 13.35 | 90.73 |

Kullanılan algoritma sonucunda çatıların tiplerinin gruplandırılmasına uygun olacak şekilde olması gereken değerler bir tablo olarak çıktı dosyası olarak kaydedilmekte ve çatı tipi ile ilgili alana eşlenerek gml dosyası güncellenebilmektedir.

Rastgele seçilmiş ve manuel olarak değerlendirmeleri gerçekleştirilmiş olan 4262 adet çatıdan 3289 tanesi manuel değerlendirmeler ile aynı sonucu vermektedir. 1050, 1060 ve 1100 numaralı çatı tiplerine ait örnekler Türkiye'deki mimari kültürde yaygın olarak bulunmamaktadır. 1120 çatı tipi ise oldukça nadir görülmekte olup, test verileri içerisinde yer almamıştır. Ancak, 1120 çatı tipi ile yalnızca eğim yönü açısından farklılık gösteren 1070 çatı tipine dayalı verilerden türetilen yapay test verileri ile yüksek doğrulukta sınıflandırma sonuçları elde edilmiştir.

Bu durumda yazılımın kesin başarı oranının yüzde % 77.38 olduğu saptanmıştır. Bununla birlikte düz ve tek yön eğimli çatı tiplerinde kontrol sınırı olarak belirlenen yüzde 5 eğim sınırı manuel kontrollerde tespit edilmesi mümkün değildir. Aynı zamanda operatör kaynaklı yorum farklılıkları kısmi anlamda çatı tiplerinin değerlendirmeleri açısından farklı yorumlamalara neden olmaktadır. Bu nedenle ortaya çıkan farklılıklar açısından yapılan kısmi kontrollerde otomatik kontrol sonuçlarının doğru oldukları tespit edilmiştir. Söz

konusu farklılık kapsamında olan çatı adeti 569 adettir. Bu durumda otomatik çatı tipi belirleme algoritmasının doğruluğu yüzde 77.38-90.73 aralığındadır. Geriye kalan çatı tiplerinde algoritmanın doğru sonuç verememesinin nedeni çatı geometrilerinin yanlış yorumlanması nedeniyle algoritmanın karma çatı tipi olan 1130 olarak belirlemesine rağmen çatı tipinin başka bir formda olmasından kaynaklanmaktadır. Yapılan değerlendirme sonuçları Çizelge 1'de verilmektedir.

Basit geometrideki çatılarda algoritmanın çalışma doğruluğu yüksek seviyededir. Operatör kaynaklı olarak çatı değerlendirmelerinin hatalar içerdiği geometrilerde çatı tiplerinin sınıflandırılması zorlaşmaktadır.

## 5. SONUÇ

Geliştirilen algoritma, CityGML veri standart/modeli ile tam uyumlu olarak çalışmakta ve bina çatı yüzeylerinin otomatik olarak ayrıştırılıp sınıflandırılabilmesine olanak sağlamaktadır. Çatı yüzeyleri arasındaki yönelim, eğim benzerlikleri ve geometrik kesişimler dikkate alınarak yapılan gruplama işlemleri sayesinde çatılar, tanımlanan karar kuralları ile sınıflandırılmakta; böylece insan müdahalesi olmadan hızlı ve tutarlı sonuçlar elde edilmektedir. Gelecekte; mevcut karar verme yapısının daha fazla çatı tipini içerecek şekilde genişletilmesi, sınıflandırma sürecine makine öğrenmesinin dâhil edilmesi, büyük veri setleri üzerinde zamana bağlı analizlerin yapılabilmesi ve ana değerlendirmeye konu olan ana bina alanları dışında bina kısımlarının da değerlendirme sürecine dahil edilmesi hedeflenmektedir.

## TEŞEKKÜR

Bu çalışma kapsamında, araştırmanın temel girdi verisi olarak kullanılan CityGML veri setlerinin temini konusunda desteklerini esirgemeyen İstanbul Büyükşehir Belediyesi İmar ve Şehircilik Dairesi Başkanlığı Harita Şube Müdürlüğü ve yöneticilerine teşekkür ederim. Özellikle Harita Şube Müdürü Sayın Osman Aydın'a, Müdür Yardımcısı Sayın Ülger Munzuroğlu'na ve emeği geçen tüm kurum çalışanlarına katkılarından dolayı minnettarım. Ayrıca, karşılaştırma verisi olarak kullanılan manuel çatı değerlendirme veri setinin hazırlanmasında büyük emek harcayan Sayın Şeyma Perk'e de içten teşekkürlerimi sunarım.

## Yazar Katkı Oranı

Çalışmanın tüm aşamaları (kavramsallaştırma, veri işleme, algoritma geliştirme, analiz, yazım ve sonuçlandırma) tek bir yazar tarafından yürütülmüştür.

## Çıkar Çatışması/Çakışması

Yazar, bu çalışma kapsamında herhangi bir çıkar çatışması veya çakışması bulunmadığını beyan etmektedir.

## KAYNAKÇA

Biljecki, F., Stoter, J., Ledoux, H., Zlatanova, S., & Çöltekin, A. (2015). Applications of 3D city models: State of the art review. ISPRS International Journal of Geo-Information, 4(4), 2842-2889.

Biljecki, F., & Dehbi, Y. (2019). Raise the roof: Towards generating LoD2 models without aerial surveys using machine learning. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, IV-4/W8, 27–34.

Gröger, G., Kolbe, T. H., Nagel, C., & Häfele, K. H. (2012). OGC city geography markup language (CityGML) encoding standard.

İstanbul Büyükşehir Belediyesi. (2021). *İstanbul İl Sınırları İçerisinde, Fotogrametrik Yöntemle 1/1000 ve 1/5000 Ölçekli Revizyon Halihazır Harita, 1/1000 Ölçekli Gerçek Ortofoto Harita ve 3 Boyutlu Kent Modeli Üretim İşi: Teknik Şartname*. İstanbul Büyükşehir Belediyesi Harita Müdürlüğü.

Krafczek, M., & Jabari, S. (2022). Generating LOD2 city models using a hybrid-driven approach: A case study for New Brunswick urban environment. Geomatica, 75(1), 130-147.

Meng, S., Soleimani-Babakamali, M. H., & Taciroglu, E. (2023). Automatic roof type classification through machine learning for regional wind risk assessment. arXiv preprint arXiv:2305.17315.

URL-1: https://www.tkgm.gov.tr/projeler/3-boyutlu-kent-modelleri-ve-kadastro-projesi

URL-2: https://www.sig3d.org/codelists/citygml/2.0/building/2.0/_AbstractBuilding_roofType.xml

© Hasan Onur Işık, 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Ceyhan Deltası Zamansal Kıyı Çizgisi Değişimlerinin Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Yöntemleriyle İzlenmesi

**Ayşe Dağlıyar*[1], Nihal Çevik[2], Zehra Taş[2], Gültekin Erten[1]**

[1]*MTA Genel Müdürlüğü, Jeoloji Etütleri Dairesi, Uzaktan Algılama Uygulamaları Birimi, Ankara, TÜRKİYE*
[2]*MTA Genel Müdürlüğü, Jeoloji Etütleri Dairesi, Coğrafi Bilgi Sistemleri Uygulamaları Birimi, Ankara, TÜRKİYE*

**Anahtar Kelimeler**
Uzaktan Algılama,
Arazi Bilgi Sistemleri
Kıyı Alanları Yönetimi
Mekansal Analiz

**ÖZET**

Ceyhan Deltası, son 40 yılda doğal ve insan kaynaklı etkenler nedeniyle önemli morfolojik ve sedimanter değişimler geçirmiştir. Bu çalışmada, Ceyhan Deltasına ait yıllık kıyı değişim oranlarının hesaplanması ve MTA Genel Müdürlüğü tarafından gerçekleştirilen, 2011 yılında yayımlanan, 11391 no.lu "Küresel Isınmaya Bağlı Deniz Seviyesi Değişimlerinin Türkiye Kıyıları Üzerindeki Etkilerinin Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Teknikleri ile Araştırılması , Mersin – İskenderun Kıyı Kuşağı Pilot Çalışması" projesi kapsamında, kullanılan istatistiksel yöntemlerle Ceyhan Deltasına ait tahmin edilen 2016 yılı gelecek kıyı çizgisi değişiminin kontrol edilmesi amaçlanmıştır. Bu amaçla, proje kapsamında değerlendirilen kıyı kuşağı 1957 – 2009 yılları arasında incelenmiş olup, elde edilen sayısal kıyı çizgisi verileri ile 2016 yılına ait gelecek kıyı çizgisi tahmin edilmiştir. Gerçekleştirilen çalışmada ise 1984 – 2024 yılları arasındaki tarihsel kıyı değişimleri tekrar incelenmiş ve özellikle 2016 yılına ait Landsat uydu verisi ile gerçek kıyı çizgisi sayısallaştırılarak tahmin edilen kıyı çizgisi karşılaştırılmıştır. Bölgede değişik tarihlerde kurulan barajların kıyı değişim sürecine büyük etkisi olduğu tespit edilmiştir. Buna göre, barajların kurulmasından sonra özellikle Ceyhan Delta ağzında transgresyon yönünde değişim gösterdiği belirlenmiştir. Özellikle 2016 yılı için yapılan kıyı çizgisi tahmininin gerçek verilerle ufak farklılıkları tespit edilmiştir, bu da kıyı süreçlerinin karmaşıklığını ortaya koymaktadır. Bu bulgular, bölgedeki kıyı yönetimi ve çevresel koruma çalışmaları için önemli veriler sağlamaktadır.

# Monitoring of Temporal Coastline Changes in Ceyhan Delta with Remote Sensing and Geographic Information System Methods

**Keywords**
Remote sensing,
Land Information Systems
Shore Land Management
Spatial Analysis

**ABSTRACT**

The Ceyhan Delta has undergone significant morphological and sedimentary changes due to natural and anthropogenic factors in the last 40 years. In this study, it is aimed to calculate the annual coastal change rates of the Ceyhan Delta and to control the estimated future coastline change of the Ceyhan Delta in 2016 with the statistical methods used in the project numbered 11391 "Investigation of the Effects of Sea Level Changes Due to Global Warming on the Turkish Coasts using Remote Sensing and Geographic Information Systems Techniques, Mersin-Iskenderun Coastal Belt Pilot Study" published in 2011 by the General Directorate of MTA. For this purpose, the coastal belt evaluated within the scope of the project was examined between the years 1957-2009 and the future coastline of 2016 was estimated with the obtained digital coastline data. In the study, historical coastal changes between 1984 and 2024 were re-examined and especially the 2016 Landsat satellite data were compared with the estimated coastline by digitizing the actual coastline. It was determined that the dams built in the region at different dates had a great impact on the coastal change process. Accordingly, it was determined that there was a change in the direction of transgression, especially at the mouth of the Ceyhan Delta after the dams were built. In particular, minor differences were detected between the 2016 coastline estimate and the actual data, which reveals the complexity of coastal processes. These findings provide important data for coastal management and environmental protection studies in the region.

## GİRİŞ

Deniz seviyesi değişimleri ve kıyı çizgisi hareketleri, dünya iklimi ve tektonik süreçlerin bir sonucu olarak milyonlarca yıl boyunca devam eden dinamik süreçlerdir. Bu değişimler, doğal süreçlerin yanı sıra insan faaliyetleri tarafından da etkilenmektedir. Tarih boyunca deniz seviyesindeki regresyon ve transgresyon kıyı ekosistemleri, insan yerleşimlerini ve ekonomik

faaliyetleri önemli ölçüde şekillendirmiştir. Deniz seviyesindeki değişimler, kıyı çizgisinin zaman içinde nasıl değiştiğini belirlemektedir. Kıyı çizgisi değişimlerini etkileyen faktörler; iklim değişiklikleri, tektonik hareketler, akarsu tortul taşınımı ve antropojenik etkiler olarak belirtilmektedir (MTA Raporu, 2011).

Kıyı bölgeleri hem doğal hem de insan kaynaklı süreçlerin kıyı çizgisi üzerindeki etkilerini anlamak için kritik öneme sahiptir. Uzaktan algılama ve CBS (Coğrafi Bilgi Sistemleri), bu değişimleri uzun vadeli ve düşük maliyetli izlemek için etkili araçlar sunmaktadır. Örneğin, Abdelaty (2021) çalışmasında Mısır'ın kuzey kıyılarında 34 yıllık kıyı değişimlerini analiz ederek, farklı valiliklerde önemli erozyon ve birikim modelleri ortaya koymuştur (Abdelaty, 2021). Benzer şekilde, El-Masry ve arkadaşları (2024), Mısır'ın Akdeniz kıyısında çok yıllı arazi kullanım ve arazi örtüsü (LULC) değişimlerini inceleyerek, turizm ve kentsel gelişimin kıyı çizgisi üzerindeki etkilerini vurgulamıştır (El-Masry et al., 2024). Farklı bir coğrafi bağlamda, Wang ve arkadaşları (2022) ise Alaska ve Doğu Sibirya'daki Arktik kıyılarında sıcaklık dalgalanmalarının kıyı gerilemesi üzerindeki kritik rolünü ortaya koymuştur (Wang et al., 2022). Buna ek olarak, Kumaat ve Rembet (2023), Endonezya'daki Amurang Körfezi'nde Dijital Kıyı Çizgisi Analiz Sistemi (DSAS) kullanarak beş yıllık erozyon ve birikim oranlarını hesaplamıştır (Kumaat & Rembet, n.d.). Son olarak, Pujianiki ve arkadaşları (2024), Bali adasında SAR görüntüleri kullanarak kıyı çizgisi değişimlerini izlemiş ve uzaktan algılama yöntemlerinin uzun vadeli kıyı değişimlerini belirlemede etkili olduğunu doğrulamıştır (Pujianiki et al., 2024). Bu çalışmalar, farklı çevresel koşullarda kıyı bölgesi değişimlerinin değerlendirilmesi ve yönetimi için uzaktan algılamanın kritik rolünü açıkça ortaya koymaktadır.

## YÖNTEM

### Çalışma Alanı

Ceyhan Deltası, Türkiye'nin güneyinde Akdeniz kıyısında yer almakta olup, Ceyhan Nehri'nin taşıdığı alüvyonlarla oluşmuş dinamik bir kıyı sistemine sahiptir. Zaman içinde hem doğal süreçler hem de insan faaliyetleri nedeniyle delta kıyı çizgisinde önemli değişimler meydan gelmiştir. Tarihsel süreçte, Ceyhan Nehri'nin taşıdığı sedimanlar, delta alanının genişlemesine ve kıyı çizgisinin denize doğru ilerlemesine neden olmuştur. Ancak son yüzyılda artan antropojenik etkilerle bu süreç tersine dönmeye başlamıştır. Küresel iklim değişikliği ve insan faaliyetleri, kıyı bölgelerinde önemli morfolojik değişimlere neden olmaktadır (Nicholls & Cazenave, n.d.; Syvitski et al., 2009). Barajlar ve su yapıları, nehir tarafından taşınan sediman miktarını azaltarak deltanın beslenmesini engellemiş ve kıyı erozyonu ile transgresyona yol açmıştır. Ceyhan Deltası'nda kıyı değişiminin izlenmesi, uydu görüntüleri, Coğrafi Bilgi Sistemleri (CBS) ve uzaktan algılama teknikleri ile mümkün hale gelmiş olup, bu veriler delta kıyısının zaman içindeki hareketlerini analiz etmek için önemli bir kaynak oluşturmaktadır. Yapılan çalışmalar, son yıllarda kıyı çizgisinin bazı bölgelerde gerilediğini ve delta ekosisteminin tehdit altında olduğunu göstermektedir.

Ceyhan Deltası, son kırk yılda doğal süreçler ve insan faaliyetleri nedeniyle önemli morfolojik ve sedimanter değişimlere uğramıştır. Kıyı bölgeleri, sediment taşınımı, deniz seviyesi değişimleri ve insan müdahaleleri gibi faktörlerden etkilenen dinamik alanlardır. Kıyı çizgisi değişimlerinin anlaşılması, sürdürülebilir kıyı yönetimi ve çevresel koruma için büyük önem taşımaktadır. Bu çalışmanın amacı, 1984 – 2024 yılları arasında Ceyhan Deltası'nda meydana gelen kıyı çizgisi değişimlerini uzaktan algılama teknikleri kullanarak analiz etmek ve MTA raporunda belirlenen tahmini 2016 yılı kıyı çizgisi ile güncel 2016 kıyı çizgisini karşılaştırmaktır.

Zamansal kıyı çizgisi değişimini belirlemek amacıyla özellikle barajlar nedeniyle sediman miktarının delta ağzında büyük değişime yol açtığı ve bu nedenle kıyı değişiminin yoğun olarak gözlendiği Ceyhan deltası çalışılmıştır (Şekil 1).

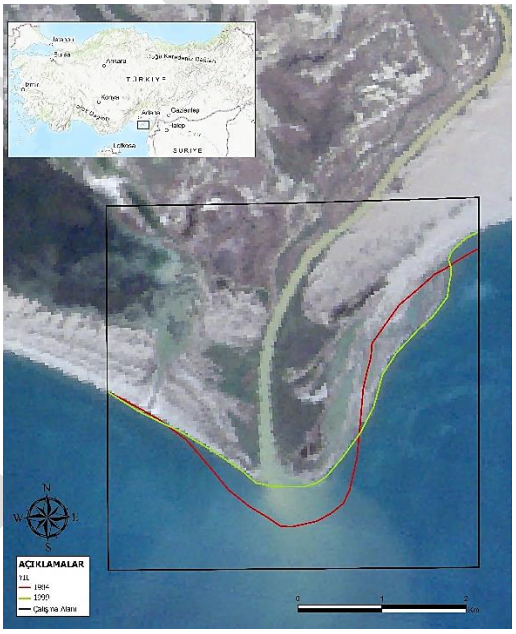


**Şekil 1.** Ceyhan Deltası, 2009 yılı arazi çalışmasından alınan kıyı çizgisi (1984 ve 1999 uydu verilerinden elde edilen kıyı çizgileri ile birlikte) (MTA Raporu, 2011).

Bu çalışmada, Ceyhan Deltası'na ait kıyı çizgisi değişim analizi için iki farklı veri seti kullanılmıştır:

**i.** MTA (11391 no.lu) rapor (2011): 1957 – 2009 yılları arasındaki topoğrafik haritalar, uydu verileri ve 2009 yılında GPS ölçümleri ile elde edilen güncel kıyı çizgisi verileri kullanılarak hazırlanmış ve 2016 yılı için kıyı çizgisi tahmini gerçekleştirilmiştir (Şekil 2).

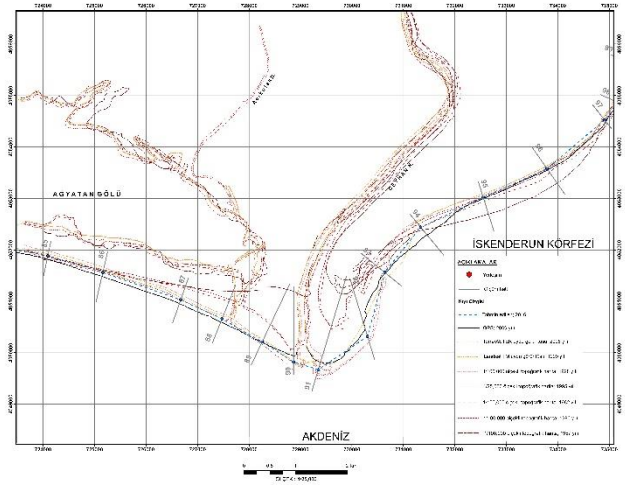


**Şekil 2.** Ceyhan Deltası, 2016 yılı tahmini kıyı çizgisi ile 1957 – 2009 yılları arasındaki verilerden elde edilen kıyı çizgisi değişimleri (MTA Raporu, 2011'den düzenlenmiştir).

**ii.** 1984 – 2024 tarihleri arasındaki uydu verileri kullanılarak kıyı çizgisi sayısallaştırılmış ve zamansal kıyı çizgisi değişimi tespit edilmiştir (Şekil 3). Bununla birlikte, 2016 yılına ait güncel uydu görüntüsü elde edilerek, tespit edilen tahmini 2016 kıyı çizgisi ile kontrol edilmiştir.

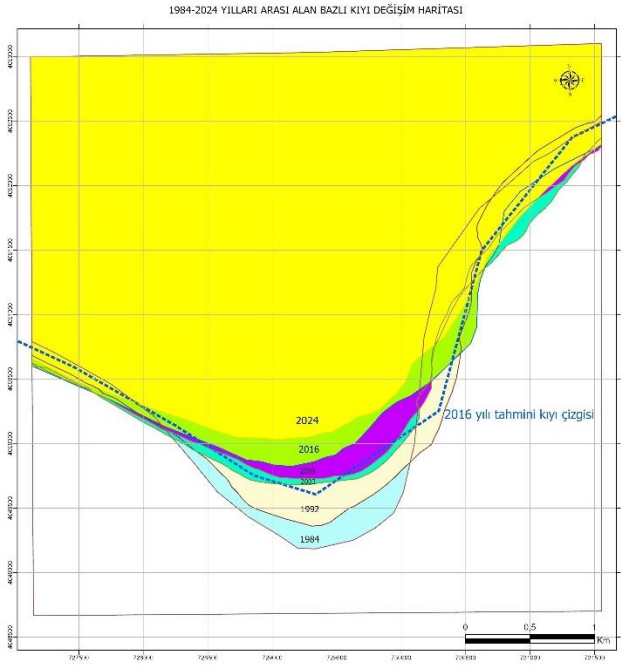


**Şekil 3.** Ceyhan Deltası, 2016 yılı tahmini kıyı çizgisi ile 1984 – 2024 yılları arasındaki verilerden elde edilen kıyı çizgisi değişimleri.

## Laboratuvar Çalışmaları

Çalışma sahasını kapsayan kıyı çizgisi değişimi tarihsel değerlendirmesinin yapılabilmesi amacıyla bölgeye ait veri envanteri araştırılmıştır. Topoğrafik veriler ve uydu görüntüleri elde edilerek tarihsel kıyı çizgileri sayısallaştırılmış ve zamansal kıyı çizgisi değişim tespiti yapılmıştır (Dağlıyar, A., 2013). Elde edilen topoğrafik haritalar (Çizelge 1), uydu görüntüleri (Çizelge 2) ve tarihleri aşağıdaki çizelgelerde belirtilmiştir.

**Çizelge1.** 1/25000 ve 1/100000 ölçekli topoğrafik haritalar ve üretim yılları.

| Pafta Adı (1/25.000) | Üretim Yılı | Pafta Adı (1/100.000) | Üretim Yılı |
|---|---|---|---|
| Mersin–O35-d1<br>Mersin-O35-d2<br>Mersin-O35-d4 | 1995 | Mersin-O35 | 1957-1982-1998 |

**Çizelge2.** Landsat uydu görüntüleri tarihsel dağılımı.

| Path/Row (175/35) | Tarih | Path/Row (175/35) | Tarih |
|---|---|---|---|
| Landsat TM | 1986 | Landsat OLI | 2013 |
| Landsat TM | 1990 | Landsat OLI | 2015 |
| Landsat TM | 1992 | Landsat OLI | 2016 |
| Landsat TM | 1993 | Landsat OLI | 2017 |
| Landsat TM | 1994 | Landsat OLI | 2018 |
| Landsat TM | 1998 | Landsat OLI | 2020 |
| Landsat TM | 2001 | Landsat OLI | 2021 |
| Landsat TM | 2003 | Landsat OLI 2 | 2022 |
| Landsat TM | 2009 | Landsat OLI 2 | 2024 |
| Landsat TM | 2010 | Landsat TM | 2011 |
| Landsat ETM+ | 1999 | Landsat OLI | 2014 |
| Landsat ETM+ | 2000 | Landsat OLI | 2019 |
| Landsat ETM+ | 2004 | Landsat OLI | 2023 |
| Landsat ETM+ | 2005 | Landsat ETM+ | 2002 |
| Landsat TM | 1984 | Landsat ETM+ | 2006 |
| Landsat TM | 1987 | Landsat TM | 1989 |
| Landsat TM | 1988 | Landsat TM | 1991 |
| Landsat TM | 1995 | Landsat TM | 1997 |
| Landsat TM | 1996 | Landsat TM | 2008 |
| Landsat TM | 2007 | **TOPLAM** | **39 görüntü** |

İlgili rapora göre; 1957 – 2009 yılları arasında gerçekleştirilen kıyı çizgisi değişimi çalışmasında elde edilen veriler sayısallaştırılmış ve 2016 yılı tahmini kıyı çizgisi elde edilmiştir. Bu çalışmada ise, barajların ve güncel değişimi tespit etmek amacıyla, 1984 – 2024 tarihleri arasında elde edilen uydu verileri yardımıyla zamansal kıyı değişimi tekrar belirlenmiş, 2016 yılına ait Landsat uydu verisi elde edilerek kıyı çizgisi sayısallaştırılmış ve gerçek kıyı çizgisi verisi elde edilmiştir. 1984 – 2024 yılları arasında 39 uydu verisi kullanılarak sayısallaştırılan zamansal kıyı çizgileri, Ceyhan Delta ağzı baz alınarak alansal değişim kilometrekare cinsinden hesaplanmıştır (Şekil 4). Yapılan hesaplamalar sonucunda determinasyon katsayısı 0.9288 olarak bulunmuştur ve kök ortalama kare sapması ise 0,11621'dir.

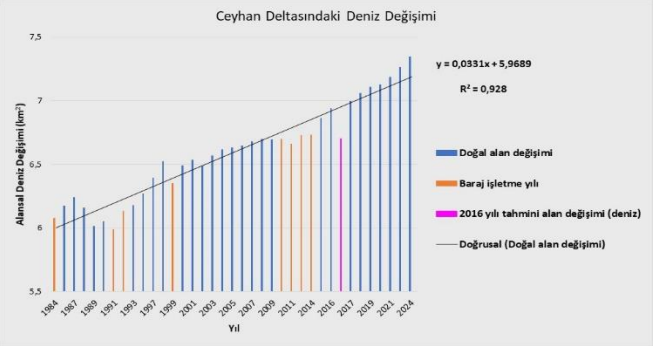


**Şekil 4.** Ceyhan nehri delta ağzı, 1984 – 2024 yılları arasındaki alansal deniz değişim diyagramı (km²/yıl).

Ceyhan Deltası'ndaki kıyı değişimlerini incelemek için her yılın Ağustos ayına ait Landsat 5, 7, 8 ve 9 uydu görüntüleri kullanılmıştır. Her yıl için bir görüntü seçilerek, zamansal olarak tutarlı bir analiz sağlanmıştır. Kıyı çizgisi değişimleri ArcGIS PRO yazılımı kullanılarak manuel olarak sayısallaştırılmıştır. Verilerin doğruluğunu artırmak için Catalyst Professional kullanılarak radyometrik ve geometrik düzeltmeler gibi ön işleme adımları uygulanmıştır. Çalışma kapsamında, 1984 – 2024 yılları arasında sayısallaştırılan kıyı çizgileri ile Ceyhan Delta ağzında gerçekleşen alansal değişim hesaplanmıştır. Hesaplamalar yapılırken Ceyhan Nehri üzerinde işletilmeye başlanmış olan barajlar da dikkate alınmıştır.

## BULGULAR

Analiz sonuçları, çalışma süresi boyunca kıyı çizgisinde belirgin değişimler olduğunu göstermektedir. Kıyı erozyonu ve birikim desenleri tespit edilmiş, sediment dağılımında dalgalanmalar gözlemlenmiştir. Deltanın bazı bölgelerinde kıyı gerilemesi yaşanırken, bazı alanlarda sediment birikimi nedeniyle kıyı ilerlemesi meydana gelmiştir. 2016 yılı için tahmin edilen kıyı çizgisinin gerçek verilerle karşılaştırılması sonucunda, küçük farklılıklar tespit edilmiş ve kıyı süreçlerinin karmaşıklığı vurgulanmıştır. Ceyhan Delta gelişimini ve sediman taşınımını etkileyen barajlar ile birlikte zamansal kıyı çizgisi değişimleri alansal olarak hesaplanmış ve aradaki fark belirlenmiştir (Çizelge 3).

**Çizelge3.** Ceyhan Deltası alansal kıyı değişimi.

| Yıl | Alan (km²) | Baraj ve HES | Yıl | Alan (km²) | Baraj ve HES |
|---|---|---|---|---|---|
| 1984 | 6,08 | Aslantaş | 2007 | 6,68 | |
| 1986 | 6,17 | | 2008 | 6,70 | |
| 1987 | 6,24 | | 2009 | 6,69 | |
| 1988 | 6,16 | | 2010 | 6,70 | Oşkan |
| 1989 | 6,02 | | | | Berkman |
| 1990 | 6,05 | | 2011 | 6,66 | Hacınınoğlu |
| 1991 | 5,99 | Sır | | | Sarsap |
| 1992 | 6,13 | Menzelet | 2013 | 6,73 | Kandil |
| 1993 | 6,18 | | | | Sarıgüzel |
| 1994 | 6,27 | | 2014 | 6,73 | Kılavuzlu |
| 1997 | 6,40 | | 2015 | 6,87 | |
| 1998 | 6,53 | | 2016 | 6,94 | |
| 1999 | 6,35 | Berke | *2016 | 6,71 | |
| 2000 | 6,49 | | 2017 | 7,00 | |
| 2001 | 6,54 | | 2018 | 7,06 | |
| 2002 | 6,49 | | 2019 | 7,11 | |
| 2003 | 6,57 | | 2020 | 7,13 | |
| 2004 | 6,62 | | 2021 | 7,19 | |
| 2005 | 6,63 | | 2023 | 7,26 | |
| 2006 | 6,65 | | 2024 | 7,35 | |

* 2016 yılı tahmini kıyı çizgisi

Tarihsel kıyı değişimi dikkate alındığında, Ceyhan Deltası'nda 1984 -2024 yılları arasında kıyı regresyon - transgresyon analizleri yapılmıştır. Determinasyon katsayısı değeri kıyı regresyonunun zamanla tutarlı bir eğilim göstermediğini ve doğal faktörler, antropojenik etkiler ve morfolojik dinamizm gibi nedenlerle değişimin düzensiz olduğunu göstermektedir.

## TARTIŞMA

Gözlemlenen kıyı çizgisi değişimleri, nehir sediment girdisi, dalga etkisi, deniz seviyesi yükselmesi ve baraj inşası gibi insan kaynaklı müdahaleler dahil olmak üzere birçok faktörden kaynaklanmaktadır. 2016 yılı için yapılan tahmin ile gerçek kıyı çizgisi arasındaki farklılıklar, aşırı hava olayları veya değişken sediment taşınım oranları gibi ek etkenlerin de sürece dahil olabileceğini göstermektedir. Uzaktan algılama ve CBS tekniklerinin uzun vadeli kıyı izleme çalışmalarında etkili bir yöntem olduğu görülmüş ve kıyı dinamikleri hakkında önemli bilgiler sağlamıştır.

## SONUÇ

Bu çalışma, Ceyhan Deltası'ndaki tarihsel kıyı çizgisi değişimlerini analiz etmek için uzaktan algılama ve CBS kullanımının önemini göstermektedir. Elde edilen bulgular, kıyı gelişimi hakkında daha iyi bir anlayış sağlamanın yanı sıra kıyı yönetimi ve çevresel koruma ile ilgili karar alma süreçlerini desteklemektedir. Daha yüksek çözünürlüklü veriler ve hidrodinamik modelleme içeren ileri çalışmalar, kıyı değişimlerinin tahmin doğruluğunu artırabilir ve kıyı planlama stratejilerini geliştirebilir.

2008 yılında yapılan istatistiksel tahmin, 2016 yılı için kıyı değişimini öngörmüş olsa da 2008'de itibaren inşa edilen 7 baraj / HES, akış rejimini ve sediman taşınımını değiştirerek tahminlerde sapmaya neden olmuştur. Bu durum , kıyı değişimi modellerinden insan kaynaklı müdahalelerin dikkate alınmasının önemini vurgulamaktadır.

Deniz seviyesindeki yükselmeler ve kıyı çizgisi değişimleri, küresel ekosistemleri ve insan topluluklarını tehdit eden ciddi bir sorundur. Bu nedenle, kıyı bölgelerinde sürdürülebilir kıyı yönetimi stratejileri, kıyı koruma projelerine yönelik politikalar hayati önem taşımaktadır.

## TEŞEKKÜR

Bu çalışma, Maden Tetkik ve Arama Genel Müdürlüğü, Jeoloji Etütleri Dairesi tarafından yürütülmüş olan 11391 no.lu "Küresel Isınmaya Bağlı Deniz Seviyesi Değişimlerinin Türkiye Kıyıları Üzerindeki Etkilerinin Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Teknikleri ile Araştırılması, Mersin İskenderun Kıyı Kuşağı Pilot Çalışması" başlıklı araştırma projesi kapsamında elde edilen kıyı çizgisi değişimlerinden de yararlanılarak, hazırlanmıştır. İlgili rapordaki proje ekibine teşekkür ederiz.

**KAYNAKÇA**

**RAPOR**

Dağlıyar, A., Nefeslioğlu, A. H., Alkevli, T., Kocedere, B., Avcı, M. K., (2011). "Küresel Isınmaya Bağlı Deniz Seviyesi Değişimlerinin Türkiye Kıyıları Üzerindeki Etkilerinin Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Teknikleri ile Araştırılması, Mersin – İskenderun Kıyı Kuşağı Pilot Çalışması", mMTA Genel Müdürlüğü, Derleme Raporu, Rapor No: 11391, Ankara.

**BİLDİRİ**

Dağlıyar, A., Kocadere, B., Avcı, M. K., Nefeslioğlu, A. H., Alkevli, T., (2013). Seyhan ve Ceyhan (Adana) Deltaları Yıllık Kıyı Değişim Oranlarının Belirlenmesi Üzerine Bir Çalışma. TMMOB Coğrafi Bilgi Sistemleri Kongresi, 11 – 13 Kasım 2013, Ankara

**MAKALE**

Abdelaty, E. (2021). Coastal Erosion Assessment of the Nile Delta Coast using Remote Sensing, GIS, and Modified Coastal Vulnerability Index. Alexandria Science Exchange Journal, 42(3), 645–655. https://doi.org/10.21608/asejaiqjsae.2021.188083

El-Masry, E. A., Magdy, A., El-Gamal, A., Mahmoud, B., & El-Sayed, M. K. (2024). Multi-decadal coastal change detection using remote sensing: the Mediterranean coast of Egypt between El-Dabaa and Ras El-Hekma. Environmental Monitoring and Assessment, 196(2). https://doi.org/10.1007/s10661-024-12359-x

Kumaat, J. C., & Rembet, V. M. (n.d.). Analysis and forecasting of shoreline changes in Amurang Bay. www.techniumscience.com

Nicholls, R. J., & Cazenave, A. (n.d.). Sea-Level Rise and Its Impact on Coastal Zones. https://www.science.org

Pujianiki, N. N., Predana, I. M. A., Airlangga, K. G. P., Simpangan, G. R. P. A., Osawa, T., Parwata, I. N. S., & Ibrahim, M. S. I. Bin. (2024). Monitoring and Analysis of Coastline Changes in the Coastal Area of Bali Island, Indonesia. Civil Engineering Dimension, 26(1), 32–50. https://doi.org/10.9744/ced.26.1.32-50

Syvitski, J. P. M., Kettner, A. J., Overeem, I., Hutton, E. W. H., Hannon, M. T., Brakenridge, G. R., Day, J., Vörösmarty, C., Saito, Y., Giosan, L., & Nicholls, R. J. (2009). Sinking deltas due to human activities. Nature Geoscience, 2(10), 681–686. https://doi.org/10.1038/ngeo629

Wang, J., Li, D., Cao, W., Lou, X., Shi, A., & Zhang, H. (2022). Remote Sensing Analysis of Erosion in Arctic Coastal Areas of Alaska and Eastern Siberia. Remote Sensing, 14(3). https://doi.org/10.3390/rs14030589

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Destek Vektör Makineleri Kullanılarak Arazi Kullanımı ve Arazi Örtüsü Sınıflandırmasında Polinom ve Doğrusal Kernel Fonksiyonlarının Karşılaştırmalı Analizi

**Mehmet Oktay Kutrak[1], Duygu Arıkan İspir[*2], Ferruh Yıldız[3]**

[1,2,3] *Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Harita Mühendisliği Bölümü, Konya, Türkiye*

**Anahtar Kelimeler**
Arazi Kullanımı,
Arazi Örtüsü,
Google Earth Engine,
Destek Vektör Makinesi,
Sentinel-2

**ÖZET**

Son yıllarda teknolojinin ilerlemesiyle birlikte, uzaktan algılama yoluyla elde edilen uydu görüntülerinin kalitesi de artmıştır. Uydu görüntülerinin artan kalitesi, coğrafyamızla ilgili çeşitli alanlarda geniş bir uygulama yelpazesi sunmaktadır. Arazi Kullanımı ve Arazi Örtüsü (AK/AÖ) sınıflandırma çalışmaları, uzaktan algılama araştırmalarında en yaygın kullanılan yöntemler arasında yer almaktadır. AK/AÖ sınıflandırmasında görüntü sınıflandırma, nesne tabanlı görüntü analizi ve makine öğrenmesi algoritmaları gibi çeşitli teknikler kullanılmaktadır. Son yıllarda, yapay zekâ destekli makine öğrenmesi algoritmaları giderek daha fazla tercih edilmektedir. Bu bağlamda, mevcut çalışma, makine öğrenmesi tabanlı bir sınıflandırma tekniği olan Destek Vektör Makinesi (SVM) algoritmasının polinom ve lineer çekirdek fonksiyonlarının performansını değerlendirmek için Sentinel-2A uydu görüntülerini kullanmaktadır. Google Earth Engine (GEE) platformu üzerinden yürütülen çalışmada, uydu görüntüleri analiz edilmiş ve sınıflandırma işlemini gerçekleştirmek için gerekli kod JavaScript ile yazılmıştır. Sınıflandırma için altı sınıf tanımlanmıştır: vejetasyon (bitki örtüsü), kentsel alan, yollar, çıplak arazi, tarım alanları ve sanayi bölgeleri. Sonuçlara göre, polinom çekirdek fonksiyonu %95 genel doğruluk ve 0.92 kappa değeri elde etmiştir. Lineer çekirdek fonksiyonu için bu değerler sırasıyla %91 ve 0.87 olarak hesaplanmıştır. Sonuçlar, polinom fonksiyonunun %4 daha yüksek doğruluk oranı ile daha iyi performans sağladığını göstermektedir.

# A Comparative Analysis of Polynomial and Linear Kernel Functions in Land Use and Land Cover Classification Using Support Vector Machines

**Keywords**
Land Use,
Land Cover,
Google Earth Engine,
Support Vector Machine,
Sentinel-2

**ABSTRACT**

With the advancement of technology in recent years, the quality of satellite images obtained via remote sensing has also increased. The increasing quality of satellite images provides a wide range of applications in various fields related to our geography. Land Use and Land Cover (LU/LC) classification studies are among the most widely used methods in remote sensing research. Various techniques are employed LU/LC classification, such as image classification, object-based image analysis, and machine learning algorithms. Recently, machine learning algorithms supported by artificial intelligence have become increasingly preferred. In this respect, the current work uses Sentinel-2A satellite images to assess the performance of the polynomial and linear kernel functions of the Support Vector Machine (SVM) algorithm, a machine learning-based classification technique. In the study conducted via the Google Earth Engine (GEE) platform, satellite images were analyzed, and the necessary code was written in JavaScript to carry out the classification process. For the classification, six classes were defined: vegetation, urban, roads, barren, agriculture, industry. According to the results, the polynomial kernel function achieved overall accuracy and kappa value of 95% and 0.92, respectively. The values for the linear kernel function were calculated as 91% and 0.87, respectively. The results indicate that the polynomial function provided better performance, with a 4% higher accuracy compared to the linear function.

TASUAK

## GİRİŞ

Uzaktan algılama teknolojisinin ilerlemesiyle birlikte uydu sayısında ciddi şekilde bir artış olmuştur. Bu artış, Dünya yüzeyi için farklı konumsal ve spektral çözünürlüklerde veri elde edilmesine olanak sağlamıştır. Bu sayede, bilgiye erişim daha hızlı, daha kolay ve daha güncel hale gelmiştir. Landsat, Sentinel, MODIS ve Göktürk-1 gibi çeşitli yörünge platformları, farklı uydular aracılığıyla elde edilen ve birçok alanda etkin bir şekilde kullanılan veriler sağlamaktadır. Dünya yüzeyindeki çevresel değişiklikler, kentsel ısı adaları (Arıkan vd., 2023a; Xu vd., 2024), arazi örtüsü ve arazi kullanımı(AÖ/AK) (Arpitha vd., 2023), sulak alanların değişimi (Singh vd., 2024), hava kalitesi ve kirlilik tespiti (Arikan vd., 2023), orman yangınları tespiti veya önleme (Makineci, 2024), bitki indekslerinin sağlık durumları(Aprilina vd., 2024), doğal afetlerin izlenmesi (Unal vd., 2024) ve iklim değişikliği (Erdoğan vd., 2024) gibi çeşitli çalışmalar uzaktan algılama verileriyle yapılması mümkündür.

Bu amaçla çeşitli sınıflandırma teknikleri literatürde geniş uygulama alanı bulmuş ve farklı araştırmalarda kullanılmıştır (Lu vd., 2007). Piksel tabanlı sınıflandırma ve nesne tabanlı sınıflandırma yöntemleri uzaktan algılama çalışmalarında en sık kullanılan teknikler arasındadır. Ancak son yıllarda bilgisayarların verileri analiz etme kapasitesindeki gelişmeye bağlı olarak makine öğrenmesi tabanlı sınıflandırma yaklaşımlarının benimsenmesi büyük ölçüde artmıştır. Özellikle doğrusal olmayan verilerin sınıflandırılmasında makine öğrenmesi, yüksek doğruluk ve güvenilirlik sunan etkili bir yaklaşım olarak ortaya çıkmıştır (Bozduman, 2021). Literatürde, farklı uydu görüntülerini kullanarak çeşitli sınıflandırma algoritmalarının performansını karşılaştıran çok sayıda çalışma bulunmaktadır. Jamil vd. (2017), büyük ölçekli ağaç türü sınıflandırma çalışmalarında Destek Vektör Makineleri (DVM), Yapay Sinir Ağları (YSA) ve Rastgele Orman (RO) gibi makine öğrenmesi algoritmalarını kullanmış ve YSA'nın daha yüksek doğruluk elde ettiği sonucuna varmıştır. Akar vd. (2019), Göktürk-2 ve Hyperion EO-1 uydu görüntülerini kullanarak yaptıkları sınıflandırma çalışmasında DVM ve RF algoritmalarını karşılaştırmış ve RF algoritmasının daha üstün performans gösterdiğini tespit etmiştir. Danacıoğlu (2023), Sentinel-2 uydu görüntülerinden Arazi Kullanımı/Arazi Örtüsü (LU/LC) haritalarının üretilmesi için CART, DVM ve RF algoritmalarının performansını değerlendirmiş ve RF algoritmasının daha iyi sonuçlar verdiğini vurgulamıştır. Krivoguz vd. (2023), Landsat-5 uydu görüntülerini kullanarak Derin Sinir Ağı (DNN), RF, DVM ve AdaBoost algoritmalarının performansını karşılaştırmış ve RF algoritmasının en yüksek performansı gösterdiğini ortaya koymuştur. Bulut vd. (2016), Landsat 8 görüntüleri üzerinde yaptıkları çalışmada DVM ve Maksimum Olabilirlik (ML) algoritmalarının performansını incelemiş ve DVM algoritmasının en başarılı sonuçları verdiğini belirtmişlerdir.

Bu çalışmada ise, makine öğrenme algoritmalarından biri olan destek vektör makinesinin, polinomal ve lineer kernel fonksiyonları incelenmiştir. Çalışma bölgesi olarak Konya şehir merkezi seçilmiş ve Sentinel-2 uydu görüntüsü kullanılmıştır. Her iki fonksiyon sonucu incelenmiş ve sınıflandırma doğruluğu ele alınmıştır.

## YÖNTEM

Şekil 1'de çalışmanın iş akış diyagramı oluşturulmuştur. Süreç, çalışma alanının belirlenmesiyle başlamakta, ardından veri toplama, ön işleme, sınıflandırma ve doğruluk değerlendirmesinin analizi şeklinde devam etmektedir. Son olarak, sınıflandırma sonuçlarının haritalanması ve analiziyle tamamlanmaktadır.

### Çalışma Alanı

Yüzölçümü bakımından Türkiye'nin en büyük ili olan Konya, nüfus yoğunluğu bakımından da altıncı sırada yer almaktadır. Şehrin ortalama rakımı yaklaşık 1.016 metredir. Konya, Türkiye'nin toplam tarım arazisinin %11,2'sini oluşturmaktadır. Konya'da yaygın olarak yetiştirilen ürünler arasında buğday, arpa, mısır, ayçiçeği ve şeker pancarı yer almaktadır. Günümüzde Konya, başta savunma, yazılım, sağlık, lojistik ve enerji sektörleri olmak üzere sanayi sektöründe öne çıkan bir şehirdir. Konya Organize Sanayi Bölgesi, 40 farklı sektörde üretim faaliyetlerine ev sahipliği yaparak Türkiye'nin en büyük sanayi bölgeleri arasında yer almaktadır (Demiroz vd., 2021). Çalışma alanı, Konya ilinin şehir merkezi ve Selçuklu ilçesinin bir kısmını kapsamakta olup 32°27'45.03''- 32°38'19.08''N ve 37°53'58.82''- 38°02'27.92''E koordinatları arasında yer almaktadır. Yaklaşık 243 km$^2$'lik bir alanı kapsamaktadır. Çalışma alanı Şekil 2'de gösterilmiştir.

Bu çalışmada, 10 metre uzamsal çözünürlüğe sahip Sentinel-2 uydu görüntüsü kullanılmıştır. Sentinel-2, Avrupa Uzay Ajansı (AUA) tarafından Dünya gözlemi için geliştirilmiş, Sentinel-2A ve Sentinel-2B'den oluşan çift uydu konfigürasyonunda tasarlanmış bir uydu sistemidir.

Sentinel-2A 23 Haziran 2015'te, Sentinel-2B ise 7 Mart 2017'de fırlatılmıştır. Sentinel-2A uydusu 10 metre uzaysal çözünürlüğe ve 12 bit radyometrik çözünürlüğe sahiptir. Toplam 13 farklı bant ile Sentinel-2 uydu görüntüleri kapsamlı spektral bilgi sağlar (ESA, 2024). Analiz için 5 Nisan 2024 tarihli Sentinel-2 görüntüsü kullanılmıştır. Uyduya ait bantların detayları ve bilgisi Çizelge 1'de ifade edilmiştir.

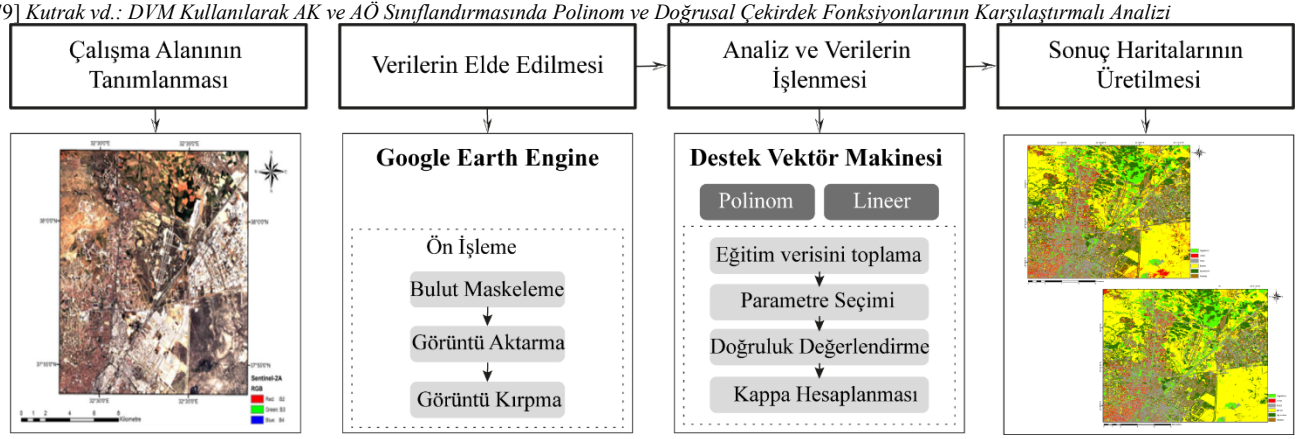


**Şekil 1.** İş akış diyagramı

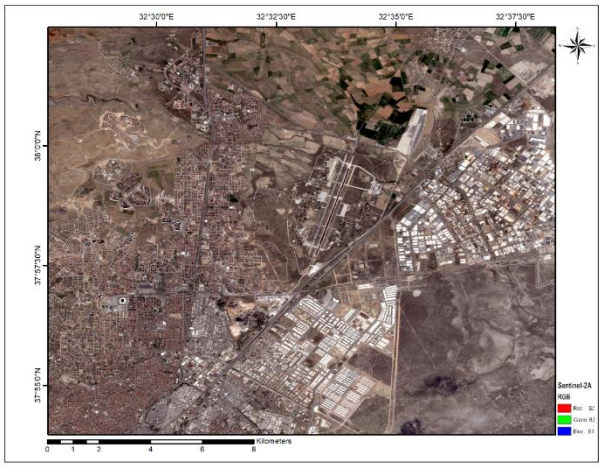

**Şekil 2.** Çalışma Alanı

Elde edilen uydu görüntülerinin sınıflandırma işlemleri Google Earth Engine (GEE) platformu kullanılarak gerçekleştirilmiştir. GEE, jeo-uzamsal verilerin işlenmesini kolaylaştıran açık kaynaklı ve ücretsiz bir platformdur. Landsat, Sentinel ve MODIS gibi çeşitli uydu sistemlerinden elde edilen verilere eşzamanlı erişim sağlayarak kullanıcıların bu görüntüler üzerinde hızlı ve verimli analizler yapmasına olanak tanır (Xiong vd., 2017). GEE, JavaScript ve Python gibi popüler programlama dilleriyle uyumlu web tabanlı bir entegre geliştirme ortamı (IDE) aracılığıyla komut dosyası yazmayı ve geliştirmeyi desteklemektedir (Dong vd., 2016). Platform, görüntü sınıflandırma (Phan vd., 2020), yüzey suyu kaynak analizi (Karaca vd., 2022), sulak alan haritalama (Çakaroz vd., 2020), ve orman yangını analizi (Yılmaz vd., 2021) dahil olmak üzere geniş bir uygulama yelpazesine sahiptir.

Elde edilen görüntülerin haritalanması için ArcGIS 10.8.2 yazılımı kullanılmıştır. ArcGIS, Environmental Systems Research Institute (ESRI) tarafından geliştirilen bir Coğrafi Bilgi Sistemi (CBS) yazılımıdır. Bu yazılım jeo-uzamsal verilerin toplanması, görselleştirilmesi ve analiz edilmesi için yaygın olarak kullanılmaktadır. Ayrıca, coğrafi verilerin etkili bir şekilde görselleştirilmesine olanak tanıyarak son derece bilgilendirici haritaların oluşturulmasını sağlar (ESRI, 2024).

**Çizelge1.** Sentinel-2 Uydu Görüntüsüne ait Bantları ve Özellikleri (ESA,2024)

| Bant Numarası | Bant İsmi | Konumsal Çözünürlük (m) | Dalga boyu (nm) | Radyometrik Çözünürlük | Bandın Kullanım Amacı |
|---|---|---|---|---|---|
| **B1** | Kıyı Aerosolü | 60 | 443.9 | 12-bit | Su üzerinde aerosol tespiti |
| **B2** | Mavi | 10 | 496.6 | | Su kütlesi ve bitki örtüsü haritalaması |
| **B3** | Yeşil | 10 | 560.0 | | Bitki örtüsü ve su izleme |
| **B4** | Kırmızı | 10 | 664.5 | | Bitki örtüsü ve toprak izleme |
| **B5** | Bitki Örtüsü | 20 | 703.9 | | Bitki örtüsü tespiti |
| **B6** | Bitki Örtüsü | 20 | 740.2 | | Bitki örtüsü tespiti |
| **B7** | Bitki Örtüsü | 20 | 782.5 | | Bitki örtüsü tespiti |
| **B8** | Yakın Kızılötesi | 10 | 835.1 | | Bitki örtüsü ve biyokütle haritalaması |
| **B8A** | Bitki Sıcak Nokta | 20 | 864.8 | | Bitki örtüsü yapısal analizi |
| **B9** | Su Buharı | 60 | 945.0 | | Su buharı içeriği |
| **B10** | Kısa Dalga Kızılötesi 1 | 60 | 1373.5 | | Bulut algılama |
| **B11** | Kısa Dalga Kızılötesi 2 | 20 | 1613.7 | | Toprak ve bitki örtüsü nemi |
| **B12** | Kısa Dalga Kızılötesi 3 | 20 | 2202.4 | | Biyokütle yakımı ve toprak çalışmaları |

TASLAK

## Destek Vektör Makinesi (DVM)

Destek Vektör Makineleri (DVM), istatistiksel öğrenme teorisine dayanan, sınıflandırma ve regresyon problemleri için yaygın olarak kullanılan denetimli bir makine öğrenimi algoritmasıdır (Cortes, 1995). Başlangıçta iki sınıflı doğrusal verileri sınıflandırmak için tasarlanan bu algoritma, giderek doğrusal olmayan ve çok sınıflı verileri de etkili bir şekilde ele alacak şekilde genişletilmiştir (Bulut vd., 2016). DVM algoritmasının temel amacı, iki sınıfı ayıran ve aralarındaki marjı maksimize eden optimum hiper düzlemi tanımlamaktır (Arıkan vd., 2023b; Bulut vd., 2016; Çölkesen, 2009). DVM, geliştirildiği günden bu yana optik karakter tanıma, el yazısı tanıma, yüz tanıma ve metin sınıflandırma gibi çeşitli alanlarda başarıyla uygulanmıştır (Çölkesen, 2009). Son yıllarda DVM, uzaktan algılama verilerinin sınıflandırılmasında yaygın olarak tercih edilen bir yöntem haline gelmiştir.

DVM algoritmasının çalışma prensibi, eğitim veri setinin öznitelik bilgilerine dayanarak sınıf etiketlerini öğrenmek için bir model oluşturmaktadır. Daha sonra sınıflandırma aşamasında, algoritma eğitim verilerinden bir hiper düzlem tanımlanmakta ve N boyutlu bir veri kümesinde, sınıflandırmayı gerçekleştirmek için N-1 boyutlu bir uzayda bir hiper düzlem tanımlanması gerekmektedir

İki sınıflı problemlerde veri kümesini ayırabilecek sonsuz sayıda hiper düzlem olmasına rağmen, sadece maksimum marjına sahip hiper düzlem seçilir (Çölkesen, 2009). Bu hiper düzlem matematiksel olarak aşağıdaki gibi ifade edilebilir:

$$w^T x + b = 0 \qquad (1)$$

Burada, w hiper düzlemi tanımlayan normal vektör, x veri noktası ve b hiper düzlemin kesişim noktasıdır. Bu formül, iki sınıfı ayıran en uygun hiper düzlemi tanımlar. Şekil 3'te gösterildiği gibi, hiper düzlemin sınırında noktalar bulunur ve bu noktalar destek vektörleri olarak adlandırılır.

DVM algoritması doğrusal ve doğrusal olmayan olmak üzere iki kategoriye ayrılır. Doğrusal yapıya sahip veri kümelerinin sınıflandırılması için doğrusal fonksiyonlardan yararlanılır. Doğrusal olmayan veri kümelerinde ise kernel fonksiyonları kullanılır. Literatürde, doğrusal olmayan özelliklere sahip uzaktan algılanmış görüntüler için farklı kernel fonksiyonları mevcuttur (Akar & Görmüş, 2019). Bu fonksiyonlar, matematiksel ifadeleri ve kullandıkları parametreler ile birlikte Çizelge 2'de sunulmuştur.

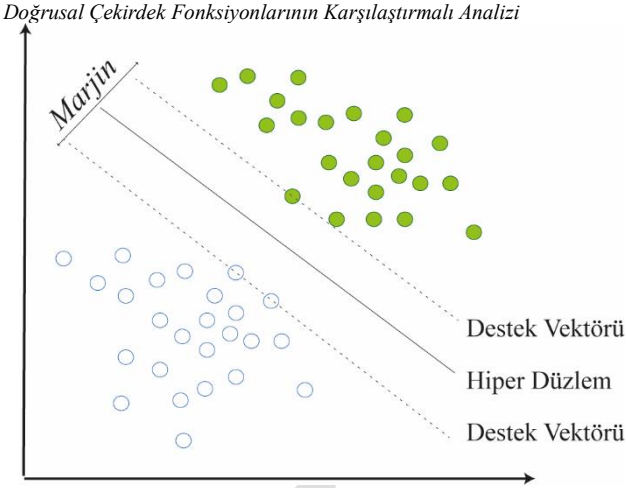


**Şekil 3.** İkili sınıflandırma probleminin DVM ile çözümü

## BULGULAR

Çalışmada 05/04/2024 tarihli Sentinel-2A görüntüsü kullanılmıştır. Görüntünün ürün öznitelikleri "ee.Image()" parametresi kullanılarak GEE platformuna aktarılmıştır. Uydu görüntüsü içe aktarıldıktan sonra sınıflandırmanın yapılacağı çalışma alanı ".clip()" fonksiyonu kullanılarak kırpılmıştır. Kırpma işleminin ardından bant kombinasyonları oluşturulmuştur. Daha sonra sınıflandırma işlemine geçilmiştir. İlk olarak eğitim verileri tanımlanmış ve altı sınıf seçilmiştir. Bu sınıflar; yerleşim alanı, yeşil alan, yol, bina, tarım alanı ve sanayi bölgesidir. Eğitim verileri seçildikten sonra sınıflandırma işlemi "ee.Classifier()" kullanılarak gerçekleştirilmiştir. Bu aşamada DVM için ".libsvm()" parametresi kullanılmıştır. Sonuç olarak toplam 1059 eğitim veri noktası oluşturulmuştur. DVM ile sınıflandırma aşamasında Polinom Kernel Fonksiyonu ve Lineer Kernel Fonksiyonunu seçilmiştir. Polinom Kernel Fonksiyonu için derece 1 olarak ayarlanmış ve gama değeri 0,3 olarak seçilmiştir. Lineer Kernel Fonksiyonunun herhangi bir parametresi olmadığı için parametre seçimi yapılmamıştır. Var olan parametreler üzerinden işlem gerçekleştirilmiştir. Sınıflandırma için gerekli ek kodlar yazıldıktan sonra sonuçlar kaydedilmiştir. Kaydedilen TIFF formatındaki görüntüler ArcGIS 10.8.2 yazılımı kullanılarak görselleştirilmiş ve haritalandırılmıştır. Polinom Kernel Fonksiyonu için sonuç görüntüsü Şekil 4'te, Lineer Kernel Fonksiyonu için sonuç görüntüsü ise Şekil 5'te sunulmuştur. Ayrıca, doğruluk analizleri ve karışıklık matrisleri Çizelge 3 ve 4'te gösterilmektedir.

**Çizelge2.** DVM'de Kullanılan Fonksiyonlar ve Parametreler

| Kernel Fonksiyonları | Matematiksel İfadeler | Parametre | Açıklama |
|---|---|---|---|
| **Lineer(Doğrusal)** | $K(xi,xj)= xi.xj$ | - | Doğrusal olarak ayrılabilen veriler için kullanılmakta |
| **Polinomal** | $K(xi,xj)=(\gamma(xi.xj)+C)^d$ $\gamma>0$ | *d:* polinomun derecesi, $\gamma$: ölçek parametresi | Eğitim verilerinin normalleştirildiği problemler için tercih edilmekte. |
| **Sigmoid** | $K(xi,xj)=tanh(\gamma(xi.xj)+C)$ $\gamma>0$ | $\gamma$: ölçek parametresi | Sinir ağlarına benzer bir yapı sağlamakta. |
| **Radyal Taban Fonksiyonu (RBF)** | $K(xi,xj)=exp(-\gamma\|\|xi.xj\|\|^2)$ $\gamma>0$ | $\gamma$: ölçek parametresi | Karmaşık ve doğrusal olmayan veriler için iyi performans göstermekte. |

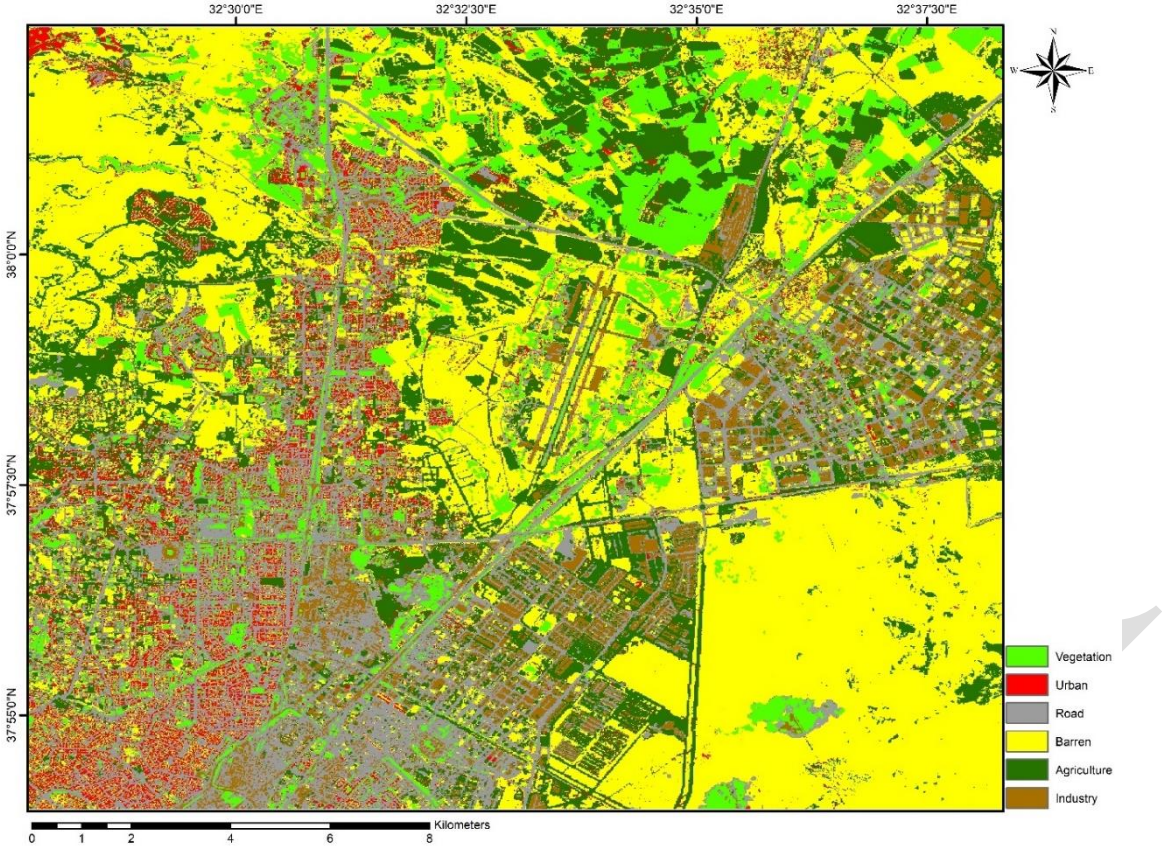


**Şekil 4.** Polinom Kernel Fonksiyonu sonucunda elde edilen harita

Şekil 4 incelendiğinde, her sınıfın genel olarak doğru sınıflandırıldığı gözlemlenebilir. Ancak bazı bölgelerde yerleşim alanları ve yollar doğru bir şekilde sınıflandırılmadığı tespit edilmiştir. Bunun temel nedeni o bölgelerdeki bina ve yolların birbirine olan yakınlığıdır. Ayrıca, 10 m'lik uydu çözünürlüğü de yollar ve binalar arasında iyi bir ayrım yapamamasının nedenidir.

Çizelge 3'te polinom kernel fonksiyonuna ait hata matrisi verilmiştir. Burada 67 yeşil alan pikseli içerisinden 2 piksel yanlış sınıflandırılmıştır. 1 piksel yerleşim alanı ve 1 piksel yol olarak yanlış sınıflandırılmıştır. Ancak 65 piksel doğru sınıflandırılmıştır. 57 yerleşim alanı pikselinden 53'ü doğru sınıflandırılırken 4'ü boş arazi pikseli olarak yanlış sınıflandırılmıştır. Yol sınıfı için, 59 pikselden 13'ü sanayi alanı pikseli olarak yanlış sınıflandırılırken, kalan 46 piksel doğru sınıflandırılmıştır. En yüksek sınıflandırma sonucu 485 pikselin tamamının doğru sınıflandırıldığı boş arazi sınıfında elde edilmiştir. Tarım arazisi sınıfında 219 pikselden 9'u sanayi alanı pikseli, 25'i boş arazi ve 2 pikselde kentsel alan olarak yanlış sınıflandırılmıştır. Geriye kalan 183 piksel ise doğru sınıflandırılmıştır. Endüstriyel alan sınıfında toplam 172 piksel bulunurken, 2 piksel yol pikseli olarak yanlış sınıflandırılmıştır.

**Çizelge3.** Polinom Kernel Fonksiyonu için hata matrisi

| Polinom | Yeşil Alan | Yerleşim Alanı | Yol | Boş Arazi | Tarım Arazisi | Endüstriyel Alan | Toplam |
|---|---|---|---|---|---|---|---|
| Yeşil Alan | 65 | 0 | 0 | 0 | 0 | 0 | 65 |
| Yerleşim Alanı | 1 | 53 | 0 | 0 | 2 | 0 | 56 |
| Yol | 1 | 0 | 46 | 0 | 0 | 2 | 49 |
| Boş Arazi | 0 | 4 | 0 | 485 | 25 | 0 | 514 |
| Tarım Arazisi | 0 | 0 | 0 | 0 | 183 | 0 | 183 |
| Endüstriyel Alan | 0 | 0 | 13 | 0 | 9 | 170 | 192 |
| Toplam | 67 | 57 | 59 | 485 | 219 | 172 | 1059 |
| P.A. | 97.01 | 92.98 | 77.97 | 100.00 | 83.56 | 98.84 | |
| U.A. | 100.00 | 94.64 | 93.88 | 94.36 | 100.00 | 88.54 | |
| O.A. | 0.95 | | | | | | |
| Kappa Değeri | 0.92 | | | | | | |

* P.A.: Üretici Doğruluğu, U.A.: Kullanıcı Doğruluğu, O.A.: Genel Doğruluk

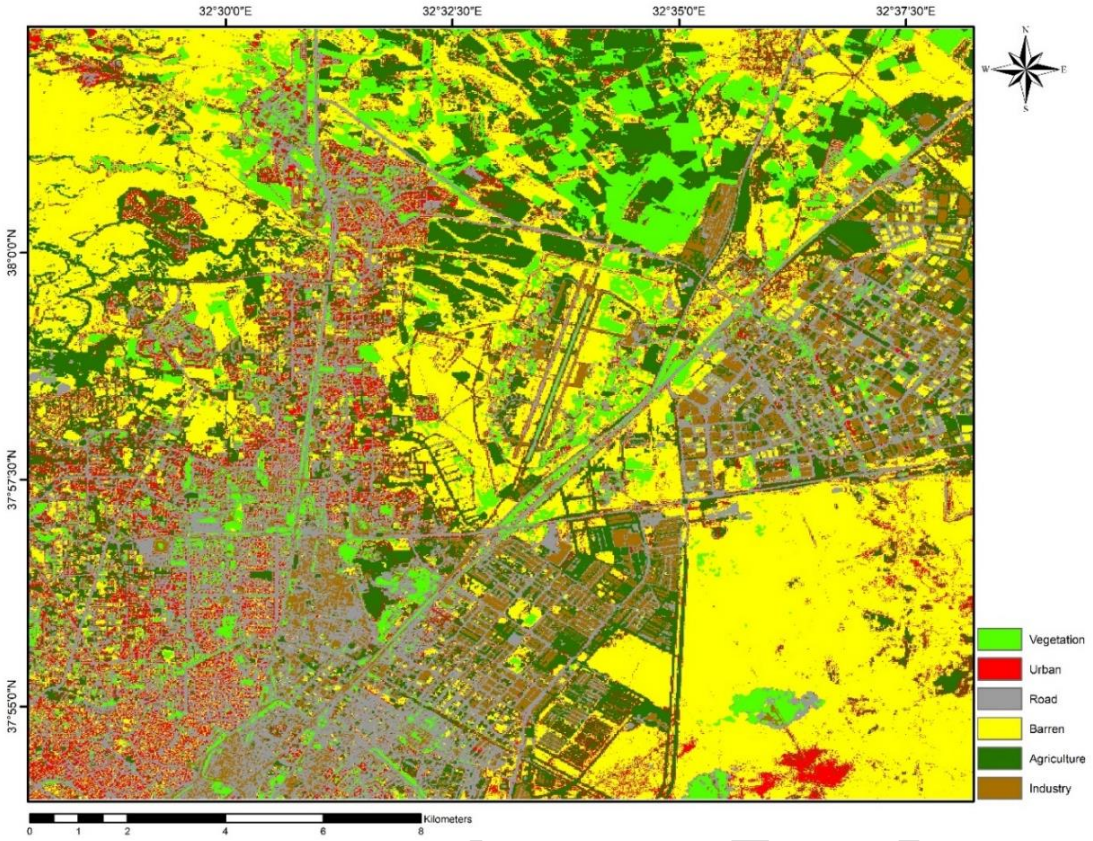


**Şekil 5.** Lineer Kernel Fonksiyonu sonucunda elde edilen harita

Şekil 5 incelendiğinde, genel olarak her sınıfın Şekil 4'e benzer şekilde doğru sınıflandırıldığı görülmüştür. Ancak belirli bölgelerde bazı sınıflandırma hataları tespit edildiği görülmektedir. Özellikle, bazı bölgelerde yerleşim alanları ve yollar arasındaki ayrım net bir şekilde yapılamamıştır ve bu da sınıflandırma doğruluğunu olumsuz etkilemektedir. Ayrıca, haritanın sağ alt köşesinde yer alan bazı bölgeler bina olarak yanlış sınıflandırılmıştır.

Çizelge 4 incelendiğinde her bir sınıfa ait pikseller için sınıflandırma doğruluğu ve hata oranları detaylı olarak değerlendirilmiştir. Yeşil alan sınıfında yer alan toplam 68 pikselin büyük çoğunluğunun doğru sınıflandırıldığı tespit edilmiştir. Ancak bu piksellerden 2 tanesi yerleşim alanı pikseli olarak, 1 tanesi de yol sınıfı pikseli olarak yanlış sınıflandırılmıştır. Buna karşılık, 65 piksel doğru sınıflandırılmıştır. Yerleşim alanında bulunan 51 pikselden 44'ü doğru sınıflandırılırken, 7 piksel boş arazi sınıfı pikseli olarak yanlış sınıflandırılmıştır. Benzer şekilde, yol sınıfı için 46 pikselden 45'i başarılı bir şekilde sınıflandırılırken, yalnızca 1 piksel yerleşim alanı pikseli olarak yanlış sınıflandırılmıştır. 261 pikselden oluşan tarım arazisi sınıfına ilişkin olarak, 45 piksel sanayi alanı sınıfı pikselleri olarak yanlış sınıflandırılırken, 31 piksel boş arazi sınıfı pikselleri olarak yanlış sınıflandırılmıştır. Geri kalan tüm pikseller doğru sınıflandırılmıştır. Endüstriyel alan sınıfı, çoğunluğu doğru sınıflandırılmış toplam 150 piksel içermektedir. Ancak, 3 piksel yol sınıfı pikselleri olarak yanlış sınıflandırılmıştır.

**Çizelge4.** Lineer Kernel Fonksiyonu için hata matrisi

| Lineer | Yeşil Alan | Yerleşim Alanı | Yol | Boş Arazi | Tarım Arazisi | Endüstriyel Alan | Toplam |
|---|---|---|---|---|---|---|---|
| Yeşil Alan | 65 | 0 | 0 | 0 | 0 | 0 | 65 |
| Yerleşim Alanı | 2 | 44 | 1 | 7 | 2 | 0 | 56 |
| Yol | 1 | 0 | 45 | 0 | 0 | 3 | 49 |
| Boş Arazi | 0 | 7 | 0 | 476 | 31 | 0 | 514 |
| Tarım Arazisi | 0 | 0 | 0 | 0 | 183 | 0 | 183 |
| Endüstriyel Alan | 0 | 0 | 0 | 0 | 45 | 147 | 192 |
| Toplam | 68 | 51 | 46 | 483 | 261 | 150 | 1059 |
| P.A. | 95.59 | 86.27 | 97.83 | 98.55 | 70.11 | 98.00 | |
| U.A. | 100.00 | 78.57 | 91.84 | 92.61 | 100.00 | 76.56 | |
| O.A. | 0.91 | | | | | | |
| Kappa Değeri | 0.87 | | | | | | |

* P.A.: Üretici Doğruluğu, U.A.: Kullanıcı Doğruluğu, O.A.: Genel Doğruluk

**TARTIŞMA**

Çizelge genel olarak incelendiğinde, en yüksek sınıflandırma doğruluğunun yol sınıfı ve endüstriyel alan sınıfı için elde edildiği görülmektedir. Bu yüksek doğruluk, bu sınıflardaki piksellerin spektral özelliklerinin diğer sınıflara göre daha belirgin olmasından kaynaklanabileceği gibi, eğitim verilerinin bu sınıflar için daha dengeli dağılmasıyla da ilgili olabilir.

Şekil 4 ve Şekil 5'te verilen sonuç görüntüleri incelendiğinde çoğunlukla her sınıfın doğru sınıflandırıldığı görülmektedir. Ancak polinom kernel fonksiyonu ile yapılan sınıflandırmada bazı bölgelerde alanların karıştığı tespit edilmiştir. Bu karışıklık doğruluk analizinde olduğu gibi sonuç görüntülerinde de belirgin olarak görülmektedir. Her iki yöntemde de bazı sınıflar yanlış sınıflandırılmıştır. Bu durum bazı bölgelerdeki alanların spektral özelliklerinin benzerliğinden kaynaklanmaktadır. Örneğin sanayi bölgesindeki bazı fabrikaların çatıları ile tarım alanının bazı kısımları bu benzerliği göstermektedir. Ayrıca kullanılan uydu görüntüsünün mekânsal çözünürlüğünün düşük olması bazı bölgeleri tanımlayamadığı için piksellerin karışmasına neden olmuştur.

Literatür incelendiğinde DVM algoritması ile ilgili sınıflandırma çalışmalarında çeşitli sonuçlar elde edildiği görülmektedir. Örneğin Üstüner (2013) RapidEye ve SPOT uydu görüntülerini DVM algoritması ile sınıflandırma için kullanmıştır. Elde edilen sonuçlara göre polinom kernel fonksiyonunun en yüksek sınıflandırma doğruluğunu sağladığı vurgulanmıştır. Benzer şekilde, Bulut (2023) uydu görüntüsü olarak LANDSAT 8 OI uydu görüntüsünü kullanmış ve SVM polinom fonksiyonunun en yüksek performansı gösterdiğini tespit etmiştir. Öte yandan, Johnson vd. (2020) kernel fonksiyonlarının karmaşık ve doğrusal olmayan verileri analiz etmek için güçlü araçlar olduğunu vurgulamıştır.

**SONUÇ**

Bu çalışmada, 10 m mekânsal çözünürlüğe sahip Sentinel-2A uydu görüntüsü üzerinde bir makine öğrenmesi algoritması olan DVM kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Çalışma alanı için toplam 6 sınıf (yerleşim alanı, yeşil alan, yol, çıplak arazi, tarım arazisi ve sanayi alanı) tanımlanmıştır. Uydu görüntüsü GEE platformuna yüklendikten sonra sınıflandırma işlemi gerçekleştirilmiştir.

Bu çalışmada elde edilen toplam eğitim örneği sayısı 1059'dur. Sonuçlara göre DVM Polinom Fonksiyonu için genel doğruluk %95, Kappa değeri ise 0,92 olarak bulunmuştur. Doğrusal Fonksiyon kullanılarak elde edilen değerler ise sırasıyla %91 ve 0,87 olarak hesaplanmıştır. Sonuçlar incelendiğinde, Polinom Çekirdek Fonksiyonunun Doğrusal Çekirdek Fonksiyonuna kıyasla daha iyi performans sağladığı görülmüştür.

Polinom Kernel Fonksiyonu iyi performans göstermesine rağmen, çalışma alanının belirli bölgelerinde yanlış sınıflandırmalar meydana gelmiştir. Bu çalışmada kullanılan uydu görüntülerinin 10m mekânsal çözünürlüğü göz önünde bulundurulduğunda, yollar ve yerleşim alanları gibi birbirine yakın piksellerin karışık pikseller olduğu söylenebilir. Sonuç olarak, bu karışık piksellerin sınıflandırma doğruluğunu etkilediği tespit edilmiştir.

Sonuç olarak, bu çalışma DVM algoritmasının özellikle çekirdek fonksiyonlarının seçimine bağlı olarak sınıflandırma görevlerinde etkin bir rol oynadığını göstermektedir.

**TEŞEKKÜR**

Bu çalışma, birinci yazarın (Mehmet Oktay KUTRAK) yüksek lisans bitirme projesinden geliştirilmiştir ve akademik literatüre katkıda bulunurken ilgili araştırmanın bulgularını genişletmeyi amaçlamaktadır.

**Yazar Katkı Oranı**

Yazarlar makaleye eşit oranda katkıda bulunmuşlardır.

**Çıkar Çatışması/Çakışması**

Yazarlar herhangi bir çıkar çatışması beyan etmemişlerdir.

**Araştırma ve Yayın Etiği Beyanı**

Yazarlar çalışmada, araştırma ve yayın etiğine aykırı bir durum olmadığını ve çalışmanın etik kurul onayı gerektirmediğini beyan eder.

**KAYNAKÇA**

Akar, Ö., & Görmüş, E. T. (2019). Göktürk-2 ve Hyperion EO-1 uydu görüntülerinden rastgele orman sınıflandırıcısı ve destek vektör makineleri ile arazi kullanım haritalarının üretilmesi. Geomatik, 4(1), 68-81.

Aprilina, A., Adriat, R., & Toersilowati, R. L. (2024). THE EFFECT OF LEAF AREA INDEX CHANGES ON LAND SURFACE TEMPERATURE IN WEST KALIMANTAN. International Journal of Remote Sensing and Earth Sciences (IJReSES), 21(1), 37-44.

Arikan, D., & Yildiz, F. (2023). Investigation of Antalya forest fire's impact on air quality by satellite images using Google earth engine. Remote Sensing Applications: Society and Environment, 29, 100922.

Arıkan, D., & Yıldız, F. (2023a). Investigation of urban heat island and carbon monoxide change using Google Earth engine in Konya. Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, 12(4), 1185-1193.

Arıkan, D., & Yıldız, F. (2023b). Sentinel-2 Uydu Görüntülerinde Destek Vektör Makinesi ve Rastgele Orman Algoritmaları Kullanılarak Piksel Tabanlı Arazi Sınıflandırması. Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 6(2), 1243-1260.

Arpitha, M., Ahmed, S., & Harishnaika, N. (2023). Land use and land cover classification using machine learning algorithms in google earth engine. Earth Science Informatics, 16(4), 3057-3073.

Bozduman, Ş. (2021). Mersin İli Arazi Kullanımı ve Arazi Örtüsü Çalışması için Makine Öğrenmesi ile Görüntü Sınıflandırması. Paper presented at the International Geoinformatics Student Symposium (IGSS).

Bulut, S. (2023). Uydu görüntüsü ve uzaktan algılama teknikleri ile arazi kullanım sınıflarının belirlenmesi. Anadolu Orman Araştırmaları Dergisi, 9(2), 150-156.

Bulut, S., & Günlü, A. (2016). Arazi kullanım sınıfları için farklı kontrollü sınıflandırma algoritmalarının karşılaştırılması. Kastamonu University Journal of Forestry Faculty, 16(2), 528-535.

Cortes, C. (1995). Support-Vector Networks. Machine learning.

Çakaroz, D., Özelkan, E., & Karaman, M. (2020). Sulak alanlarda uzaktan algılama ile belirlenen zamansal değişime kuraklığın etkisinin incelenmesi: Umurbey deltası (Çanakkale) örneği. Avrupa Bilim ve Teknoloji Dergisi(20), 898-916.

Çölkesen, İ. (2009). Uzaktan algılamada ileri sınıflandırma tekniklerinin karşılaştırılması ve analizi. Mühendislik ve Fen Bilimleri Enstitüsü.

Danacıoğlu, Ş. (2023). Arazi Örtüsü Haritalamasında Farklı Makine Öğrenmesi Algoritmalarının Değerlendirilmesi: İzmir İli Örneği. Türk Coğrafya Dergisi(84), 105-117.

Demiroz, A., & Yildiz, F. (2021). Investigation of the dynamic behavior of soils of Konya Organized Industrial Zone by equivalent linear analysis method.

Dong, J., Xiao, X., Menarguez, M. A., Zhang, G., Qin, Y., Thau, D., . . . Moore III, B. (2016). Mapping paddy rice planting area in northeastern Asia with Landsat 8 images, phenology-based algorithm and Google Earth Engine. Remote Sensing of Environment, 185, 142-154.

Erdoğan, E., & Yılmaz, V. (2024). Examination of the Effects of Climate Change on Türkiye through the Google Earth Engine Platform. Türk Uzaktan Algılama ve CBS Dergisi, 5(1), 102-116.

ESA, (2024). Introducing Sentinel-2 [Erişim Tarihi: 20.01.2025], https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-2/Introducing_Sentinel-2#:~:text=Sentinel%2D2%20carries%20an%20innovative,provides%20unprecedented%20views%20of%20Earth.

Jamil, A., & Bayram, B. (2017). Tree species extraction and land use/cover classification from high-resolution digital orthophoto maps. IEEE Journal of selected topics in applied earth observations and remote sensing, 11(1), 89-94.

Johnson, J. E., Laparra, V., Pérez-Suay, A., Mahecha, M. D., & Camps-Valls, G. (2020). Kernel methods and their derivatives: Concept and perspectives for the earth system sciences. PloS one, 15(10), e0235885.

Karaca, M., Yağmur, N., & Balçık, F. (2022). İstanbul Terkos Gölü zamansal değişiminin Google Earth Engine kullanılarak belirlenmesi. Geomatik, 7(3), 235-242.

Krivoguz, D., Chernyi, S. G., Zinchenko, E., Silkin, A., & Zinchenko, A. (2023). Using Landsat-5 for accurate historical LULC classification: A comparison of machine learning models. Data, 8(9), 138.

Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. International journal of remote sensing, 28(5), 823-870.

Makineci, H. B. (2024). Investigation of burned areas with multiplatform remote sensing data on the Rhodes 2023 forest fires. Ain Shams Engineering Journal, 15(10), 102949.

Phan, T. N., Kuch, V., & Lehnert, L. W. (2020). Land cover classification using Google Earth Engine and random forest classifier—The role of image composition. Remote Sensing, 12(15), 2411.

Singh, R., Saritha, V., & Pande, C. B. (2024). Monitoring of wetland turbidity using multi-temporal Landsat-8 and Landsat-9 satellite imagery in the Bisalpur wetland, Rajasthan, India. Environmental Research, 241, 117638.

Unal, E. O., Kocaman, S., & Gokceoglu, C. (2024). Impact assessment of geohazards triggered by 6 February 2023 Kahramanmaras Earthquakes (Mw 7.7 and Mw 7.6) on the natural gas pipelines. Engineering geology, 334, 107508.

Üstüner, M. (2013). Destek vektör makineleri yöntemi ile arazi kullanımı sınıflandırılmasında kernel fonksiyonlarına ait karşılaştırmalı parametre duyarlık analizi: Rapideye ve spot örneği.

Xiong, J., Thenkabail, P. S., Tilton, J. C., Gumma, M. K., Teluguntla, P., Oliphant, A., . . . Gorelick, N. (2017). Nominal 30-m cropland extent map of continental Africa by integrating pixel-based and object-based algorithms using Sentinel-2 and Landsat-8 data on Google Earth Engine. Remote Sensing, 9(10), 1065.

Xu, S., Wang, D., Liang, S., Jia, A., Li, R., Wang, Z., & Liu, Y. (2024). A novel approach to estimate land surface temperature from landsat top-of-atmosphere reflective and emissive data using transfer-learning neural network. Science of the Total Environment, 955, 176783.

Yılmaz, O. S., Oruç, M. S., Ateş, A. M., & Gülgen, F. (2021). Orman yangın şiddetinin Google Earth Engine ve coğrafi bilgi sistemleri kullanarak analizi: Hatay-Belen örneği. Journal of the Institute of Science and Technology, 11(2), 1519-1532.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Optik ve SAR Uydu Verilerinden Yüzey Deformasyonlarının Analizi: Sabiha Gökçen Havalimanı ve Çevresi

**Salih Tatcı*[1], Berkay Korik, Esra Erten[1], Nebiye Musaoğlu[1]**

[1]*İstanbul Teknik Üniversitesi, İnşaat Fakültesi, Harita Mühendisliği Bölümü, İstanbul, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama,
Yapay Açıklıklı Radar,
InSAR,
Sabiha Gökçen Havalimanı

**ÖZET**

Yer gözlem uydularından sağlanan veriler, geniş alanlarda sürekli, hızlı ve etkili bilgi çıkarımı için önemli bir kaynaktır. Bu veriler, özellikle havalimanları, metro hatları ve limanlar gibi büyük ölçekli mühendislik yapılarında meydana gelen yatay ve düşey deformasyonların belirlenmesinde, yapısal güvenliğin sağlanması açısından kritik bir rol oynamaktadır. Bu çalışmada, Sabiha Gökçen Havalimanı çevresindeki deformasyonları tespit etmek amacıyla Sentinel-1 SAR verileri, Sentinel-2 ve Pleiades uydu verileri birlikte kullanılmıştır. Sentinel-1 verilerinden, düşey yönlü hareketler, Sentinel-2 görüntülerinden ise yüzeydeki arazi kullanımı değişimleri belirlenmiştir. Sentinel-2 verilerinden, bitki örtüsü ve yapay yüzeyler gibi arazi örtüsü ve arazi kullanımına ilişkin değişimlerin ortaya konması için görüntülere NDVI (Normalised Vegetation Index), NDBI (Normalized Difference Built-up Index) ve SAVI (Soil-Adjusted Vegetation Index) indisleri uygulanmıştır. Düşey düzlemdeki değişimler ise uydu radar interferometrisi (Interferometric Synthetic Aperture Radar, InSAR) teknikleriyle analiz edilmiş; bu kapsamda SBAS (Small Baseline Subset) ve PS (Persistent Scatter) InSAR yöntemleri kullanılarak bölgenin detaylı bir değerlendirilmesi yapılmıştır. Optik verilerin entegrasyonu ile SAR verilerinden elde edilen sonuçlar desteklenmiş ve böylece hem arazi örtüsünde hem de düşeyde meydana gelen değişimlerin yüksek doğrulukla belirlenmesi sağlanmıştır.

# Analysis of Surface Deformations from Optical and SAR Satellite Images: Sabiha Gökçen Airport and Surroundings

**Keywords**
Remote sensing,
Synthetic Aperture Radar,
InSAR,
Sabiha Gökçen Airport

**ABSTRACT**

Earth observation data are an important resource for continuous, rapid, and effective information extraction over large areas. It plays a critical role in determining horizontal and vertical deformations in large-scale engineering structures, such as airports, metro lines, harbors, etc., ensuring structural safety. In this study, Sentinel-1 SAR data was used alongside Sentinel-2 and Pleiades satellite data to detect deformations around Sabiha Gökçen Airport. Sentinel-1 data was used to identify vertical movements, while the optical images from Sentinel-2 helped determine changes in land use on the surface. Spectral indices such as NDVI (Normalized Vegetation Index), NDBI (Normalized Difference Built-up Index), and SAVI (Soil-Adjusted Vegetation Index) were applied to capture changes related to land cover and land use, such as vegetation and artificial surfaces. These spectral indices enabled the identification of the horizontal changes in the study area, particularly transformations occurring in urbanized areas compared to natural cover. Vertical changes were analyzed using satellite radar interferometry (Interferometric Synthetic Aperture Radar, InSAR) techniques, employing SBAS (Small Baseline Subset) and PS (Persistent Scatter) InSAR methods for a detailed assessment of the region. The integration of optical data supported the results obtained from SAR data, thereby ensuring a highly accurate determination of both horizontal and vertical changes.

## GİRİŞ

Modern mühendislik yapılarının güvenliği ve sürdürülebilirliği, zemin deformasyonlarının hassas bir şekilde izlenmesine bağlıdır. Özellikle metro inşaatı, havalimanları gibi geniş coğrafi alanlara yayılan büyük ölçekli yapılar, bu tür deformasyonlara karşı oldukça duyarlıdır. Bu yapılarda meydana gelen yatay arazi kullanımı değişimleri ile düşey zemin hareketleri hem altyapı bütünlüğünü hem de operasyonel güvenliği ciddi şekilde tehdit edebilir. Bu kapsamda, uzaktan algılama teknolojileri, özellikle de ücretsiz erişilebilen uydu görüntüleri, geniş alanlardan hızlı ve maliyet etkin bir şekilde veri toplanmasını sağlayarak, zemin deformasyonlarının izlenmesinde mühendislik yapıları için güçlü bir araç haline gelmiştir (Zhang vd. 2023, Yağmur vd. 2022, Bayik ve Abdikan, 2021, Halıcıoğlu, vd. 2021).

Bu çalışmada, Sabiha Gökçen Havalimanı çevresinde meydana gelen yatay arazi kullanımı ve düşey yüzey değişimleri, uzaktan algılama verileri kullanılarak bölgedeki operasyonel güvenliğin sağlanması ve olası risklerin önlenmesi açısından incelenmiştir.

## VERİ VE YÖNTEM

Zamansal analizler Sentinel-1 ve Sentinel-2 verileri kullanılarak gerçekleştirilmiş, yüksek mekansal çözünürlüğe sahip Pleiades görüntüleri ise doğrulama amacıyla değerlendirilmiştir. Sentinel-1 SAR görüntüleri, hava koşullarından bağımsız, özellikle deformasyon takibi ve afet izleme çalışmalarında, 2019 yılından beri Avrupa Uzay Ajansı'nın (ESA) açık veri politikası (free data policy) sayesinde yaygın olarak kullanılan standart bir kaynak haline gelmiştir (Erten ve Rossi, 2019). Sentinel-2 ise, multispektral optik görüntüler ile arazi örtüsü ve arazi kullanım değişimlerinin analizinde etkilidir ve bu amaçlar için sık aralıklarla veri sağlar. Aynı yörüngede bulunan iki özdeş uydu olan Sentinel-2B ve Sentinel-2C ile aynı bölgeyi ziyaret süresi 5 güne indirilmektedir. Ayrıca Sentinel-2A uydusunun görevinin yeni bir konfigürasyonla 1 yıl daha uzatılması ile gözlem sıklığının artması sağlanmıştır. Birbirini tamamlayan optik ve SAR verilerinin birlikte kullanımı deformasyon analizlerinde bütüncül bir değerlendirmeyi olanaklı kılmaktadır (Zhang vd. 2025, Yağmur vd. 2022). Pleiades gibi uydulardan sağlanan yüksek çözünürlüklü görüntüleri ise hem detaylı bilgi üretme hem de doğrulamada önemli bir veri kaynağıdır.

Çalışmada kullanılan verilerin tarihleri, Şekil 1'de gösterilmektedir. Sentinel-1 verileri 12 günlük aralıklarla, Sentinel-2 verileri ise yıllık frekansla alınmıştır. Çalışmada 2017-2023 yılları arasında 210 adet Sentinel-1 Burst görüntüsü, 2017-2023 arasında 7 adet Sentinel-2 uydu görüntüsü, 2019 ve 2023 yıllarına ait 2 adet Pleiades görüntüsü kullanılmıştır.

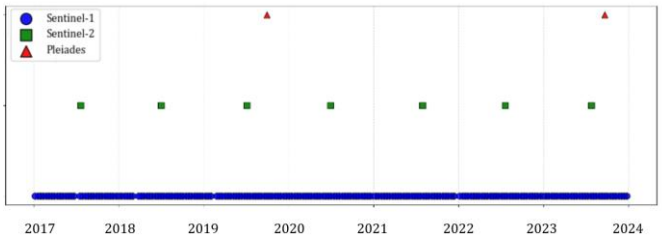


Şekil 1. Sentinel-1, Sentinel-2 ve Pleiades görüntülerinin algılanma tarihleri

Sonuçların üretilmesi için izlenen genel işlem adımları Şekil 2'de gösterilmektedir. SAR verilerinden deformasyonların belirlenmesinde SBAS ve PSI teknikleri kullanılmıştır (Ferretti vd., 2001; Berardino vd., 2002). PSI, sabit yansıtıcı hedefler üzerinde; SBAS ise doğal yüzeylerde, dağınık saçıcılar aracılığıyla deformasyonların zamansal hareketinin izlenmesinde başarılı sonuçlar sağlamaktadır (Bayik ve Abdikan, 2021).

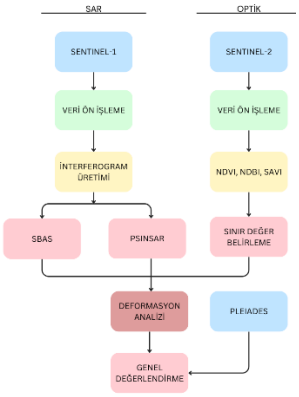


Şekil 2. Çalışmada izlenen işlem adımlarının genel akış diyagramı

Sentinel-2 görüntülerine uygulanan NDVI (Normalised Vegetation Index), NDBI (Normalized Difference Built-up Index) ve SAVI (Soil-Adjusted Vegetation Index) indisleri ile bölgedeki bitki örtüsü, yapılaşma ve boş alanlardaki değişimler belirlenmiştir. Sonuçlar, İTÜ UHUZAM arşivinden elde edilen yüksek çözünürlüklü Pleiades görüntüleri ile doğrulanmış, optik ve radar verilerinin entegrasyonu sayesinde yataydaki arazi kullanımı değişimi ve düşey deformasyonlar bütüncül bir yaklaşımla analiz edilmiştir.

## BULGULAR ve TARTIŞMA

Sabiha Gökçen Havalimanı ve yakın çevresi, 2017–2023 yılları arasını kapsayan Sentinel-1 görüntüleri kullanılarak SBAS ve PSI teknikleri ile analiz edilmiştir (Şekil 3). Interferometri sonuçlarında deformasyon tespit edilen bölgeler, zamansal Sentinel-2 görüntülerine uygulanan indis sonuçları ve Pleiades görüntüsü ile detaylı olarak incelenmiştir (Şekil 4).

* **Ramazan Güngör**

*(ramazan.gungur@cbu.edu.tr) ORCID ID 0000-0002-6338-8554
(mujgan.ergene@std.yildiz.edu.tr) ORCID ID 0000-0002-1118-0006
(fbalik@yildiz.edu.tr) ORCID ID 0000-0003-1243-8299
(murat.ates@cbu.edu.tr) ORCID ID 0000-0002-2815-1404

**Kaynak Göster (APA):**

Güngör R, Ergene E. M., Şanlı F. B., Ateş A. M & Yılmaz O. S. (2025). Yağmur Suyu Hasadı Yapılacak Optimum Alanların Belirlenmesi ve Kuraklık Özelliklerinin İncelenmesi: Demirci İlçesi Örneği, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

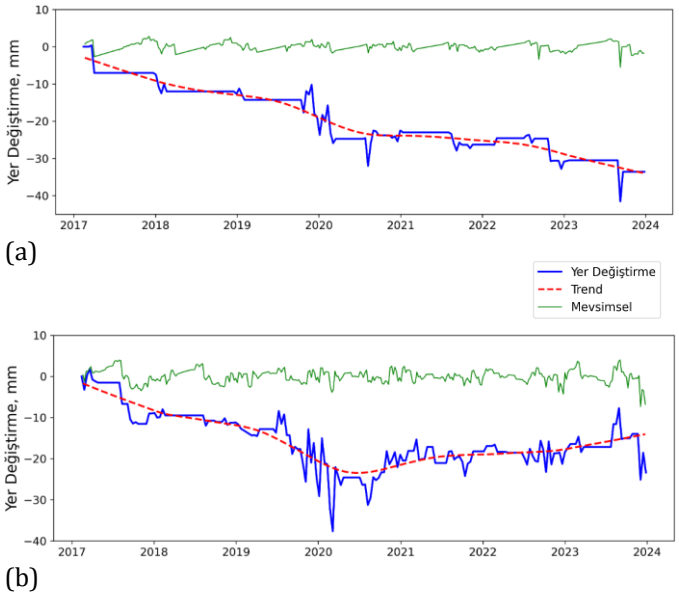


(a)

(b)




(c)




(d)

Şekil 3. Değişim görülen yerdeki yıllara göre a) PS ve b) SBAS sonuçları ve havalimanı pistinden seçilen noktanın c) 2018 d) 2023 yıllarındaki görüntüleri

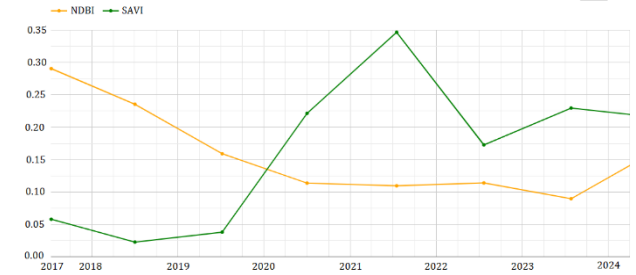


(a)




(b)

(c)



(d)



(e)

Şekil 4. a) NDBI ve SAVI zaman serisi b) PS ve c) SBAS yöntemiyle ilgili noktanın elde edilen yer değiştirme zaman serisi grafikleri ve ilgili noktanın (d) 2019 (e) 2023 yıllarındaki Pleiades görüntüleri

Şekil 3'te sunulan analiz sonuçları, havalimanı pistinden seçilen bir noktadaki yer değiştirme davranışını PSI (a) ve SBAS (b) yöntemleriyle elde edilen zaman serileri üzerinden göstermektedir. Her iki yöntem de 2020 yılı itibariyle belirgin bir deformasyon eğilimi ortaya koymaktadır. Özellikle PSI verisinde, 2020 sonrası dönemde deformasyon eğrisinde değişim gözlemlenmiştir. İlgili noktada kalıcı saçıcı değişimi olmaması nedeniyle ani değişimler ve ortalamadan (trend) düşük miktarda sapmalar gözlemlenmiştir. SBAS yöntemi ise daha düşük çözünürlükte olmakla birlikte benzer bir eğilim göstermektedir. Bu deformasyonun fiziksel karşılığı, Şekil 3(c) ve (d)'de sunulan 2018 ve 2022 yıllarına ait uydu görüntülerinde açıkça görülebilmektedir; analiz noktası çevresinde, pist alanının genişletilmesi ve zemin yapısındaki değişiklikler belirgindir. Bu bağlamda, her iki interferometrik yaklaşım da yapılaşmanın ve zemin müdahalelerinin neden olduğu yüzey deformasyonlarını başarıyla ortaya koymaktadır.

Şekil 4'te sunulan analiz sonuçları, çalışma alanındaki belirgin bir yansıtıcının (bina) yıkımının, PSI ve SBAS interferometrik yöntemlerle elde edilen deformasyon zaman serileri üzerindeki etkisini açık biçimde ortaya koymaktadır. Şekil 4(d) ve 4(e)'de görüldüğü üzere, 2019 yılı itibariyle mevcut olan yapı, 2023 yılında tamamen ortadan kaldırılmıştır. Bu yapısal değişiklik, PSI yöntemiyle elde edilen zaman serisinde (Şekil 4b) 2019 yılı sonunda deformasyon eğrisinde ani bir kırılma olarak gözlemlenmektedir. PSI yöntemi, yüksek koheranslı ve sabit yansıtıcı noktaları temel aldığından, yapının yıkılması sonucu ilgili konumda veri kaybı meydana gelmiş ve grafikte ani saptamalar görülmüştür. Buna karşın, daha geniş alanları ve düşük koheranslı pikselleri değerlendirebilen SBAS yöntemi (Şekil 4c), deformasyon takibini sürdürebilmiştir.

Söz konusu yapısal değişim, optik uydu verileriyle de doğrulanmaktadır. Şekil 4(a)'daki grafik, bölgeye ait NDBI ve SAVI zaman serilerini içermektedir. 2017–2023 döneminde NDBI değerlerinde gözlenen sürekli azalma, yapay yüzey oranındaki düşüşe işaret etmektedir. Buna karşılık, 2020 sonrası dönemde SAVI değerlerinde kaydedilen belirgin artış, alanda toprağın açığa çıktığını göstermektedir. Bu fiziksel dönüşüm, radar sinyalinin geri saçılım özelliklerini ve koherens düzeyini etkileyerek özellikle PSI tabanlı analizlerin kalitesini olumsuz yönde etkilemiştir.

PSI ve SBAS yöntemleri, farklı teknikler ve veri odaklılıkları ile yer değişikliği analizlerinde kullanılır. PSI, daha stabil ve kalıcı yüzeyler üzerinde hassas ölçümler yaparken, SBAS küçük bazlı interferogramlar kullanarak geniş alanlardaki değişiklikleri daha dinamik bir şekilde yakalar.

## Öneri

Çalışmada kullanılan yöntemin sürdürülebilirliği, geniş alanlarda ön bilgi sağlama kapasitesi açısından önemli bir avantaj sunmaktadır. Açık veri kaynaklarına dayalı olması, maliyet etkinliği ve erişilebilirlik açısından yöntemin uygulanabilirliğini artırmaktadır. Özellikle, büyük ölçekli mühendislik yapılarının deformasyon izleme süreçlerinde etkin bir araç olarak değerlendirilebilecek InSAR tabanlı yaklaşım, Sentinel-1C uydusunun devreye alınmasıyla birlikte artan görüntüleme sıklığı sayesinde daha yüksek zamansal çözünürlük sunarak analiz kapasitesini önemli ölçüde artıracaktır. Bu yönüyle, InSAR teknolojisi, belediyeler ve yerel yönetimler tarafından da düzenli olarak kullanılabilecek, maliyet etkin ve ölçeklenebilir bir izleme alternatifi olarak öne çıkmaktadır.

## Teşekkür

Bu çalışma, TÜBİTAK 2209-A kapsamında desteklenen "Optik ve SAR Uzaktan Algılama Verileri ile Deformasyon Belirleme" başlıklı proje kapsamında hazırlanmıştır.

## Yazar Katkı Oranı

Salih Tatcı: Makale yazımı, analizler, Berkay Korik: Bildiri yazımı, analizler, Esra Erten: Yöntem, bildiri yazımı, Nebiye Musaoğlu: Yöntem, bildiri yazımı

## KAYNAKÇA

Berardino, P., Fornaro, G., Lanari, R., & Sansosti, E. (2002). A new algorithm for surface deformation monitoring based on small baseline differential SAR interferograms. IEEE Transactions on Geoscience and Remote Sensing, 40(11), 2375-2383.

Bayik, C., & Abdikan, S. (2021). Monitoring of small-scale deformation at sea-filled Ordu-Giresun Airport, Turkey from multi-temporal SAR data. Engineering Failure Analysis, 130, 105738.

Erten, E., Rossi, C. (2019). The worsening impacts of land reclamation assessed with Sentinel-1: The Rize (Turkey) test case. International Journal of Applied Earth Observation and Geoinformation, 74, 57-64.

Ferretti, A., Prati, C., & Rocca, F. (2001). Permanent scatterers in SAR interferometry. IEEE Transactions on Geoscience and Remote Sensing, 39(1), 8-20.

Halicioglu, K., Erten, E. & Rossi, C. (2021). Monitoring deformations of Istanbul metro line stations through Sentinel-1 and levelling observations. Environmental Earth Sciences, 80, 361.

Yağmur, N., Erten, E., Musaoğlu, N., Safak, E. (2022). Assessing spatio-temporal Dynamics of large airport's surface stability. Geocarto Inernational, 37(26),13734–13747.

Zhang, R., Zhang, W., Huang, W., Ma, T., Wang, Q., Fang, K., Wang, K. (2023). High-precision monitoring method for airport deformation based on time-series InSAR technology. Construction and Building Materials, 366, 130144.

Zhang, Z., Wu, S., Zhao, C., Shi, G., Ding, X., Zhang, B., Li, Z., Wang, Y., Lu, Z. (2025). Evaluation of InSAR applicability using a new multi-index and optical imagery: A case study in the Guangdong-Hong Kong-Macao greater bay area, China, Remote Sensing Applications: Society and Environment, 37,101474.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Yağmur Suyu Hasadı Yapılacak Optimum Alanların Belirlenmesi ve Kuraklık Özelliklerinin İncelenmesi: Demirci İlçesi Örneği

**Ramazan Güngör[*1], Emine Müjgan Ergene[2], Füsun BALIK ŞANLI[3], Ali Murat ATEŞ[4], Osman Salih YILMAZ[5]**

[1]*Manisa Celal Bayar Üniversitesi, Mimarlık ve Şehir Planlama Bölümü, Manisa, Türkiye*
[2]*Yıldız Teknik Üniversitesi, Harita Mühendisliği Bölümü, İstanbul, Türkiye*
[3]*Yıldız Teknik Üniversitesi, Harita Mühendisliği Bölümü, İstanbul, Türkiye*
[4]*Manisa Celal Bayar Üniversitesi, Bilgisayar ve Öğretim Teknolojileri Bölümü, Manisa, Türkiye*
[5]*Manisa Celal Bayar Üniversitesi, Mimarlık ve Şehir Planlama Bölümü, Manisa, Türkiye*

**Anahtar Kelimeler**
Analitik Hiyerarşi Prosesi,
Kuraklık,
Toprak Koruma Servisi-Eğri Numarası
Yağmur Suyu Hasadı,

**ÖZET**

Çalışmada, optimum yağmur suyu hasadı (YSH) alanlarının belirlenmesi için Çok Kriterli Karar Destek (ÇKKD) yöntemlerinden biri olan Analitik Hiyerarşi Prosesi (AHP) kullanılmıştır. AHP'ye dahil edilen parametrelerden en yüksek ağırlık değeri %27 ile akış potansiyeline aittir. Akış potansiyeli verisi, toprak sınıfı verisi ve bölge yağış verileri kullanılarak Toprak Koruma Servisi-Eğri Numarası (SCS-CN) yöntemi ile elde edilmiştir. AHP'de kullanılan tüm parametrelerin ikili karşılaştırmaları sonucu tutarlılık oranı %9 olarak hesaplanmıştır. Ayrıca YSH için optimum alanların belirlenmesinde Orta Çözünürlüklü Görüntüleme Spektroradyometresi (MODIS) veri seti kullanılarak 2010-2024 zaman periyoduna ait Sıcaklık Durum İndeksi (TCI) ve Bitki Örtüsü Sağlık İndeksi (VHI) gibi kuraklık izlemede kullanılan spektral bant indeksleri incelenmiştir. AHP ile belirlenen optimum alanlar ile kuraklık indeksleri arasında Pearson korelasyon analizi uygulanmıştır. Bu analize göre optimum alanların VHI ile arasındaki korelasyon katsayısı r=-0,112, TCI ile arasındaki korelasyon katsayısı ise r=-0,149 olarak hesaplanmıştır. Çalışma sonucunda elde edilen optimum alanların büyük çoğunluğu bölgenin kuzey doğusunda toplanmış ve 5 sınıfa ayrılmıştır. Optimum alanlar hiç uygun değil 17,08 km$^2$ (%1,30), uygun değil 604,18 km$^2$ (%45,96), orta uygun 568,96 km$^2$ (%43,28), uygun 123,52 km$^2$ (%9,40) ve çok uygun 0,77 km$^2$ (%0,06) olarak tespit edilmiştir.

# Determination of Optimal Rainwater Harvesting Areas and Analysis of Drought Characteristics: The Case of Demirci District

**Keywords**
Analytic Hierarchy Process,
Drought,
Soil Conservation Service-Curve Number,
Rainwater Harvesting

**ABSTRACT**

In this study, the Analytic Hierarchy Process (AHP), one of the Multi-Criteria Decision Analysis (MCDA) methods, was employed to identify optimal Rainwater Harvesting (RWH) zones. Among the parameters integrated into the AHP, flow potential was assigned the highest weight at 27%. The flow potential data were derived using the Soil Conservation Service Curve Number (SCS-CN) method, based on inputs from soil classification and regional precipitation data. The pairwise comparisons of all parameters utilized in the AHP resulted in a consistency ratio of 9%, indicating acceptable reliability of the weight assignments. In addition, to enhance the spatial assessment of suitable RWH areas, spectral band indices commonly used in drought monitoring—namely the Temperature Condition Index (TCI) and the Vegetation Health Index (VHI)—were analyzed using the MODIS (Moderate Resolution Imaging Spectroradiometer) dataset over the period 2010–2024.A Pearson correlation analysis was conducted to examine the relationship between the AHP-derived suitability zones and the drought indices. The correlation coefficient between the optimal areas and VHI was calculated as r= -0.112, while the coefficient with TCI was r= -0.149.The study findings revealed that the majority of the optimal RWH areas were concentrated in the northeastern part of the region and were classified into five suitability categories: not suitable 17.08 km$^2$ (1.30%), less suitable 604.18 km$^2$ (45.96%), moderately suitable 568.96 km$^2$ (43.28%), suitable 123.52 km$^2$ (9.40%), highly suitable: 0.77 km$^2$ (0.06%).

## GİRİŞ

Küresel iklim değişikliği ve artan su talepleri, mevcut su kaynaklarının daha verimli ve sürdürülebilir şekilde yönetilmesini zorunlu hale getirmiştir. Özellikle yarı kurak bölgelerde artan kuraklık şiddeti ve sıklığı, su kıtlığı riskini ciddi boyutlara taşımaktadır. Nitekim dünya nüfusunun %67'si, su eksikliği ve yeraltı sularının bilinçsiz kullanımı nedeniyle bu durumdan doğrudan etkilenmektedir. Yüksek kuraklık riski taşıyan ülkelerden bir tanesi de Türkiye olup mevsimsel kuraklıklar sonucu düzensiz ve düşük yağışların neden olduğu su kıtlığı söz konudur (Özben ve Güngör, 2024). Ortaya çıkan bu durum ise mevcut su kaynaklarını tehdit etmektedir. Bu bağlamda, geleneksel kaynaklara ek olarak yeni ve çevre dostu çözümler aranmakta, teknolojik uygulamaların kullanımı giderek yaygınlaşmaktadır. Bu çözümlerden biri olan Yağmur Suyu Hasadı (YSH), düşük maliyetli ve sürdürülebilir bir yöntem olarak öne çıkmaktadır. YSH hem yeraltı suyu seviyesinin korunmasına hem de evsel ve tarımsal su ihtiyacının karşılanmasına katkı sağlar (Hassan vd., 2025).

Türkiye'de yıllık su kullanımının %73'ü tarımda gerçekleşirken, YSH uygulamaları içme suyu kaynaklarının korunmasına da önemli katkılar sunabilir (Muratoğlu, 2020). Ayrıca, bu yöntemle toprak nemi artar, sel ve erozyon riski azalır, tarımsal verimlilik desteklenir. Ancak YSH alanlarının doğru belirlenmesi, çok sayıda çevresel ve mekânsal verinin analizini gerektirir. Bu noktada Coğrafi Bilgi Sistemleri (CBS) ve Çok Kriterli Karar Destek Sistemleri (ÇKKD), karar sürecini bilimsel temele oturtarak en uygun alanların belirlenmesinde önemli rol oynamaktadır (Vohland ve Barry, 2009).

Bu çalışmada, YSH için en uygun alanların belirlenmesi amaçlanmış olup, ÇKKD yöntemlerinden biri olan Analitik Hiyerarşi Prosesi (AHP) yöntemi kullanılmıştır. Bu kapsamda YSH uygulamalarında yaygın olarak kullanılan 8 parametre seçilmiş ve CBS ortamında analiz edilerek YSH alanları belirlenmiştir. Ayrıca belirlenen bu alanlar kuraklık analizlerinde kullanılan spektral bant indeksleri ile karşılaştırılarak YSH alanları ve kuraklık arasındaki ilişki incelenmiştir.

**Çalışma Alanı**

Çalışma alanı olarak belirlenen Demirci, Ege Bölgesi'nde yer alan Manisa iline bağlı bir ilçedir. İlçenin kuzey ve kuzeydoğusu, Demirci-Simav Dağları ile çevrilidir (Demirci Belediyesi, 2025). Demirci ilçesinin Hidrolojik Toprak Grupları (HTG) incelendiğinde, B, C ve D grubu toprakların yoğunlukta olduğu görülmektedir. YSH açısından C ve D grubu topraklar uygun kabul edilir (Radwan ve Alazba, 2023). Bu toprakların oranı ise yaklaşık %88'dir. Son 40 yıla ait yağış verileri değerlendirildiğinde, yıllık yağış miktarının 593 ila 807 mm arasında değiştiği belirlenmiştir. Bu durum, YSH açısından en önemli parametrelerden biri olan maksimum yüzey sızma kapasitesini olumlu yönde etkilemektedir (Ammar vd., 2016). Tüm bu nedenlerden dolayı, YSH için optimum alanların belirlenmesine yönelik çalışmada Demirci ilçesi çalışma alanı olarak seçilmiştir (Şekil 1).

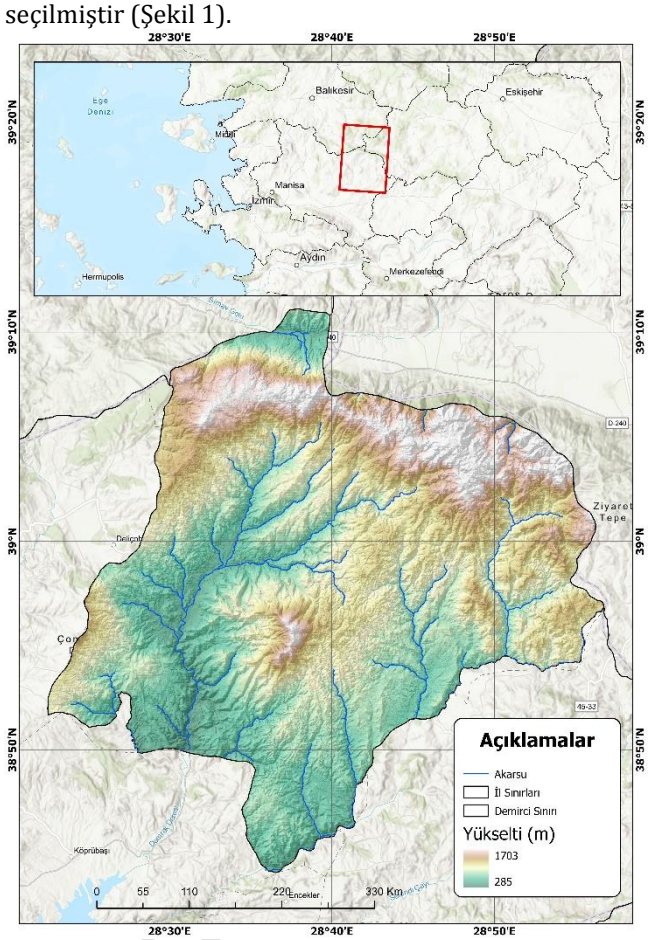


**Şekil 11**.Çalışma alanı

**YÖNTEM**

Çalışma başlıca 4 işlem adımından oluşmaktadır (Şekil 2). İlk adımda YSH alanlarının belirlenmesinde yaygın olarak kullanılan (Çizelge 1) parametrelere ait sınırlar belirlenmiştir. Belirlenen sınırlar neticesinde her bir veri 5 sınıfa ayrılarak yeniden sınıflandırılmış ve özelliğine göre puanlanmıştır. İkinci adımda AHP yöntemi kullanılarak parametrelere ilişkin ağırlıklar hesaplanmıştır. Üçüncü adımda her parametre için hesaplanan ağırlık değerleri kullanılarak üretilen grid haritalar çakıştırılmış ve YSH için optimum alanlar belirlenmiştir. Son adımda ise belirlenen optimum alanlar Orta Çözünürlüklü Görüntüleme Spektroradyometresi (MODIS) veri seti kullanılarak 2010-2024 zaman periyoduna ait Sıcaklık Durum İndeksi (TCI) ve Bitki Örtüsü Sağlık İndeksi (VHI) gibi kuraklık izlemede kullanılan spektral bant indeksleri (Çizelge 2) ile incelenmiştir.

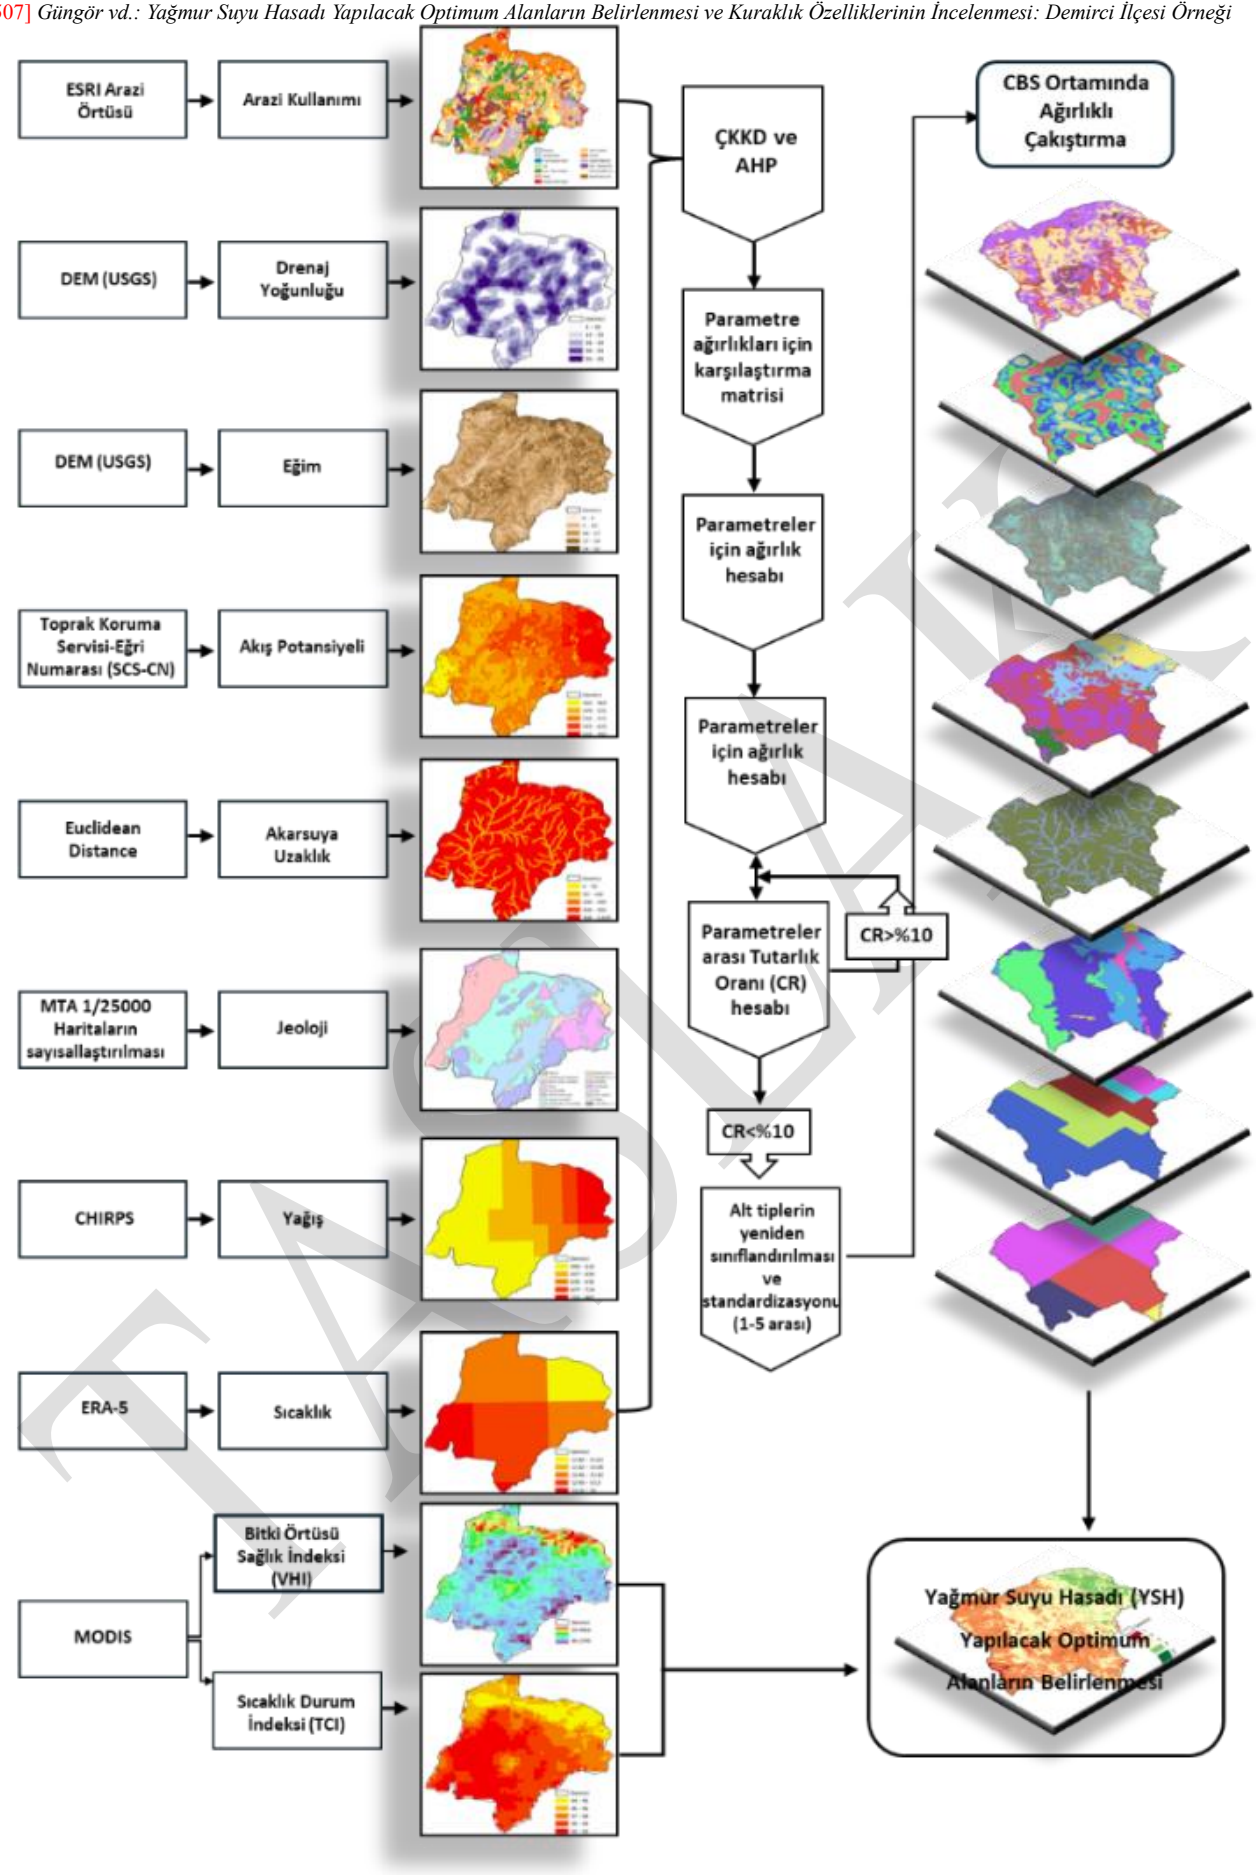


**Şekil 12**.İş akış diyagramı

**Çizelge 2**. Çalışmada kullanılan parametreler

| Veri | Kaynak |
|---|---|
| Arazi Kullanımı | ESRI Arazi Örtüsü https://livingatlas.arcgis.com/landcover/ |
| Drenaj Yoğunluğu | DEM (USGS), UTM-35, WGS 1984 https://earthexplorer.usgs.gov/ |
| Eğim | DEM (USGS), UTM-35, WGS 1984 https://earthexplorer.usgs.gov/ |
| Akış Potansiyeli | Toprak Koruma Servisi-Eğri Numarası (SCS-CN) yöntemi ile elde edilmiştir. |
| Akarsuya Uzaklık | ArcGIS Pro 3.1 ile Euclidean distance yöntemi ile elde edilmiştir. |
| Jeoloji | MTA 1/25000 Haritaların ArcGIS Pro 3.1 ile sayısallaştırılması https://yerbilimleri.mta.gov.tr/Default.aspx |
| Yağış | CHIRPS: Rainfall Estimates from Rain Gauge and Satellite Observations https://data.chc.ucsb.edu/products/CHIRPS-2.0/ |
| Sıcaklık | ERA5-Land Monthly Aggregated https://cds.climate.copernicus.eu/ |

**Analitik Hiyerarşi Prosesi (AHP)**

AHP, farklı harita katmanlarının önem düzeylerini hesaplamak ve katman özelliklerini bütünleşik bir şekilde kullanmak amacıyla (Saaty, 1977) tarafından geliştirilmiş bir ÇKKD yöntemidir. YSH için optimum alanların belirlenmesinde etkili olan parametrelilerin belirlenmesi ve uygun alt kategorilere ayrılması amacıyla kullanılmıştır.

**Spektral kuraklık İndeksleri**

**Çizelge 3**. Kuraklık indeksleri

| | | |
|---|---|---|
| $TCI=100x\frac{T_{max}-T_{Gözlenen}}{T_{max}-T_{min}}$ | (1) | (Kogan, 1995) |
| $VHI=\alpha\times VCI+(1-\alpha)\times TCI$ | (2) | |

$T_{max}$:Maksimum arazi yüzey sıcaklığı
$T_{Gözlenen}$:Gözlenen arazi yüzey sıcaklığı
$T_{min}$:Maksimum arazi yüzey sıcaklığı
VCI (Vegetation Condition Index): NDVI (Normalized Difference Vegetation Index) kullanılarak sağlıklı bitki örtüsünü ölçer.
α (alfa katsayısı): Çalışmada 0.5 olarak kabul edilmiştir.

**SCS-CN Yöntemi**

Farklı arazi örtüleri üzerinde gerçekleşen yağış olaylarından yararlanarak yüzey akışı hacmini hesaplamada en yaygın kullanılan yöntemlerden biri SCS-CN yöntemidir (3). SCS-CN yöntemi HTG özelliklerine göre eğri numarasını (CN) belirler (4) (Mishra ve Singh, 2013).

$$Q=\frac{(P-0.2S)^2}{(P+0.8S)} \quad P<0.2S \text{ ise } Q=0 \qquad (3)$$

$$S=\frac{25400}{CN}-254 \qquad (4)$$

Burada; $P$: Yağış toplamı (mm), $S$: Toprağın maksimum sızma miktarı (mm), $Q$: Akış potansiyeli (mm). CN ise HTG ve arazi özelliğine göre belirlenir.

**BULGULAR**

Çalışmada topografik ve meteorolojik parametreler kullanılarak YSH için optimum alanlar AHP yöntemi ile tespit edilmiştir. Burada kullanılan parametrelerin ikili karşılaştırılması sonucu en yüksek ağırlık değeri (%27) akış potansiyeli parametresinden elde edilmiştir (Çizelge 3). Ayrıca çalışmada tutarlılık indeksi ve rassallık indeksine göre hesaplanan tutarlılık oranı %9 dur. Bu değer %10 dan küçük olduğu için parametrelerin karşılıklı tutarlılığı sağlanmıştır. Çalışma kapsamında kullanılan parametrelere ilişkin haritalar ise farklı aralıklarda kategorize edilerek çakıştırmaya uygun hale getirilmiştir (Şekil 3).

**Çizelge 3**. Kullanılan parametreler ve ağırlıkları

| Kriterler | Ağırlık (%) |
|---|---|
| Arazi Kullanımı | 10 |
| Drenaj Yoğunluğu | 11 |
| Eğim | 16 |
| Akış Potansiyeli | 27 |
| Akarsuya Uzaklık | 6 |
| Jeoloji | 5 |
| Yağış | 22 |
| Sıcaklık | 3 |

TASLAK

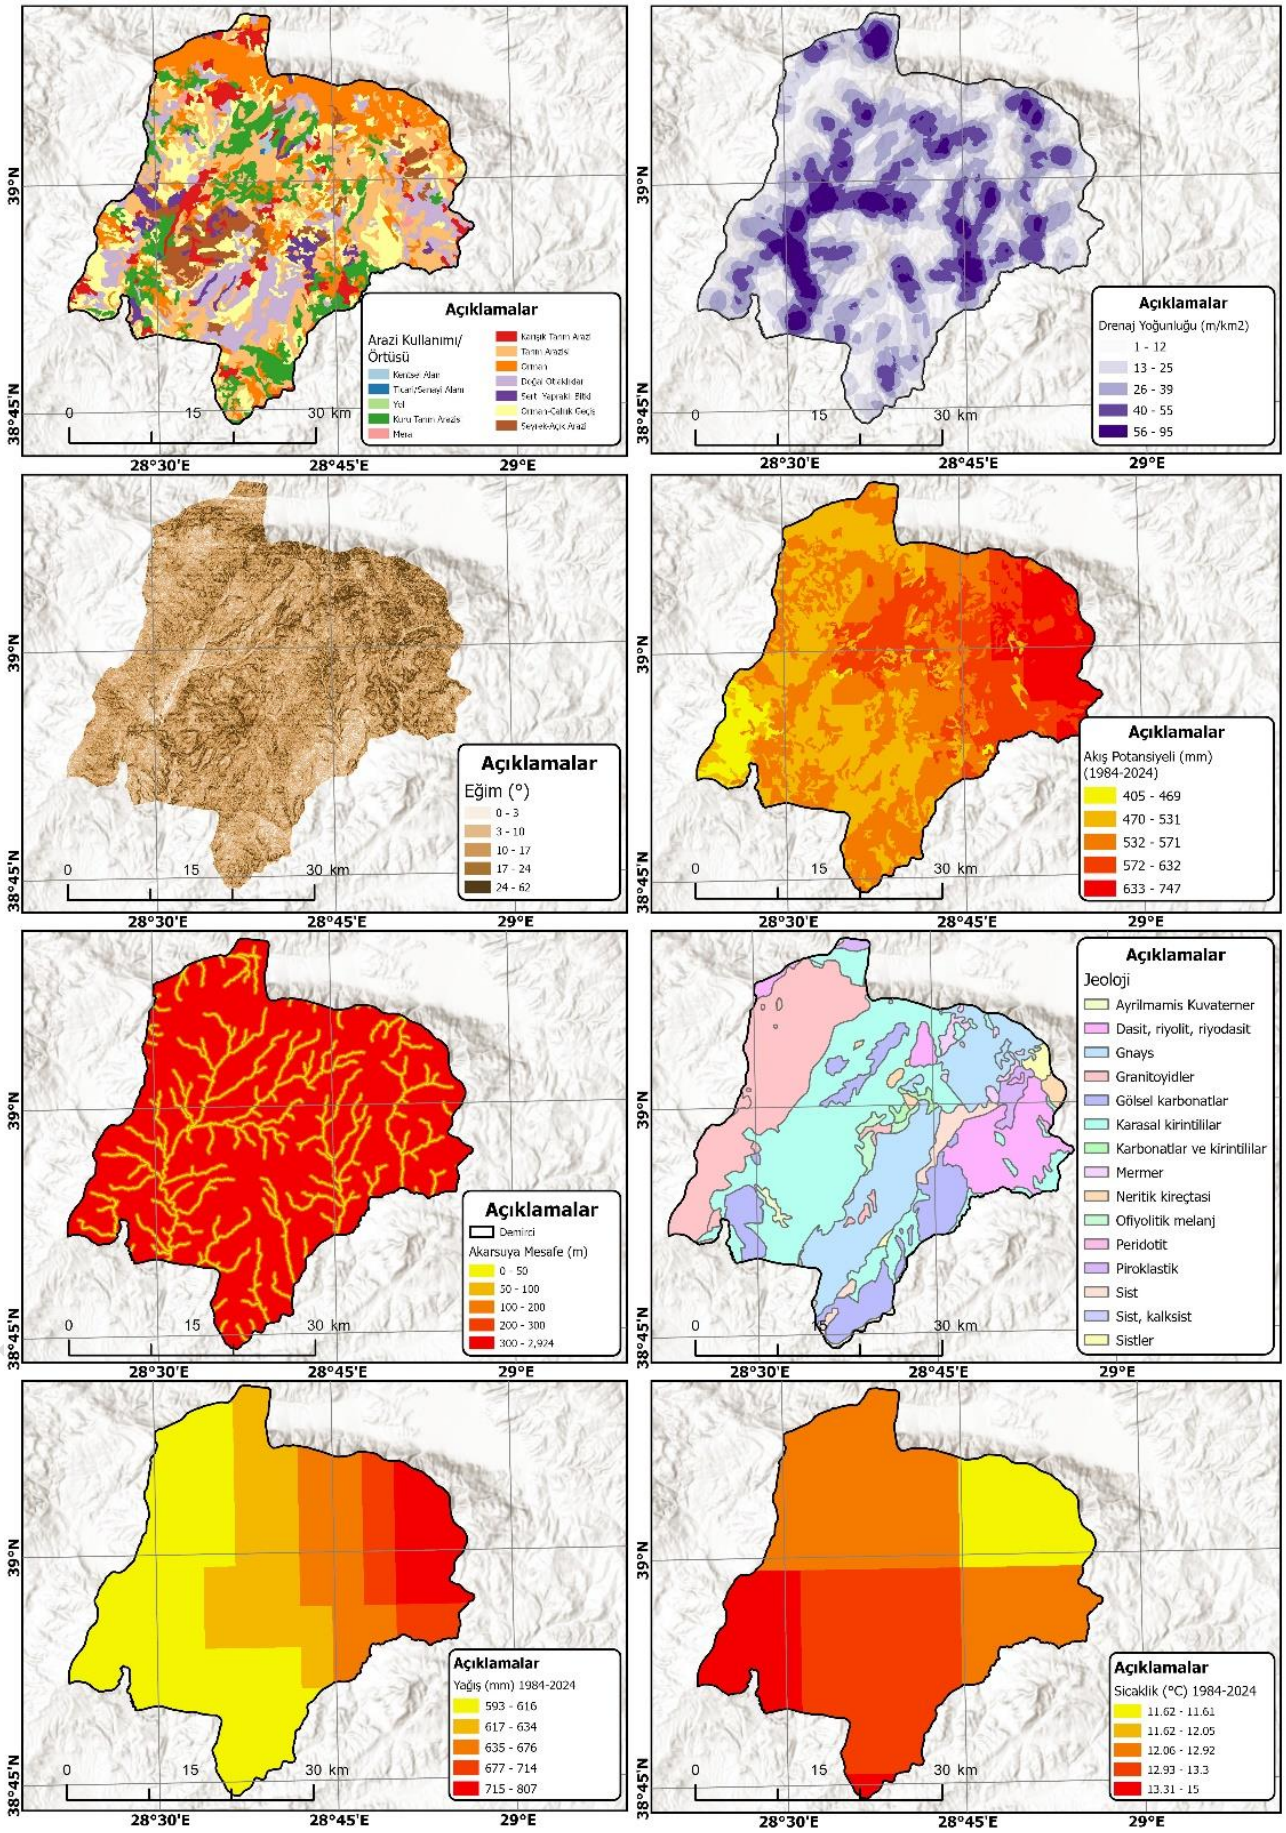


**Şekil 13.**Çalışmada kullanılan parametreler

Çalışma bölgesinde B, C ve D toprak grubunda alanlar yer almaktadır (Şekil 4). Bu grupların arazi örtüsü/kullanımı ile çakıştırılması sonucu elde edilen CN' ler ise 55-95 arasındadır. HTG ve CN kullanılarak hesaplanan *S* değeri 13-208 mm arasında olup *Q* ise 405-747 mm arasında belirlenmiştir. Yani çalışma alanının

tamamı akış potansiyeline sahiptir. YSH için toplam 693.25 km² (%52,74) optimum alan, 621.26 km² (%47,26) optimum olmayan alan tespit edilmiştir (Çizelge 4). Tespit edilen optimum alanlar daha çok Demirci ilçesinin kuzey doğusunda yoğunlaşmaktadır (Şekil 5). Ayrıca optimum alanlar en çok 250.92 km² ile tarım arazilerinde yer almaktadır.

**Çizelge 4.** Optimum alanlar

| Sınıf | Alan (km2) | Oran % |
|---|---|---|
| Hiç Uygun Değil | 17.08 | 1.30 |
| Uygun Değil | 604.18 | 45.96 |
| Orta Uygun | 568.96 | 43.28 |
| Uygun | 123.52 | 9.40 |
| Çok Uygun | 0.77 | 0.06 |

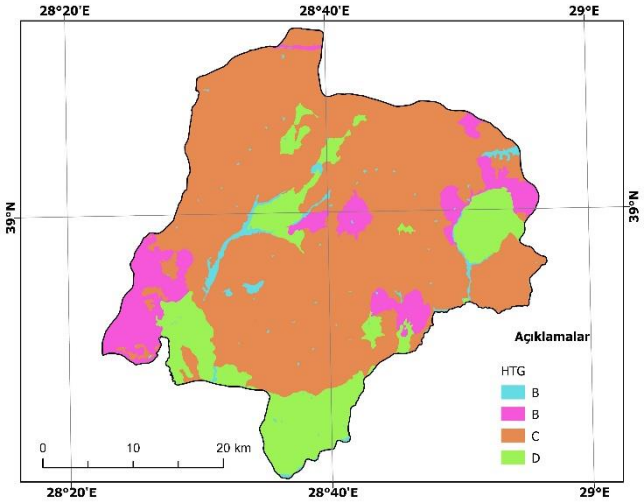


**Şekil 14.**Hidrolojik toprak grupları (HTG)

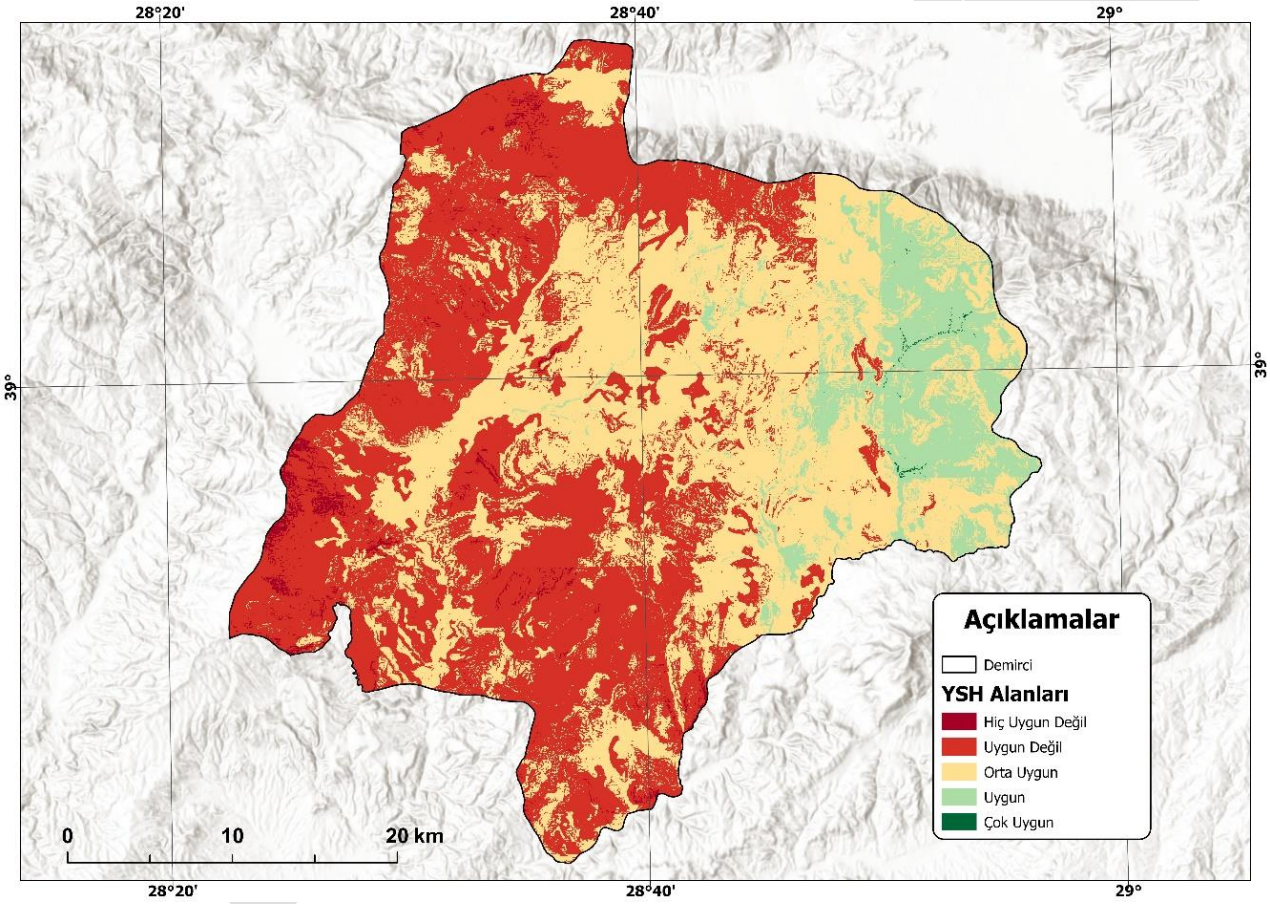


**Şekil 15.**YSH için optimum alanlar

2020-2024 zaman periyodunda ortalama TCI değerleri 43-49, VHI değerleri ise 40-59 arasında hesaplanmıştır. Bu değerler bölgenin kuraklık değerlerinin normal düzeyde olduğunu göstermektedir(Bento, Gouveia, DaCamara ve Trigo, 2018). Ayrıca AHP ile belirlenen optimum alanlar ile kuraklık indeksleri arasında Pearson korelasyon analizi uygulanmıştır. Bu analize göre optimum alanların VHI ile arasındaki korelasyon katsayısı r=-0.112, TCI ile arasındaki korelasyon katsayısı ise r=-0.149 olarak hesaplanmıştır. Bu değerler optimum alanlar ve kuraklık indeksleri arasında negatif yönlü zayıf bir ilişkinin olduğunu göstermektedir. Yani YSH için belirlenen optimumum alan arttığında kuraklık değerleri az da olsa azalma eğilimi göstermektedir. Bu durum optimum alanlarında normal sınırın altında kuraklık riski taşıdığını ifade etmektedir.

**TARTIŞMA**

Çalışma alanında YSH için %52,74 oranında optimum alan tespit edilmiştir. Bu oran (Adham ve diğerleri, 2018) tarafından yapılan ve benzer coğrafi özelliğe sahip bölgeler ile karşılaştırıldığında yüksek bir orandır. (Al-Adamat, Diabat ve Shatnawi, 2010) optimum alanları daha düşük oranlarda belirlemiştir. Bu durum çalışma alanlarının farkı topografik ve iklimsel özelliklerde olmasından kaynaklanabilir. Bu çalışmada optimum alanlar özellikle tarım arazilerinde yoğunlaşmıştır. Bu bulgu (Dile vd., 2013 tarafından yapılan çalışma ile benzer sonuçlar üretmiştir. Optimum

alanların TCI ve VHI kuraklık indeksleri ile ilişkisinde negatif yönlü zayıf bir korelasyon üretmesi kurak ve yarı kurak bölgelerdeki (Vohland ve Barry, 2009) tarafından yapılan çalışmalara ile kısmın uyumludur. Ancak (Dervash ve Wani, 2022) YSH alanları ile kuraklık indeksleri arasında daha güçlü bir negatif korelasyon tespit etmiştir. Bu durum çalışılan bölgelerin nem, yağış rejimi veya toprak özelliklerinin farklı olmasından kaynaklanabilir.

**SONUÇ**

Bu çalışma YSH için optimum alan belirlemede literatürdeki benzer çalışmalarla tutarlı sonuçlar üreterek AHP yönteminin bu alandaki etkinliğini ispatlamıştır. Özellikle yağış ve akış potansiyeli gibi iklim verilerinin ağırlıklı faktörler olması benzer çalışmalar ile uyumludur. Ancak kuraklık indekslerinin YSH alanları zayıf ilişki göstermesi Demirci ilçesinin iklim özelliklerinin özgünlüğünden kaynaklıdır. Elde edilen sonuçlar benzer özellikteki coğrafyalarda yapılacak su yönetimi stratejilerine katkı sağlayacaktır. Gelecek çalışmalarda makine öğrenmesi ve derin öğrenme gibi dinamik modelleme tekniklerinin kullanılması, farklı iklim ve kuraklık parametrelerinin test edilmesi önerilmektedir.

**KAYNAKÇA**


Adham, A., Sayl, K. N., Abed, R., Abdeladhim, M. A., Wesseling, J. G., Riksen, M., & Ritsema, C. J. (2018). A GIS-based approach for identifying potential sites for harvesting rainwater in the Western Desert of Iraq. International Soil and Water Conservation Research, 6(4), 297-304. doi:10.1016/J.ISWCR.2018.07.003

Al-Adamat, R., Diabat, A. & Shatnawi, G. (2010). Combining GIS with multicriteria decision making for siting water harvesting ponds in Northern Jordan. Journal of Arid Environments, 74(11), 1471-1477. doi:10.1016/J.JARIDENV.2010.07.001

Ammar, A., Riksen, M., Ouessar, M. & Ritsema, C. (2016). Identification of suitable sites for rainwater harvesting structures in arid and semi-arid regions: A review. International Soil and Water Conservation Research, 4(2), 108-120. doi:10.1016/J.ISWCR.2016.03.001

Bento, V. A., Gouveia, C. M., DaCamara, C. C. & Trigo, I. F. (2018). A climatological assessment of drought impact on vegetation health index. Agricultural and Forest Meteorology, 259, 286-295. doi:10.1016/J.AGRFORMET.2018.05.014

Dervash, M. A. & Wani, A. A. (2022). Climate change alleviation for sustainable progression. CRC Press.

Dile, Y. T., Karlberg, L., Temesgen, M. & Rockström, J. (2013). The role of water harvesting to achieve sustainable agricultural intensification and resilience against water related shocks in sub-Saharan Africa. Agriculture, Ecosystems & Environment, 181, 69-79. doi:10.1016/J.AGEE.2013.09.014

Hassan, W. H., Mahdi, K. & Kadhim, Z. K. (2025). GIS-based multi-criteria decision making for identifying rainwater harvesting sites. Applied Water Science, 15(3), 45. doi:10.1007/s13201-025-02378-5

Kogan, F. N. (1995). Droughts of the late 1980s in the United States as derived from NOAA polar-orbiting satellite data. Bulletin of the American Meteorological Society, 76(5), 655-668.

Mishra, S. K. & Singh, V. P. (2013). Soil conservation service curve number (SCS-CN) methodology (C. 42). Springer Science & Business Media.

Muratoglu, A. (2020). Grey water footprint of agricultural production: An assessment based on nitrogen surplus and high-resolution leaching runoff fractions in Turkey. Science of The Total Environment, 742, 140553. doi:10.1016/J.SCITOTENV.2020.140553

Özben, O. M. & Güngör, M. (2024). Denizli Serinhisar ilçesi havzasında yağmur suyu hasadına uygun bölgelerin belirlenmesi. Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 30(5), 668-678. doi:10.5505/pajes.2023.85616

Radwan, F. & Alazba, A. A. (2023). Suitable sites identification for potential rainwater harvesting (PRWH) using a multi-criteria decision support system (MCDSS). Acta Geophysica, 71(1), 449-468. doi:10.1007/s11600-022-00895-4

Saaty, T. L. (1977). A scaling method for priorities in hierarchical structures. Journal of mathematical psychology, 15(3), 234-281.

Vohland, K. & Barry, B. (2009). A review of in situ rainwater harvesting (RWH) practices modifying landscape functions in African drylands. Agriculture, Ecosystems & Environment, 131(3-4), 119-127. doi:10.1016/J.AGEE.2009.01.010

Demirci Belediyesi, (2025). Demirci Hakkında, Manisa [Erişim tarihi: 15.05.2025], https://www.demirci-bld.gov.tr/cografi-konumu.aspx


© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Uydu Görüntülerinde Gemi Tespiti için Bölge Tabanlı CNN Modellerinin Karşılaştırılması

**Nuri Erkin Öçer**[*1], **Uğur Avdan**[1]

[1]*Eskişehir Teknik Üniversitesi, Yer ve Uzay Bilimleri Enstitüsü, Eskişehir, Türkiye*

**Anahtar Kelimeler**
Derin Öğrenme
Gemi Tespiti
R-CNN
Uydu Görüntüleri
Uzaktan Algılama

**ÖZET**

Son on yılda derin öğrenmeye dayalı teknikler görüntülerde nesne tespitinde önemli ilerlemeler sağlamıştır. Bilgisayarlı Görü alanında geliştirilen bu araçlar Uzaktan Algılama alanında da geniş uygulama alanı bulmaktadır. Bunlardan biri olan bölge-tabanlı konvolüsyonel sinir ağı (R-CNN) tekniği, uzaktan algılama görüntülerindeki birçok nesneyi yüksek doğrulukla tespit etmek üzere kullanılmıştır. Bunun yanında, giderek artan mekânsal çözünürlükleriyle uydu görüntüleri, tespit edilmesi daha önceden imkansız olan birçok nesne için artık önemli bir veri kaynağı haline gelmiş durumdadır. Bu araştırmada bölge-tabanlı nesne tespit algoritmalarından olan Faster R-CNN ve Mask R-CNN modelleri kullanılarak optik uydu görüntülerinde gemi tespiti konusu ele alınmıştır. Çalışmanın amacı bu iki modelin gemi tespit performansını karşılaştırmak, birbirlerine göre avantajlı yönlerini ortaya koymak ve tespit kısıtlarını gözlemlemektir. Çalışmada ayrıca farklı derinlikteki özellik çıkarım ağlarının ve çeşitli sentetik veri artırma yöntemlerinin tespitler üzerindeki etkileri incelenmiştir. Bu amaçlar doğrultusunda, 1 metre mekânsal çözünürlüklü 9714 adet uydu görüntüsünde gemiler etiketlenerek veri setleri oluşturulmuştur. Test görüntülerindeki tespitlerde $F1_{\text{Mask R-CNN}}$= 0,9024 ve $F1_{\text{Faster R-CNN}}$=0,8427 olmuştur. Mask R-CNN özellikle küçük gemilerin tespitinde Faster R-CNN'den daha başarılı olmuştur. Her iki yöntem de açık sularda bile olsalar birbirlerine yakın konumlanmış gemilerin tespitinde hatalar yapmış ancak karasal yapılardan kaynaklı az sayıda yanlış alarm üretmiştir.

# Comparison of Region-Based CNN Models for Ship Detection in Satellite Imagery

**Keywords**
Deep Learning
R-CNN
Remote Sensing
Satellite Images
Ship Detection

**ABSTRACT**

In the last decade, techniques based on deep learning have made significant advances in object detection in images. These tools, developed in the field of Computer Vision, are finding wide application in Remote Sensing. One of them, the region-based convolutional neural network (R-CNN) technique, has been used to detect many objects in remote sensing images with high accuracy. In addition, with their increasing spatial resolution, satellite imagery has become an important source of data for many objects that were previously impossible to detect. In this research, the issue of ship detection in optical satellite imagery is addressed using Faster R-CNN and Mask R-CNN models, which are region-based object detection algorithms. The aim of the study is to compare the ship detection performance of these two models, to reveal their advantages over each other and to observe their detection constraints. The study also examines the effects of different depth feature extraction networks and various synthetic data augmentation methods on the detections. For these purposes, datasets were created by labeling ships in 9714 satellite images with 1-meter spatial resolution. $F1_{\text{Mask R-CNN}}$=0.9024 and $F1_{\text{Faster R-CNN}}$=0.8427 for the detections in the test images. Mask R-CNN was more successful than Faster R-CNN especially in detecting small vessels. Both methods made errors in the detection of ships located close to each other, even in open waters, but the number of false alarms due to land-based structures remained low.

## 1. GİRİŞ

* **Sorumlu Yazar**

*(neocer@eskisehir.edu.tr) ORCID ID 0000-0001-7404-7686
(uavdan@eskisehir.edu.tr) ORCID ID 0000-0001-7873-9874

**Kaynak Göster (APA):**

Öçer & Avdan (2025). Uydu Görüntülerinde Gemi Tespiti için Bölge Tabanlı CNN Modellerinin Karşılaştırılması, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

Uzaktan algılama görüntülerinde gemi tespiti ülke karasularının güvenliği, liman yönetimi, deniz taşımacılığı ve insani kurtarma faaliyetleri gibi birçok alanda kendine yer bulan bir görevdir. Son yıllarda, mekânsal çözünürlükleri giderek artan uydu görüntüleri bu konu için önemli bir veri kaynağı haline gelmiştir. Bunun yanında, makine öğrenimi ve özellikle derin öğrenmeye dayalı geliştirilen yeni algılama modelleri görüntülerde nesne tespiti konusunda insan kabiliyetlerini geride bırakmış ve bu modeller uzaktan algılama görüntülerindeki nesnelerin tespiti için başarıyla uyarlanmıştır. Bu açıdan, uydu görüntüleri ve derin öğrenmeye dayalı modellerin bir arada kullanılması gemi tespiti konusunda önemli bir fırsat sağlamaktadır.

Güncel nesne tespit modellerinin çoğu makine öğrenimine dayanmaktadır. Bu yöntemde makine, etiketlenmiş verileri kullanarak hedef nesne özelliklerini öğrenmektedir (Hinton & Salakhutdinov, 2006). Bu alanda ortaya konulan toplam kanal özellikleri (ACF) (Zhao vd., 2017), yönlendirilmiş gradyan histogramları (HOG) özelliklerini kullanan DVM sınıflandırması (Han, Zhang, Cheng, Guo ve Ren, 2015), Rastgele Orman Yöntemi (Erdem ve diğerleri, 2018), (Çömert, Matci, & Avdan, 2019), (Türk & Balçık, 2023) ve Viola-Jones algoritması (Hamid, O'Hara ve Tabb, 2014) gibi geleneksel makine öğrenimine dayalı yöntemler uzaktan algılama görüntülerinde nesne tespitinde başarıyla kullanılmıştır. Bununla birlikte, bu ve benzeri algoritmaların en önemli dezavantajı, girdilerin eğitim standardından sapması durumunda hesaplama süresinin üssel olarak artması ve performansın keskin şekilde düşmesidir (Xia, Wan ve Yue, 2011).

Son yıllarda makine öğrenimi dallarından biri olan derin öğrenme yönteminin ve spesifik olarak konvolüsyonel sinir ağlarının (Convolutional Neural Networks-CNN) yardımıyla görüntü sınıflandırması ve nesne tespitinde önemli ilerlemeler sağlanmıştır (Krizhevsky, Sutskever, & Hinton, 2012). İnsanın öğrenme kabiliyetinin makineye uyarlama aracı olarak ele alınabilecek olan CNN, kendisini oluşturan derin sinir ağları ve konvolüsyon sürecinin çalışma biçimi sayesinde eğitiminde kendisine verilen etiketli girdileri mekânsal kaymalardan, biçim bozulmalarından veya ölçek değişikliklerinden belirli ölçüde etkilenmeyecek şekilde öğrenebilmekte ve karşılaştığı yeni veriler için son derece isabetli tahminler üretebilmektedir (Cheng, Zhou, & Han, 2016).

Özünde bir sınıflandırma aracı olan CNN'ler çeşitli yollarla nesne tespitinde de kullanılmaktadır. Bunlardan bölge-tabanlı CNN (R-CNN) yaklaşımında iki aşamalı bir süreç içerisinde önce görüntüler içerisindeki nesne olma potansiyeli yüksek bölgelere dair öneriler üretilmekte sonrasında bunlar kullanılarak görüntüdeki aday nesneler için sınıflandırma ve sınırlayıcı kutu (konum) tahminleri üretilmektedir. Bu türün örneklerinden olan Faster R-CNN (Ren, He, Girshick, & Sun, 2016) ve Mask R-CNN (He, G., Dollar, & Girshick, 2018) uzaktan algılama görüntülerinde birçok türde nesnenin tespiti için kullanılmıştır (Ocer, ve diğerleri, 2020), (Akar, ve diğerleri, 2024). Diğer bir yaklaşım ise nesne tespitini bir regresyon problemi olarak ele alan ve sınırlayıcı kutuların koordinatlarını ve sınıf olasılıklarını CNN'leri kullanarak doğrudan görüntü özelliklerinden tahmin eden YOLO (You Only Look Once) (Redmon, Divvala, Girshick, & Farhadi, 2016) ve SSD (Single Shot MultiBox Detector) (Liu ve diğerleri, 2016) gibi modellerin dâhil olduğu tek-kademeli, bölge öneri ağına ihtiyaç duymayan yöntemlerdir. Çeşitli varyantlarıyla YOLO, uzaktan algılamada nesne tespitinde kendine çokça yer bulmaktadır (Biyik, Atik, & Duran, 2023). CNN temelli bir diğer tespit aracı ise aslen bir segmentasyon modeli olan U-Net'dir. Bu model de çeşitli nesnelerin algılanmasında kullanılmıştır (Erdem & Avdan, 2020).

Uydu ve hava görüntülerinde nesne tespiti için gerçekleştirilen çalışmaların çoğunda, küçük boyutlu hedefler için yüksek performansları nedeniyle bölge-tabanlı CNN'ler kullanılmaktadır. Bu türün ilk örneği olan R-CNN (Girshick, Donahue, Darrell, & Malik, 2014) yönteminde, görüntüde yer alan olası nesneler için aday kutuların üretilmesi öğrenmeyi içermeyen yollarla, örneğin Seçmeli Arama (Uijlings, Sande, Gevers, & Smeulders, 2013) veya EdgeBox (Dollár & Zitnick, 2014) gibi araçlar kullanılarak gerçekleştirilmektedir. SPP-net (He K. Z., 2015), Fast R-CNN (Girshick, Fast R-CNN, 2015), Faster R-CNN ve Mask R-CNN gibi sonraki çalışmalarda aday bölgelerin belirlenmesi ve özellik çıkarımının tamamı konvolüsyonel katmanlar aracılığıyla gerçekleştirilmektedir. Böylelikle, R-CNN yönteminden farklı olarak, diğer bahsi geçen yöntemlerde konvolüsyon işleminin her aday bölge için tekrar edilmesi gerekliliği ortadan kalkmıştır. Fast, Faster ve Mask R-CNN yöntemlerinde, önerilen nesne konumlarının düzeltilmesi için ayrıca bir regresyon öğrenmesi de uyarlanmıştır. Fast R-CNN yöntemine, bölgeleri daha yüksek doğrulukta ve hızda önermek üzere bölge öneri ağının eklenmesiyle Faster R-CNN yöntemi geliştirilmiş ve kendinden önceki tüm modellerden daha hızlı ve doğru sonuçlar elde edilmiştir. Mask R-CNN ise Faster R-CNN mimarisi üzerine inşa edilmiş bir yapı olup görüntüler üzerindeki nesneleri sınırlayıcı kutular yerine maskelerle işaretlemek üzere tasarlanmıştır. Bu yöntemde ayrıca ilgi bölgesi hizalaması kullanılarak nesnelerin konumlarının kendinden önceki yöntemlere göre daha doğru bir şekilde belirlenmesini sağlanmıştır.

Uydu görüntülerinde nesne tespiti alanındaki güncel çalışmaların büyük çoğunluğunda Faster R-CNN yöntemi tercih edilmiştir (Yang, ve diğerleri, 2018), (Liu, Kuang, & Li, 2017), (Gao, He, Sun, Jia, & Zhang, 2019), (Tayara & Chong, 2018), (Bakırman & Sertel, 2023). Bu yöntemde nesne çıkarımları ve etiketlemeleri dik sınırlayıcı kutularla yapılmaktadır (Şekil 1.a). Nesneler; alt ve üst, sağ ve sol uç sınırlarını içine alan dikdörtgen kutularla işaretlenmektedir. Bu yöntemde nesneyle beraber nesneye ait olmayan arka plan bölgeleri de kaçınılmaz olarak işaretli alan içerisinde kalmaktadır. Nesnelere dair çıkarılan özellikleri etkileyen bu sorunu hafifletmek adına önerilen bir yaklaşımda (Yang, ve diğerleri, 2018), (Gao, He, Sun, Jia, & Zhang, 2019), görüntülerdeki nesnelerin dönük sınırlayıcı kutularla işaretlenmesi önerilmiştir (Şekil 1.b). Mask R-CNN'de ise işaretleme, nesne sınırlarına göre çizilen maskeler vasıtasıyla yapılmaktadır (Şekil 1.c).

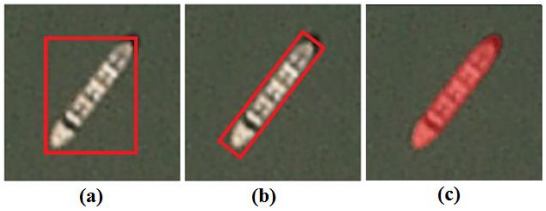


**Şekil 1.** Görüntüdeki bir geminin; a) dik sınırlayıcı kutu, b) dönük sınırlayıcı kutu, c) maske ile işaretlenmesi

Bu çalışmada, uydu görüntülerinde yer alan gemilerin tespiti bölge-tabanlı nesne tespit algoritmalarından olan Faster R-CNN ve Mask R-CNN yöntemleriyle karşılaştırmalı olarak ele alınacaktır. Bünyesinde barındırdığı özellik piramit ağı, ilgi bölgesi hizalaması ve nesnelerin maskeyle işaretlenmesi ile Mask R-CNN'nin gemi tespitine dair çalışmalarda sıklıkla kullanılan Faster R-CNN'e göre performansının değerlendirilmesi ve bu iki yöntemin birbirine göre avantaj ve dezavantajlarının ortaya konulması hedeflenmektedir. Elde edilen tespit sonuçları çeşitli metrikler kullanılarak değerlendirilecek ve modellerin başarılı ve başarısız olduğu durumlar tartışılacaktır. Ayrıca, özellik çıkarımında farklı omurga ağlarının ve çeşitli veri artırım tekniklerinin tespit sonuçları üzerindeki etkileri incelenecektir.

## 2. YÖNTEM

Bu çalışmada izlenen akış süreci Şekil 2'de gösterilmektedir. Ham görüntülerden başlayan süreçte öncelikle içeriklerdeki gemiler işlenip etiketlenerek eğitim, doğrulama ve test veri kümeleri oluşturulmuştur. Ardından, eğitim ve doğrulama (validasyon) kümeleri kullanılarak modeller eğitilmiş ve test görüntülerindeki gemilerin tespiti ile süreç tamamlanmıştır. Bu bölümde sırasıyla çalışmada kullanılan verilere, tespit modellerine ve eğitimlerine ilişkin detaylara ve tespit değerlendirme metriklerine yer verilmektedir.

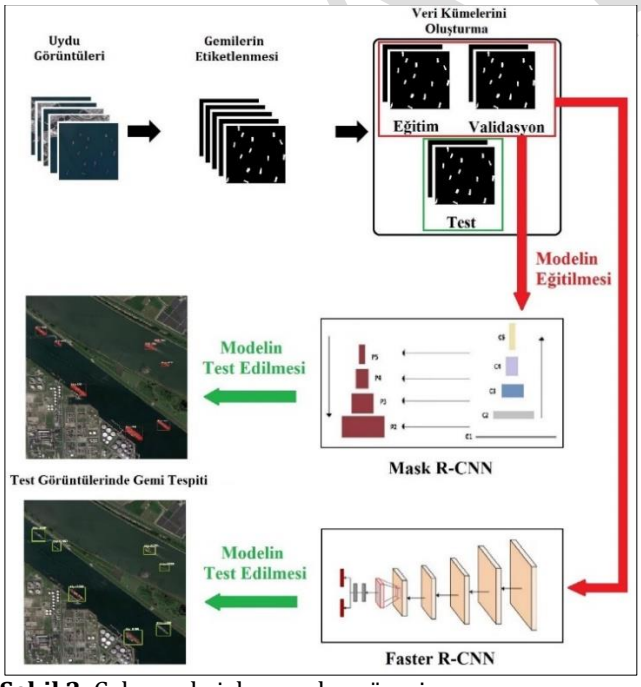


**Şekil 2.** Çalışmada izlenen akış süreci

### 2.1. Veri

Çalışmada kullanılan veriler Google Earth tarafından sağlanan 1 metre mekânsal çözünürlüklü, geotif formatındaki RGB uydu görüntüleridir. Görüntüler SAS Planet yazılımı aracılığıyla indirilmişlerdir. İçeriklerinde sivil limanlar, askeri üsler, açık sular, iç sular gibi çeşitli alanlardan gemi içeren sahneler bulunmaktadır. Görüntüler, modellerde işlenebilir hale getirilmek üzere 768x768 piksel büyüklüğünde toplam 9714 parçaya ayrılmıştır. Bunlar kullanılarak eğitim, validasyon ve test veri kümeleri oluşturulmuştur. Görüntülerin içerisindeki toplam 17911 gemi QGIS yazılımı kullanılarak sayısallaştırılmış, bunlar için poligonlar (maskeler) ve sınırlayıcı kutular oluşturulmuştur (Tablo 1).

**Tablo 1.** Veri kümelerindeki görüntü ve gemi sayıları

| | Eğitim Kümesi | Validasyon Kümesi | Test Kümesi | Toplam |
|---|---|---|---|---|
| Görüntü Sayısı | 6217 | 1727 | 1770 | 9714 |
| Gemi Sayısı | 11534 | 3197 | 3180 | 17911 |

### 2.2. Tespit Modelleri

Uydu görüntülerinde yer alan gemilerin tespiti için bu çalışmada Faster R-CNN ve Mask R-CNN modelleri kullanılmıştır. Bir girdi görüntüsü bu modellerde Şekil 3'te gösterilen aşamalardan geçerek işlenmektedir. Faster R-CNN çıktı olarak gemileri sınırlayıcı kutularla işaretlemekte ve her bir sınırlayıcı kutunun gemi olma olasılığını hesaplamaktadır. Mask R-CNN ise bunlara ilave olarak sınırlayıcı kutularla tespiti yapılan gemilerin her biri için maske de üretmektedir.

Bölge önerisine dayalı nesne tespit algoritmaları olan bu iki model şu modüllerden oluşmaktadır:

1. Özellik çıkarım ağı,
2. Bölge öneri ağı,
3. Önerilerin işlenmesi,
4. Bölge-tabanlı Konvolüsyonel Sinir Ağı.

Bu aşamalar Faster R-CNN'de ve Mask R-CNN'de farklı şekilde ele alınmaktadır.

Özellik çıkarımı Faster R-CNN'de CNN tabanlı bir omurga ağ (ResNet, VGG gibi), Mask R-CNN'de ise Özellik Piramit Ağı (Feature Pyramid Network – FPN) tarafından gerçekleştirilmektedir. FPN, özellik çıkarım ağındaki yüksek çözünürlüklü ancak sığ semantik değere sahip katman özelliklerini semantik değeri yüksek derin katman özellikleriyle kaynaştırmaktadır.

Bölge Öneri Ağı'nda (Region Propasal Network - RPN) ise oluşturulan özellik haritaları kullanılarak görüntüde nesne olması muhtemel bölgeler önerilmektedir. Özellik haritalarında çapaların oluşturulmasıyla başlanıp paralel yürütülen iki konvolüsyon işlemiyle görüntüdeki olası nesneler için sınırlayıcı kutular oluşturulmakta ve bu kutuları görüntüdeki gerçek nesnelere oturtmak üzere konum düzeltme işlemi (regresyon) uygulanmaktadır. Bu süreç, Faster R-CNN'de tek bir özellik haritası üzerinden yürütülürken Mask R-CNN'de FPN'de üretilmiş farklı ölçeklerdeki özellik haritaları kullanılmakta ve önerilen RoI'nin boyutuna bağlı olarak, özellik yamalarını çıkarmak için en uygun ölçekteki özellik haritası katmanı seçilmektedir. Diğer bir değişle,

Faster R-CNN'den farklı olarak nesne önerileri tek bir özellik haritasından değil, önerilen nesnenin büyüklüğüne bağlı olarak uygun ölçekteki özellik haritasından çıkarılmaktadır.

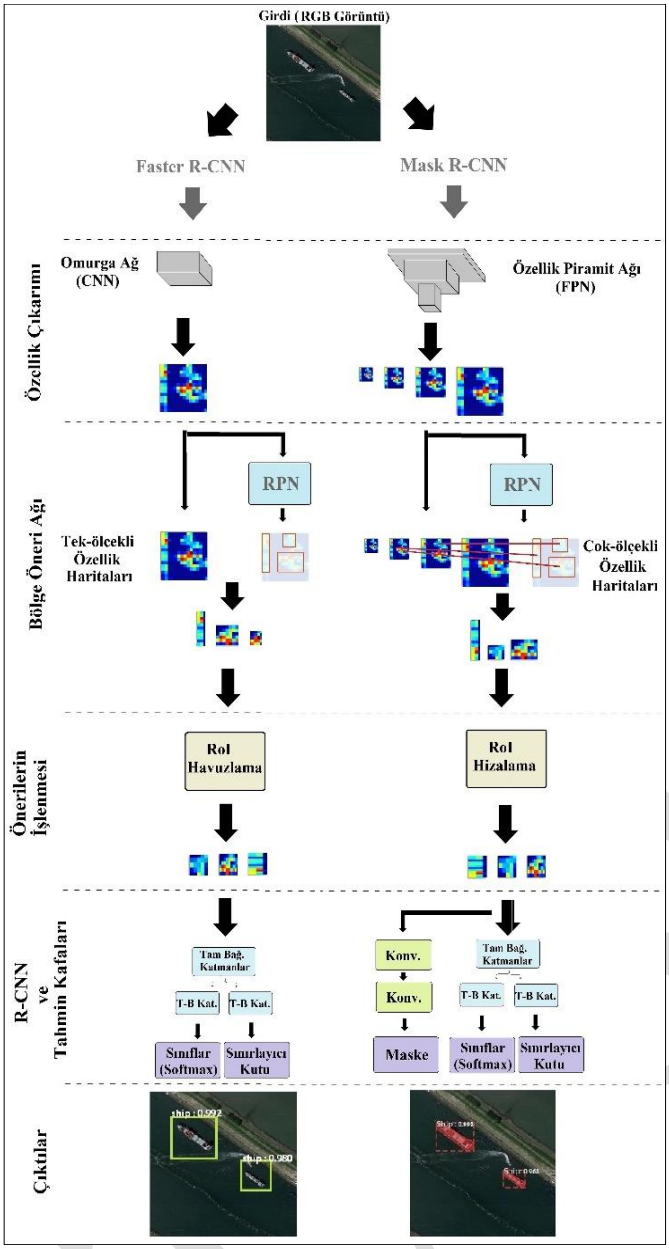


**Şekil 3**. Bir girdi görüntüsünün Faster R-CNN ve Mask R-CNN modellerinde işlenerek içerikteki gemilerin tespit edilmesi süreci

Bölge öneri tabanlı nesne tespit algoritmalarındaki son modülde tam-bağlantılı katmanlar yer almaktadır. Tam-bağlantılı katmanlar ancak büyüklükleri belirli tensörleri işleyebildiğinden bu katman girdilerinin aynı formata getirilmesi gerekmektedir. Bu işlem Faster R-CNN'de, aday nesnelerin görüntüden kesilip çıkarılarak bir havuzda toplanmasıyla gerçekleştirilmektedir (RoI Havuzlama). RoI Havuzlama yönteminde, özellik haritasında nesne için üretilen öneri sınırları, girdi özellik haritasının sınırıyla (pikselleriyle) yeniden hizalanmaya zorlanmaktadır yani sınırlar dijitalleştirilmektedir. Mask R-CNN'de ise hücrelerin sınırını dijitalleştirmeyen RoI Hizalaması (RoI Align) kullanılmakta ve her hedef hücrenin aynı boyutta olması sağlanmaktadır. Ayrıca ilgi bölgesi hücresinin içindeki değerleri daha iyi hesaplamak için enterpolasyon uygulanmaktadır. Orijinal çalışmada (He, G., Dollar, & Girshick, 2018), doğal görüntülerdeki nesne tespitinde RoI Hizalamasının doğruluğu RoI Havuzlamasına göre yüzde yirmiye varan oranda iyileştirdiği belirtilmiştir.

Faster R-CNN ve Mask R-CNN modellerindeki son işlem adımı bölge-tabanlı konvolüsyonel sinir ağıdır (R-CNN). Bu modül, her iki modelde de RPN önerilerinden uygun olanların gemi sınıfına atanmasını ve sınırlayıcı kutuların yer doğruluğuna göre daha düzgün ayarlanmasını sağlamaktadır. Mask R-CNN'de bunlara ilave olarak maskelemenin de model tarafından öğrenilip gerçekleştirilmesini sağlayan bir konvolüsyon dalı eklenmiştir (Şekil 4).

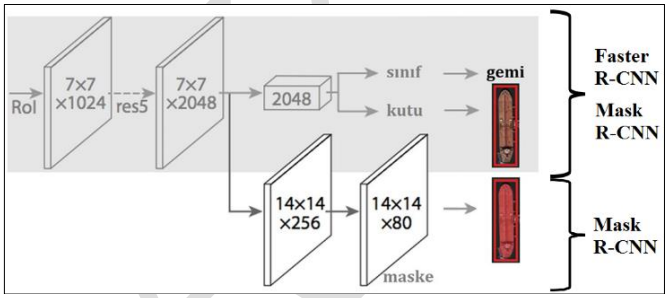


**Şekil 4.** Nesne tespitindeki son modülde Faster R-CNN, öneri bölgeleri için sınıf ve sınırlayıcı kutu tahminleri, Mask R-CNN bunlara ilave olarak nesne maskesi üretmektedir

Böylece, yukarıda ifade edilen dört aşama sonrasında bir girdi görüntüsünden öncelikle özellik haritaları oluşturulmuş sonra RPN ile nesne önerileri çıkarılmış ve bunlar Faster R-CNN'de RoI havuzlaması, Mask R-CNN'de RoI hizalaması vasıtasıyla aynı formata getirilerek tam-bağlantılı katmanları da içeren R-CNN modülünde işlenmeye hazır hale getirilmiştir. Son olarak R-CNN modülüyle görüntüdeki nesnelerin konumlarıyla beraber tespiti gerçekleştirilmektedir.

### 2.3. Modellerin Eğitimi

Bu çalışmadaki deneylerin Faster R-CNN ile alakalı kısımlarında Henon'un (2017) ve Mask R-CNN ile alakalı olanlarında Waleed'in (2017) Tensorflow ve Keras derin öğrenme çerçevelerinde çalışan GitHub uyarlamaları kullanılmıştır. Modeller uçtan-uca eğitilmiştir. Faster R-CNN'de ikisi RPN için ve ikisi R-CNN için olmak üzere 4 farklı kayıp fonksiyonu, Mask R-CNN'de ise bunlara ilave olarak R-CNN modülünde maske kayıp fonksiyonu tanımlıdır. Modeller, takvimi Tablo 2'de verilen ve başlangıç değeri 0,001 olan öğrenme oranı kullanılarak toplamda 80 bin iterasyonda eğitilmiştir. Eğitimde 0,0001'lik bir ağırlık bozunumu (weight decay) ve 0,9'luk momentum değerleriyle momentumlu stokastik gradyan iniş yöntemi ve geri-yayılım algoritması kullanılmıştır.

**Tablo 2.** Eğitimde kullanılan öğrenme oranının turlara göre değişim takvimi

| Tur Sayısı | Öğrenme Oranı |
|---|---|
| 1-2 | lr x 2 |
| 3-4 | lr |

| | |
|---|---|
| 15-24 | lr/2 |
| 25-34 | lr/4 |
| 35-40 | lr/6 |
| 41-50 | lr/8 |
| 51-60 | lr/10 |
| 61-70 | lr/12 |
| 71-80 | lr/15 |
| 81-90 | lr/20 |
| 91-100 | lr/25 |

*lr = 0.001*

Modellerde omurga ağ olarak ResNet-50 ve ResNet-101 kullanılmıştır. Ağ ağırlıkları, bu modellerin Common Objects in Context (COCO) veri seti kullanılarak ön-eğitim almış değerleriyle başlatılmıştır. RPN aşamasında, mini-yığınların eğitimi için toplamda 512 çapa örneklenmiş ve R-CNN'e 256 öneri gönderilmiştir. Pozitif örneklerin negatiflere oranı 1:3'tür. Tespitin yer doğruluğu kutusuyla olan kesişim/birleşim oran eşiği (Intersection over Union - IoU) olarak 0,5 kullanılmıştır yani bir RoI, yer doğruluğuyla en az 0,5'lik bir IoU'ya sahipse doğru tespit, değilse yanlış tespit olarak kabul edilmiştir. Maske kaybı yalnızca doğru tespitler için tanımlanmıştır. Çapa büyüklükleri {8, 16, 32, 64, 128} ve adım sayıları {4, 8, 16, 32, 64} olarak tanımlanmıştır. Her büyüklükteki çapa kutuları için üç farklı en boy oranı {1:1, 1:2, 2:1} kullanılmıştır.

Ağların eğitilmesinde veri artırımına da başvurulmuştur. Veri artırımı, eğitim veri kümesindeki her örnek görüntüden yapay olarak değiştirilmiş yeni görüntüler oluşturma işlemidir. Bu teknik, eğitim verisi miktarının artırılmasını sağlamakta ve veri sayısının az + ağdaki parametre sayısının fazla olduğu durumlarda karşılaşılan aşırı-uyumu (over-fitting) önlemekte ve tespit performansını artırmayı sağlamaktadır. Bunun için çalışmada farklı görüntü işleme yöntemleriyle artırılmış veri setleri oluşturulmuş ve bunlarla eğitilen modelin tespit performansları karşılaştırılmıştır. Çalışmada orijinal görüntülere; (1) 90 veya 270 derecelik döndürme, (2) yukarı-aşağı veya sağ-sol döndürme, (3) parlaklığı veya kontrastı yüzde 10 artırma veya azaltma ve (4) keskinliği veya bulanıklığı yüzde 10 artırma işlemleri ve bunların çeşitli kombinasyonları uygulanmıştır.

Deneyler, Ubuntu 16.04 işletim sisteminde Intel i7-6850k işlemcili, 64 GB RAM'e sahip, Nvidia GeForce GTX 1080 Ti ekran kartlı bir bilgisayarda gerçekleştirilmiştir.

### 2.4. Tespit Değerlendirme Metrikleri

Bu çalışmada tespit performansı kesinlik, geri getirme, F1-skoru ve keskinlik-geri getirme eğrileri kullanılarak değerlendirilmektedir. Bu metrikler vasıtasıyla tespit performansı sadece doğru tespitlerle (True positives - TP) değil, üretilen yanlış alarmlar (False Positives - FP) ve gözden kaçan nesneler (False Negatives - FN) de göz önüne alınarak hesaplanmaktadır. Kesinlik, geri getirme ve F1 skoru sırasıyla şöyle tanımlıdır:

$$Kesinlik = \frac{TP}{TP+FP} \quad (1)$$

$$Gerigetirme = \frac{TP}{TP+FN} \quad (2)$$

$$F1 = 2 \cdot \frac{kesinlik \cdot gerigetirme}{kesinlik + gerigetirme} \quad (3)$$

Bu çalışma kapsamında, modellerce üretilen herhangi bir tespit tahmini eğer yer-doğruluğuyla olan IoU değeri 0,5'ten büyükse gerçek doğru (TP), aksi halde yanlış tespit (FP) olarak değerlendirilmiştir.

## 3. BULGULAR

Gerçekleştirilen deneyler neticesinde elde edilen bulgular bu bölümde dört kısım halinde sunulmaktadır. İlk üç kısımda, daha iyi tespitler için en uygun model ve eğitim verisi ayarlamaları incelenmekte, son kısımda ise Faster R-CNN ve Mask R-CNN modellerinin ürettiği sonuçlar karşılaştırmalı olarak sunulmaktadır.

### 3.1. Nesne Güven Eşiğinin Tespitler Üzerindeki Etkisi

Çalışmada öncelikli olarak modellerin R-CNN katmanındaki sınıflandırma tahmin kafasında RPN'den gelen önerilerin nesne olup olmadığını belirlemeye yarayan nesnellik skor eşiği için optimal değeri belirlemeye dönük deneyler yapılmıştır. Gelen öneri için bu kafanın ürettiği skor bu eşiğin altında olduğu takdirde öneri "arka plan" olarak görülmekte, üstünde olduğu takdirde "gemi" olarak atanmaktadır. Yapılan deneylerde bu eşik 0'dan başlatılarak 0,1'lik adımlarla artırılmıştır. Farklı güven eşiklerindeki geri-getirme, kesinlik, F1 skoru ve IoU değerlerinin değişimi Şekil 5'te gösterilmiştir. Sonuçlara göre optimal güven eşiği, en yüksek F1-skorunu veren 0,5 değeri olmuştur. Eldeki veri seti için doğru tespitler ve yanlış alarmlar arasında en dengeli tespit sonuçları bu değerle sağlanmıştır. Eşik değeri olarak 0,5 kullanıldığında Mask R-CNN'nin ürettiği doğru tespitler yer-doğruluklarıyla yüzde 75 oranında çakışmıştır (IoU=0,75). Deneylerin kalan kısmında her iki model için de nesne güven eşiği olarak 0,5 kullanılmıştır.

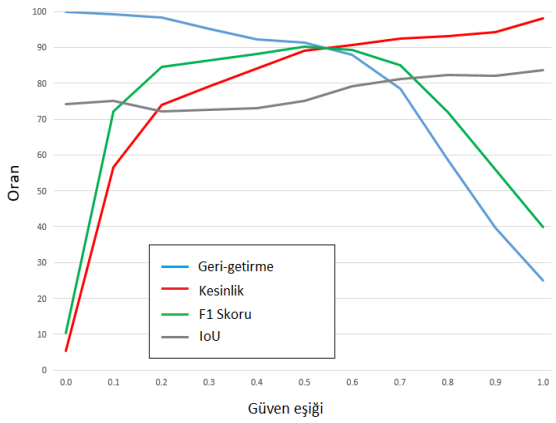


**Şekil 5.** Farklı güven eşikleri için modelin ürettiği tespit metrikleri

### 3.2. Omurga Ağların Tespitler Üzerindeki Etkisi

Deneylerin ikinci kısmında, özellik çıkarıcı olarak farklı derinliklerdeki omurga ağlar kullanılarak Faster R-CNN ve Mask R-CNN modelleri test kümesi üzerinde çalıştırılmıştır. Omurga ağ olarak 50 ve 101 katmandan oluşan ResNet-50 ve ResNet-101 kullanılmıştır.

Toplamda 3180 adet yer-doğruluğunun (geminin) yer aldığı görüntüler için üretilen doğru tespitler, yanlış alarmlar ve gözden kaçan nesneler kullanılarak modellerin geri-getirme, kesinlik ve F1-skorlarına bakılmıştır (Tablo 4). Sonuçlara göre, en yüksek geri-getirme, kesinlik ve F1-skor değerleri, ResNet-101 ile çalıştırılan Mask R-CNN tarafından sağlanmıştır. Faster R-CNN'den farklı olarak bünyesinde Özellik Piramit Ağı, RoI hizalama katmanı ve maske tahmin kafasını içeren bu model F1-skorunu yaklaşık 6 puan (yüzde 7) artırmıştır. Her iki model için de 101-katmanlı ResNet-101 50-katmanlı muadiline göre daha iyi tespitler üretmiştir. Diğer yandan bu modeller ve ağlar için görüntü başına harcanan işlem zamanlarına bakıldığında, kullanılan Mask R-CNN uyarlamasının Faster R-CNN'e göre neredeyse iki kat hızlı çalıştığı ve iki model için de daha derin omurga ağ kullanımının işlem zamanını artırdığı görülmektedir.

**Tablo 4.** Faster R-CNN ve Mask R-CNN'nin farklı omurga ağlarla test kümesi üzerindeki tespit performansı

| Yöntem (R-CNN) | FPN | RoI Hiz | İşlem Süresi (s) | TP | FP | Geri Get. (%) | Kesinlik (%) | F1 (%) |
|---|---|---|---|---|---|---|---|---|
| Faster (ResNet101) | X | X | 0,238 | 2674 | 492 | 84,1 | 84,5 | 84,2 |
| Faster (ResNet50) | X | X | 0,226 | 2591 | 464 | 81,5 | 84,8 | 83,1 |
| Mask (ResNet101) | √ | √ | 0,131 | 2904 | 352 | **91,3** | **89,2** | **90,2** |
| Mask (ResNet 50) | √ | √ | 0,124 | 2878 | 364 | 90,5 | 88,8 | 89,6 |

### 3.3. Veri Artırımının Tespitler Üzerindeki Etkisi

Bu bölümde eğitim kümesindeki görüntülere farklı yollarla uygulanan dönüşümler neticesinde oluşturulan artırılmış veri setleriyle eğitilen modelin tespit performansı incelenmiştir. Deneylerde dört temel görüntü işleme yöntemi ve bunların çeşitli kombinasyonları kullanılarak toplam 9 adet artırılmış veri seti oluşturulmuştur (Tablo 5). Tablo 6'da bu setlerle eğitilmiş modelin tespit sonuçları verilmiştir. Görüldüğü üzere uygulanan her artırım yöntemi sonuçlarda iyileşme sağlamıştır. En iyi sonuç, modelin dört görüntü dönüşümünün beraber uygulanmasıyla oluşturulan AVS9 setiyle aldığı eğitimle sağlanmıştır. Eğitimde sadece ham görüntülerin kullanıldığı model, 3180 geminin yer aldığı test verisi için 2904 doğru tespitte bulunurken AV9 setiyle eğitilen model 3024 gemiyi doğru tespit etmiştir. Yanlış alarm sayısı da 352'den 279'a düşmüştür. Modelin F1-skoru %90,24'ten %93,29'a yükselmiştir.

**Tablo 5.** Artırılmış veri setleri ve bunlarda görüntülere uygulanan işlemler

| Artırılmış Veri Seti | Görüntüye Uygulanan İşlem |
|---|---|
| AVS 1 | 90 veya 270 derecelik döndürmeden biri |
| AVS 2 | Yukarı-aşağı veya sağ-sol döndürme |
| AVS 3 | Parlaklık veya kontrastan birinin yüzde 10 artırılması veya azaltılmasından biri |
| AVS 4 | Keskinliğin veya bulanıklığın yüzde 10 artırılmasından biri |
| AVS 5 | AVS 1 + AVS 2 |
| AVS 6 | AVS 2 + AVS 3 |
| AVS 7 | AVS 2 + AVS 4 |
| AVS 8 | AVS 2 + AVS 3 + AVS 4 |
| AVS 9 | AVS 1 + AVS 2 + AVS 3 + AVS 4 |

**Tablo 6.** Farklı artırma yöntemleriyle oluşturulmuş veri kümelerinin kullanılmasıyla eğitilmiş olan Mask R-CNN modelinin test kümesi üzerindeki tespit sonuçları

| Veri Seti | Yer Doğ. | TP | FP | Geri Get. (%) | Kesinlik (%) | F1 (%) |
|---|---|---|---|---|---|---|
| Orijinal | 3180 | 2904 | 352 | 91,32 | 89,2 | 90,2 |
| AVS 1 | 3180 | 2988 | 316 | 93,96 | 90,4 | 92,2 |
| AVS 2 | 3180 | 2986 | 324 | 93,90 | 90,2 | 92,0 |
| AVS 3 | 3180 | 2971 | 336 | 93,43 | 89,8 | 91,6 |
| AVS 4 | 3180 | 2964 | 344 | 93,21 | 89,6 | 91,4 |
| AVS 5 | 3180 | 2984 | 322 | 93,84 | 90,3 | 92,0 |
| AVS 6 | 3180 | 3002 | 296 | 94,40 | 91,0 | 92,7 |
| AVS 7 | 3180 | 2996 | 304 | 94,21 | 90,8 | 92,5 |
| AVS 8 | 3180 | 3006 | 301 | 94,53 | 90,9 | 92,7 |
| AVS 9 | 3180 | 3024 | 279 | **95,09** | **91,6** | **93,3** |

### 3.4. Karşılaştırma: Faster R-CNN - Mask R-CNN

Belirlenen 0,5'lik nesne güven eşiği ve ResNet-101 omurga ağı ile çalıştırılan modeller AVS9 eğitim setiyle eğitilerek test görüntülerinde tespitte kullanılmıştır.

Öncelikle iki model 20 farklı nesne güven eşiği değeriyle çalıştırılarak modellerin kesinlik-geri getirme eğrileri elde edilmiştir (Şekil 6). Y ekseninin kesinliği ve X ekseninin geri-getirmeyi temsil ettiği bu tabloda eğrinin üstte olması daha iyi performansa işaret etmektedir. Mask R-CNN modeli deneylerde kullanılan tüm güven eşiklerinde Faster R-CNN'den iyi sonuçlar üretmiştir.

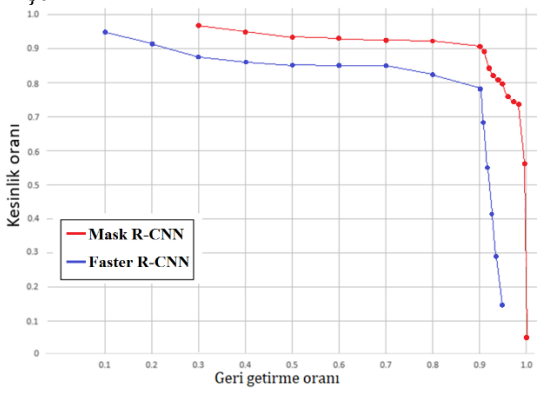


**Şekil 6.** Modellerin farklı nesne güven eşik değerlerinde test verisi için ürettikleri kesinlik-geri getirme eğrileri

Modellerin ürettiği bazı tespit sonuçları Şekil 7 ve Şekil 8'de gösterilmektedir. Herhangi bir kara parçasını içermeyen Şekil 7'deki görüntüde on üç gemi bulunmaktadır. Faster R-CNN bu gemilerden yedisini, Mask R-CNN ise dokuzunu doğru şekilde tespit etmiştir.

Her iki model de birbirine yakın konumlanmış gemiler söz konusu olduğunda gemilerden birini veya birkaçını gözden kaçırma eğilimindedir. Yuvarlak içerisinde yaklaştırılan sahnelerden ilkinde Faster R-CNN yan yana bulunan dört gemiden ancak birini, ikincisinde ise dört gemiden ikisini doğru tespit edebilmiştir. Aynı sahnelerde ise Mask R-CNN ikişer doğru tespit yapmıştır. Ayrıca görüntü içerisindeki küçük bir gemi Mask R-CNN tarafından tespit edilmişken Faster R-CNN'nin gözünden kaçmıştır.

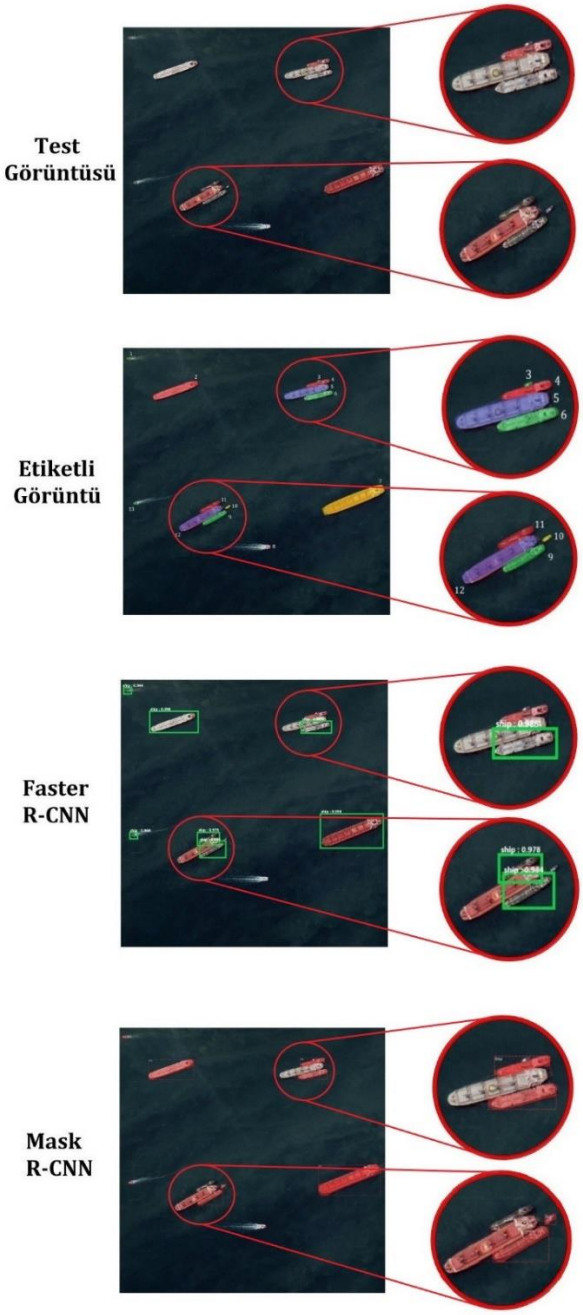


**Şekil 7.** Açık denizde bulunan gemileri içeren bir test görüntüsü ve modellerin bu görüntü için ürettikleri tespitler

Rotterdam'daki bir iç limanda bulunan gemileri içeren bir uydu görüntüsünün yer aldığı Şekil 8'de ise toplam sekiz gemi bulunmaktadır. Faster R-CNN bunlardan yedisini, Mask R-CNN ise tamamını doğru tespit etmiştir. Sahnede yer alan, karaya yanaşmış iki gemi de her iki model tarafından tespit edilmiştir. Faster R-CNN'nin gözünden kaçan tek gemi ise küçük boyutlu bir gemi olmuştur. Büyük oranda karasal alanın yer aldığı bu görüntü için iki model de karada veya denizde herhangi bir yanlış alarm üretmemiştir.

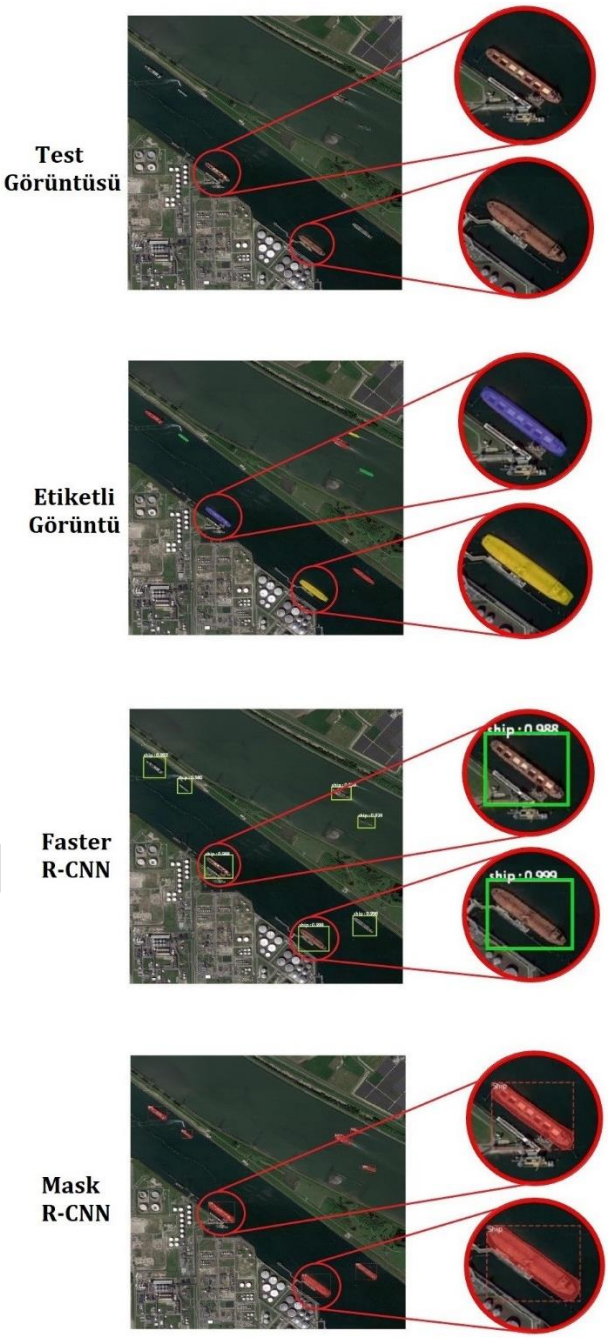


**Şekil 8.** Bir iç limanda bulunan gemileri içeren bir test görüntüsü ve modellerin bu görüntü için ürettikleri tespitler

## 4. TARTIŞMA

Çalışmada bölge-tabanlı iki nesne tespit modeli olan Faster R-CNN ve Mask R-CNN, uydu görüntülerindeki gemileri tespit etmek üzere uyarlanmış, gerekli veri setleri oluşturulmuş ve çeşitli koşullar altında birbirleriyle karşılaştırılmıştır. Sonuçlara göre, bünyesinde barındırdığı Özellik Piramit Ağının, RoI hizalama katmanının ve tahmin kafasında yer alan konvolüsyonel maskeleme dalının katkısıyla Mask R-CNN modeli uydu görüntülerinde gemi tespitinde Faster

R-CNN'e göre daha üstün bir performans göstermiştir. Mask R-CNN'nin tespit işleminde kullanılmasıyla önceki yaklaşımlardan farklı olarak gemiler görüntülerde sınırlayıcı kutulara ilave olarak gerçek görünümlerine daha sadık biçimde maskelerle de işaretlenmişlerdir. Bunun için ödenen bedel ise modeli eğitmekte kullanılan verilerdeki gemilerin daha fazla emek isteyen maske poligonlarıyla işaretlenme zorunluluğu ve dolayısıyla uzayan veri hazırlama süreci olmuştur. Bu modelin FPN'le beraber çalıştırılmasıyla omurga ağın farklı bloklarından gelen semantik açıdan zengin fakat çözünürlüğü düşük özellik haritaları, çözünürlüğü yüksek fakat semantik değeri zayıf olanlarla kaynaştırılmış, böylelikle hem mekânsal çözünürlüğü hem de semantik değeri yüksek haritalar elde edilerek özellikle küçük nesnelerin tespitinde başarı oranı artmıştır. Ayrıca, Mask R-CNN'de RPN'den gelen nesne önerilerinin sınırları RoI hizalaması aracılığıyla dijitalleştirilmeden özellik haritasından çıkarılmış ve işlenmiş bu sayede özellikle konum tespitinde doğruluklar (IoU) artmıştır.

Deneylerde ayrıca, iki model için özellik çıkarımı işlemi ResNet-50 ve ResNet-101 gibi farklı derinliklerdeki omurga ağlarla gerçekleştirilmiştir. Daha derin katman yapısı sayesinde, ResNet-101'in elimizdeki veri seti için daha başarılı bir özellik çıkarıcı olduğu görülmüştür. Ayrıca, verinin sentetik olarak artırılmasının sonuçlar üzerindeki etkisi nicel bir şekilde ele alınmış ve veri seti için farklı görüntü işleme yöntemleri bir arada kullanılmıştır. Çalışmada artırılmış herhangi bir veri setiyle eğitilen modelin, artırılmamış veri setiyle eğitilen modelden daha iyi sonuçlar verdiği görülmüştür. Bunda, eğitilebilir parametre sayısı yüksek olan ResNet ağlarının daha çok sayıdaki veri sayesinde eğitimdeki aşırı-uyumdan uzaklaşmasının etkili olduğu değerlendirilmektedir.

Çalışmada her iki yöntemin de görüntülerdeki gemileri yüksek başarı oranlarıyla tespit etmesine rağmen bazı durumlarda yetersiz kaldıkları gözlenmiştir. Özellikle birbirine yakın gemiler söz konusu olduğunda modellerin hedeflerden bazılarını gözden kaçırdığı veya iki gemiyi tek gemi olarak algıladığı durumlarla karşılaşılmıştır (Şekil 9). Kullandığımız nesne algılama modelleri eğitim safhasında, RPN'de üretilen nesne önerilerinin değerlendirmesini yer-doğruluklarıyla çakışmalarına bakarak yapmaktadır. Burada nesne işaretlemeleri dik sınırlayıcı kutular kullanılarak yapılmaktadır. Nesne haricindeki alanları da bünyesinde barındıran bu temsil yöntemi yukarıda ifade edildiği gibi, birbirine yakın gemilerin algılanması söz konusu olduğunda yanlış tespitlere, gözden kaçmalara sebebiyet vermektedir. Bu sorunun çözümü için (Yang & Sun, 2018)'de nesnenin dönüklük açısıyla yönlendirilmiş, standart dik kutulara göre nesnelere çok daha doğru oturma kabiliyetindeki dönük sınırlayıcı kutuların kullanılması ve hata fonksiyonlarının buna göre tanımlanarak eğitimin ve tespitin gerçekleştirilmesi önerilmiştir.

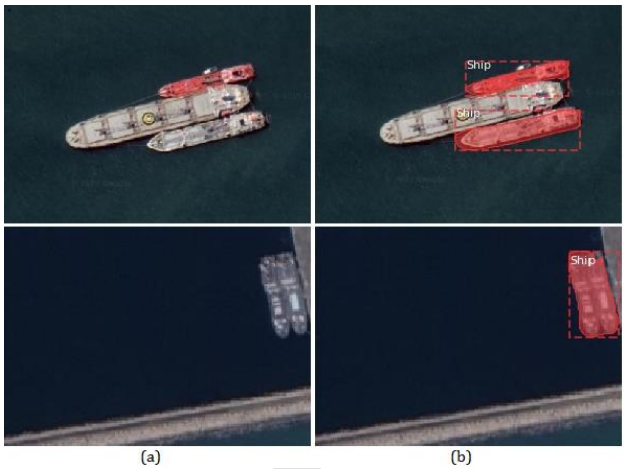


**Şekil 9.** Orijinalleri (a) sütununda verilen görüntüler için modelin ürettiği hatalı tespitler (b) sütununda gösterilmektedir

Hız açısından değerlendirildiğinde çalışmadaki en hızlı model ResNet-50 ile beraber çalıştırılan Mask R-CNN olmuştur. Model saniyede 8 adet *768x768* piksellik görüntüyü işlemiştir. Kullanılan yöntem yüksek tespit performansına karşın bu haliyle gerçek-zamanlı tespitten yani saniyede en az 24 görüntü işlemekten uzaktır. Gerçek-zamanlı gemi tespiti gerektiren uygulamalar için bu iki yöntem bu koşullarda uygun değildir. Bunu sağlayabilmek için girdi görüntüsünün boyutunun küçültülmesi veya bölge öneri ağı içermeyen tek-aşamalı modellerin kullanılması değerlendirilebilir.

## 5. SONUÇ

Bu çalışma kapsamında, uydu görüntülerinde gemi tespiti görevi için bölge-tabanlı iki farklı CNN modelinin performansları Google Earth'den sağlanan görüntülerle oluşturulan veri setleri kullanılarak karşılaştırılmıştır. Elde edilen sonuçlara göre, bünyesinde FPN, RoI hizalama ve maskeleme katmanlarını barındıran Mask R-CNN modeli Faster R-CNN'den yüzde 7 daha yüksek F1-skorunu neredeyse iki kat işlem hızıyla sağlamıştır. Buna rağmen iki yöntemin de mevcut çözünürlük için işlem hızları gerçek-zamanlı tespit için yavaş kalmıştır. Test görüntüleri için üretilen tespitlere göre Mask R-CNN özellikle küçük gemilerin algılanmasında daha iyi bir performans ortaya koymuştur. Sonuçlarda en dikkat çekici kısım, birbirine yakın konumlanmış gemiler söz konusu olduğunda her iki modelin de ya bütün hedefleri tek bir gemi olarak algılaması ya da gemilerden birini veya birkaçını gözden kaçırması olmuştur. Diğer taraftan her iki modelin de karaya yanaşmış gemileri başarılı bir şekilde ayırt etme kabiliyetinde olduğu ve karasal bölgelerden kaynaklı az sayıda hatalı tespit ürettiği görülmüştür. Bunların haricinde, modellerde özellik çıkarıcı olarak farklı derinliklere sahip CNN'ler kullanılmış, daha derin ağların daha iyi sonuç sağladıkları görülmüştür. Ayrıca, modellerin eğitiminde kullanılan veriler çeşitli yollarla işlenerek artırılmış ve artırılan veri setleriyle eğitim alan modellerin daha yüksek başarıma sahip olduğu ortaya konulmuştur.

Gelecek çalışmalarda mevcut sonuçları iyileştirmeye dönük olarak, modellerin RPN safhasındaki nesne işaretlemelerinin standart dik kutular yerine dönük sınırlayıcı kutularla yapılması ve hata fonksiyonlarının

bunlara göre düzenlenerek modellerin iyileştirilmesi ve bunların tespit sonuçlarına etkisinin araştırılması planlanmaktadır.

**TEŞEKKÜR**

Bu çalışma Nuri Erkin Öçer tarafından Eskişehir Teknik Üniversitesi'nde Profesör Dr. Uğur Avdan danışmanlığında yürütülen "Uzaktan Algılama Görüntülerinde Derin Öğrenme Temelli Yaklaşımlar Kullanarak Nesne Tespiti" başlıklı doktora tezinin bir kısmından faydalanılarak yazılmış ve Eskişehir Teknik Üniversitesi BAP Komisyonu tarafından 1707F461 numaralı proje kapsamında desteklenmiştir. Yazarlar destek için teşekkürlerini sunar.

**Araştırmacıların katkı oranı**

**Nuri Erkin Öçer:** Literatür taraması, Yazılım, Deneyler, Makale yazımı; **Uğur Avdan:** Düzenleme, Makale yazımı

**Çatışma Beyanı**

Herhangi bir çıkar çatışması bulunmamaktadır.

**KAYNAKÇA**

Akar, Ö, Saralioğlu, E., Güngör, O., & Bayata, H. F. (2024). Semantic segmentation of very-high spatial resolution satellite images: A comparative analysis of 3D-CNN and traditional machine learning algorithms for automatic vineyard detection. International Journal of Engineering and Geosciences, 9(1), 12-24

Antelo, J., Ambrosio, G., Gonzalez, J., & Galindo, C. (2009, July). Ship detection and recognitionin high-resolution satellite images. In 2009 IEEE International Geoscience and Remote Sensing Symposium (Vol. 4, pp. IV-514). IEEE.

Bakırman, T., & Sertel, E. (2023). A benchmark dataset for deep learning-based airplane detection: HRPlanes. Geomatik, 8(3),212-223.

Biyik, M. Y., Atik, M. E., & Duran, Z. (2023). Deep learning-based vehicle detection from orthophoto and spatial accuracy analysis. International Journal of Engineering and Geosciences, 8(2), 138-145.

Cheng, G., Zhou, P., & Han, J. (2016). Learning rotation-invariant convolutional neural networks for object detection in VHR optical remote sensing images. IEEE Transactions on Geoscience and Remote Sensing, 54(12), 7405-7415.

Çömert, R., Matci, D. K., & Avdan, U. (2019). Object based burned area mapping with random forest algorithm. International Journal of Engineering and Geosciences, 4(2), 78-87.

Erdem, F., Derinpınar, M. A., Nasırzadehdızajı, R., Oy, S., vd. (2018). Rastgele Orman Yöntemi Kullanılarak Kıyı Çizgisi Çıkarımı İstanbul Örneği. Geomatik, 3(2), 100-107. https://doi.org/10.29128/geomatik.362179

Erdem, F., & Avdan, U. (2020). Comparison of Different U-Net Models for Building Extraction from High-Resolution Aerial Imagery. International Journal of Environment and Geoinformatics, 7(3), 221-227. https://doi.org/10.30897/ijegeo.684951

Girshick, R. (2015). Fast r-cnn. In Proceedings of the IEEE international conference on computer vision (pp. 1440-1448).

Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 580-587).

Hamid, R., O'Hara, S., & Tabb, M. (2014). Global-scale object detection using satellite imagery. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 40, 107-113.

Han, J., Zhang, D., Cheng, G., Guo, L., & Ren, J. (2014). Object detection in optical remote sensing images based on weakly supervised learning and high-level feature learning. IEEE Transactions on Geoscience and Remote Sensing, 53(6), 3325-3337.

He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). Mask r-cnn. In Proceedings of the IEEE international conference on computer vision (pp. 2961-2969).

He, K., Zhang, X., Ren, S., & Sun, J. (2015). Spatial pyramid pooling in deep convolutional networks for visual recognition. IEEE transactions on pattern analysis and machine intelligence, 37(9), 1904-1916.

He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 770-778).

Henon, Y. (2017), Keras-rcnn, GitHub, GitHub repository, https://github.com/yhenon/kerasrcnn/tree/master/keras_rcnn/layers.

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. Advances in neural information processing systems, 25.

Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., & Berg, A. C. (2016). Ssd: Single shot multibox detector. In Computer Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part I 14 (pp. 21-37). Springer International Publishing.

Ocer, N. E., Kaplan, G., Erdem, F., Kucuk Matci, D., & Avdan, U. (2020). Tree extraction from multi-scale UAV images using Mask R-CNN with FPN. Remote sensing letters, 11(9), 847-856.

Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 779-788).

Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. Advances in neural information processing systems, 28.

Shi, Z., Yu, X., Jiang, Z., & Li, B. (2013). Ship detection in high-resolution optical imagery based on anomaly detector and local shape feature. IEEE Transactions on Geoscience and Remote Sensing, 52(8), 4511-4523.

Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1-9).

Türk, S. T., & Balçık, F. (2023). Rastgele orman algoritması ve Sentinel-2 MSI ile fındık ekili alanların belirlenmesi: Piraziz Örneği. Geomatik, 8(2), 91-98.

Uijlings, J. R., Van De Sande, K. E., Gevers, T., & Smeulders, A. W. (2013). Selective search for object recognition. International journal of computer vision, 104, 154-171.

Waleed, A. (2017), Mask R-CNN for object detection and instance segmentation on Keras and TensorFlow, GitHub, GitHub repository, https://github.com/matterport/Mask_RCNN

Xia, Y., Wan, S., & Yue, L. (2011, August). A novel algorithm for ship detection based on dynamic fusion model of multi-feature and support vector machine. In 2011 Sixth International Conference on Image and Graphics (pp. 521-526). IEEE.

Zhao, A., Fu, K., Sun, H., Sun, X., Li, F., Zhang, D., & Wang, H. (2017). An effective method based on ACF for aircraft detection in remote sensing images. IEEE Geoscience and Remote Sensing Letters, 14(5), 744-748.

Zhu, C., Zhou, H., Wang, R., & Guo, J. (2010). A novel hierarchical method of ship detection from spaceborne optical image based on shape and texture features. IEEE transactions on geoscience and remote sensing, 48(9), 3446-3456.

Zitnick, C. L., & Dollár, P. (2014). Edge boxes: Locating object proposals from edges. In Computer Vision–ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part V 13 (pp. 391-405). Springer International Publishing.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Uzaktan Algılama Verileri Kullanarak Kentsel Alanlarda Karbon Monoksit Salınımlarının Araştırılması

**Duygu ARIKAN İSPİR**[*1], **Hasan Bilgehan MAKİNECİ**[1]

[1,2]*Konya Teknik Üniversite, Mühendislik ve Doğa Bilimleri Fakülte, Harita Mühendisliği Bölüm, Konya, Türkiye*

**Anahtar Kelimeler**
Hava Kalitesi,
Karbon Monoksit,
Sentinel-5P,
Zamansal Değişim

**ÖZET**

Atmosferdeki çeşitli gazlar, mekânsal hava kalitesini doğrudan etkilemektedir. Bu gazlardan biri olan karbon monoksit (CO), iklim değişikliğine neden olan sera gazları arasında yer almakta ve hem atmosfer kirliliği hem de iklim üzerinde önemli etkilere sahiptir. CO gazının çevresel etkilerinin doğru şekilde değerlendirilebilmesi için düzenli aralıklarla izlenmesi gerekmektedir. Bu çalışmanın amacı, Konya İli Karatay İlçesi sınırlarında bulunan ve turistik yoğunluğu yüksek olan Mevlâna Müzesi ve çevresindeki CO gazı salınımının zamansal değişimini incelemektir. Çalışma kapsamında 2020-2025 yılları arasında dört farklı üç aylık periyotta (Ocak-Mart, Nisan-Haziran, Temmuz-Eylül, Ekim-Aralık) CO yoğunluğundaki değişim, Sentinel-5P uydu verileri kullanılarak analiz edilmiştir. Sonuç olarak, incelenen yıllarda CO salınımında genel bir artış gözlenmiş ve hava kalitesinde anlamlı bir iyileşme tespit edilememiştir. Çalışma kapsamında, 2020-2025 yılları arasında üç aylık periyotlarla (Ocak-Mart; Nisan-Haziran; Temmuz-Eylül; Ekim-Aralık) dört farklı dönemde yaşanan CO miktarının değişimini Sentinel-5P uydu verilerinden faydalanılarak incelenmiştir. Sonuç olarak çalışma kapsamında belirlenen yıllarda CO salınımının genel olarak artış gösterdiği ve hava kalitesinde pozitif bir değişim yaşanmadığı görülmüştür.

# Investigation of Carbon Monoxide Emissions in Urban Areas Using Remote Sensing Data

**Keywords**
Air Quality,
Carbon Monoxide,
Sentinel-5P,
Temporal Changes

**ABSTRACT**

Many gases in the atmosphere directly affect spatial air quality. Carbon monoxide (CO), one of these gases, is among the greenhouse gases that cause climate change and has significant effects on both atmospheric pollution and climate. In order to accurately assess the environmental impacts of CO gas, it should be monitored at regular intervals. The aim of this study is to examine the temporal change of CO gas emissions in and around the Mevlâna Museum, which is located within the borders of Karatay District of Konya Province and has a high tourist density. Within the scope of the study, the change in CO concentration in four different three-month periods (January-March, April-June, July-September, October-December) between 2020-2025 was analyzed using Sentinel-5P satellite data. As a result, a general increase in CO emissions was observed in the analyzed years and no significant improvement in air quality was detected. Within the scope of the study, the change in the amount of CO in four different periods in three-month periods (January-March; April-June; July-September; October-December) between 2020-2025 was analyzed using Sentinel-5P satellite data. As a result, it was observed that CO emissions generally increased in the years determined within the scope of the study and there was no positive change in air quality.

[*] **Sorumlu Yazar**

[*](darikan@ktun.edu.tr) ORCID ID 0000-0001-9976-7479

**Kaynak Göster (APA):**

Arıkan İspir D & Makineci HB (2025). Uzaktan Algılama Verileri Kullanarak Kentsel Alanlarda Karbon Monoksit Salınımlarının Araştırılması, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## GİRİŞ

Tatsız, kokusuz ve renksiz bir gaz olan CO, atmosferi kirleten zehirli bir reaktif gaz olarak kabul edilmektedir (Schneising et al., 2019; Sha et al., 2021). Bu gaz uçucu organik bileşiklerin eksik yanması sonucu oluşmaktadır. Diğer gazlara göre ömrü nispeten kısadır. CO gazı, araçların, endüstrinin veya biyokütlenin yanması sonucu atmosfere yayılmaktadır (Novelli et al., 1998). Ayrıca bu gaz sera gazı olarak da kabul edilmektedir. Çünkü, atmosferdeki bu gaz, ozon ($O_3$), hidroperoksi ($H_2O_2$) ve hidroksil (OH) radikalleri gibi atmosferik oksidanlarla reaksiyona girerek, OH radikallerinin tüketilmesine neden olur. Bu durum, OH seviyelerinin azalmasına yol açar ve metan ($CH_4$) gibi birincil sera gazlarının atmosferde daha uzun süre kalmasına neden olur. Sonuç olarak, atmosferin kimyasal bileşimi ve radyasyon özellikleri üzerinde dolaylı ancak önemli etkiler ortaya çıkar (Novelli et al., 1998).

CO gazı sadece hava kalitesine değil aynı zamanda insan sağlığına da olumsuz etkileri bulunmaktadır (Wu et al., 2020). Bu gazın yüksek miktarda solunması durumunda, kırmızı kan hücrelerindeki hemoglobinin oksijen taşıma yeteneği zarar görebilir ve bu da ciddi sağlık problemlerine yol açabilir (Omaye, 2002; Schneising et al., 2019).

Yüzey ve havadan yapılan ölçümler, belirli bölgelerde atmosferik bileşenlerin miktarını hassas bir şekilde tespit edebilirken, küresel düzeyde kapsamlı veriler elde etmek için uydu sistemlerinin kullanılması gerekmektedir (Arikan ve Yildiz, 2023). Uydu tabanlı gözlemler, dünya genelinde geniş alanları kapsayarak atmosferik değişkenlerin izlenmesini sağlar (Schneising et al., 2019). Bu amaç doğrultusunda çeşitli uydu araçları kullanılmaya başlanılmıştır. Avrupa Uzay Ajansı (ESA) tarafından geliştirilen Sentinel uydu görevlerinden birisi olan Sentinel-5 Precursor (Sentinel-5P) uydusu bir yer gözlem uydusudur ve hava kalitesi çalışmalarından etkin veri toplamayı hedeflemiştir (de Vries vd., 2016)

Yapılan çalışmada Ekim 2017'de başarılı bir şekilde fırlatılan Sentinel-5 Precursor uydusundaki TROPOspheric Monitoring Instrument (TROPOMI) uydusu kullanılmıştır. Uydu sistemi Dünya'dan yansıyan güneş radyasyonunu itme-süpürme modunda ölçen, uzay kaynaklı bir dip görüntüleme spektrometresidir (Veefkind et al., 2012). Karasal yüzeyde geniş bir şerit boyunca tarama yapar ve ultraviyole (UV) ile kısa dalga kızılötesi (SWIR) arasındaki dalga boyu aralıklarını kapsar. Günlük küresel kapsama ile yüksek mekansal çözünürlüğü birleştirerek, çeşitli gazların küresel ölçekte olağanüstü ayrıntıda izlenmesini mümkün kılar ve bu da yeni uygulama olanakları sunar (Schneising et al., 2019).

Bu çalışmada, Konya ilinin yoğun insan ve araç hareketliliğine sahip merkezlerinden biri olan Mevlâna bölgesi odak alınarak, karbon monoksit (CO) gazının dağılımı ve zaman içindeki değişimi detaylı şekilde analiz edilmiştir. Kentsel alanlarda hava kalitesinin, özellikle yoğun nüfuslu ve turistik bölgelerdeki insan sağlığı üzerindeki etkileri göz önüne alındığında, bu tür bir izleme çalışması büyük önem taşımaktadır. Araştırma kapsamında 2020 yılından 2025 yılına kadar olan beş yıllık süreçte, üçer aylık aralıklarla CO seviyeleri düzenli olarak takip edilmiştir. Bu periyodik gözlemler, bölgedeki mevsimsel değişikliklerin, insan hareketliliğinin ve olası çevresel politikaların CO düzeylerine etkisini ortaya koymayı hedeflemektedir. Bu çalışma sayesinde, uzaktan algılama verilerinin kentsel ölçekte kullanımıyla, hava kalitesi analizine dair daha hassas ve zaman-mekân açısından ayrıntılı bir perspektif sunmasıdır.

## YÖNTEM

### Çalışma Alanı

Konya il merkezinde konumlanan Mevlâna bölgesi hem tarihi ve kültürel dokusuyla hem de yoğun kentsel faaliyetleriyle öne çıkan önemli bir yerleşim alanıdır (Çengel et al.). Mevlâna Müzesi'nin de içerisinde bulunduğu bu bölge, yıl boyunca yüksek ziyaretçi potansiyeline sahip olup, aynı zamanda Konya'nın şehir içi ulaşım ağının kesişim noktalarından biridir (Bolotbekova et al., 2025). Bölge, yaklaşık olarak 37.8715° kuzey enlemi ve 32.5053° doğu boylamında yer almaktadır. Bu konumu itibarıyla hem insan hem de araç trafiğinin yoğunlaştığı bir merkez niteliğinde olan Mevlâna çevresi, hava kirleticilerinin özellikle karbon monoksit (CO) gibi gazların izlenmesi açısından kritik bir araştırma alanı oluşturmaktadır. Bu bağlamda, bölgenin mekânsal özellikleri ve kullanım yoğunluğu, hava kalitesi verilerinin değerlendirilmesinde önemli bir zemin sunmaktadır.

### Verilerin Elde Edilmesi

Bu çalışmada 2020-2025 yıllarını kapsayacak Sentinel-5 uydusundan CO sütun kütle yoğunluğu verileri indirilmiştir. Bu, bir tür alan yoğunluğudur ve birim alandaki madde sayısı ya da yoğunluğunu ifade eder. Hacimsel sayı yoğunluğunun, dikey bir yol boyunca entegre edilmesiyle elde edilen bir kavramdır (Grzybowski vd. 2023). Verilerin temin edilmesinde, uzaktan algılama ve büyük veri analizleri için yaygın olarak kullanılan Google Earth Engine (GEE) platformu tercih edilmiştir. GEE, büyük ölçekli coğrafi verilerin işlenmesi ve analiz edilmesinde güçlü bir altyapı sunmaktadır. Bu platformu, verilerin indirilmesi, ön işlenmesi ve analiz edilmesinde önemli bir rol oynamıştır. Copernicus programı kapsamında hava kirliliğini izlemeye yönelik yürütülen ilk görev, Sentinel-5 sensörünün devreye alınmasıyla gerçekleştirilmiştir (Gibson et al., 2019).

Çalışmada kullanılan veriler OFFL olarak indirilmiştir. Bu verilerin tercih edilmesinin temel nedeni; ürünü algılamadan birkaç gün sonra kullanılabilir olmasıdır. CO, TROPOMI cihazının kısa dalga kızılötesi (SWIR) bantlarında gerçekleştirdiği radyans ölçümleri aracılığıyla tespit edilebilmektedir. Bu bantlara ait dip görüntüleme verilerinin mekânsal çözünürlüğü genellikle 7 km × 7 km boyutlarındadır(Schneising et al., 2019; Veefkind et al., 2012). Uydu sistemi sayesinde karbonmonoksit, azot dioksit, ozon metan gibi kirletici gazların izlenmesi mümkün olmaktadır (Safarianzengir et al., 2020).

Çalışma kapsamında CBS yazılımıyla üretilen karelajlar toplamda 70 nokta içermektedir. Değerlendirme yapılırken Mevlâna Müzesi ve çevre sokakları içeren 15 nokta ayrıştırılmış ve ek analizler gerçekleştirilmiştir.

**BULGULAR**

Şekil1'de 2020'den 2025'e kadar, Ocak-Mart, Nisan-Haziran, Temmuz-Eylül ve Ekim-Aralık olmak üzere dört farklı dönemin ortalama değerlerindeki değişimi göstermektedir. Tüm dönemlerde belirgin dalgalanmalar görülse de 2022 yılı civarında tüm dönemlerde belirgin düşüşler yaşanmıştır. Sıcaklıkların fazla olduğu Temmuz-Eylül dönemi incelendiğinde 2021 yılında en yüksek ortalama değere ulaşmış, ancak sonraki yıllarda önemli düşüşler yaşanmıştır. Ocak-Mart döneminde diğer dönemlere göre CO miktarı daha yüksektir. Diğer dönemlere kıyasla Nisan-Haziran dönemi stabil bir seyir izlemiştir. 2024 yılında en yüksek değerine ulaşmıştır.

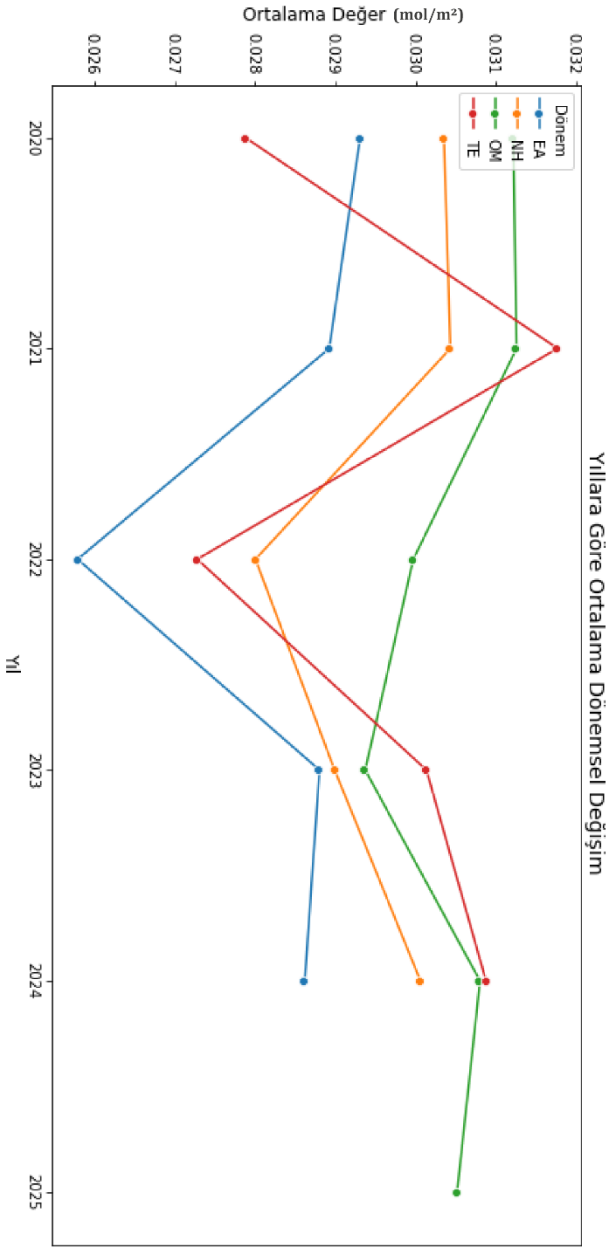


**Şekil 1.** 2000-2025 yılları arasında CO miktarının mevsimsel olarak değişimi

Şekil2'de, 2020'den 2024'e kadar olan yıllar için, her bir yıl özelinde dört farklı dönemin (OM, NH, TE, EA) dönemsel değer dağılımlarını kutu grafikleri sunulmuştur. 2020 yılında, OM dönemi en yüksek medyan değere sahipken, TE dönemi en düşük medyan değere sahiptir. NH ve EA dönemlerinin medyan değerleri birbirine yakındır. 2021 yılında ise, OM hala en yüksek medyan değere sahipken, TE'nin medyan değeri biraz yükselmiştir ancak hala diğerlerine göre düşüktür. Değer aralıkları genel olarak 2020'ye benzerdir. 2022 yılına gelindiğinde, tüm dönemlerin medyan değerlerinde belirgin bir düşüş gözlemlenmektedir. 2023 yılı incelendiğinde, OM ve TE dönemlerinin medyan değerleri tekrar yükselişe geçmiştir. NH ve EA dönemlerinin medyan değerleri de artmıştır. Değer aralıkları 2022'ye göre daralmıştır. Son olarak 2024 yılında ise, Tüm dönemlerin medyan değerleri genel olarak yüksek seviyelerini korumaktadır. TE dönemi diğerlerine yaklaşmıştır. Tüm yıllar göz önünde bulundurulduğunda, OM dönemi, en yüksek değerlere yakın medyan değerlere sahiptir. Bu da bu zaman diliminde CO miktarının daha fazla olduğunu ifade etmektedir.

SLAM

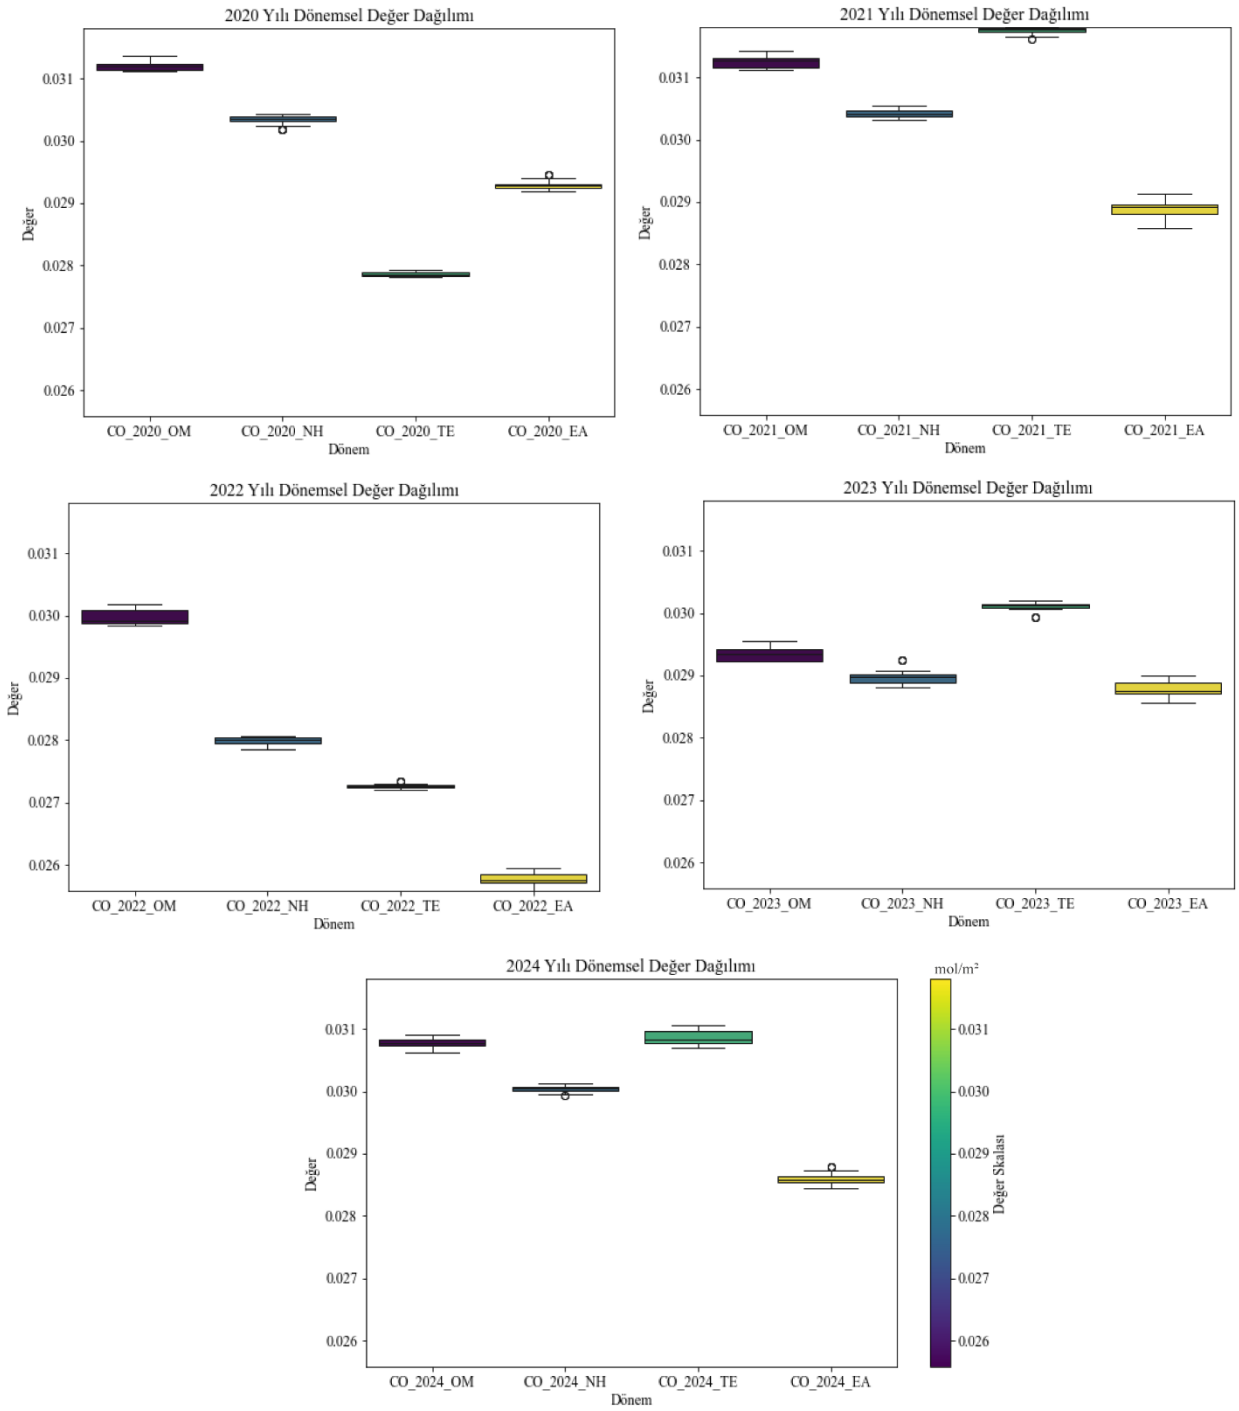


**Şekil 2.** Yıllara göre CO durumunun kutu grafiği gösterimi

Şekil 3'te, çalışma alanında yıllar bazında ölçülen karbon monoksit (CO) değerlerinin mekânsal dağılımı görselleştirilmiştir. Her bir yıl için elde edilen veriler, Mevlâna bölgesi ve çevresindeki CO yoğunluklarının değişimini yansıtmaktadır. Görselde dikkat çeken en önemli detay, 2020-2021 yıllarında CO miktarının görece düşük olduğu, ancak 2022 yılından itibaren bu miktarların arttığı ve özellikle 2024 yılında en yoğun seviyeye ulaştığıdır. Bu durum, bölgedeki insan ve araç trafiğinde yaşanan artışlarla birlikte çevresel önlemlerin yetersizliğini işaret edebilir. Ayrıca, dağılım haritasında CO miktarının merkezî noktalarda yoğunlaştığı ve yıl bazlı değişimlerin homojen bir şekilde gerçekleşmediği gözlemlenmektedir. Bu durum, mevsimsel etkiler kadar kentsel faaliyetlerin yıllık planlamalarıyla da ilişkilendirilebilir.

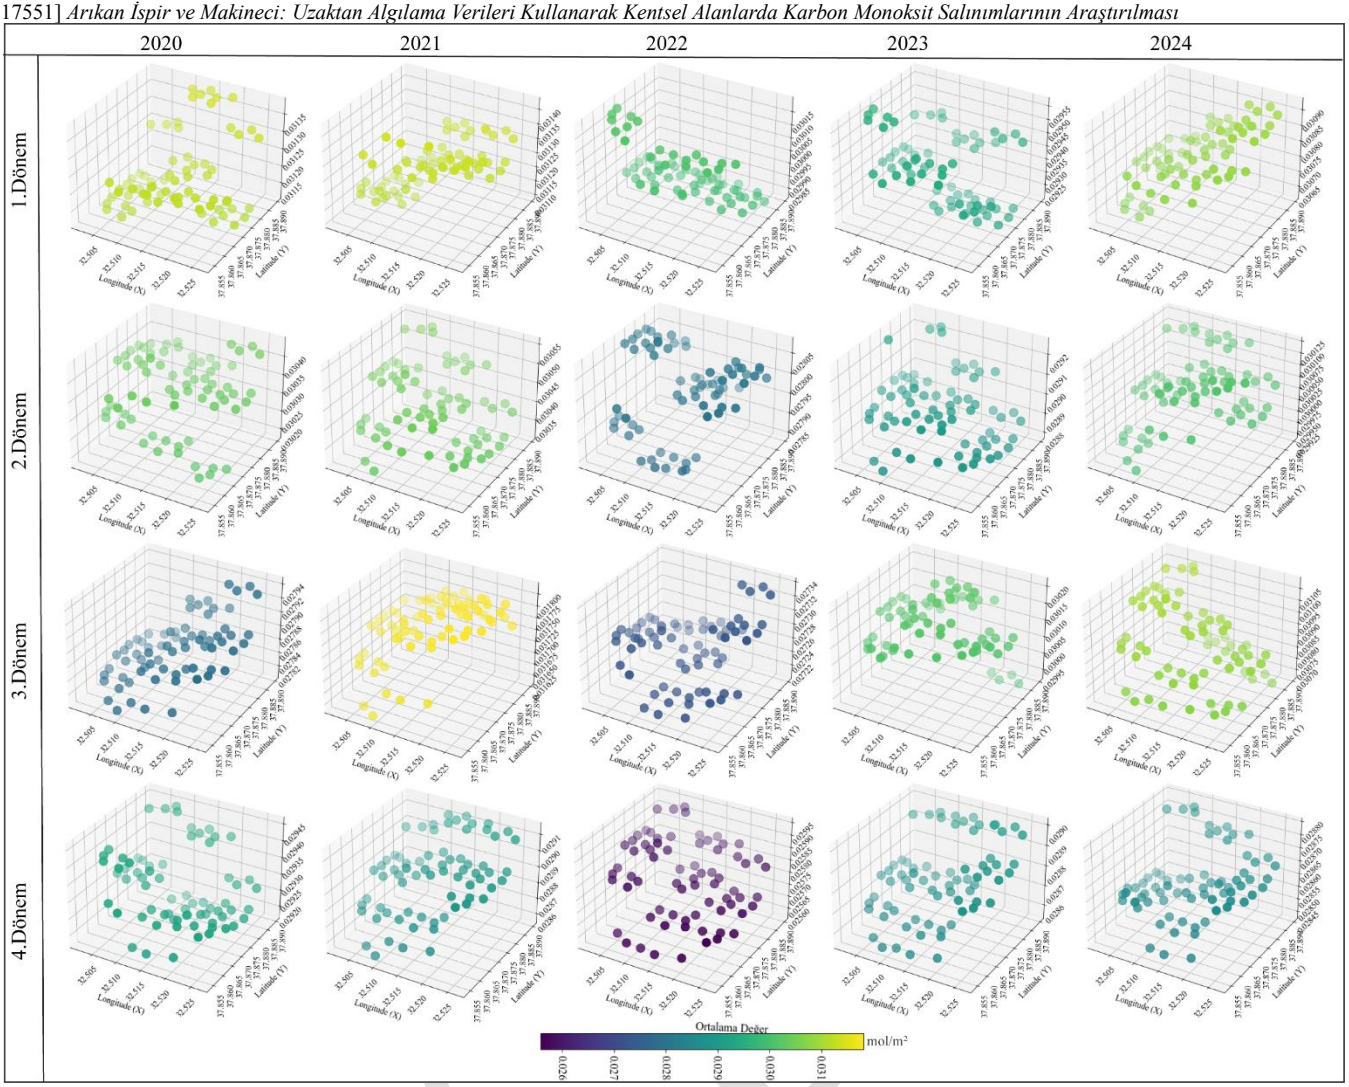


**Şekil 3.** Çalışma bölgesindeki CO miktarının yıllara göre dağılımı

Şekil 4'te çalışma alanı olan Mevlâna bölgesine ait ısı haritası verilmiştir. Şekil de kırmızı tonlarından mavi tonlarına doğru bir değişim söz konusudur. Buradaki kırmızı ve turuncu renk ile ifade edilen bölgelerde CO miktarı fazla, mavi tonlarına doğru bu miktar azalmaktadır. Ankara Caddesi, Elmalı Caddesi, Adana Çevre Yolu Caddesi gibi ana caddeler ve yollar boyunca CO miktarı arttığı görülmektedir. Bu durum da araç trafiğinin CO emisyonlarının önemli bir kaynağı olduğunu desteklemektedir. Ayrıca

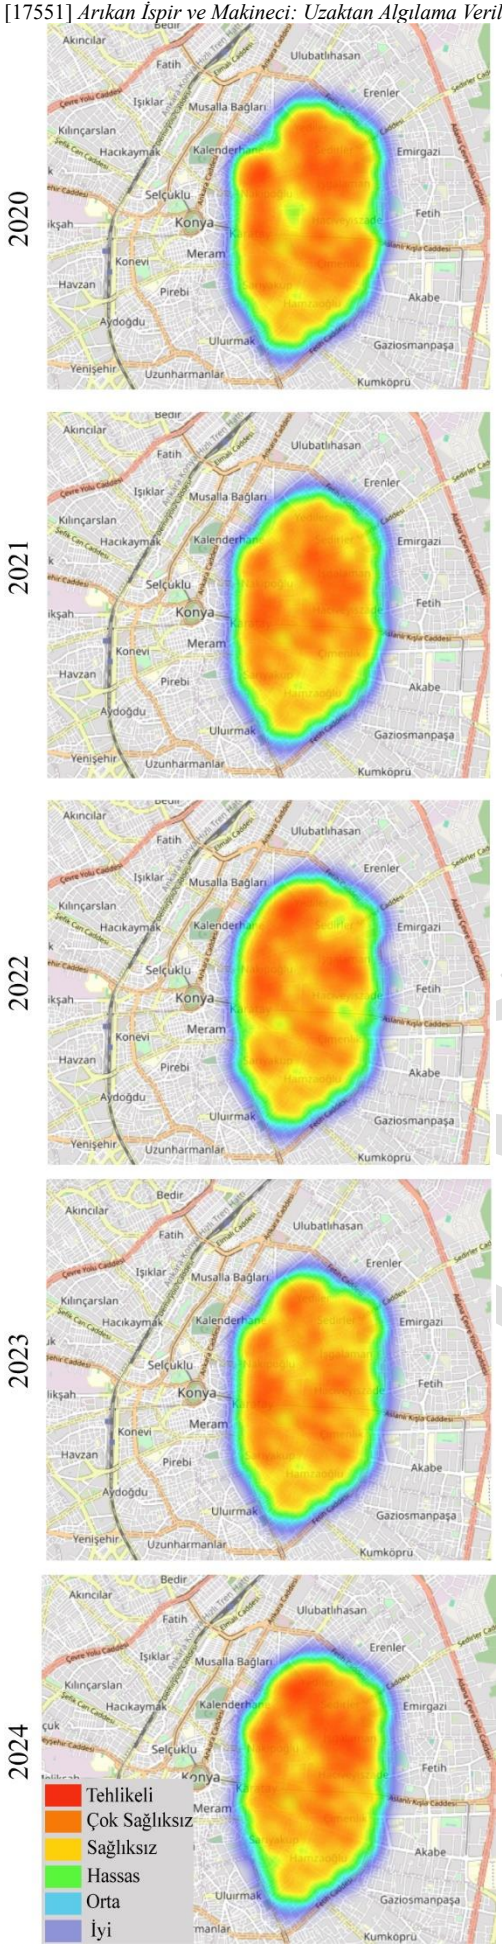


**Şekil 4.** Yıllara göre CO miktarının ısı haritası

**TARTIŞMA**

Bu çalışmanın bulguları, Sentinel-5P uydu verilerinin kentsel hava kirliliği izlemelerinde etkili bir araç olduğunu ortaya koymaktadır. Özellikle Konya gibi geniş yüzölçümüne sahip, hızlı gelişen şehirlerde, hava kalitesine yönelik yapılacak izleme çalışmaları için uzaktan algılama tabanlı yöntemler hem zaman hem de maliyet açısından önemli avantajlar sunmaktadır. Arikan ve Yildiz (2023), Makineci (2022) ve Safarianzengir vd. (2020) yapmış oldukları çalışmalarında Sentinel uydusundan elde ettikleri CO verilerini incelemişlerdir. Bu çalışmada CO verileri aynı uydu sisteminden elde edilmiştir. Yapılan çalışmalar ulusal hava kalitesi istasyonu ile uydu verilerinden elde edilen sonuçların benzer olduğu görülmüştür. Bu durum uydu verilerinden kısa zamanda hava kirliliği tespitine olanak sağladığını göstermektedir.

Bu çalışmada elde edilen sonuçlar, CO gazı dağılımının mevsimsel ve yıllık bazda önemli dalgalanmalar gösterdiğini ortaya koymuştur. Bu dalgalanmalar, sadece meteorolojik koşullardan değil; aynı zamanda turistik yoğunluk, trafik hacmi ve ısınma gibi insan faaliyetlerinden de etkilenmektedir.

Bununla birlikte, çalışmada değerlendirilen CO yoğunlukları özellikle Ocak-Mart dönemlerinde daha yüksek seviyelere ulaşmıştır. Bu durum, kış aylarında artan fosil yakıt kullanımı ve atmosferik kararlılığın düşük olmasıyla açıklanabilir. Ayrıca yıllar içindeki genel artış eğilimi, hava kalitesine yönelik önlemlerin yeterince etkin uygulanmadığını göstermektedir. Bu sonuçlar, yerel yönetimlerin çevresel politikalarını yeniden gözden geçirmesi ve özellikle merkezi bölgelerde trafik yoğunluğunu azaltıcı önlemler alması gerektiğini ortaya koymaktadır. Gelecekte yapılacak çalışmalarda, CO dışında diğer hava kirleticilerin de aynı yöntemle değerlendirilmesi ve çoklu gaz analizlerinin yapılması, daha kapsamlı sonuçlara ulaşılmasına katkı sağlayacaktır.

**SONUÇ**

Bu çalışma, Konya ili Mevlâna bölgesinde 2020-2025 yılları arasında karbon monoksit (CO) gazı salınımının uzaktan algılama verileri kullanılarak analiz edilmesini amaçlamıştır. Sentinel-5P uydusuna ait TROPOMI verileri aracılığıyla elde edilen dönemsel veriler sayesinde hem mevsimsel hem de yıllık bazda CO miktarının değişimleri belirlenmiştir. Elde edilen sonuçlar, özellikle kış aylarında CO seviyelerinde artışlar yaşandığını ve şehir merkezinde yoğun insan ve araç trafiğinin bu durumu önemli ölçüde etkilediğini göstermiştir. Bu bağlamda çalışma, hava kalitesinin mekânsal ve zamansal düzeyde izlenmesi için uydu tabanlı veri kullanımının güçlü bir araç olduğunu bir kez daha ortaya koymuştur. Bu çalışma sayesinde, Konya şehir merkezinde CO kirliliğinin önemli bir sorun olduğunu açıkça ortaya koymaktadır. En yüksek CO miktarları, merkezi ve işlek bölgelerde yoğunlaşmıştır ve araç trafiği bu duruma önemli bir katkı sağlamaktadır. Şehir merkezinden uzaklaştıkça hava kalitesi CO açısından iyileşme göstermektedir.

Hava kalitesinin izlenmesi, kent planlaması açısından kritik bir rol oynamaktadır. Özellikle karbon monoksit (CO) yoğunluğunun yüksek olduğu alanlarda, trafik akışının yeniden düzenlenmesi, toplu taşıma sistemlerinin iyileştirilmesi ya da emisyonları azaltmaya

yönelik çeşitli kontrol önlemlerinin uygulanması gerekmektedir. Ayrıca, bu bölgelerde yaşayan halkın bilinçlendirilmesi de alınacak önlemlerin etkinliği açısından büyük önem taşımaktadır.

**Yazar Katkı Oranı**

Yazarların makaleye eşit oranda katkı sağlamışlardır.

**Çıkar Çatışması/Çakışması**

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

**Araştırma ve Yayın Etiği Beyanı**

Yazarlar çalışmada, araştırma ve yayın etiğine aykırı bir durum olmadığını ve çalışmanın etik kurul onayı gerektirmediğini beyan eder.

**KAYNAKÇA**


Arikan, D., & Yildiz, F. (2023). Investigation of Antalya forest fire's impact on air quality by satellite images using Google earth engine. *Remote Sensing Applications: Society and Environment*, *29*, 100922.

Bolotbekova, A., Hakli, H., & Beskirli, A. (2025). Trip route optimization based on bus transit using genetic algorithm with different crossover techniques: a case study in Konya/Türkiye. Scientific reports, 15(1), 2491.

Çengel, M. A., & Singery, M. A Spatial Analysis of Konya's Mevlana Square and its Surroundings.

de Vries, Johan, vd. (2016). TROPOMI on ESA's Sentinel 5p ready for launch and use. Fourth international conference on remote sensing and geoinformation of the environment (RSCy2016). Vol. 9688. SPIE.

Gibson, L., vd. (2019). Detecting historic informal settlement fires with sentinel 1 and 2 satellite data-Two case studies in Cape Town. Fire Safety Journal, 108, 102828.

Grzybowski, P. T., Markowicz, K. M., & Musiał, J. P. (2023). Estimations of the ground-level NO2 concentrations based on the sentinel-5P NO2 tropospheric column number density product. *Remote Sensing*, *15*(2), 378.

Makineci, Hasan Bilgehan. (2022). İstanbul ili merkez ilçelerindeki NO2 ve CO emisyonlarının uzaktan algılama ve yersel istasyon verileri kullanılarak incelenmesi. Türkiye Uzaktan Algılama Dergisi 4.2 : 62-74.

Makineci, Bilgehan Hasan, vd. (2023). Spatio-temporal Analysis of Sentinel-5P Data of Konya City Between 2019-2021. Harita Dergisi.

Novelli, P., vd. (1998). Distributions and recent changes of carbon monoxide in the lower troposphere. Journal of Geophysical Research: Atmospheres, 103(D15), 19015-19033.

Omaye, S. T. (2002). Metabolic modulation of carbon monoxide toxicity. Toxicology, 180(2), 139-150.

Safarianzengir, vd. (2020). Monitoring, analysis and spatial and temporal zoning of air pollution (carbon monoxide) using Sentinel-5 satellite data for health management in Iran, located in the Middle East. Air Quality, Atmosphere & Health, 13, 709-719.

Schneising, O., vd. (2019). A scientific algorithm to simultaneously retrieve carbon monoxide and methane from TROPOMI onboard Sentinel-5 Precursor. Atmospheric Measurement Techniques, 12(12), 6771-6802.

Sha, M. K., vd. (2021). Validation of methane and carbon monoxide from Sentinel-5 Precursor using TCCON and NDACC-IRWG stations. Atmospheric Measurement Techniques Discussions, 2021, 1-84.

Veefkind, J. vd. (2012). TROPOMI on the ESA Sentinel-5 Precursor: A GMES mission for global observations of the atmospheric composition for climate, air quality and ozone layer applications. Remote Sensing of Environment, 120, 70-83.

Wu, Q., ve Lu, J. (2020). Air pollution, individual investors, and stock pricing in China. International Review of Economics & Finance, 67, 267-287.


© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Topoğrafik Vektör Veritabanı(TOPOVT) için İşletim Sistemlerinin Önemi

**Duygu BALCI*[1]**

[1]*Harita Genel Müdürlüğü, Bilgisayar Yüksek Mühendisi, Ankara, Türkiye*

**Anahtar Kelimeler**
Coğrafi Bilgi Sistemi, TOPOVT, PostgreSQL, Windows, Linux

**ÖZET**

Yenidünya kavramıyla birlikte evrende var olan her şeye bakışımızın değiştiği bir çağdayız. Bu bakışın değişmesinde bilgi birikiminin artması ve artan bilgi birikimi ile birlikte evrendeki bağlantısallığı anlamamızın da rolü büyüktür. Günümüzde evrendeki her şeyin birbiri ile olan bağını anlamak ve bu bağın bağlantısallığını kavramak ise araştırmacıların temel konuları arasına girmektedir. Gelişmiş dünya, yeni problemler ve bu problemlerin çözüm aracı olan yeni teknolojiler ortaya çıkarmıştır. Bilgi sistemleri de bu teknolojilerin içerisinde yer almaktadır ve nasıl ki canlılık kendi soyunun devamını sağlayabilmek için bulunduğu ortama uyumlanmaya çözüm arıyorsa, bilgi sistemlerinde de çalıştığımız ortamların birbirine uyumlanması vazgeçilemez bir gereklilik halini almıştır. Coğrafi Bilgi Sistemleri, yer küreye hâkim olma çabası ve bu çabanın teknolojik aracıdır. Bu aracın kullanımının değerlendirilmesi ise gelecekte daha verimli sistem kullanımı açısından son derece önemlidir. Bu çalışma kapsamında Harita Genel Müdürlüğünce, görüntülerden detay çıkarımı yoluyla üretilen tüm vektör verilerin depolandığı ve yönetildiği veritabanı olan Topoğrafik Vektör Veritabanı (TOPOVT)'nın Windows ve Linux işletim sistemleri üzerindeki performans karşılaştırmaları yapılmıştır. Gerçekleştirilen karşılaştırmalı analizler sonucunda, TOPOVT veritabanı Linux tabanlı sistemlerde Windows'a kıyasla SELECT sorgularında %95'e varan hız artışı sağlamış,
bu da sistem tercihinin yalnızca teknik değil, stratejik bir karar olduğunu ortaya koymuştur.

# Importance of Operating Systems for Topographic Vector Database (TOPOVT)

**Keywords**
Geographic Information System, TOPOVT, PostgreSQL, Windows, Linux

**ABSTRACT**

We are in an era where our perspective on everything in the universe has changed with the concept of the new world. The increase in knowledge and our understanding of the connectivity in the universe have a great role in this change. Today, understanding the interconnectedness of everything in the universe and grasping the connectivity of this connection are among the basic subjects of researchers. The developed world has created new problems and new technologies that are the solution tools for these problems. Information systems are also included in these technologies, and just as life seeks solutions to adapt to its environment in order to ensure the continuation of its own race, the adaptation of the environments we work in to each other has become an indispensable necessity in information systems. Geographic Information Systems are the effort to dominate the globe and the technological tool of this effort. The evaluation of the use of this tool is extremely important for more efficient system use in the future. Within the scope of this study, the performance comparisons of the Topographic Vector Database (TOPOVT), which is the database where all vector data produced by the General Directorate of Mapping through feature extraction from images are stored and managed, on Windows and Linux operating systems were made. As a result of the comparative analysis, the TOPOVT database demonstrated up to 95% faster SELECT query performance on Linux-based systems compared to Windows, highlighting that
operating system preference is not merely technical but also a strategic decision.

* **Duygu BALCI**
*(duygu.balci@harita.gov.tr) ORCID ID 0000 – 0003 – 2868 – 6019

**Kaynak Göster (APA):**
Balci D. (2025). Topoğrafik Vektör Veritabanı(TOPOVT) için İşletim Sistemlerinin Önemi. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## 1. GİRİŞ

Evrenin ve canlı yaşamının kökenine dair farklı bilimsel ve felsefi yaklaşımlar bulunmaktadır. Bu çalışma ise, insanlık tarihindeki bilgi üretimi ve teknolojik gelişim süreçlerini tarihsel, kültürel ve bilimsel veriler ışığında ele almaktadır. Yerküremiz, geçmişten bugüne birçok kültürün ve medeniyetin izlerini taşımakta; insanın çevresine dair anlayışı, zamanla gelişen bilgi birikimiyle birlikte çeşitlenmektedir (Şenel, 2020).

Geçmişte yaşamış farklı canlı türleri, kendi çevresel koşullarına uyum sağlamak üzere farklı özellikler geliştirmiştir. Bu çeşitlilik, insanların çevresiyle kurduğu ilişkinin zaman içinde nasıl değiştiğini anlamak açısından değerlidir.

Geçmişten günümüze, günümüzden de geleceğe bakarken hayatımızda var olan şeyleri anlamlandırabilmek için bağlantısallık kavramını kullanarak bir yaklaşım ortaya koymak yanlış olmayacaktır (Kılıç, 2024). Bağlantısallığı, evrenimizde var olan her maddenin/durumun birbiri ile olan ilişkisini ve her ortaya çıkan tanımlanmamış verinin tanımlanması noktasında bağlantı oluşturduğu bir veri bilimi olarak ortaya koyabiliriz.

Canlılara baktığımızda, hayatta kalmanın çevreyle kurulan ilişkiye bağlı hale geldiğini görüyoruz; örneğin Avustralya'da Aborjinler, çevreyle uyumlu bir yaşam benimseyerek bunu yeterli görmüş ve buna uygun bir kültür geliştirmişlerdir (Tabar, 2020). Öte yandan, 7000 km kuzeyde, Japonya'da belki de doğanın baskısı sonucu insanlar gelişmiş, ilerlemiş ve farklı bir uyum biçimiyle kendi kültürlerini oluşturmuşlardır. Bu da uyumlanma sürecinin, kendi içindeki seçilimlerle farklı sonuçlar üretebildiğini göstermektedir.

Oluşan bu durumu teknoloji ile ya da tek bir bakış açısı ile değerlendirmek, sınıflandırmak oldukça güçtür. Durumun sınıflandırılması, çok disiplinli bir yaklaşımla daha kolay olacaktır. Odak; üretilen teknoloji değil, sahip olunan bilgidir. Bu noktada günümüzde gerçekliklerin tersine işlediği ve bir 'şey'in canlı olarak sınıflandırılabilmesi için bilgi üretmesi/düşünmesi gerekliliğini ifade eden yeni yaklaşımlar bulunmaktadır (Rohr, 2014;Miller, 2017;Kılıç, 2024). Bu yaklaşımlar üzerinde durursak; biraz iddialı bir düşünce olsa da bilgisayar, sunucu, yapay zekâ gibi kavramların da canlı olduğunu ve soylarını devam ettirebilmek adına gelişimsel bir dönüşümün gerektiğini düşünebiliriz.

Peki, bu gelişimin konumuz olan bilgi teknolojileri ile ilgisi nedir? Bilgi teknolojileri alanında da evrende olduğu gibi uyumlanamayan her teknoloji yok olmaya mahkûmdur. Uyumlanmak kavramını biraz daha açacak olursak, bir maddenin başka bir madde içerisinde yaşamını sürdürebilmesi için gerekli kombinasyonları sağlamasıdır. Fazla enerjiye ihtiyacı varsa, onu üretmesi, fazla ışığa maruz kalıyorsa yüzeyini ona göre revize etmesi buna örnek verilebilir. Yani teknolojik gelişimi merkez alabiliriz.

Teknolojik gelişimin parçalarını daha iyi anlatmak için bir örnek ortaya koyarsak; Sumatra orangutanları, omnivor beslenen, dişileri 30-50 kg, erkekleri 50-90 kg olan, el ve ayaklarında beşer parmak bulunan ve başparmakları hareketli bir primattır. Ayrıca dik hareket yeteneği de vardır (Caldecott ve Miles, 2005). Fiziksel özellikleri insana bu kadar yakınken temel fark neredediir? Elbette zihinsel yeteneklerde. Donanım büyük ölçüde benzer olsa da, işletim sistemi yani bilişsel kapasite çok daha farklıdır. İnsan zihninin soyut düşünme, planlama ve karmaşık dil kullanma yeteneği geliştikçe, bu bilişsel kapasiteyi destekleyen çevresel araçlar ve teknoloji de gelişmek zorunda kalmıştır.

Bu doğrultuda bilişim sistemleri de yönetsel mekanizmalar ve bunların yetenekleri ile zaman içinde şekillenen bir gelişim göstermektedir. Harita Genel Müdürlüğü (HGM) içerisindeki Topoğrafik Vektör Veritabanı (TOPOVT) kurumun temel iş gücünün sağlandığı sistemlerden birisi olup, bu sistemin tıpkı canlılıkta ya da bağlantısallıkta olduğu gibi değişimi ya da gelişimi için yapılan işlemler bu çalışmanın konusudur.

Bu kapsamda kurumumuzda kullanılmakta olan TOPOVT, topoğrafik detayların topolojik vektör verilerle, topoğrafyanın ise eş yükseklik eğrileri ile temsil edildiği, mevki isimlerini ve yerleşim yeri isimlerini de içeren, tüm ülkeyi kapsayan vektör veri tabanının (Yılmaz ve Canıberk, 2018) performans, stabilite ve güvenlik, uzun vadeli bakım ve destek, geçiş ve uyumluluk noktalarında İşletim sistemleri üzerindeki dönüşüm süreci incelenecektir.

## 2. YÖNTEM

Dünyada egemen olan türümüzün gerek egemen olmasının temel gereksinimi gerekse egemenliğinin sonucu "aktarım yapabilme" yani "iletişim kurabilme" yeteneğidir. Bu iletişim ister işaret dili olsun ister sözlü iletişim olsun bir bilgi akışını göstermektedir.

Tarih öncesi dönemlere ait bazı arkeolojik buluntular, insanın çevresine dair gözlem yeteneklerini ve temel araç üretme becerilerini ortaya koymaktadır. Bu tür beceriler yanında hareketlilikler de göze çarpmaktadır (Bergman, 2022). Bu tür erken dönem hareketlilikler; yön bulma, araç yapma, planlama ve bilgi aktarımı gibi becerilerin sistematik olarak kullanılmaya başlandığını ortaya koymaktadır. Dolayısıyla, bilgi üretimi ve aktarımı yalnızca günümüzün değil, insanlık tarihinin en erken dönemlerinden itibaren sürdürülen bir çabadır.

İnsanların, göç eden hayvanların izlerini takip ederek kendi göç yollarını oluşturdukları süreçte, bu yolları kayda geçirip geçirmedikleri ya da bu yolların onlar için sembolik ya da işlevsel bir anlam taşıyıp taşımadığı hâlâ tartışmaya açıktır. İnsanlık tarihinin yaklaşık %99'luk kısmının yazının henüz icat edilmediği dönemleri kapsadığı düşünüldüğünde, bu tür sorulara kesin yanıtlar vermek güçtür. Bununla birlikte, varsayım düzeyinde kalan bu soruların ötesinde açıkça görülebilen bir olgu vardır: İnsanlar, yaşadıkları anları, deneyimleri ve anıları bir şekilde gelecek kuşaklara aktarma arzusunu her dönemde taşımışlardır. Bu aktarımlar kimi zaman maddi kültür unsurlarıyla, kimi zaman da sözlü gelenek ve ritüeller aracılığıyla gerçekleşmiş, böylece belleğin sürekliliği sağlanmıştır.

Somut arkeolojik buluntulara dayanarak yapılan yorumlar, insanın çevresini anlamlandırma ve kayıt altına alma eğiliminin oldukça erken dönemlere uzandığını göstermektedir. Örneğin, 1963 yılında

gerçekleştirilen kazılar sırasında günümüzden yaklaşık 8200 yıl öncesine tarihlenen ve Çatalhöyük'te ortaya çıkarılan duvar resimleri, insanların yaşadıkları çevreyi betimleme ve temsil etme isteğine işaret eden ilk haritalar arasında değerlendirilmektedir (Halaç, 2020; Hodder, 2019). Yazının icadından sonraki döneme ait en erken örneklerden biri ise, M.Ö. 2200 yılına tarihlenen ve Akadlara ait olan Ga-Sur haritasıdır. Kil tablet üzerine çivi yazısıyla hazırlanmış bu harita, yazılı haritacılığın bilinen en eski örneklerinden biri olarak kabul edilmektedir (Geçili, 2020). Bu örnekler, insanlığın gözlem yeteneklerinin ve mekânsal farkındalığının zamanla geliştiğini ve bu doğrultuda haritacılık alanında da ilerlemeler kaydedildiğini göstermektedir.

Tarihsel süreçte, tıpkı günümüzde olduğu gibi, gelişmeler üretim biçimlerini; üretim biçimleri kültürel yapıları; kültürel yapılar ise teknolojik dönüşümleri etkilemiştir. Konunun bağlamsal niteliği dikkate alındığında, bazı durumlarda yeni teknolojik gelişmeler (örneğin matbaanın icadının Reform hareketlerine etkisi veya Sanayi Devrimi'nde olduğu gibi) toplumsal dönüşümlere zemin hazırlarken; bazı durumlarda ise (örneğin Fransız Devrimi ya da Sovyet Devrimi) toplumsal devrimler teknolojik yeniliklerin önünü açan bir dinamik olarak ortaya çıkmıştır (Giedion,1948).

Ateşin denetim altına alınması, tarımın keşfi, sanayi üretimine geçiş, buhar makinelerinin geliştirilmesi, programlanabilir sistemlerin ortaya çıkışı ve günümüzde nesnelerin interneti (IoT) gibi gelişmeler; insanlık tarihindeki büyük teknolojik ve endüstriyel dönüşümlerin temel kilometre taşlarını oluşturmaktadır. Her yeni devrim, yalnızca teknolojik bir sıçramayı değil, aynı zamanda kendi içsel dinamikleriyle şekillenen yeni bir toplumsal ve kültürel yapıyı da beraberinde getirmektedir (McClellan ve Dorn, 2015).

Türk Dil Kurumu (TDK) tarafından harita "Coğrafya, tarih, dil, nüfus vb. konularda yeryüzünün bütününün veya bir bölümünün belirli bir oranda küçültülerek bir düzlem üzerine çizilmiş hâli" olarak tanımlanmaktadır. Tanımından da anlayabileceğimiz gibi harita, bir topluluğun, toplumun ya da ulusun fark etmeksizin tarihini, dilini, nüfusunu, sosyolojisini, psikolojisini yani içinde insan-insan ve insan-doğa ilişkisinin olduğu her alanı etkileyebilecek konumdadır.

Haritacılık ve coğrafya bilgisi, gelişmiş kültürlerin uygarlık olabilmesi ve bu uygarlıklarını yaymaları için son derece önemlidir. Bu önemi Cengiz Han'ın fetihlerinde gördüğümüz gibi (Balcı ve Kaya, 2023) kurtuluş savaşında coğrafyanın dengeleri bozmasında da net olarak görmekteyiz.

Bu kapsamda ülkemizin öncü kurumlarından birisi olan Harita Genel Müdürlüğünün haritacılık alanında yaptığı çalışmalar çok değerlidir. Hava fotoğrafları, uydu görüntüleri, jeodezik verileri, ortofoto üretimi, raster harita üretimi, vektör haritaları ve Topoğrafik vektör veritabanı bunlardan sadece birkaçıdır. Bu çalışmanın konusu ise "topoğrafik veritabanıdır".

Topoğrafik veritabanının anlaşılması için öncelikle topoğrafik vektör harita kavramını anlamak gerekir. Topoğrafik vektör harita, her bir noktası üç boyutlu koordinatlarla temsil edilen ölçeğin gerektirdiği oranda seçilmiş nokta, çizgi, alan detayları ve bu detayların öznitelik bilgilerinin de temsil edildikleri haritadır (Özbalmumcu, 2007). Bu haritalar, topoğrafik veri tabanlarında depolanır. Depolanan veri, hayatın olağan akışında aktif olarak kullanılır, sosyo-ekonomik değer taşır ve stratejik öneme sahiptir. İşte bu sebeple topoğrafik veritabanlarının güncel tutulması, kaliteli ürünler ve doğru kararlar için temel gerekliliktir. Güncel veriler, karar destek sistemlerinin etkinliğini artırarak doğru analiz ve planlama yapılmasını sağlar (Yılmaz vd., 2022). Bu verilerin ham hâli anlamsız bir yapıda olabilir. Verinin anlamlı ve kullanışlı bir hâle gelebilmesi için belirli aşamalardan geçmesi gerekmektedir. Bu sürecin ilk aşaması, analiz edilecek verinin doğru bir biçimde sınıflandırılmasıdır. Söz konusu sınıflandırma, verinin uygun şekilde depolanmasını, etkin biçimde kullanılmasını ve matematiksel işlemlere hazır hale getirilmesini mümkün kılmaktadır.

Çağımızda yani "bilgi toplumunda" her türlü bilgi veriye dönüştürülmek istenir ve bu veriler de veritabanları aracılığı ile depolanır ve sunulur. Günümüzde verilerin çeşitlenmesi ve miktar olarak artması ile büyük veri kavramı ortaya çıkmıştır.

Burada büyük verileri yönetmek için de çeşitli veritabanı sistemleri bulunmaktadır (Iglesias, 2023). Verilerin türüne, üretilecek olan son ürünün farklılığına, gerekli olan performansa göre farklı sistemler tercih edilebilmektedir. Aslında bu da kendi içerisinde gelişimsel bir yaklaşımı bize sunar.

Veritabanları genel olarak ilişkisel ve ilişkisel olmayan sistemler olarak ikiye ayrılır. Verileri tablolar hâlinde düzenleyen ve bu tablolar arasında ilişkiler kurarak karmaşık sorguları yanıtlayabilen sistemlerde genellikle ilişkisel veritabanları tercih edilir. Öte yandan, büyük veri ve gerçek zamanlı uygulamalarda, daha esnek şema yapıları sunan ilişkisel olmayan veritabanı sistemleri ön plana çıkar (Iglesias, 2023).

Bu nedenle, hangi veritabanı türünün tercih edileceği, yalnızca veri modeli ve kullanım senaryosuna değil, aynı zamanda sistemin performans gereksinimlerine ve altyapı koşullarına da bağlıdır.

Bir veritabanının performansı, güvenliği, bakımı ve sürdürülebilirliği sadece veritabanı yönetim sistemine değil, aynı zamanda üzerinde koştuğu sunucunun özelliklerine de bağlı ve bağımlıdır.

En önemli bağımlılıklardan birisi ise işletim sistemidir. Uygulama yazılımları ile donanım birimlerinin yönetimini sağlayan ve kullanıcıya bunları doğrudan veya desteklediği bir arayüz ile gösteren sistem yazılımlarının bütününe işletim sistemi denir (Canbaz ve Erdemir, 2021).

Bu çalışmaya konu TOPOVT, PostgreSQL üzerinde koşmaktadır. PostgreSQL veri tabanı ilişkisel bir veritabanıdır. Yani beyin nöronları gibi her nokta ilişkili olduğu takdirde birbirine bağlanabilir ve her bağlantı üzerinden ilişkili olduğu her veriye ulaşılabilir.

Çalışmamızın bir diğer bileşeni olan Coğrafi Bilgi Sistemi (CBS), konum tabanlı verilerle yürütülen bir çalışmadır. Bu tür verilerin etkin bir şekilde yönetilebilmesi için ise belirli eklentilere ve araçlara ihtiyaç duyulmuştur. Bunlardan en önemlisi ise PostGIS eklentisidir. Coğrafi bilgi sistemleri için kullanılan bu eklenti konum tabanlı bilgilerin depolanması,

sorgulanması ve analiz edilmesi kapsamında olmazsa olmazdır (Lizardo ve Davis, 2017).

PostGIS açık kaynak kodlu bir çözümdür ki bu da kullanım alanının artmasına ve çeşitlenmesine sebep olmuştur. Harita uygulamalarında, konum tabanlı uygulamalarda, akıllı şehir projelerinde (Sinconde vd., 2018), yer kaynaklarının tespitinde ve analizinde (Chaudhry ve Yousaf, 2019), afet yönetimi ve acil durum planlanması gibi alanlarda da kendine yer bulmuş ve her geçen gün bulduğu o yerin hacmini arttırarak değiştirmeye devam etmektedir.

PostgreSQL'in kullandığı bu eklentiler, veritabanı yönetiminde çeşitli işlevleri destekleyerek konumsal verilerin işlenmesini, analiz edilmesini ve yönetilmesini sağlamaktadır. Örneğin, PostGIS eklentisi PostgreSQL'e coğrafi veri ekleme yeteneği kazandırırken, postgis_topology ise coğrafi veriler arasındaki topolojik ilişkileri analiz etmek için kullanılmaktadır. Adres verilerini coğrafi koordinatlara dönüştürmek için postgis_tiger_geocoder, adresleri standart hale getirmek için address_standardizer eklentisi kullanılmaktadır. Ayrıca, hatalı veya benzer kelimeleri eşleştirme amacıyla fuzzystrmatch, yönlendirme algoritmalarını çalıştırmak için pgrouting, harici coğrafi veri kaynaklarını PostgreSQL'e bağlamak için ogr_fdw ve LIDAR verilerini analiz etmek için pointcloud eklentileri tercih edilmektedir. Bu eklentiler, çalışmamızda konum tabanlı verilerin daha verimli işlenmesini sağlamak amacıyla kullanılmaktadır (PostgreSQL, 2025).

Bu çalışmanın ana motivasyonlarından en başta geleni, Windows işletim sisteminde güvenlik zafiyetleri nedeniyle sürekli güncelleme gereksinimi ve bu güncellemelerin bazı çalışan programlar üzerinde olumsuz etkiler yaratmasıdır. Ayrıca, açık kaynak kodlu olarak geliştirilen PostgreSQL'in sık, yaygın ve en çok deneyimlendiği ortamın dışında çalışırken performans kısıtlamalarıyla karşılaşması da önemli bir faktördür (Gündüz, 2004). Bu kısıtlamalar, son kullanıcı da dâhil olmak üzere işleyişi olumsuz etkileyerek sistemin Linux ortamına taşınması fikrini ortaya çıkarmıştır.

Veritabanı özelinde güncellemelerden dolayı yakın tarihlerde yaşanan problemlere örnek verecek olursak; 12 Aralık 2023 tarihinde yayımlanan KB5033371 nolu güncellemenin (Microsoft, 2023), Windows Server üzerinde koşan PostgreSQL servisinde sorunlara yol açtığı gözlemlenmiştir. Yine 12 Mart 2024 tarihinde yayımlanan KB503857 nolu güncellemesi de bazı sebeplerle PostgreSQL servislerinin çalışmasını engellemiştir. Bu servislerin çalışabilir hâle tekrar getirilmesi ya güncellemenin kaldırılması ile ya da bu güncellemeye ek bir güncelleme ile sorunun giderilmesini beklemekle geçebilmektedir. Beklemek ya da güncellemenin kaldırılması da son derece yüksek riskleri ortaya çıkarabilmektedir. Veritabanındaki veri ve kullanıcı sayısı büyüklüğü göz önüne alındığında bu denli sorunların yaşanmaması, yaşansa dahi en kısa zamanda çözümlenmesi gerekliliği hâsıl olmaktadır.

Bunlara ek olarak Linux'un de PostgreSQL gibi açık kaynak kodlu ve ücretsiz olması, lisans maliyetlerini ortadan kaldırmakta ve yeni bir tercih sebebini daha ortaya çıkarmaktadır. Her ikisi de aktif ve geniş topluluklara sahip açık kaynak kodlu projeler olduğu için yaşanabilecek herhangi bir sorunda çözüm önerileri daha hızlı ve çözüm odaklı olabilmektedir.

Bu çalışma, PostgreSQL ve PostGIS performanslarını işletim sistemi bazında karşılaştırmak için deneysel bir yöntem benimsemektedir.

## 3. UYGULAMA ve BULGULAR

İnsanlık tarihindeki gelişmeler, sadece fiziki araçların değil, soyut sistemlerin de çevresel koşullar doğrultusunda şekillendiğini göstermektedir. Nasıl ki tarım devrimi insan topluluklarını kalıcı yerleşimlere itmiş ve bu, mimari, yönetim ve bilgi aktarımı gibi alanlarda büyük dönüşümler yaratmışsa; dijital çağda da veri işleme ve sunma biçimleri benzer bir dönüşüm içindedir. Bu bağlamda işletim sistemleri, çağdaş bilişim dünyasının 'yaşam ortamları' olarak değerlendirilebilir. Tıpkı farklı kullanım amaçları için geliştirilmiş sistemlerin çeşitli ortamlarda farklı verimlilik göstermesi gibi, bilgi sistemleri de çalıştıkları işletim sistemlerine göre farklı performanslar sergileyebilmektedir.

Çalışmanın bu bölümünde farklı işletim sistemleri üzerinde çalışan PostgreSQL ve PostGIS için; performans, stabilite ve güvenlik, uzun vadeli bakım ve destek, sürdürülebilirlik açısından karşılaştırmalar gerçekleştirilecektir.

### 3.1. Performans Karşılaştırmaları

Günümüzde her alanda bir ürünün varlığını sürdürebilmesi ya da yok edilmesi, onun performans çıktılarının sonuçlarına göre değişebilmektedir. Bilgi sistemleri alanında veritabanının performans sonuçları da seçeceğimiz sistem çalışma ortamına karar vermemizde oldukça önemli bir yere sahiptir.

Bu karar aşamasında, çalışma ortamı olarak hangi işletim sisteminin tercih edileceği; ihtiyaçlara, belirli kriterlere göre yapılan karşılaştırmalara ve önceki çalışmaların sonuçlarının değerlendirilmesine göre belirlenir. Bu çalışma içerisinde karşılaştırma yapılmış olup, çalışmanın sonucu da başka çalışmalara sonuç değerlendirmesi olarak katılabilecektir.

Karşılaştırma noktasında sistemin performansı için önemli değer olarak kabul ettiğimiz ana unsur, girdi değişken değerlerinin aynı olmasına rağmen sonuçlardaki yaşanan/yaşanabilecek farklılıkların ortaya çıkmasıdır. İşte bu farklılıklara dayanarak ürünün daha uzun süre hayatta kalma olasılığı olan ortama taşınması gerekliliğidir.

Aşağıda sunucu ortamlarının donanım karşılaştırmaları belirtilmiştir. Sunucuların donanım özellikleri birebir aynı seçilmiştir.

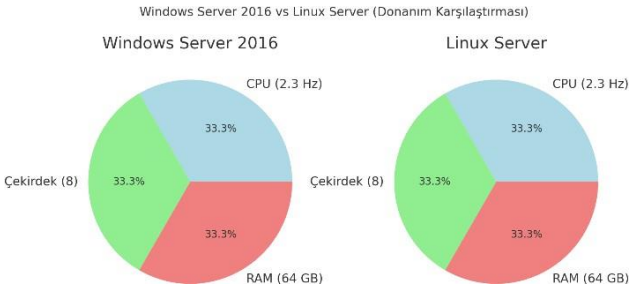


*Şekil 1: Donanım Karşılaştırması*

TOPOVT veritabanı 2019 yılından 2023 yılına kadar Windows işletim sisteminde hizmet vermiştir. Bu hizmet bir master iki stand-by sunucu olarak hizmet kesintisi yaşanmadan devam etmiştir. Windows İşletim Sistemi üzerinde yaklaşık olarak 500 GB'lık bir coğrafi veriye sahip olan TOPOVT'nin, bu işletim sistemi üzerinde koşarken yaşanılan sorunların minimize edilmesi, performansın artırılması ve son kullanıcının daha hızlı ve verimli çalışabilmesi adına Linux tabanlı bir işletim sistemine geçişine karar verilmiştir. 2022 yılının ikinci yarısında ortam değişikliği yapılabilmesi için gerekli analiz, planlama ve test süreçlerine başlanmıştır. Bu hazırlık süreci ise 2023 yılının ikinci yarısında tamamlanmış ve taşıma işlemi gerçekleştirilmiştir.
2022 yılından 2023 yılına kadar geçen sürede yapılan analiz ve test çalışmaları sonucunda veritabanının kayıpsız, hizmet kesintisi olmadan, sürekliliği sağlanacak şekilde taşıma işlemleri gerçekleştirilmiştir. 2023 yılından günümüze kadar geçen sürede de sorunsuz olarak hizmet vermeye devam etmektedir.
Windows ve Linux ortamında çalışan TOPOVT'nin performans farklarına bakarken SELECT, INSERT, UPDATE veya DELETE süreleri üzerinde analizler gerçekleştirilmiştir.
Büyük veriye sahip katmanlar üzerinde belirli bir alanda sorgu süreleri kaydedilmiştir. Art arda yapılan sorgularda ise indekslemenin işlevsellikleri de ortaya çıkarılmıştır. Tablo 1'de görüldüğü üzere Linux sunucu SELECT sorgularında neredeyse %95 daha hızlı yanıt vermiştir.

| Sorgu Sırası | Windows (ms) | Linux (ms) | Fark (ms) | Linux Daha Hızlı (%) |
|---|---|---|---|---|
| 1 | 314.659 | 28.338 | 286.321 | %90.99 |
| 2 | 283.148 | 18.044 | 265.104 | %93.63 |
| 3 | 289.963 | 17.559 | 272.404 | %93.95 |
| 4 | 291.021 | 18.234 | 272.787 | %93.74 |
| 5 | 302.640 | 18.514 | 284.126 | %93.88 |
| 6 | 284.498 | 17.729 | 266.769 | %93.77 |
| 7 | 293.110 | 17.605 | 275.505 | %94.00 |

*Tablo 1: Select Sorgu Süreleri*

Veritabanında bulunan en büyük boyuta sahip olan katmanlardan bazılarının (ağaç, yol ve küçük bina) birlikte (nokta, çizgi, alan) sorgulanması sonucunda sorgu süreleri Şekil 2'de gösterilmiştir.

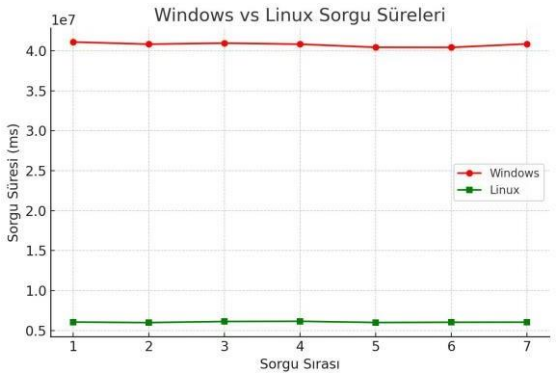


*Şekil 2:Boyutu Büyük Katmanların Sorgu Süreleri*

İç içe sorgularla yapılan SELECT işlemi sonucunda (nokta, çizgi, alan) hız karşılaştırmasında Linux İşletim sisteminin Windows'tan yaklaşık 8 kat daha hızlı cevap verdiği gözlemlenmiştir.

Bu farkın nedeni:

- Linux üzerinde daha verimli disk erişimi ve bellek yönetiminin olması,
- PostgreSQL'in Shared Buffers ve Work Mem ayarlarının Linux tarafında daha optimize olması,
- Windows'un arka planda çalışan hizmetlerinin PostgreSQL performansını yavaşlatması,
- Linux'ta Kernel seviyesinde yapılan optimizasyonlar (örneğin Huge Pages desteği),
- PostgreSQL'in I/O Scheduler yönetimi Linux tarafında çok daha efektif olması gibi sebeplerle hız açısından oldukça yüksek bir fark oluşturabilmektedir.

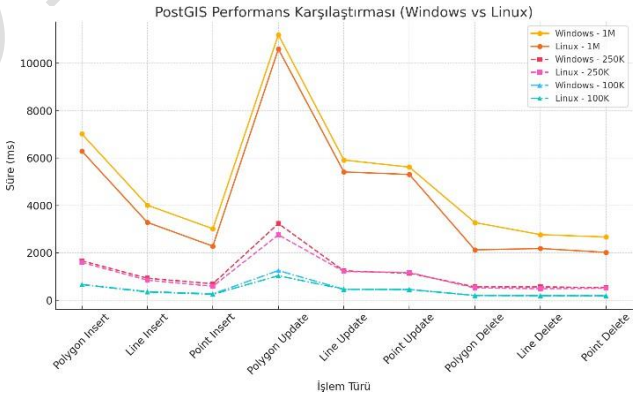


*Şekil 3: 100K, 250K ve 1M'luk sorgu süreleri karşılaştırması*

Her iki ortamda yapılan test sonucunda nokta, çizgi ve alan detaylar üzerinde rastgele oluşturulan 100K, 250K ve 1M'luk veriler INSERT, UPDATE veya DELETE edilmiştir. Bu sorgular sonucunda sorgu süreleri Şekil 3'te gösterilmiştir. Küçük veri setlerinde farklar daha az olmasına rağmen, Linux işletim sistemi büyük veri setlerinde %35'e kadar daha hızlı sonuçlar vermiştir.

### 3.2. Stabilite ve Güvenlik

Günümüzde en değerli varlıklardan birisi olan verinin stabilitesi ve güvenliği de oldukça önemlidir. İncelemiş olduğumuz sistem veritabanı yönetiminin ve kullanıcı tarafının kullanım kolaylığı açısından 1 Master, 2 Stand-by sunucu olarak hizmet vermektedir. Master olarak kurulmuş olan bir ana sunucu üzerinden birisi merkezde, diğeri felaket kurtarma merkezinde bulunan iki tane stand-by sunucu ile eşlenik olarak çalışmaktadır. Sadece master sunucu üzerine yazma yetkisi vardır. Diğer iki sunucudan sadece okuma işlemi yapılabilmektedir.

Bu kapsamda, performans analizinde sunucular arasındaki senkronizasyon gecikmeleri önemli bir değerlendirme kriteri olarak karşımıza çıkmaktadır. Master-Standby replikasyonunda, PostgreSQL'in Write Ahead Logging (WAL) sistemi kullanılmaktadır. WAL, veri bütünlüğünün korunmasını ve veritabanı kurtarma (yedekten dönme) süreçlerinin etkin bir şekilde yürütülmesini sağlayan bir mekanizmadır. Bir değişiklik veritabanına yazılmadan önce WAL dosyasına kaydedilir. Bu işlem, olası veri kaybını önlemeye yardımcı olur ve gerektiğinde verinin yeniden yüklenmesini sağlar (PostgreSQL,2025).

Kullanıcı INSERT, UPDATE veya DELETE gibi işlemler gerçekleştirdiğinde, bu değişiklikler doğrudan WAL dosyasına yazılır. Bu yazma işlemi tamamlanmadan veritabanında herhangi bir değişiklik gerçekleşmez. PostgreSQL, çalışma mantığı gereği, wal_buffers kullanarak bu kayıtları öncelikle bellekte (RAM) tutar ve ardından fsync(), fdatasync() veya open_datasync() gibi yöntemlerle diske yazar. Bu adımlar tamamlandığında veri güvence altına alınmış olur. Daha sonra ise gerçek tabloların güncellenme süreci başlar. Ancak bu güncelleme sırasında beklenmedik bir durum meydana gelir ve işlemler tamamlanamazsa, WAL dosyaları yapılan değişiklikleri saklamaya devam eder. Böylece, bu kayıtlar sayesinde veritabanı gerektiğinde kurtarılabilir bir durumda bekletilir (PostgreSQL,2025).

Veritabanında güncellenmesi gereken bir veri olduğunda kullanılan disk yazma yöntemleri şu şekildedir:

***open_datasync:*** Verinin diske yazılmasıyla eş zamanlı olarak senkronize edilmesini sağlar; ancak dosya metadatasını güncellemez.

***fdatasync:*** Yalnızca dosya verilerini diske senkronize eder.

***fsync:*** Hem dosya verilerini hem de metadata bilgilerini (dosya boyutu, izinler, zaman damgaları vb.) diske senkronize eder.

***fsync_writethrough:*** Writethrough modu etkinleştirildiğinde, veriler hem disk önbelleğine hem de fiziksel diske aynı anda yazılır.

Linux sistemlerde PostgreSQL, veri yazma işlemlerinde varsayılan olarak fdatasync() sistem çağrısını tercih ederken, Windows sistemlerde ise daha kapsayıcı olan fsync() varsayılan olarak kullanılmaktadır. fsync() çağrısı sadece veri içeriğini değil, aynı zamanda zaman damgaları gibi metadata bileşenlerini de disk üzerine yazar. Bu, veri bütünlüğü açısından avantaj sağlarken performans açısından ek yük oluşturabilir. fdatasync() ise yalnızca veri içeriğini yazmakla yetinir, bu da Linux'ta PostgreSQL için performans kazancı sağlar.

| Metod | İşlem Hızı (ops/sec) | İşlem Süresi (usecs/op) |
|---|---|---|
| **Linux (fdatasync)** | **3493.782** ops/sec | **286 µs/op** |
| **Windows (fsync)** | **1744.789** ops/sec | **573 µs/op** |

*Tablo 1 İşlem Hızları Karşılaştırılması*

Yapılan bazı ölçümlerde, fdatasync() çağrısının fsync()'e göre yaklaşık iki kata kadar daha hızlı olabildiği raporlanmıştır (Tablo 1). Bu fark, Linux'un açık kaynak yapısı ve esnek yapılandırma olanaklarıyla birleştiğinde kullanıcıya güvenlik-performans dengesini yapılandırma özgürlüğü sunar. Windows ise kapalı kaynak kod yapısıyla birlikte, veri güvenliğini sistem seviyesinde daha katı önlemlerle sağlamayı tercih etmektedir.

Ek olarak, Linux sistemlerde "write-through" gibi dosya sistemi özellikleri aktif edilerek veri, ön belleğe yazılırken eş zamanlı olarak disk üzerine de kaydedilebilir (Linux Manuel, 2025).

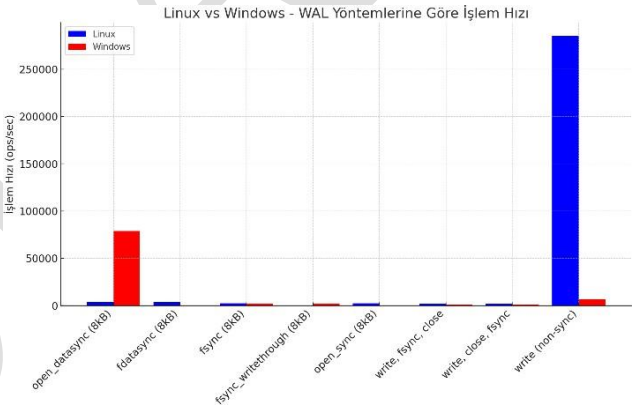


*Tablo 2: WAL Yöntemlerine Göre İşlem Hızı*

Diğer sistem çağrılarının karşılaştırılması ile birlikte işlem hızı ve işlem süreleri Tablo-2 ve Tablo-3'te gösterilmiştir. Linux WAL kayıtlarını senkronize etmede Windows'a göre oldukça hızlı çalışmaktadır.

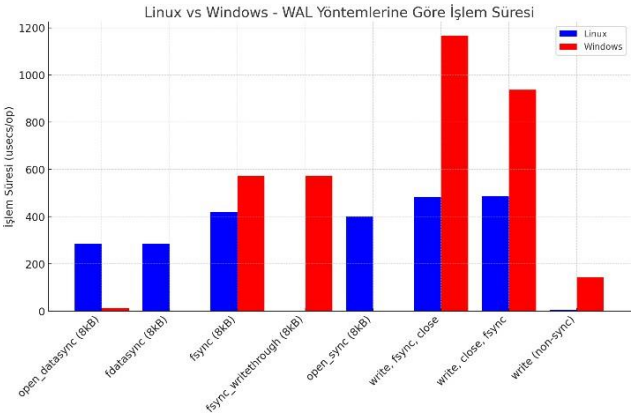


*Tablo 3: WAL Yöntemlerine Göre İşlem Süresi*

PostgreSQL'in replikasyon ve senkronizasyon performansı üzerinde Tablo 4'teki verilen değerler analiz edilmiştir.

| Yöntem | Linux (ops/sec) | Windows (ops/sec) | Sonuç |
|---|---|---|---|
| open_datasync | 3,494 ops/sec | **78,804 ops/sec** | Windows **çok daha hızlı**, ama disk önbellek kullanıyor. |
| fsync | **2,381 ops/sec** | 1,744 ops/sec | Linux **daha hızlı ve tutarlı**. Windows gecikmeli. |
| write, fsync, close | **2,068 ops/sec** | 857 ops/sec | Linux **çok daha hızlı ve istikrarlı**. |
| write (non-sync) | **285,097 ops/sec** | 6,954 ops/sec | Linux burada **devasa bir farkla** daha hızlı. |

*Tablo 4: Performans Karşılaştırması*

### 3.3. Uzun Vadeli Bakım ve Destek

1991 yılında Linus Torvalds tarafından geliştirilen ve ücretsiz olarak kullanıma açılan Linux çekirdeği, başta üniversite öğrencileri ve yazılım meraklıları tarafından Unix benzeri sistemler üzerinde çalışmak isteyenler için büyük bir fırsat yaratmıştır (Moody, 2001). Torvalds, sistemin başlangıçta "sadece bir hobi" olduğunu belirtmiş, GNU projesi kadar profesyonel olmasının planlanmadığını da ifade etmiştir(Linux). Ancak ilerleyen yıllarda, Linux'un kaynak kodunun açık olması, çeşitli kurum ve firmalar tarafından bu çekirdek üzerine özelleştirilmiş dağıtımların geliştirilmesine yol açmıştır. Bu dağıtımların bazıları yalnızca teknik destek ve kurumsal özellikler sunmakla kalmayıp, ticari lisans ve hizmet modellerine de geçmiştir. Red Hat Enterprise Linux (Red Hat, 2025), SUSE Linux Enterprise Server (SUSE, 2025), Canonical destekli Ubuntu Advantage (Ubuntu, 2025), Oracle Linux (Oracle, 2025) ve ClearOS (ClearOS, 2025) gibi dağıtımlar bu kapsamda değerlendirilebilir (Williams, 2010).

1985 yılında yaklaşık 100 USD fiyatla piyasaya sürülen ve kullanıcı dostu yapısıyla dikkat çeken Windows 1.0, günümüzde Windows 11 sürümüyle gelişimini sürdürmektedir. Windows 11 Pro sürümü, resmi kaynaklarda 199 USD seviyesinde ücretlendirilmekle birlikte, küresel ölçekte farklı lisanslama modelleriyle çeşitli fiyatlandırmalara da sahiptir. Dikkat çekici olan nokta, teknolojik gelişmelerin maliyetleri düşürmesine ve kullanıcı sayısının artmasına rağmen, özellikle dijital lisanslama sistemleriyle birlikte yazılım ücretlerinin zaman içinde yükselme eğilimi göstermesidir (Microsoft 1, 2025).

Her iki işletim sisteminin tedarikçileri, kurumsal müşterilere yönelik olarak farklı fiyatlandırma ve destek politikaları benimsemektedir. Bu politikalarda; stratejik kullanım önceliği, kurumsal yapı büyüklüğü, satın alma kapsamı, 7/24 destek gereksinimi ve yerinde hizmet gibi birçok unsur etkili olmaktadır. Kurumlar, genellikle bu kapsamda görevlendirdikleri uzman personel ile sistem yönetimini sürdürmektedir.

Microsoft Windows, kapsamlı dokümantasyonları, kullanım kılavuzları ve resmi destek forumlarıyla kullanıcılarına yönlendirme sunarken; Linux dağıtımları, geliştirici toplulukları ve açık kaynak katkı modeliyle daha katılımcı bir destek yapısı sergilemektedir. Linux kullanıcıları, sistemin her parçasıyla ilgili kaynak koda ulaşabildiğinden, destek imkânları geniş ve derindir. Öte yandan, Windows kullanıcıları genellikle kaynak koda erişemez ve destek süreçleri daha sınırlı bir çerçevede yürütülür. Ancak her iki sistem için kurumsal destek alındığında sağlanan hizmet kalitesi açısından büyük bir farklılık gözlenmemektedir.

Windows, grafiksel kullanıcı arayüzünü (GUI) varsayılan olarak sunarak kullanıcıya hızlı ve sezgisel bir deneyim sağlamayı amaçlamaktadır (Shneiderman ve Plaisant, 2010; Norman, 2013). Linux sistemleri ise başlangıçta komut satırı tabanlı yapısıyla daha teknik kullanıcıları hedef almış olsa da, zamanla GNOME, KDE, Xfce gibi masaüstü ortamlarıyla bu farkı büyük ölçüde kapatmıştır. Yine de GUI'siz kullanımda Linux, ileri düzey bilgi gerektirir. Bu da sistem üzerinde daha fazla kontrol isteyen uzman kullanıcılar için Linux'u esnek ve güçlü bir platform haline getirmektedir (Raymond, 2003; Ward, 2014).

Bu koşullarda geliştirime, yönetim ve uzun vade kullanım söz konusu olduğunda açık kaynak kodu ile Linux çok daha etkindir. 2025 yılı itibari ile Windows 11 hizmete devam ederken Ekim 2025'de Microsoft tarafından Windows 10 desteği sona erdirilecektir. Oysa Linux'ta çekirdek sürekli gelişirken, destek kesme söz konusu olmaz; ancak tedarikçi firmaların kurumsal tüzel kişiliklerinde değişimler yaşanabilir. Net bir ifade ile Microsoft kapanırsa Windows kapanır, herhangi bir Linux dağıtıcı şirketi kapanırsa diğer şirket ile devam edilebilir.

### 3.4. Sürdürülebilirlik

Verinin sürdürülebilmesi kavramı içerisinde en önemli alt dallarından birisi yedekleme sistemidir. Sağlıklı bir yedekleme sağlıklı bir geri dönüşü garanti eder.

PostgreSQL veritabanları özellikle büyük ölçekli projelerde kullanıldığında, verinin yedeklenmesi ve yedeklenen verinin herhangi bir olumsuz durumda geri döndürülmesi oldukça kritik öneme sahiptir. Bu kapsamda PostgreSQL için yedekleme yapmak amacıyla kullanılabilecek çeşitli yedekleme araçları bulunmaktadır. En genel kapsamda pg_dump, pgAdmin ve zamanlayıcı tabanlı yedekleme çözümleri kullanılmaktadır. Fakat proje boyutu büyüdükçe ortaya çıkan gereksinimler artıp çeşitlendiği için farklı çözümlere de ihtiyaç duyulmaktadır. Bu gibi daha gelişmiş ve profesyonel yedekleme stratejileri için pgBackRest ve pgBarman gibi özel araçlar geliştirilmiştir.

Pg_dump küçük veritabanı yedeklemelerinde daha çok tercih edilen bir araçtır çünkü büyük boyuttaki veritabanlarında sürekli ve sık yedekleme stratejilerinde performans sorunları ortaya çıkartabilir (PostgreSQL 2, 2025). PgAdmin ise kullanıcı dostu bir arayüze sahip olmasına rağmen yine büyük veritabanlarında performans kaybından dolayı çok tercih edilmemektedir. İşlemlerin manuel yapılması gerekliliği de tercih edilmemesine ön etkenlerden birisidir. Zamanlayıcı ile yedekleme ise veritabanlarının belirli zamanlarda otomatik olarak Windows'ta Windows Task Scheduler,

Linux'ta Cron aracılığı ile tetiklenen bir takvim ile alınmasının sağlanmasıdır.

Büyük ve kurumsal veritabanlarında ise ihtiyacın çeşitlenmesi dolayısı ile gelişmiş yedekleme araçları tercih edilmektedir. Bunlardan en çok kullanılanları ise pgBackrest (Pgbackrest, 2025) ve PgBarman(Pgbarman, 2025) araçlarıdır. Bu araçlar veritabanının sadece yedeklemesi işlevinde görev almasının yanı sıra replikasyon ve point-in-time recovery (belirli zamandaki veritabanına geri dönüş) işlemlerini de desteklemektedir. Bu araçlar, yalnızca yedekleme ve geri yükleme işlemlerini değil, aynı zamanda veri bütünlüğü, performans, güvenlik ve süreklilik açısından önemli avantajlar sunmaktadır.

Gelişmiş yedekleme araçları her iki ortamda da kullanılabilir olmasına rağmen, Linux sunucu ortamında bu araçların kurulum, konfigürasyon ve yönetimi daha kolaydır. Linux tabanlı sistemlerde bu araçlar, bağlılıkları doğrudan paket yönetiminden kurulduğu için sorunsuz bir şekilde yapılandırılabilirken, Windows'ta kullanımı ek yapılandırmalar gerektirebilir.

## 4. İRDELEME

Günümüzde işletim sistemleri üzerine yapılan karşılaştırmaların büyük çoğunluğu Linux ve Windows ekseninde gerçekleşmektedir. Her iki işletim sistemi de yaygın olarak kullanılmakta olup, farklı avantaj ve dezavantajlara sahiptir. Windows, grafik tabanlı arayüzü ve kullanıcı dostu yapısıyla öne çıkarken; Linux, güvenlik, özelleştirilebilirlik ve performans açısından daha güçlü bir seçenek olarak değerlendirilmektedir.

Son yıllarda güvenlik ihtiyacının artması, Linux tabanlı sistemlerin daha fazla tercih edilmesine neden olmuştur. Yapılan araştırmalar, güvenlik ön planda olduğunda Linux'un daha çok tercih edildiğini, kullanıcı dostu ve kolay erişilebilir bir sistem ihtiyacında ise Windows'un öne çıktığını göstermektedir (Awan ve Khan, 2022).

1985 yılında grafik tabanlı bir arayüzle geliştirilen Windows işletim sistemi, kullanıcı deneyimini önceliklendiren bir yapıya sahiptir. Ancak, bu grafik odaklı tasarım daha fazla sistem kaynağı tüketmesine neden olmaktadır. Buna karşılık, Linux çekirdeği üzerine inşa edilen işletim sistemleri, grafik arayüz yerine performansa ve sistem verimliliğine odaklanarak geliştirilmiştir. Bu nedenle, yüksek performans gerektiren sunucu altyapılarında Linux sistemlerinin daha işlevsel olduğu gözlemlenmektedir.

Bununla birlikte, Linux tabanlı sistemlerin verimli kullanılabilmesi için daha teknik bilgiye sahip personel gereksinimi, potansiyel bir dezavantaj olarak değerlendirilebilir. Ancak, uzun vadede düşünüldüğünde, Windows işletim sistemleri için ödenecek yüksek lisans ücretleri yerine, teknik bilgiye sahip personel istihdam edilmesi daha düşük maliyetli bir çözüm sunabilir.

Sonuç olarak, işletim sistemi seçimi kullanım senaryosuna, güvenlik gereksinimlerine ve maliyet faktörlerine bağlı olarak değerlendirilmelidir. Kritik veri güvenliği ve yüksek performans gerektiren sistemlerde Linux işletim sistemleri öne çıkarken, kullanıcı dostu bir deneyim ve geniş yazılım uyumluluğu arayanlar için Windows tercih sebebi olmaya devam etmektedir.

## 5. SONUÇ

PostgreSQL, 35 yılı aşkın süredir kesintisiz olarak geliştirilen, açık kaynaklı ve ilişkisel bir veritabanı yönetim sistemidir. Geliştirildiği ilk günden bu yana güvenilirlik, veri bütünlüğü, genişletilebilirlik ve performans gibi temel kriterler açısından kullanıcılar arasında güçlü bir itibar kazanmıştır (PostgreSQL). Özellikle büyük ölçekli veri analizleri ve karmaşık sorgu işlemleri gerektiren projelerde sunduğu güçlü analitik kapasite ve gelişmiş yedekleme mekanizmaları ile tercih sebebi olmaktadır. Bununla birlikte, PostgreSQL'in bu yüksek performansı sağlayabilmesi, sadece yazılımın kendisine değil; aynı zamanda çalıştığı işletim sistemine, yapılandırma biçimine ve yönetim stratejilerine de doğrudan bağlıdır.

Tarih boyunca bilgi üretimi ve aktarımı, uygarlıkların sürekliliğini sağlayan en temel unsurlardan biri olmuştur. Yazının icadından dijital çağın büyük veri yönetimine uzanan bu süreçte, bilginin saklanması ve erişilebilirliğinin sağlanması için geliştirilen yapılar da sürekli iyileşmiştir. Günümüzde veritabanı sistemleri, bu kültürel devamlılığın dijital temsilcisi niteliğindedir. Bu açıdan, TOPOVT örneğinde olduğu gibi bir sistemin hangi işletim sistemi üzerinde çalıştığı yalnızca teknik bir tercih değil; aynı zamanda bilgiye verilen önemin, onun sürdürülebilirliğine yönelik yaklaşımın da bir göstergesidir.

Bu çalışma kapsamında, PostgreSQL veritabanının farklı işletim sistemi ortamlarında nasıl performans gösterdiği analiz edilmiştir. Özellikle Linux ve Windows sunucular üzerinde yapılan testlerde, PostgreSQL'in kaynak kullanımı, sorgu süreleri, sistem stabilitesi, güvenlik özellikleri, bakım gereksinimleri ve uzun vadeli sürdürülebilirliği gibi başlıklar altında detaylı bir karşılaştırma yapılmıştır.

İşletim sistemlerine ilişkin tercihlerin yalnızca teknik gereksinimlerle sınırlı olmadığı, aynı zamanda bilişsel ve kültürel alışkanlıklarla da biçimlendiği gözlemlenmektedir. Bilginin paylaşımına, katılımcılığa ve kolektif üretime dayalı açık kaynak felsefesi; tarihsel süreçte bilginin sözlü ya da yazılı yollarla aktarımındaki temel ilkelere benzemektedir. Dolayısıyla teknolojik altyapılardaki yönelimler, geçmişte toplumların çevresel ve toplumsal koşullara göre geliştirdikleri üretim ve iletişim biçimlerinin dijital çağdaki yansımaları olarak da değerlendirilebilir.

Elde edilen bulgular, PostgreSQL'in Linux tabanlı sistemler üzerinde daha tutarlı, optimize ve kaynak açısından daha verimli bir performans sergilediğini göstermektedir. TOPOVT kapsamında yapılan uygulamalarda, özellikle PostGIS eklentisinin kullanıldığı durumlarda, Linux işletim sisteminin PostgreSQL ile daha uyumlu çalıştığı ve daha düşük sistem kaynakları ile yüksek düzeyde işlem performansı sağladığı gözlemlenmiştir.

Bu sonuç, PostgreSQL'in çok çekirdekli işlemcilerle daha etkili paralel sorgu planları oluşturabilme yeteneği ve Linux çekirdeğinin veritabanı süreçlerine daha

doğrudan müdahale edebilmesine bağlanabilir. Ek olarak, Linux sistemlerinde PostgreSQL için mevcut olan geniş konfigürasyon ve optimizasyon seçenekleri, özelleştirilmiş veri işleme süreçlerinin daha etkili bir şekilde yönetilmesine olanak tanımaktadır.

Sonuç olarak, veritabanı performansının yalnızca yazılım düzeyinde değil, aynı zamanda altyapı ve işletim sistemi düzeyinde de değerlendirilmesi gerektiği ortaya konulmuştur. Özellikle büyük ölçekli, mekânsal verilerle çalışan ve yüksek sorgu yoğunluğu barındıran projelerde PostgreSQL'in Linux ortamında konuşlandırılması, sistemin genel verimliliği ve sürdürülebilirliği açısından önemli avantajlar sunmaktadır. Bu bulgular, yalnızca PostgreSQL'in değil, benzer sistemlerin dağıtımı sırasında da altyapı seçiminin stratejik bir karar olarak değerlendirilmesi gerektiğine işaret etmektedir.

## 6. KAYNAKÇA


### Makale

Awan M. T., Khan K. (2022). "Linux Vs. Windows: A Comparison of Two Widely Used Platforms", Journal of Computer Science and Technology Studies - JCSTS 4(1): 41-54.

Bergman J. (2022). Java Man: A Creature Between Apes and Humans, an Extinct Ape, or a Primitive Man? Answers Research Journal 15, 109–120.

Canbaz, S. Ve Erdemir, G. (2021). Açık Kaynak Kodlu Gerçek Zamanlı İşletim Sistemlerinin İncelenmesi. İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi. 30 – 37. https://doi.org/10.47769/izufbed.877030

Chaudhry N., Yousaf M. M. (2019). "Spatial querying of mineral resources using PostGIS". Conference: International Conference on Advancements in Computational SciencesAt: The University of Lahore, DOI: 10.23919/ICACS.2019.8688999.

Geçili, D. (2020). Osmanlı Devleti'nde Harita Çizimi Mektebi. Mersin Üniversitesi Sosyal Bilimler Enstitüsü e-Dergisi. 3,4.

Giedion, S. (1948). Mechanization takes command: A contribution to anonymous history. Oxford University Press.

Halaç, H. H. & Ulaş, E. & Karaçor, F. (2020). Çevrimiçi Ziyaretçi Yorumlarında Çatalhöyük Neolitik Kenti. Nevşehir Hacı Bektaş Veli Üniversitesi SBE Dergisi, 11(3), 1506-1520.

Iglesias, M.J.F. (2023). Brief Introduction to Database Systems. University of Vigo. DOI: 10.13140/RG.2.2.35951.30884.

Kutoğlu, Ş. H., Ghasempour, F., & Şekertekin, A. (2021). Investigation of Possible MODIS AOD Anomalies as Earthquake Precursors for Global Earthquakes. Advances in Space Research. doi: 10.1016/j.asr.2021.06.036.

Miller, W.B., (2017). Biological İnformation Systems: Evolution As Cognition-Based İnformation Management. Progress in Biophysics and Molecular Biology Volume 134, May 2018, 1-26.

Rohr, D. (2014). A Theory of Life as Information-Based Interpretation of Selecting Environments. Springer Science+Business Media Dordrecht. Biosemiotics. 7:429– 446

Sinconde D., Mselle L., Shidende N., Comai S. Ve Matteucci M. (2018). "Developing an Intelligent PostGIS Database to Support Accessibility Tools for Urban Pedestrians". Urban Science. 2, 52; doi:10.3390/urbansci2030052.

Tabar, Ü. (2020). Zaman, mekân ve inanç ekseninde Avustralya Aborijinleri. Journal of Social and Humanities Sciences Research, 7(59), 2585-2601.

### Kitap

Caldecott, J. Ve Miles, L. (2005). World Atlas of Great Apes and their Conservation. UNEP-WCMC the University of California Press. Chapter 11.

Hodder, I. (2019). Çatalhöyük, Leoparın Öyküsü. Yapı Kredi Yayınları.

Kılıç, T. (2024). Yeni Bilim: Bağlantısallık Yeni Kültür: Yaşamdaşlık (7. Baskı). İstanbul: Ayrıntı Yayınevi.

McClellan, J. E., & Dorn, H. (2015). Science and technology in world history: An introduction (3rd ed.). Johns Hopkins University Press.

Moody, G. (2001). Rebel Code: Linux and the Open Source Revolution. Perseus Publishing.

Norman, D. A. (2013). The Design of Everyday Things (Revised ed.). Basic Books.

Raymond, E. S. (2003). The Art of UNIX Programming. Addison-Wesley.

Shneiderman, B., ve Plaisant, C. (2010). Designing the User Interface: Strategies for Effective Human-Computer Interaction (5th ed.). Pearson.

Şenel, A. (2020). Kemirgenlerden Sömürgenlere İnsanlık Tarihi (6. Baskı). İmge Kitap Evi

Ward, B. (2014). How Linux Works: What Every Superuser Should Know (2nd ed.). No Starch Press.

Williams, S. (2010). Free as in Freedom (2.0): Richard Stallman's Crusade for Free Software. O'Reilly Media.

### Bildiri

Balcı, D. ve Kaya, İ.A.(2023). Yeni Dünya Düzeninde Coğrafi Bilgi Sistemlerinin Etkinliği. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) XII. Teknik Sempozyumu - 24-26 Mayıs 2023 – Sivas, Türkiye.

Gündüz D. (2004). PostgreSQL veritabanı Sunucusu. Linux Kullanıcıları Derneği Semineri.

Lizardo, L.E.O. ve Davis, C.A. (2017). A PostGIS extension to support advanced spatial data types and integrity constraints. In Proceedings of SIGSPATIAL'17, Los Angeles Area, CA, USA, November 7–10,

Özbalmumcu, M. (2007). Fotogrametrik Yöntemle Topoğrafik Vektör Harita Üretimi Ve Proje Yönetiminde Uyulması Gereken Teknik Esaslar. TUFUAB IV. Teknik Sempozyumu, İstanbul.

Topan, H., Cam, A., Erdoğan, B., & Görmüş, K. S. (2022). Pléiades 1A Pankromatik Üçlü Bindirmeli Şerit Görüntülerinin 3B Konum Doğruluğunun Algılayıcıya Bağımlı Yöneltme Yöntemi İle Değerlendirilmesi. VIII. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu, Ankara. http://doi.org/10.15659/uzalcbs2022.12846

Yılmaz A., Okul A., Canıberk M., Yüksel B. (2022). Türkiye Topoğrafik Vektör Veritabanı (Topovt) Gerçek Zamanlı Güncelleme Sistemi. TUFUAB IX. Teknik Sempozyumu, Afyon.

### Tez

Atalay, C. (2024). Köşe-yansıtıcı Geometrisinin Radargrametrik Yöneltme ve Dijital Yüzey Modeli Kalitesi Üzerindeki Etkisi. (Doktora Tezi), Zonguldak Bülent Ecevit Üniversitesi, Zonguldak.

### İnternet adresi

ClearOS, https://www.clearos.com/ [Erişim tarihi: 24.03.2025]

Linux, https://www.linux.com/news/linuss-famous-email/ [Erişim tarihi: 25.03.2025]

Linux Manuel, https://man7.org/linux/man-pages/man2/fdatasync.2.html [04.04.2025]

Microsoft, https://learn.microsoft.com/tr-tr/answers/questions/2190276/kb5033371-nolu- update-paketi-hakk-nda?forum=windowserver- all&referrer=answers [Erişim tarihi: 25.03.2025]
Microsoft 1, https://www.microsoft.com/tr-tr/d/windows-11-pro/dg7gmgf0d8h4 [Erişim tarihi: 25.03.2025]
Pgbackrest, https://pgbackrest.org/ [Erişim tarihi: 25.03.2025]
Pgbarman, https://pgbarman.org/ [Erişim tarihi: 25.03.2025]
PostgreSQL https://www.postgresql.org/ [Erişim tarihi: 25.03.2025]
PostgreSQL 1, https://www.postgresql.org/docs/current/wal-intro.html [Erişim tarihi: 25.03.2025]
PostgreSQL 2, https://www.postgresql.org/docs/current/backup.html [Erişim tarihi: 25.03.2025]
Red Hat, https://www.redhat.com [Erişim tarihi: 25.03.2025]
Oracle Linux, https://www.oracle.com/linux/ [Erişim tarihi: 25.03.2025]
SUSE, https://www.suse.com [Erişim tarihi: 25.03.2025

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Zaman Serisi Sentinel-2 Uydu Görüntülerinden Derin Öğrenme ile Ürün Türü Tespiti

**İbrahim YEĞEN[1], Oğuzhan TOSUN[2], Mustafa TÜRKER[3]**

[1, 2]*Hacettepe Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 06800, Beytepe, Çankaya, Ankara*

**Anahtar Kelimeler**
Mahsul türü tespiti
U-Net
Derin Öğrenme
Zaman Serisi
CNN

**ÖZET**

Tarım faaliyetleri, günümüzde hızla artan küresel nüfus, değişen ve öngörülemez hâle gelen iklim koşulları ile tarım arazilerinin şehirleşme ve endüstriyel dönüşüm gibi etkenlerle giderek azalması sonucu, ciddi sürdürülebilirlik sorunlarıyla karşı karşıya kalmaktadır. Bu çok boyutlu sorunlar, geleneksel tarım yöntemlerinin etkinliğini sınırlarken, tarımsal üretimin planlanması, izlenmesi ve yönetimi noktasında daha hassas, hızlı ve ölçeklenebilir çözümlere olan ihtiyacı da beraberinde getirmiştir. Bu bağlamda, uzaktan algılama teknolojileri ile derin öğrenme yaklaşımlarının entegrasyonu yalnızca geniş alanlarda otomatik ürün tespiti sağlamakla kalmayıp, aynı zamanda iklim adaptasyonu ve gıda güvenliği politikalarının şekillenmesinde de stratejik bir araç hâline gelmiştir. Bu çalışmada, zaman serisi örüntüleri öğrenme yeteneğine sahip BCDUNetConvLSTM isimli hibrit derin öğrenme modeli ve çok zamanlı Sentinel-2 uydu görüntüleri kullanılarak, tarımsal ürün türleri sınıflandırılması gerçekleştirilmiştir. Model mimarisi temel olarak klasik U-Net yapısına dayanan BCDUNetConvLSTM, zaman serisi uydu görüntülerinden elde edilen bilgileri etkili şekilde işleyebilmek amacıyla evrişimli uzun kısa süreli bellek katmanları (ConvLSTM) ile geliştirilmiştir. Kırklareli bölgesinde seçilen tarımsal alanda gerçekleştirilen testler sonucunda model, özellikle bölgede yaygın olan ürün türlerinde (*mısır, çeltik, buğday*...) yüksek sınıflandırma başarısı göstermiştir. Elde edilen %93.0 genel ortalama doğruluk değeri, %95.5 F1 skor ve %92.3 ortalama kesişim-birleşim oranı (Intersection-over-Union - IoU) değeri, çok zamanlı Sentinel-2 görüntülerinden güvenilir tarımsal ürün haritalaması yapılabileceğini ortaya koymuştur.

# Crop Type Detection Using Deep Learning from Time-Series Sentinel-2 Satellite Images

**Keywords**
Croptype detection
U-Net
Deep Learning
Time Series
CNN

**ABSTRACT**

Agricultural activities today are confronted with significant sustainability challenges due to a rapidly growing global population, increasingly unpredictable climate conditions, and the progressive reduction of arable land driven by urbanization and industrial transformation. These multifaceted issues have rendered traditional agricultural practices insufficient, thereby creating a growing need for more precise, rapid, and scalable solutions in the planning, monitoring, and management of agricultural production. In this context, the integration of remote sensing technologies with deep learning approaches has emerged not only as a means to enable automated crop detection over large areas, but also as a strategic tool in shaping climate adaptation and food security policies. Within the scope of this study, a hybrid model named BCDUNetConvLSTM, which possesses temporal pattern learning capabilities, is proposed and applied for pixel-wise classification of crop types using multi-temporal Sentinel-2 satellite imagery. The model architecture is fundamentally based on the classical U-Net structure; however, to effectively process temporal information derived from time-series satellite data, it is enhanced with convolutional long short-term memory layers (ConvLSTM). Experimental results demonstrate that the model achieves high classification performance, particularly in frequently occurring crop classes, and yields an overall pixel accuracy of 93.0%, an F1-score of 95.5%, and mean Intersection-over-Union (IoU) of 92.3%, thereby indicating the model's capacity to produce reliable crop maps from multi-temporal satellite imagery.

* **Sorumlu Yazar**

*(ibrahimyegen02@gmail.com) ORCID ID 0009-0009-8613-300X
(oguzhantosun@hacettepe.edu.tr) ORCID ID 0009-0006-2389-9700
(mturker@hacettepe.edu.tr) ORCID ID 0000-0001-5604-0472

**Kaynak Göster (APA):**

Yeğen İ., Tosun O. & Türker M. (2025). Zaman Serisi Sentinel-2 Uydu Görüntülerinden Derin Öğrenme İle Ürün Türü Tespiti, 13. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

## GİRİŞ

Tarımsal faaliyetler, insanlık tarihi boyunca medeniyetlerin sürdürülebilirliği ve toplumsal refahın sağlanmasında temel bir rol oynamıştır (Buttar ve Sachan, 2023; Van Kirk ve Addy, 2023). Ancak günümüzde artan nüfus, iklim değişikliği ve şehirleşmeye bağlı tarım alanlarının azalması gibi sorunlar, sürdürülebilir tarım için önemli tehditlerdir. Türkiye'de 1945 ile 2017 yılları arasında toplam tarım alanlarının yaklaşık 4,7 milyon hektar azaldığı rapor edilmiş ve 1990–2018 yılları arasında Türkiye nüfusu yaklaşık %45,2 artarken, aynı dönemde kişi başına düşen tarım arazisi %39,3 oranında azaldığı rapor edilmiştir (Yücer, 2020). Bu demografik ve mekânsal değişimler, tarımsal üretimin planlanmasında geleneksel yöntemlerin sınırlı kalmasına yol açmış ve son teknoloji çözümlerin gerekliliğini gündeme getirmiştir. Bu bağlamda, tarımsal ürün türlerinin doğru ve zamanında tespiti, tarım desenlerinin analizi, iklim dirençli üretim stratejileri ve veri odaklı tarım politikalarının geliştirilmesi açısından kritik öneme sahiptir (Zhang ve ark., 2012; Lobell ve Asner, 2004). Yapay zekâ alanında bilgisayarlı görüde Derin öğrenmeye dayalı Evrişimli Sinir Ağları (CNN) ile Uzaktan algılama teknolojilerinin birleşimi, tarım arazilerini izleme süreçlerinde önemli bir dönüşüm yaratmıştır. Çok bantlı uydu görüntülerinin derin öğrenme teknikleriyle işlenmesi, otomatik ve yüksek doğruluklu sınıflandırma çözümleri sunmaktadır (Kussul ve ark., 2017). Otomatik görüntü sınıflandırmada yaygın kullanılan U-Net mimarisi, CNN tabanlı yapısıyla piksel düzeyinde detaylı segmentasyon sağlamakta, ancak zaman serili verilerde yetersiz kalmaktadır (Ronneberger ve ark., 2015; Rußwurm ve Körner, 2018). Özellikle tek zamanlı uydu görüntüsü ile tarım alanlarının sınıflandırılıp tespit edilmesi yerine çok zamanlı görüntüler kullanılarak zamana duyarlı sınıflandırma işlemi daha yüksek doğruluklu sonuçlar verdiği gözlemlenmiştir (Gómez ve ark., 2016, Long ve ark., 2013).

Bu çalışmada, Kırklareli'de tarım alanlarının otomatik tespiti ve sınıflandırılması için Bi-directional U-Net ConvLSTM (BCDUNetConvLSTM) modeli önerilmektedir. Temel U-Net mimarisi üzerine geliştirilen bu modelde, görüntüyü sıkıştırarak anlamlı temsillere dönüştüren bir kodlayıcı (encoder) ve bu temsilleri yeniden adımlayarak yapılandıran bir çözücü (decoder) yapı bileşenleri arasında çift yönlü Evrişimli Uzun Kısa Bellek (ConvLSTM) köprüleri yer almakta, zamansal bilgilerin işlenmesi sağlanmaktadır. Ayrıca SE blokları ile dikkat mekanizması ve kalıcı bağlantılarla öğrenme derinliği artırılmış, yardımcı çıkışlarla eğitim sürecinde derin denetim sağlanmıştır. Çalışmanın amacı, çok bantlı Sentinel-2 zaman serisi görüntülerinden 11 farklı tarım ürününün yüksek doğrulukla sınıflandırılmasıdır. Önerilen BCDUNetConvLSTM modelinin başarısı doğruluk, F1 skor, Cohen Kappa ve geri çağırma değeri gibi çeşitli değerlendirme metrikleri kullanılarak analiz edilmiş, doğruluk değerlendirilmesi ile model performansı ve sonuçları tartışılmıştır.

## YÖNTEM

Çalışmada temel veri kaynağı olarak Avrupa Uzay Ajansı tarafından sağlanan, Kırklareli'ne ait beş farklı tarihte elde edilmiş 10 ve 20 metre mekânsal çözünürlüklü Sentinel-2 Level-2A görüntüleri kullanılmıştır. Her bir tarih için görüntüler mozaiklenerek 15 kanallık zaman serisi yığınlarına dönüştürülmüştür. Çalışma alanına ait etiket verileri, T.C. Tarım ve Orman Bakanlığı tarafından oluşturulan Çiftçi Kayıt Sistemi'nden (ÇKS) alınarak parsel geometrisi, alanı ve ürün türü bilgileriyle eşleştirilmiştir. BCDUNetConvLSTM modeli, uzamsal ve zamansal örüntüleri öğrenebilecek şekilde tasarlanmış ve 11 farklı tarım ürününü sınıflandırmak üzere eğitilmiştir.

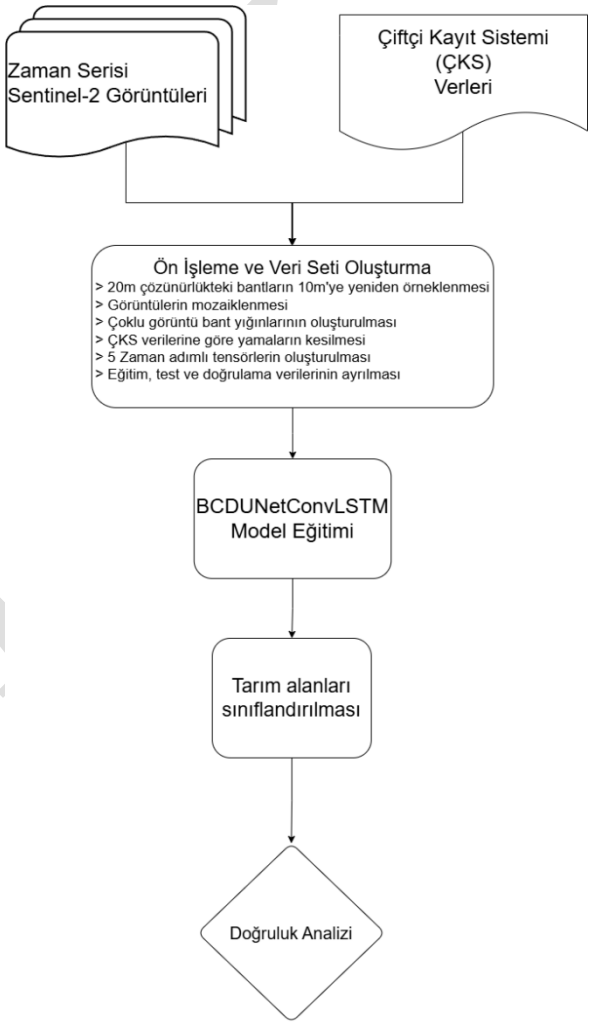


**Şekil 1.** Yöntemin akış diyagramı.

### Çalışma Alanı ve Veriler

Çalışma alanı olarak tarımsal çeşitliliği yüksek Kırklareli ili seçilmiş, analizlerde 2021 yılı Nisan, Haziran, Temmuz, Ağustos ve Eylül aylarına ait Sentinel-2 görüntüleri kullanılmıştır (Şekil 1). Model eğitimi için bölgede yaygın olarak yetiştirilen 11 ürün türü (*arpa, ayçiçeği, buğday, çayır otu, çeltik, ceviz, kolza, mısır, tritikale, yonca, yulaf*) hedeflenmiştir. Sentinel-2 uydu görüntülerine ait bantlar ve eklenen indisler, ürünlerin spektral farklılıklarını yansıtarak sınıflandırma başarımına katkı sağlamıştır.

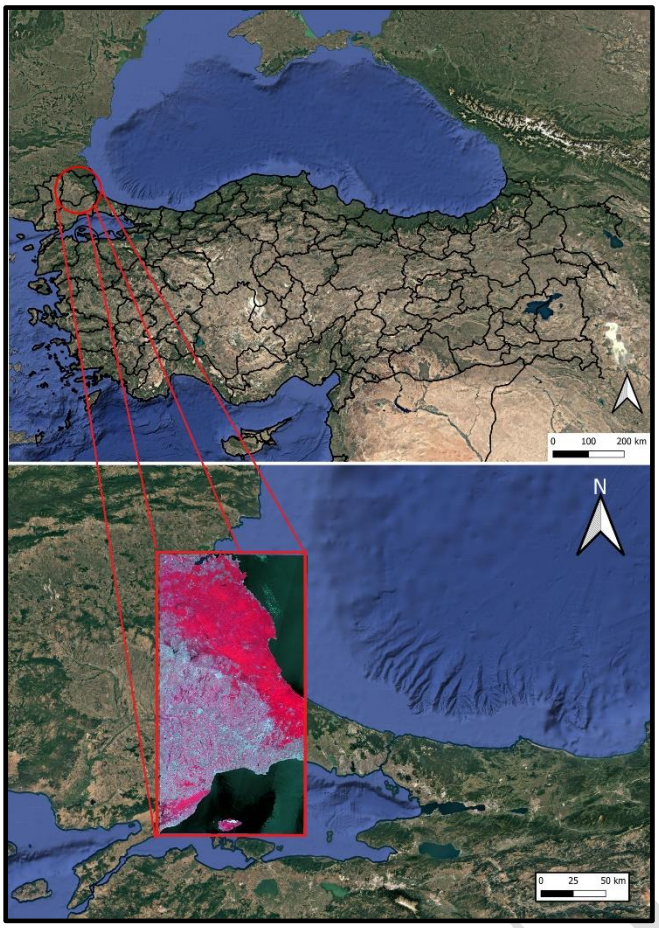


**Şekil 2.** Çalışma Alanı

Çalışmada yer gerçeği veri olarak ÇKS'de bulunan 14.869 adet parsel kullanılmıştır. Kullanılan parsellerin seçilen uydu görsellerinde işlendiği teyit edilmiştir ve doğruluğu kabul edilmiştir. Parsellerin geometri, alan ve ürün türü bilgileri kullanılarak veri etiketlemesi gerçekleştirilmiştir. (Şekil 3).

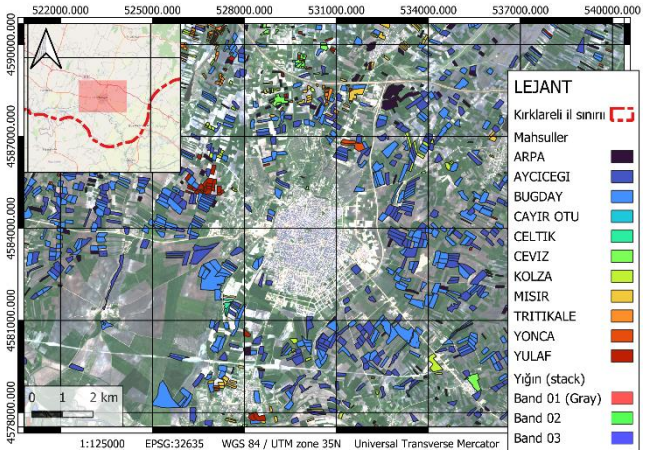


**Şekil 3.** ÇKS Tarım Arazileri

## Veri Setinin Hazırlanması ve Ön İşlemeler

Çalışmada, 2021 yılı Nisan, Haziran, Temmuz, Ağustos ve Eylül aylarında Sentinel-2 uydusu tarafından Kırklareli ili üzerinde elde edilen Seviye-2A (L2A) görüntüler kullanılmıştır. Platformun sunduğu çok bantlı görüntüleme kapasitesi doğrultusunda, 10 m çözünürlüklü bantlara ek olarak 20 m çözünürlüklü bantlar da 10 m'ye yeniden örneklenmiş; Normalleştirilmiş Bitki Örtüsü Fark İndeksi (NDVI) [0–10 000], Normalleştirilmiş Bitki Örtüsü Fark İndeksi (NDVI) [–1–1], Normalleştirilmiş Su Fark İndeksi (NDWI), Geliştirilmiş Bitki Örtüsü İndeksi (EVI) ve Kırmızı Kenar Normalleştirilmiş Bitki Örtüsü Fark İndeksi (RED-NDVI) dâhil olmak üzere toplam 15 kanaldan oluşan zaman serisi yığınlar (stack) hâlinde yapılandırılmıştır (Tablo 1).

| Bant/İndeks | Açıklama | Çözünürlük (m) |
|---|---|---|
| Band-2 | Mavi (Blue) | 10 |
| Band-3 | Yeşil (Green) | 10 |
| Band-4 | Kırmızı (Red) | 10 |
| Band-8 | Yakın Kızılötesi (NIR) | 10 |
| Band-5 | Kırmızı Kenar (VRE) | 10 (20m'den yeniden örneklenmiş) |
| Band-6 | Kırmızı Kenar (VRE) | 10 (20m'den yeniden örneklenmiş) |
| Band-7 | Kırmızı Kenar (VRE) | 10 (20m'den yeniden örneklenmiş) |
| Band-8A | Kırmızı Kenar (VRE) | 10 (20m'den yeniden örneklenmiş) |
| Band-11 | SWIR-1 | 10 (20m'den yeniden örneklenmiş) |
| Band-12 | SWIR-2 | 10 (20m'den yeniden örneklenmiş) |
| NDVI [0,10000] | Normalize Bitki İndeksi (ölçekli) | Türetilmiş |
| NDVI [-1,1] | Normalize Bitki İndeksi (gerçek) | Türetilmiş |
| NDWI | Su İndeksi | Türetilmiş |
| EVI | Geliştirilmiş Bitki İndeksi | Türetilmiş |
| RedEdge NDVI | Kırmızı Kenar NDVI | Türetilmiş |

**Tablo 1.** Yığın görüntülerin içerdiği bantlar ve türetilmiş indisler

Sentinel-2 görüntülerinin çalışma alanına ait iki geçiş blok olması nedeniyle öncelikle mozaikleme yapılmış, ardından Kırklareli il sınırları esas alınarak görüntüler kırpılmıştır. ÇKS verileriyle eşleştirme sürecinde, her bir tarım parselinin farklı noktaları merkeze alınarak 64×64 piksel boyutunda yamalar oluşturulmuştur. Hazırlanan yama kümesi, ÇKS'den alınan ürün etiketleriyle eşleştirilerek 11 tarım ürününü temsil edecek biçimde etiketlenmiştir. Veri seti eğitim (%70), doğrulama (%15) ve test (%15) olarak üç gruba ayrılmış; sınıf dağılımında denge gözetilerek modellerin genelleme performansının sağlıklı biçimde ölçülmesi hedeflenmiştir.

**BCDUNetConvLSTM Modeli ve Eğitim Süreci**

Bu çalışmada kullanılan BCDUNetConvLSTM modeli, klasik U-Net yapısına ConvLSTM, kalıcı bağlantılar ve SE () dikkat mekanizmaları uygun hale getirilerek zamansal ve uzamsal örüntüleri birlikte öğrenebilmesi, tarımsal değişimleri hassas biçimde tespit etmesi amaçlanarak geliştirilmiştir. 71.364 örnekten oluşan veri kümesi, veri artırımı yöntemleri (aynalama, döndürme) ve sınıf ağırlığı uygulanarak oluşturulmuştur.

Eğitim süreci **Google Colab** platformunda **NVIDIA T4** GPU ile yaklaşık 4.5 saat sürmüştür. Epoch sayısı 50 olarak planlanmış, metrikler bakımından en iyi modele 25. epoch'ta ulaşılmış ve model kaydedilmiş, 35. epoch'ta metriklerde bir gelişme olmadığı için erken durdurma algoritması devreye girerek eğitim süreci tamamlanmıştır. Adam optimizer ve ReduceLROnPlateau algoritmaları kullanılmıştır. Modelin performansı IoU, doğruluk ve F1 skor, duyarlılık Cohen Kappa ve geri çağırma değeri ile değerlendirilmiştir.

Kayıp fonksiyonu, Cohen Kappa ve ortalama IoU değer grafikleri sırasıyla Şekil 3, 4 ve 5'te verilmiştir.

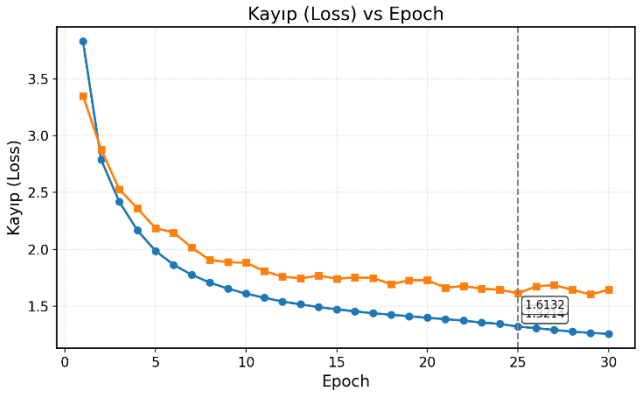


**Şekil 4.** Kayıp fonksiyonu grafiği

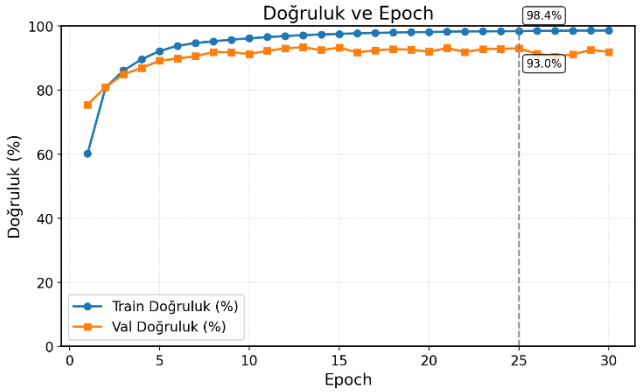


**Şekil 5.** Doğruluk değer grafiği

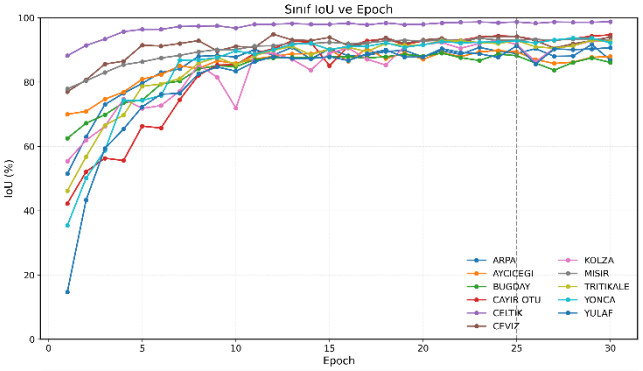


| ARPA | AYCICEGI | BUGDAY | CAYIR OTU | CELTIK | CEVIZ | KOLZA | MISIR | TRITIKALE | YONCA | YULAF |
|---|---|---|---|---|---|---|---|---|---|---|
| 88.9% | 89.1% | 88.2% | 94.2% | 98.7% | 94.2% | 91.7% | 93.0% | 92.9% | 92.8% | 91.3% |

**Şekil 6.** Her sınıf için IoU değer grafiği

## BULGULAR ve TARTIŞMA

Eğitim sürecinde doğruluk, ortalama IoU, Cohen Kappa ve F1 skor değeri metriklerinde istikrarlı bir artış gözlemlenmiştir. %88.2 IoU değeri ile ***Buğday*** en düşük IoU değerine sahip sınıf olmuştur. Doğrulama seti üzerinde %93,0 doğruluk, %95,5 ağırlıklı F1 skor, %92,3 ortalama IoU ve 0.92 Cohen Kappa değeri elde edilmiştir. Bu sonuçlar, modelin sınıflar arası ayırt edici özellikleri başarılı şekilde öğrendiğini ortaya koymakta olup, genel performansı artırmak için veri artırımı, hiper parametre optimizasyonu ve sınıf dengeleme gibi yöntemlerin gelecekteki çalışmalarda değerlendirilmesi önerilmektedir. Model ile oluşturulan tematik sınıflandırma haritası Şekil 7'de sunulmuştur.

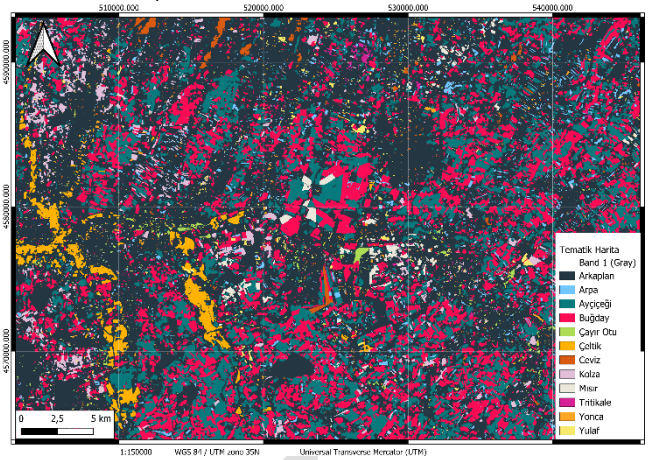


**Şekil 7.** Model ile Oluşturulmuş Tematik Sınıflandırma Haritası

Şekil 8'de, geliştirilen ve eğitilen model tarafından elde edilen sınıflandırma sonuçları ile yer gerçeği (ground truth) verileri yan yana görsel olarak sunulmuştur. Görsel karşılaştırma, modelin sınıfları yüksek doğrulukla tahminler üretebildiğini ve tarım alanları sınırlarını ayırabildiği gözlemlenmiştir. Şekil (a), model tarafından tahmin edilen tematik haritayı, Şekil (b) ise referans (yer gerçeği) haritasını temsil etmektedir.

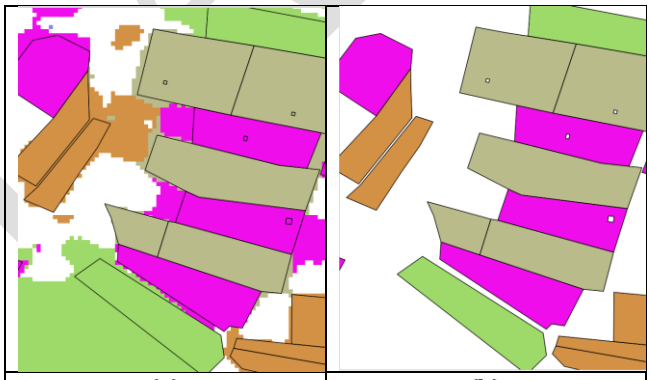


**Şekil 8.** Model tahmini (a) ile yer gerçeği (b) tematik haritalarının karşılaştırılması

Modelin performansını sayısal olarak değerlendirmek amacıyla, test verisi üzerinde rastgele seçilmiş örnek noktalar üzerinden bir karışım matrisi oluşturulmuş ve tahmin edilen etiketler ile yer gerçeği arasındaki eşleşmeler analiz edilerek genel doğruluk ve Kappa katsayısı hesaplanmıştır. Rastgele örnekleme ile elde edilen ve Tablo 2'de sunulan karışım matrisi; sınıf bazında başarı oranlarını, sınıflar arası karışmaları ve modelin genel tutarlılığını ortaya koymaktadır. Tabloda her satır modelin tahmin ettiği, her sütun ise gerçek (referans) sınıfı temsil etmektedir. Matristen elde edilen genel doğruluk (%95.2) ve Kappa katsayısı (0.94), modelin yüksek istikrarla doğru sınıflandırma yaptığını göstermektedir.

| Sınıf | ARPA | AYÇİÇEĞİ | BUĞDAY | ÇAYIR OTU | ÇELTİK | CEVİZ | KOLZA | MISIR | TRİTİKALE | YONCA | YULAF | TOPLAM | KD (%) |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| ARPA | 272 | 2 | 2 | 0 | 0 | 0 | 3 | 1 | 2 | 3 | 1 | 286 | 95.1 |
| AYÇİÇEĞİ | 0 | 492 | 12 | 0 | 4 | 0 | 2 | 1 | 0 | 0 | 0 | 511 | 96.3 |
| BUĞDAY | 7 | 12 | 524 | 0 | 2 | 1 | 0 | 5 | 0 | 0 | 4 | 555 | 94.4 |
| ÇAYIR OTU | 0 | 0 | 2 | 75 | 0 | 2 | 0 | 0 | 0 | 0 | 0 | 79 | 94.9 |
| ÇELTİK | 0 | 1 | 1 | 1 | 137 | 0 | 0 | 0 | 0 | 0 | 4 | 144 | 95.1 |
| CEVİZ | 3 | 0 | 1 | 3 | 0 | 116 | 2 | 3 | 0 | 1 | 0 | 129 | 89.9 |
| KOLZA | 0 | 8 | 2 | 0 | 0 | 0 | 198 | 0 | 4 | 0 | 0 | 212 | 93.4 |
| MISIR | 0 | 1 | 0 | 0 | 0 | 5 | 0 | 287 | 1 | 0 | 1 | 295 | 97.3 |
| TRİTİKALE | 0 | 0 | 1 | 0 | 0 | 0 | 1 | 0 | 113 | 0 | 0 | 115 | 98.3 |
| YONCA | 0 | 0 | 0 | 1 | 0 | 3 | 0 | 0 | 0 | 93 | 0 | 97 | 95.9 |
| YULAF | 0 | 0 | 3 | 0 | 5 | 0 | 0 | 0 | 0 | 0 | 104 | 112 | 91.2 |
| **TOPLAM** | 282 | 516 | 549 | 80 | 148 | 127 | 206 | 297 | 120 | 97 | 114 | 2536 | |
| ÜD (%) | 96.5 | 95.3 | 95.4 | 93.8 | 92.6 | 91.3 | 93.4 | 96.6 | 94.2 | 95.9 | 91.2 | | |

**Genel Doğruluk (OA): 95.11%** **Kappa: 0.9435**

*KD: Kullanıcı Doğruluğu* *ÜD: Üretici Doğruluğu*

**Tablo 2.** Karışım Matrisi, Doğruluk ve Kappa Değeri

Rastgele seçilen test noktalarına dayalı olarak oluşturulan karışım matrisine göre modelin sınıf bazlı başarımı oldukça yüksektir. Doğruluk değerleri ürün türlerinde %94'ün üzerinde seyretmiş olup, özellikle *Tritikale* (%98,3*), Mısır* (%97.3*) ve Çayır otu* (%94.9*)* gibi sınıflarda modelin güçlü tahmin performansı sergilediği görülmektedir. Bazı sınıflarda modelin tahmin doğruluğu ile sınıf ayırt etme başarısı arasında küçük farklılıklar gözlemlenmiştir.

Örneğin *Ayçiçeği* sınıfında model bu sınıfa ait örneklerin %95.3'ünü doğru tahmin etmiştir, ancak bu sınıfa ait olduğu tahmin edilen tüm piksellerin yalnızca %96.3'ü gerçekten *Ayçiçeği* sınıfına aittir. Bu durum, modelin bazı farklı sınıflara ait pikselleri de zaman zaman *Ayçiçeği* olarak sınıflandırdığını göstermektedir. Benzer şekilde, *Çeltik*, *Ceviz* ve *Kolza* sınıfları arasında belirgin düzeyde sınıflandırma karışıklıkları gözlemlenmiştir. Bu tür karışıklıkların yalnızca spektral örtüşmelerden kaynaklanmadığı; aynı zamanda modelin eğitimi ve doğrulama sürecinde kullanılan yersel etiket verilerinin güvenilirliğiyle de doğrudan ilişkili olduğu değerlendirilmektedir. Nitekim sıklıkla vurgulandığı üzere, ÇKS verilerine dayalı olarak gerçekleştirilen ürün deseni sınıflandırma çalışmalarında, etiket verisinin doğruluğu ve güncelliği metodolojik güvenilirlik açısından tartışmalı bir konudur. Eğitim sürecinde esas ürünün spektral yansıması ile yer gerçeği veri olarak ÇKS ile elde edilen etiket veri arasında farklılık tespitte ve piksel düzeyinde tanımlayabilmede doğrulukta istenmeyen düşüş ve yanıltıcı geçiş, zaman adımlı belleği yanılttığı düşünülmektedir. Parsel düzeyindeki ürün bilgisinin heterojen arazi kullanımı, eksik veya hatalı beyanlar, sınıflandırma dönemine ait verilerin güncellenmemesi gibi nedenlerle gerçek durumu yansıtmayabilmesi, modelin doğru tahminlerinin yanlış olarak değerlendirilmesine neden olabilmektedir. Bu durum, özellikle düşük destekli sınıflarda model başarısının eksik temsil edilmesine ve istatistiksel metriklerin göreli olarak zayıf görünmesine yol açmaktadır. Dolayısıyla, sınıflar arası spektral benzerliklerin yanı sıra, etiket verisinin doğruluk ve tutarlılık düzeyi, genel model performansını etkileyen temel kısıtlayıcı faktörlerden biri olarak değerlendirilmelidir.

## SONUÇ

Bu çalışma kapsamında, zamansal çözünürlüğü yüksek Sentinel-2 uydu görüntüleri kullanılarak, çok zamanlı veriler üzerinde çalışan BCDUNetConvLSTM modeli ile 11 farklı tarımsal ürün türü sınıflandırılmıştır. Modelin genel doğruluk, F1 skoru ve ortalama IoU gibi performans metriklerine göre elde ettiği sonuçlar, özellikle fenolojik gelişim süreçleri zamana bağlı olarak değişen ürün türlerinin ayrıştırılmasında başarılı olduğunu ortaya koymuştur.

Model eğitim sürecinde karşılaşılan en belirgin zorluk sınıf dengesizliği olmuş; bu durum, bazı sınıflarda düşük performansa yol açmıştır. Normalize edilmiş sınıf ağırlıkları ve veri artırma teknikleriyle bu etki kısmen azaltılabilmiştir. Modelin doğruluk gelişimi süreci **Şekil 5**'te gösterildiği üzere istikrarlı bir ilerleme sergilerken, sınıf bazlı IoU performansları **Şekil 6**'da detaylandırılmıştır. Yaygın sınıflarda yüksek başarı elde edilirken, *Arpa, Ayçiçeği ve Buğday* gibi sınıflarda performansın diğer sınıflara nazaran düşük olduğu görülmüştür. Bu durum, gelecekte daha dengeli veri kümeleri, örnekleme teknikleri veya az sayıda örnekle öğrenme gibi yaklaşımların gerekliliğini ortaya koymaktadır. Model, zaman serili uydu verilerine dayalı tarımsal sınıflandırma uygulamalarında güçlü bir potansiyele sahip olup, ileri çalışmalar için veri kalitesinin artırılması, ek spektral indekslerin entegrasyonu ve zaman serilerinin daha etkin kullanımı önerilmektedir.

Elde edilen bulgular hem uzamsal hem de zamansal boyutta anlamlı desenleri birlikte öğrenebilen ConvLSTM tabanlı hibrit mimarilerin, tarım gibi mevsimsel değişimlerin belirgin olduğu alanlarda yüksek çözünürlüklü sınıflandırma görevlerinde avantaj sunduğunu göstermektedir. Özellikle fenolojik gelişimi zamana yayılan mahsullerde, klasik tek zamanlı analizlerin yetersiz kaldığı durumlarda bu tür zaman serili modellerin sınıflandırma doğruluğunu ciddi oranda artırabileceği anlaşılmıştır. Bu bağlamda, çalışma sonuçları yalnızca yöntemsel bir katkı sunmakla kalmamakta, aynı zamanda sürdürülebilir tarım izleme sistemlerinin geliştirilmesi açısından da pratik bir değer taşımaktadır. Bununla birlikte, modelin klasik U-Net mimarisiyle doğrudan karşılaştırılmamış olması, LSTM yapıların zamansal bilgi kazandırmadaki katkısının sayısal olarak ölçülmesini sınırlamaktadır. Bu eksiklik, modelin performans avantajlarını nitel olarak ortaya koysa da farklı mimarilerle yapılacak kontrollü karşılaştırmalara olan ihtiyacı da ortaya koymaktadır. Gelecek çalışmalarda, aynı veri seti üzerinde klasik U-

Net, DeepLabV3, Dönüştürücütabanlı yapılar gibi alternatif yaklaşımların sistematik olarak değerlendirilmesi hem zaman serili hem de çok kaynaklı (örneğin optik-SAR füzyonu) veri entegrasyonuyla modelin genellenebilirliğinin test edilmesi önemli katkılar sağlayacaktır. Böylece, tarımsal ürün sınıflandırması gibi karmaşık problemler için daha kararlı ve ölçeklenebilir çözümler geliştirilebilecektir.

**TEŞEKKÜR**

Bu çalışmada, deneyim ve görüşleriyle sürece katkı sunan Melih Altay, Merve Hilal Arslan ve Müslüm Altun'a; ayrıca ÇKS verilerini sağlayan T.C. Tarım ve Orman Bakanlığı'na teşekkür ederiz.

**Yazar Katkı Oranı**

**İbrahim YEĞEN:** Literatür Taraması, Veri Analizi, Metodoloji Geliştirme, Yazım

**Oğuzhan TOSUN**: Literatür Taraması, Veri Analizi, Metodoloji Geliştirme, Yazım

**Mustafa TÜRKER:** Literatür Taraması, Metodoloji Düzenleme, Sonuçların Değerlendirilmesi, Revizyon

**Çıkar Çatışması/Çakışması**

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

**KAYNAKÇA**

Azad, R., Asadi-Aghbolaghi, M., Fathy, M., & Escalera, S.(2019). Bi-directional ConvLSTM U-Net withdensely connected convolutions. In *Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops* (pp. 0–0).

Buttar, S., & Sachan, M. (2023). CropNet: A ResNet-based deep learning model for crop classification using Sentinel-2 satellite imagery. *The Journal of Supercomputing*.

Gömez, C., White, J. C., & Wulder, M. A. (2016). Optical remotely sensed time series data for land cover classification: a review. *ISPRS Journal of Photogrammetry and Remote Sensing, 116*, 55–72.

Hu, J., Shen, L., & Sun, G. (2018). Squeeze-and-excitation networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 7132–7141). Salt Lake City, UT, USA.

Kussul, N., Lavreniuk, M., Shelestov, A., & Yailymov, B. (2017). Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters*, 14(5), 778–782.

Lee, C.-Y., Xie, S., Gallagher, P., Zhang, Z., & Tu, Z. (2015). Deeply-supervised nets. In Proceedings of the 18th International Conference on Artificial Intelligence and Statistics (AISTATS) (pp. 562–570).

Lobell, D. B., & Asner, G. P. (2004). Cropland distributions from temporal unmixing of MODIS data. Remote Sensing of Environment, 93(3), 412–422.

Long, J. A., Lawrance, R. L., Greenwood, M. C., Marshall, L., & Miller, P. R. (2013). Object-oriented crop classification using multitemporal ETM+ SLC-off imagery and random forest. *Remote Sensing, 50*, 418–436.

Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. In Medical Image Computing and Computer-Assisted Intervention (MICCAI) (pp. 234–241). Springer.

Rußwurm, M., & Körner, M. (2018). Multi-temporal land cover classification with sequential recurrent encoders. ISPRS International Journal of Geo-Information, 7(4), 129.

Shi, X., Chen, Z., Wang, H., Yeung, D.-Y., Wong, W.-K., & Woo, W.-C. (2015). Convolutional LSTM network: A machine learning approach for precipitation nowcasting. Advances in Neural Information Processing Systems, 28.

Torunlar, H., Tuğaç, M. G., & Duyan, K. (2021). Nesne tabanlı sınıflandırma yönteminde Sentinel-2A uydu görüntüleri kullanılarak tarımsal ürün desenlerinin belirlenmesi; Konya- Karapınar örneği. Türkiye Uzaktan Algılama Dergisi, 3(2), 36–46.

Tunca, E., & Köksal, E. S. (2021). Sentinel 2 uydu görüntülerinden bazı bitki türlerinin makine öğrenmesi ile belirlenmesi. ÇOMÜ Ziraat Fakültesi Dergisi, 9(1), 189–200.

Van Kirk, J., & Addy, F. (2023). Semantic segmentation of cropland with satellite imagery. Stanford University Report.

Yücer, A. (2020) The Land Use in Turkey: A General Assessment and Affecting Factors. *Journal of Geoscience and Environment Protection*, **8**, 102-116.

Zhang, K., Kang, J., Xu, X., & Zhang, L. (2020). Accessing the temporal and spectral features in crop type mapping using multi-temporal Sentinel-2 imagery: A case study of Yi'an County, Heilongjiang Province, China. Computers and Electronics in Agriculture, 176, 105618.

Zhang, M., & Kovacs, J. M. (2012). The application of small unmanned aerial systems for precision agriculture: A review. Precision Agriculture, 13(6), 693–712.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Süper Çözünürlük Uygulamasının Askeri Operasyonlara Etkisi – Sentinel-2 Uydu Görüntüsü Örneği

**Kürşat Samet DEMİR**[1], **Doç. Dr. S. Sefa BİLGİLİOĞLU**[2]

[1]*T.C. Milli Savunma Bakanlığı, Harita Genel Müdürlüğü, Askeri Coğrafya Dairesi Başkanlığı, Ankara, Türkiye*
[2]*T.C. Aksaray Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Aksaray, Türkiye*

**Anahtar Kelimeler**
Uzaktan Algılama
Derin Öğrenme,
Süper Çözünürlük,
Askeri Operasyonlar,
Uydu Görüntüleri

**ÖZET**

Bu çalışmada, askeri operasyonlar için kritik olan uzaktan algılama verilerinin kalitesini artırmaya yönelik süper çözünürlük (Super-Resolution) tekniklerinin potansiyeli incelenmiştir. Çalışmanın odak noktası, Sentinel-2 uydu görüntülerine uygulanan ESRGAN (Enhanced Super-Resolution Generative Adversarial Network) yöntemidir. Uzaktan algılama verilerinde, genellikle çözünürlük sınırlamaları ve görüntü kalitesi, askeri analizler ve hedef tanımlama süreçlerinde zorluklar yaratmaktadır. Özellikle savaş alanlarındaki görüntülerin düşük çözünürlüklü olması, doğru hedef belirleme ve detaylı analiz yapmayı zorlaştırmaktadır. Bu çalışmada, ESRGAN yöntemi ile çözünürlük artırılarak, askeri operasyonlarda kritik olan detaylar daha net hale getirilmiştir. Çalışma, Bakhmut bölgesine ait Sentinel-2 görüntüleri üzerinde gerçekleştirilmiştir. Bu bölge, askeri anlamda stratejik öneme sahip olup, görüntülerin yüksek çözünürlükte analizi, hedef tespiti ve ilerleme değerlendirmesi gibi operasyonel süreçlerde büyük fayda sağlamaktadır. Süper çözünürlük tekniği ile detayların belirginleşmesi, karar alma süreçlerini hızlandırarak, askeri strateji geliştirmede etkinliği artırmaktadır. Çalışma, süper çözünürlüğün askeri alandaki uygulamalarını inceleyerek, bu teknolojinin gelecekte daha hassas, verimli ve güvenilir uzaktan algılama uygulamalarına entegrasyonunu desteklemektedir.

# The Impact of Super-Resolution Application on Military Operations – A Sentinel-2 Satellite Image Case

**Keywords**
Remote Sensing
Deep Learning
Super Resolution,
Military Operations,
Satellite Imagery

**ABSTRACT**

This study investigates the potential of super-resolution techniques to enhance the quality of remote sensing data, which is critical for military operations. The focus of the study is the application of ESRGAN (Enhanced Super-Resolution Generative Adversarial Network) on Sentinel-2 satellite imagery. Remote sensing data often faces challenges due to resolution limitations and image quality, which complicates military analysis and target identification processes. In particular, low-resolution imagery in combat zones makes it difficult to accurately identify targets and perform detailed analyses. In this study, the ESRGAN method is employed to increase resolution, making critical details clearer for military operations. The study is conducted on Sentinel-2 imagery of the Bakhmut region, a strategically significant area. High-resolution imagery of this region plays a crucial role in operational processes, such as target detection and progress assessment. By enhancing image resolution, super-resolution techniques help expedite decision-making, increasing the effectiveness of military strategy development. The study highlights the applications of super-resolution in military contexts, supporting the integration of this technology into future remote sensing applications that require greater accuracy, efficiency, and reliability.

## GİRİŞ

Günümüzde uydu görüntüleri, askeri operasyonlar, doğal afetler, çevre izleme ve tarım gibi birçok alanda kritik bir rol oynamaktadır (Campbell & Wynne, 2011). Bu görüntüler, stratejik kararların alınmasında, hedef tespiti ve analizlerinde, coğrafi bilgi sistemleri (GIS) uygulamalarında kullanılır. Ancak, bu görüntülerin çoğu, çözünürlük sınırlamaları nedeniyle detay eksikliği gösterir ve bu durum, özellikle askeri operasyonlarda ciddi zorluklar oluşturur (Zhang et al., 2020). Düşük çözünürlüklü görüntüler, hedeflerin net bir şekilde tespit edilmesini ve çevresel analizlerin doğru bir şekilde yapılmasını engeller. Bu tür sınırlamalar, operasyonel verimliliği azaltarak, zaman kaybına ve yanlış analizlere yol açabilir (Wang et al., 2022).

Son yıllarda, görüntü çözünürlüğünü artırmak amacıyla derin öğrenme tabanlı yöntemler, özellikle Süper Çözünürlük (Super-Resolution) teknikleri, büyük bir gelişim göstermiştir (Yang et al., 2019). ESRGAN (Enhanced Super-Resolution Generative Adversarial

Network), bu alanda öne çıkan yöntemlerden biridir ve düşük çözünürlüklü görüntülerin daha yüksek çözünürlükte, net ve detaylı bir şekilde yeniden oluşturulmasını sağlar (Wang et al., 2018). Bu yöntem, özellikle askeri operasyonlar gibi hassas alanlarda, daha doğru ve güvenilir analizler yapabilmek için son derece faydalıdır (Zhang et al., 2020).

Modern askeri stratejilerin başarılı şekilde uygulanabilmesi büyük ölçüde yüksek çözünürlüklü uzaktan algılama verilerinin kullanılabilirliğine bağlıdır. Özellikle düşman bölgelerindeki taktik hedeflerinin belirlenmesi, harekât alanı değerlendirmesi ve hasar analizi gibi kritik görevler için submetrik çözünürlükte görüntüler gereklidir (Zhang ve ark., 2020). Ancak, ticari yüksek çözünürlüklü uyduların operasyonel maliyetleri ve politik kısıtlamalar, birçok askeri birim için ESA'nın ücretsiz sunduğu Sentinel-2 görüntülerini tek uygun veri kaynağı haline getirmektedir. Sentinel-2 MSI sensörünün 10 metre uzamsal çözünürlüğü, askeri araçların (2-5 m) ve küçük askeri tesislerin (5-10 m) teşhisinde önemli sınırlamalar oluşturmaktadır (Wang ve ark., 2022).

Bu çalışmada, süper çözünürlük için ESRGAN yöntemi tercih edilmiştir. ESRGAN, detay üretme kapasitesi, görsel gerçekçiliği, işlem hızının yüksekliği ve açık kaynak kod yapısıyla alternatif yöntemlere kıyasla öne çıkmaktadır. ESRGAN yöntemi kullanılarak, Sentinel-2 uydu görüntülerinin çözünürlüğü artırılmış ve elde edilen yüksek çözünürlüklü görüntülerin askeri operasyonlardaki potansiyel kullanım alanları incelenmiştir. Çalışmanın odak noktası, özellikle Bakhmut bölgesine ait uydu görüntülerinin analiziyle, yüksek çözünürlüklü görüntülerin askeri stratejilerin geliştirilmesindeki rolünü ortaya koymaktır.

## YÖNTEM

Sentinel-2 uydularından elde edilen düşük çözünürlüklü görüntülere derin öğrenme tabanlı süper çözünürlük yöntemi uygulanarak, görsel kalitenin ve detay seviyesinin artırılması hedeflenmiştir. Uygulanan yöntem üç temel bileşenden oluşmaktadır: görüntü kaynağı olarak Sentinel-2 uydu sistemi, çözünürlük artırma sürecinde kullanılan derin öğrenme yapısı ve bu süreci gerçekleştiren süper çözünürlük tekniği. Aşağıda, bu bileşenler detaylı olarak açıklanmıştır.

### Sentinel-2 Uydu Sistemi

Sentinel-2, Avrupa Uzay Ajansı (ESA) tarafından geliştirilen bir uydu sistemidir ve dünya yüzeyini yüksek çözünürlükle gözlemlemeye olanak tanır. Bu sistem, özellikle çevresel izleme, tarım ve askeri alanlarda geniş kullanım alanlarına sahiptir. Sentinel-2, her 5 gün içinde küresel bir kapsama sağlamak için iki uydudan oluşur ve 13 farklı spektral bantta veri sağlar. Bu sayede, farklı yüzeylerin ve nesnelerin çok detaylı bir şekilde analiz edilmesi mümkün hale gelir. Bu çalışmada, Bakhmut bölgesine ait Sentinel-2 uydu görüntüleri kullanılarak, süper çözünürlük uygulaması gerçekleştirilmiştir. Görüntülerin orijinal çözünürlüğü 10 metreden alınan görüntülerle çalışılmıştır.

### Derin Öğrenme

Derin öğrenme, yapay zekâ alanında son yıllarda önemli bir gelişim göstermiş ve özellikle görüntü işleme, doğal dil işleme ve ses tanıma gibi alanlarda başarı göstermiştir (LeCun et al., 2015). Derin öğrenme algoritaları, özellikle sinir ağları kullanarak, büyük veri setlerinden anlamlı özellikler çıkarma ve karmaşık görevleri yerine getirme konusunda etkilidir (Goodfellow et al., 2016). Bu çalışmada, derin öğrenme tabanlı bir model olan ESRGAN (Enhanced Super-Resolution Generative Adversarial Network) kullanılarak, düşük çözünürlüklü uydu görüntülerinin yüksek çözünürlüklü hale getirilmesi sağlanmıştır. ESRGAN, nesne tanıma ve çözünürlük iyileştirme gibi karmaşık görüntü işleme görevlerini başarılı bir şekilde yerine getirebilen bir derin öğrenme modelidir (Wang et al., 2018).

### Süper Çözünürlük

Süper çözünürlük, düşük çözünürlüklü bir görüntünün daha yüksek çözünürlüklü bir versiyonunun üretilmesi işlemidir (Nasrollahi & Moeslund, 2014). Bu işlem, görüntüdeki detayların kaybolmadan netleştirilmesine yardımcı olur. Süper çözünürlük, genellikle iki ana yaklaşımla yapılır: tekli görüntü süper çözünürlüğü (Single Image Super-Resolution, SISR) ve çoklu görüntü süper çözünürlüğü (Multi-Image Super-Resolution, MISR) (Yang et al., 2019). Bu çalışmada, tekli görüntü süper çözünürlüğü yöntemi kullanılmıştır. ESRGAN, bu alandaki en etkili yöntemlerden biri olarak, generatif adversarial ağlar (GAN) kullanarak daha gerçekçi ve net görüntüler üretmektedir (Wang et al., 2018). Modelin eğitiminde, düşük çözünürlüklü uydu görüntüleri ile yüksek çözünürlüklü karşılıkları arasındaki farklar öğrenilmiş ve bu sayede görüntülerin çözünürlüğü artırılmıştır.

## BULGULAR

Bu çalışmada, ESRGAN temelli süper çözünürlük yöntemi kullanılarak Sentinel-2 uydu görüntülerinin çözünürlüğü 4 kat artırılmış ve elde edilen görseller detaylı biçimde analiz edilmiştir. Orijinal Sentinel-2 görüntüsünün çözünürlüğü 10 metre iken, uygulanan yöntemle bu değer yaklaşık olarak 2,5 metreye iyileştirilmiş ve daha yüksek ayrıntı seviyeleri elde edilmiştir.



**Şekil 1.** Orijinal Sentinel-2 Uydu Görüntüsü



**Şekil 2.** SR Uygulanmış Sentinel-2 Uydu Görüntüsü

Süper çözünürlük uygulaması öncesi ve sonrasına ait görüntüler Şekil 1 ve Şekil 2'de yer almaktadır. Görsellerde özellikle bina kümeleri şehir içi yapılaşma alan sınırlarında belirgin bir netlik artışı gözlenlenmektedir. Söz konusu görüntülerde, Şekil-1'de hendek veya bina olduğu gözlemlenmesi zor iken SR uygulanmış Şekil-2'deki görüntüde bina olduğu ve askeri yapılanma olduğu gözlemlenmiştir.

**Şehir içi yapılaşma**: ESRGAN çıktısında binalar arasındaki sınırlar daha net ayrılabilir hale gelmiştir.

Bu iyileşmeler, hem görüntü yorumlama süreçlerini hızlandırmakta hem de askeri keşif, hedef tespiti ve operasyonel planlama gibi uygulamalarda daha güvenilir veri üretimini mümkün kılmaktadır.

**SONUÇ**

ESRGAN (Enhanced Super Resolution Generative Adversarial Network) tabanlı bir derin öğrenme yöntemi kullanılarak, Sentinel-2 uydu görüntülerinin çözünürlüğü artırılmış ve bu iyileştirmenin askeri operasyonlara etkisi değerlendirilmiştir (Wang et al., 2018). Uydu görüntülerinin çözünürlük seviyesinin yükseltilmesi, hem görsel analiz hem de coğrafi bilgi sistemleri (GIS) tabanlı uygulamalar açısından önemli avantajlar sağlamaktadır (Drusch et al., 2012).

Süper çözünürlük uygulaması sayesinde, daha düşük çözünürlüklü Sentinel-2 görüntülerinde belirgin olmayan yapısal detaylar görünür hale getirilmiş, bu sayede hedef tanıma, yol izleme, arazi sınıflandırma ve keşif gibi stratejik görevlerde karar vericilere daha zengin veri sunulmuştur (Wang et al., 2018). Özellikle Bakhmut bölgesine ait test görüntülerinde, ESRGAN yöntemiyle yapılan iyileştirme sonucunda binalar arasındaki sınırlar, tarım arazilerinin geometrisi ve yol altyapısı gibi kritik detaylar net bir şekilde ayrıştırılabilmiştir (Ledig et al., 2017; Drusch et al., 2012).

Bu sonuçlar, süper çözünürlük teknolojilerinin yalnızca akademik ya da teorik değil; aynı zamanda sahaya yönelik, pratik ve etkili çözümler sunduğunu ortaya koymaktadır. Gelecekte, farklı derin öğrenme mimarilerinin ve çok spektral veri setlerinin kullanılmasıyla, bu tür sistemlerin daha da geliştirilebileceği ve askeri operasyonların istihbarat ayağına daha yüksek katma değer sağlayabileceği öngörülmektedir (Yang et al., 2019).

**KAYNAKÇA**

Campbell, J. B., & Wynne, R. H. (2011). Introduction to remote sensing (5th ed.). Guilford Press.

Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., ... & Bargellini, P. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. Remote Sensing of Environment, 120, 25-36.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.

Karabiber, F. (2017). Uzaktan algılama verilerinin askeri amaçlı kullanımında gelişmeler. Harita Teknolojileri Elektronik Dergisi, 9(2), 25-34.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. Nature, 521(7553), 436–444.

Ledig, C., Theis, L., Huszár, F., Caballero, J., Cunningham, A., Acosta, A., ... & Shi, W. (2017). Photo-realistic single image super-resolution using a generative adversarial network. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 4681-4690).

Nasrollahi, K., & Moeslund, T. B. (2014). Super-resolution: A comprehensive survey. Machine Vision and Applications, 25, 1423–1468.

Yang, W., Zhang, X., Tian, Y., Wang, W., Xue, J., & Liao, Q. (2019). Deep learning for single image super-resolution: A brief review. IEEE Transactions on Multimedia, 21(12), 3106–3121.

Zhang, Y., Li, H., & Shen, H. (2020). High-resolution remote sensing imagery in military applications: Recent developments and future directions. ISPRS Journal of Photogrammetry and Remote Sensing, 169, 1–19.

Wang, H., Wang, B., Zhang, J., & Liu, Y. (2022). Deep learning-based super-resolution for military remote sensing images: A review and case study. Remote Sensing, 14(3), 550.

Wang, X., Yu, K., Wu, S., Gu, J., Liu, Y., Dong, C., ... & Change Loy, C. (2018). ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks. In Proceedings of the European Conference on Computer Vision (ECCV) Workshops, 63–79.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Yerden Görüntüye RFM Yöntemi Kullanılarak Göktürk-1 Stereo Pankromatik Görüntülerinden Üç Boyutlu Koordinat Hesabı

**Onur Erişik**[*1], **Hüseyin Topan**[2]

[1]*Hava Kuvvetleri Komutanlığı, Ankara, Türkiye*
[2]*Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Zonguldak, Türkiye*

**Anahtar Kelimeler**
RFM,
3B Koordinat Hesabı,
GeoTransform,
Göktürk-1

**ÖZET**

Optik görüntülerden iki veya üç boyutlu konum bilgisi elde edilmeside RFM (Rasyonel İşlev Modeli) yaygın olarak kullanılan bir koordinat dönüşümü yöntemidir. Bu yöntemle görüntü ile yer koordinat sistemi arasında dönüşüm sağlanabilmektedir. Dönüşüm için gerekli olan katsayılar (RPC: Rational Polynomial Coefficients – Rasyonel Polinom Katsayıları) görüntü sağlayıcı kurum tarafından hesaplanarak kullanıcıya sağlanabildiği gibi kullanıcılar tarafından yer kontrol noktaları yardımıyla da hesaplanabilmektedir. Bu bildiride, Göktürk-1 uydu görüntüleri ile birlikte kullanıcıya sunulan RPC'ler kullanılarak yerden görüntüye RFM yöntemi ile üç boyutlu koordinat hesabı gerçekleştirilmiştir. Zonguldak şehir merkezine ait Göktürk-1 uydusuna ait bindirmeli görüntülerle yapılan çalışmada doğrudan yöneltme ile sırasıyla $m_X = \pm 8{,}53$ m, $m_Y = \pm 11{,}75$ m, $m_h = \pm 4{,}34$ m doğruluğa ulaşılırken, demet dengelemede birinci derece RFM ile yer kontrol noktalarında yaklaşık ±3.7 cm ve denetim noktalarında ±9.88 m doğruluğa ulaşılmıştır. Aynı veriler Catalyst Total Suite OrthoEngine yazılımındaki RFM ile değerlendirildiğinde dahi ±1 YÖA doğruluğa erişilememiştir. Çalışma, ikinci yazar tarafından MATLAB ortamında geliştirilen GeoTransform yazılımı ile gerçekleştirilmiş.

# 3D Georeferencing of Göktürk-1 Stereo Panchromatic Images Using RFM Method With Type of Ground to Image

**Keywords**
RFM,
3D Reconstruction,
GeoTransform,
Göktürk-1

**ABSTRACT**

RFM (Rational Function Model) is a widely used coordinate transformation method to estimate two or three-dimensional coordinates from optical images. This method makes the coordinate transformation between image and ground. The coefficients required for the transformation (RPC: Rational Polynomial Coefficients) can be provided by the image distributor, or alternatively they can be calculated by users with the help of ground control points. In this paper, three-dimensional coordinates were estimated using the RFM method with the RPCs from ground to image in case of Göktürk-1 images covering Zonguldak city centre. Direct orientation accuracy was estimated as $m_X = \pm 8{,}53$ m, $m_Y = \pm 11{,}75$ m, $m_h = \pm 4{,}34$ m, while approximately ±3.7 cm at GCPs and ±9.88 m at CPs were achieved with the first-degree RFM following the bundle adjustment. The same data were run by the Catalyst Total Suite OrthoEngine software, nevertheless the accuracy was worse than ±1 GSD. The study was carried out with GeoTransform developed by the second author in MATLAB.

## GİRİŞ

Uydu görüntülerinden 3B konum belirleme, temelde görüntü koordinatlarının yer (nesne) koordinatlarına dönüştürülmesiyle sağlanır. Dönüşüm doğruluğu kullanılan matematik modele, yardımcı verilerin doğruluğuna, kontrol noktalarının, çizgilerinin veya yüzeylerinın kalitesine bağlı olarak değişkenlik gösterir (Wolf & Dewitt, 2000). Bu amaçla genellikle iki tür algılayıcıya bağımlı yöntem kullanılır. Birincisi algılayıcı sistemin iç ve dış yöneltme ögelerini kullanan ve algılayıcıya göre farklılıklar gösterebilen yöntemler, diğeri ise algılayıcıya bağımlı RFM'dir (Rational Function Model – Rasyonel İşlev Modeli).

Bu bildiride kullanılan RFM, algılayıcının iç ve dış yöneltme ögelerine bağlı kalmadan, görüntü ve nesne koordinatları arasında rasyonel bir işlevle koordinat dönüşümü sağlamaktadır (OGC, 1999). RFM'nin beklenen ($m_0 \leq \pm 1$ YÖA) düzeyde doğruluk sağlaması ve algılayıcı geometrisinden bağımsız olması, 1999 yılında yörüngesine oturtulan IKONOS uydusundan

buyana özellikle yüksek çözünürlüklü uydu görüntülerinden yüksek doğrulukta 2B/3B koordinat elde edilmesine olanak sağlamıştır (Poli & Toutin, 2012).

Bu bildiride ele alınan Göktürk-1 görüntüleri çeşitli araştırmalara konu olsa da RFM ile 3B konum doğruluğunun araştırılması henüz gerçekleştirilmemiştir (Aytekin & Topan, 2024). Bindirmeli uydu görüntülerinden 3B konum doğruluğu hesaplamada standart bir yöntem olan RFM yönteminin GeoEtrim'in alt yazılımı olan GeoTransform'a kazandırılması ve deneysel çalışmanın Göktürk-1 görüntüleri ile gerçekleştirilmesini amaçlayan, ikinci yazarın danışmanlığında birinci yazarın yüksek lisans tezinden uyarlanan bu bildiride algılayıcıya bağımlı yerden görüntüye RFM yöntemi kullanılarak Göktürk-1 stereo pankromatik görüntülerinden 3B konum bilgisi elde edilmesi amaçlanmıştır.

**YÖNTEM**

Yukarıda da değinildiği gibi RFM, temelde algılayıcıdan bağımsız bir matematiksel model olarak değerlendirilebilir. Ancak RPC'lerin elde ediliş yöntemine göre algılayıcıdan bağımsız ve algılayıcıya bağımlı RFM olarak iki yaklaşım bulunmaktadır (Tao ve Hu, 2002). Ayrıca RFM, yerden görüntüye ve görüntüden yere dönüşümü de sağlayacak şekilde iki türe sahiptir. Bu bildiride algılayıcıya bağımlı RFM yöntemi incelenecek olup diğer yaklaşıma değinilmeyecektir.

Algılayıcıya bağımlı RFM'de RPC'ler (Rational Polynomial Coefficients-Rasyonel Polinom Katsayıları) algılayıcıya bağımlı yöneltme yöntemiyle tek veya bindirmeli görüntüler kullanılarak yaklaşık olarak hesaplanan yer koordinatları ile bunlara karşılık gelen görüntü koordinatları yardımıyla hesaplanarak kullanıcıya sunulur. Bu katsayılar başlangıçta (1999'lu yıllarda) sadece yerden görüntüye dönüşümü sağlayacak şekilde kullanıcıya sunulurken günümüzde görüntüden yere dönüşümü sağlayan katsayılar da standart olarak verilmektedir.

Bu bildiride kullanılan yerden görüntüye RFM yöntemi (1) ve (2) bağıntıları ile açıklanmaktadır.

$$r_n = \frac{\sum_{i=0}^{m_i}\sum_{j=0}^{m_j}\sum_{k=0}^{m_k} a_{ijk} X_n^i Y_n^j Z_n^k}{\sum_{i=0}^{m_i}\sum_{j=0}^{m_j}\sum_{k=0}^{m_k} b_{ijk} X_n^i Y_n^j Z_n^k} \tag{1.a}$$

$$c_n = \frac{\sum_{i=0}^{m_i}\sum_{j=0}^{m_j}\sum_{k=0}^{m_k} c_{ijk} X_n^i Y_n^j Z_n^k}{\sum_{i=0}^{m_i}\sum_{j=0}^{m_j}\sum_{k=0}^{m_k} d_{ijk} X_n^i Y_n^j Z_n^k} \tag{1.b}$$

$$r_n = (r - r_0)/s_r \tag{2}$$

Burada $r$ ve $c$ sırasıyla görüntü koordinat sistemindeki satır ve sütun koordinatlarını, *X, Y* ve *Z* yer koordinatlarını, *n* normalizasyon yapıldığını, *0* ötelemeyi, *s* ölçeği, *a, b, c* ve *d* katsayıları (RPC) ifade etmektedir. RFM'nin derecesi *i+j+k<3* kuralına uymak zorundadır. (2) bağıntısı $c_n$, $X_n$, $Y_n$ ve $Z_n$ için benzer şekilde uyarlanabilir. Her ne kadar *X, Y* ve *Z* kartezyen dik koordinat gösterimi için kullanılsa da algılayıcıya bağımlı RFM WGS84 coğrafi koordinatları ile gerçekleştirilmektedir. Dolayısıyla *X* boylam, *Y* enlem ve *Z* yükseklik olarak düşünülebilir. Normalizasyon yapılarak koordinatlar ±1 aralığına getirilerek olası kötü şartlı matris oluşumu önlenir.

Yerden görüntüye koordinat dönüşümünü ifade eden (1) bağıntısı RFM kullanılarak ortogörüntü üretiminde dolaylı ölçüler dengelemesinin işlevsel (fonksiyonel) modelinin oluşturulmasında kullanılabilir. Ancak sayısal yükseklik modeli üretimi gibi uygulamalarda, bindirmeli görüntülerden 3B koordinat hesabının gerçekleştirilmesi gerekir. Bunun için, Tao and Hu (2002) tarafından önerilen hesaba göre

$$r' = \frac{a'_0 + a'_1 Z_u + a'_2 Y_u + a'_3 X_u}{b'_0 + b'_1 Z_u + b'_2 Y_u + b'_3 X_u} \tag{3.a}$$

$$c' = \frac{c'_0 + c'_1 Z_u + c'_2 Y_u + c'_3 X_u}{d'_0 + d'_1 Z_u + d'_2 Y_u + d'_3 X_u} \tag{3.a}$$

$$\begin{aligned}
a'_0 &= a_{000} Z_s Y_s X_s - a_{001} Z_o Y_s X_s - a_{010} Z_s Y_o X_s \\
&\quad - a_{100} Z_s Y_s X_o \\
a'_1 &= a_{110} Y_s X_s \\
a'_2 &= a_{101} Z_s X_s \\
a'_3 &= a_{011} Z_s Y_s \\
b'_0 &= b_{000} Z_s Y_s X_s - b_{001} Z_o Y_s X_s - b_{010} Z_s Y_o X_s \\
&\quad - b_{100} Z_s Y_s X_o \\
b'_1 &= b_{110} Y_s X_s \\
b'_2 &= b_{101} Z_s X_s \\
b'_3 &= b_{011} Z_s Y_s \\
c'_0 &= c_{000} Z_s Y_s X_s - c_{001} Z_o Y_s X_s - c_{010} Z_s Y_o X_s \\
&\quad - c_{100} Z_s Y_s X_o \\
c'_1 &= c_{110} Y_s X_s \\
c'_2 &= c_{101} Z_s X_s \\
c'_3 &= a_{011} Z_s Y_s \\
d'_0 &= d_{000} Z_s Y_s X_s - d_{001} Z_o Y_s X_s - d_{010} Z_s Y_o X_s \\
&\quad - d_{100} Z_s Y_s X_o \\
d'_1 &= d_{110} Y_s X_s \\
d'_2 &= d_{101} Z_s X_s \\
d'_3 &= d_{011} Z_s Y_s
\end{aligned} \tag{4}$$

$$\begin{bmatrix} v_{r_{sol}} \\ v_{c_{sol}} \\ v_{r_{sa\check{g}}} \\ v_{c_{sa\check{g}}} \end{bmatrix} = \begin{bmatrix} a'_{1sol} - r_{sol} b'_{1sol} & a'_{2sol} - r_{sol} b'_{2sol} & a'_{3sol} - r_{sol} b'_{3sol} \\ c'_{1sol} - c_{sol} d'_{1sol} & c'_{2sol} - c_{sol} d'_{2sol} & c'_{3sol} - c_{sol} d'_{3sol} \\ a'_{1sa\check{g}} - r_{sa\check{g}} b'_{1sa\check{g}} & a'_{2sa\check{g}} - r_{sa\check{g}} b'_{2sa\check{g}} & a'_{3sa\check{g}} - r_{sa\check{g}} b'_{3sa\check{g}} \\ c'_{1sa\check{g}} - c_{sa\check{g}} d'_{1sa\check{g}} & c'_{2sa\check{g}} - c_{sa\check{g}} d'_{2sa\check{g}} & c'_{3sa\check{g}} - c_{sa\check{g}} d'_{3sa\check{g}} \end{bmatrix} \begin{bmatrix} Z \\ Y \\ X \end{bmatrix} - \begin{bmatrix} r_{sol} b'_{0sol} - a'_{0sol} \\ c_{sol} d'_{0sol} - c'_{0sol} \\ r_{sa\check{g}} b'_{0sa\check{g}} - a'_{0sa\check{g}} \\ c_{sa\check{g}} d'_{0sa\check{g}} - c'_{0sa\check{g}} \end{bmatrix} \tag{5}$$

Burada *v* düzeltmeyi temsil etmektedir. (5) bağıntısı

$$\underline{v} = \underline{A}\,\underline{P} - \underline{l} \tag{6}$$

şeklinde matris gösterimi ile gösterilebilir. En küçük kareler yaklaşımı ile $\underline{v}^T \underline{v} = en\ k\ddot{u}\ddot{c}\ddot{u}k$ şeklinde kabul edilirse

$$\underline{P} = (\underline{A}^T \underline{A})^{-1} \underline{A}^T \underline{l} \tag{7}$$

şeklinde yer koordinatları hesaplanabilir. Dengeleme hesabında görüntü koordinatları (*r* ve *c)* ölçü (*l*), RPC'lere ve denetim noktalarının yaklaşık yer koordinatlarına getirilecek düzeltmeler dengeleme bilinmeyeni ($d_{RPC}$) olarak kabul edilmiştir. Bu durumda, dolaylı ölçüler dengelemesine göre demet dengelemenin işlevsel modeli

TASLAK

$$\underline{A} = \begin{bmatrix} \underline{A}_{RPC_{sol}} & \underline{0} \\ \underline{0} & \underline{A}_{RPC_{sağ}} \quad \underline{A}_{XYZ} \end{bmatrix} \tag{8}$$

$$\underline{A}_{RPC} = \begin{bmatrix} \frac{\partial r}{\partial a_{000}} & \cdots & \frac{\partial r}{\partial b_{111}} & \frac{\partial c}{\partial c_{000}} & \cdots & \frac{\partial c}{\partial d_{111}} \end{bmatrix} \tag{9}$$

$$\underline{A}_{XYZ} = \begin{bmatrix} \frac{\partial r}{\partial X} & \frac{\partial r}{\partial Y} & \frac{\partial r}{\partial Z} \\ \frac{\partial c}{\partial X} & \frac{\partial c}{\partial Y} & \frac{\partial c}{\partial Z} \end{bmatrix} \tag{10}$$

$$\underline{d}_{unk} = [da_{000} \dots dd_{111}\ dX\ dY\ dZ]^T \tag{11}$$

$$\underline{d}_{unk} = [\underline{d}_{RPC} \quad \underline{d}_{XYZ}] \tag{12}$$

$$\underline{l} - \underline{l}\big|_0 = \begin{bmatrix} (r - r|_0)_{sol} & & \\ (c - c|_0)_{sol} & & \\ & (r - r|_0)_{sağ} & \\ & (c - c|_0)_{ssağ} & \end{bmatrix} \tag{13}$$

$$\underline{d}_{unk} = \left(\underline{A}^T\underline{A} + \kappa\underline{E}\right)^{-1}\underline{A}^T\left(\underline{l} - \underline{l}\big|_0\right) \tag{14}$$

$$\overline{RPC} = \underline{RPC}\big|_0 + \underline{d}_{RPC} \tag{15}$$

$$\overline{XYZ} = \underline{XYZ}\big|_0 + \underline{d}_{XYZ} \tag{16}$$

$$\underline{v} = \underline{l}\big|_0 - \underline{l} + \underline{A}\,\underline{d}_{RPC} \tag{17}$$

$$\bar{\underline{l}} = \underline{l} + \underline{v} \tag{18}$$

$$m_0 = \pm\sqrt{\frac{\underline{v}^T\underline{v}}{f}} \tag{19}$$

$$f = 2n - u \tag{20}$$

Burada $v$ düzeltmeleri, $|_0$ yaklaşık değerleri, $\underline{A}$ RPC ve denetim noktalarının yaklaşık yer koordinatlarına göre oluşturulan Jakobiyen matrisi, $m_0$ soncul karesel ortalama hatayı temsil etmektedir ve $m_0 \leq \pm 1$ piksel olması beklenir (Leprince, Barbot, Ayoub, & Avouac, 2007). κ düzenlileştirme için kullanılan Tikhonov katsayısıdır ve $\underline{A}^T\underline{A}$'nın özdeğerleri arasından seçilir. $\underline{E}$ ise birim matristir (Terlemezoğlu & Topan, 2020a). $f$ serbestlik derecesi, $n$ toplam nokta sayısı, $u$ ise bilinmeyen sayısıdır. $\underline{A}_{RPC}$'nin boyutları $2n \times u_{RPC}$, $\underline{A}_{XYZ}$'nin boyutları ise $2n \times 3n_{DN}$ ($n_{DN}$ denetim noktası sayısı) kadardır. Burada kullanılan denetim noktaları, algılayıcıdan bağımsız bir modeldeki bağımsız denetim noktalarından farklı şekilde (15) bağıntısındaki hesapta kullanıldığından yer kontrol noktalarından tamamen bağımsız değildir. Dengeleme bilinmeyenleri ($\underline{d}_{unk}$) Cayley, Moore-Penrose (pseudo) veya Terlemezoğlu and Topan (2020a) tarafından önerilen Tikhonov düzenlileştirmesi ile anlamlı bir $m_0$'a ulaşılacak şekilde hesaplanamamıştır. Bunun yerine

$$\underline{v} = \underline{A}_{RPC}\underline{d}_{RPC} + \underline{A}_{XYZ}\underline{d}_{XYZ} - \left(\underline{l} - \underline{l}\big|_0\right) \tag{21}$$

$$\underline{A} = [\underline{A}_{RPC} \quad \underline{A}_{XYZ}] \tag{22}$$

$$\underline{N} = \underline{A}^T\underline{A} = \begin{bmatrix} \underline{A}_{RPC}^T\underline{A}_{RPC} & \underline{A}_{RPC}^T\underline{A}_{XYZ} \\ \underline{A}_{XYZ}^T\underline{A}_{RPC} & \underline{A}_{XYZ}^T\underline{A}_{XYZ} \end{bmatrix} = \begin{bmatrix} \underline{N}_{11} & \underline{N}_{12} \\ \underline{N}_{12}^T & \underline{N}_{22} \end{bmatrix} \tag{23}$$

$$\begin{bmatrix} \underline{N}_{11} & \underline{N}_{12} \\ \underline{N}_{12}^T & \underline{N}_{22} \end{bmatrix}\begin{bmatrix} \underline{d}_{RPC} \\ \underline{d}_{XYZ} \end{bmatrix} = \begin{bmatrix} \underline{n}_1 \\ \underline{n}_2 \end{bmatrix} \tag{24}$$

$$\underline{N}_{11}\underline{d}_{RPC} + \underline{N}_{12}\underline{d}_{XYZ} = \underline{n}_1$$
$$\underline{N}_{12}^T\underline{d}_{RPC} + \underline{N}_{22}\underline{d}_{XYZ} = \underline{n}_2 \tag{25}$$

$$\underline{N}_{22}^{-1}\underline{N}_{12}^T\underline{d}_{RPC} + \underline{N}_{22}^{-1}\underline{N}_{22}\underline{d}_{XYZ} = \underline{N}_{22}^{-1}\underline{n}_2 \tag{26}$$

$\underline{N}_{22}^{-1}\underline{N}_{22} = \underline{I}$ olduğundan

$$\underline{d}_{RPC} = (\underline{N}_{11} - \underline{N}_{12}\underline{N}_{22}^{-1}\underline{N}_{12}^T)^{-1}(\underline{n}_1 - \underline{N}_{12}\underline{N}_{22}^{-1}\underline{n}_2) \tag{27}$$

$$\underline{d}_{XYZ} = \underline{N}_{22}^{-1}\underline{n}_2 - \underline{N}_{22}^{-1}\underline{N}_{12}^T\underline{x}_{RPC} \tag{28}$$

şeklinde hesaplanabilir. GeoTransform'a 3B RFM ile koordinat hesabı hakkındaki çalışmalar devam ettiğinden kestirim yanlılığı (bias) düzeltmesi, uyuşumsuz ölçü tespiti, ağırlıklı dengeleme hesabı ve öge anlamlılık testi gibi özellikler henüz kazandırılamamıştır. Bu nedenle bu bildiride bu konulara yer verilmemiştir. Tüm işlemler Şekil 1'deki gibi bir iş akışı ile gösterilebilir.

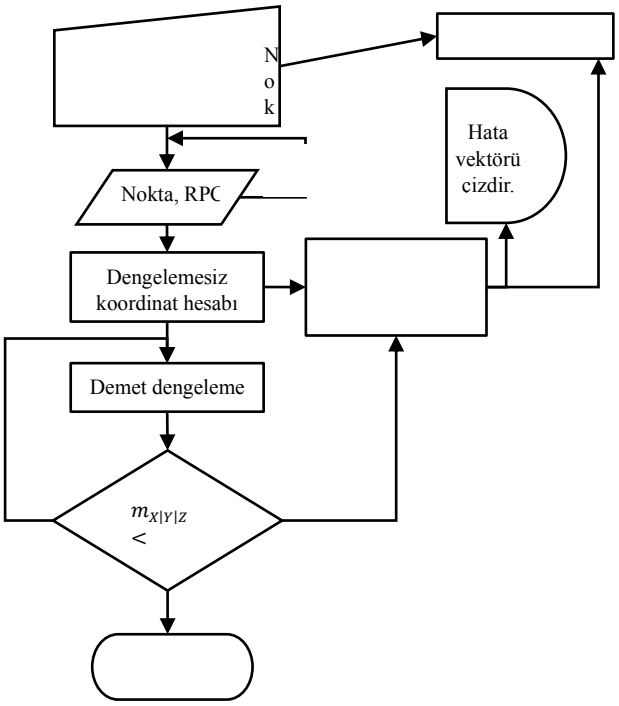


**Şekil 1.** GeoTransform'un RFM için iş akışı.

**UYGULAMA**

Uygulamada Zonguldak test bölgesine ait Göktürk-1 üçlü bindirmeli görüntüleri ile bölgede tesis edilen 51 adet nokta kullanılmıştır. Görüntülerin kapladıkları alanlar ve nokta dağılımı Şekil 2'de gösterilmektedir. Tüm hesaplamalar ikinci yazar tarafından MATLAB ortamında geliştirilen GeoTransform yazılımı ile gerçekleştirilmiştir. Elde edilen sonuçlar, uzaktan algılama uygulamalarında yaygın olarak kullanılan Catalyst Total Suite OrthoEngine yazılımı sonuçları ile de karşılaştırılmıştır (Çizelge 1).

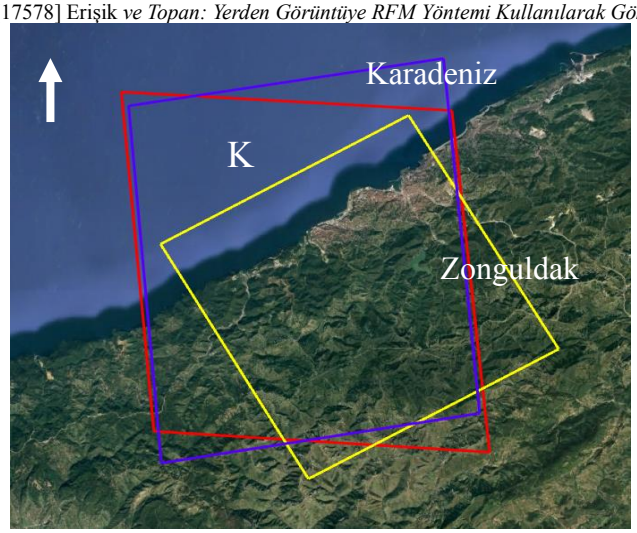


83350 – 83118 -82902 numaralı görüntü sınırları

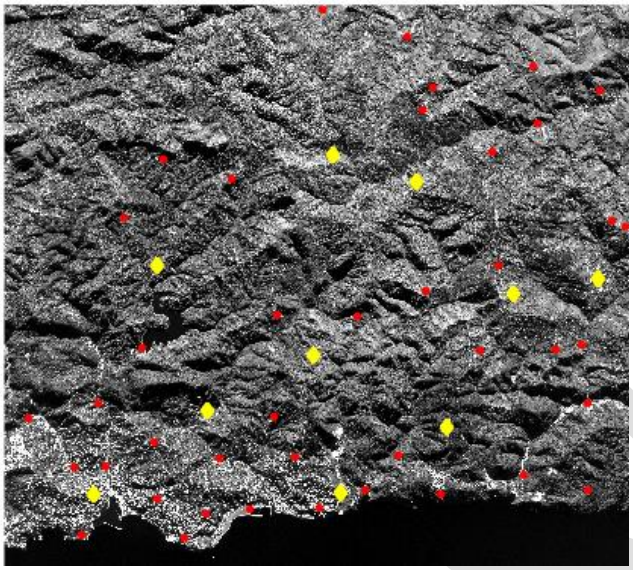

#YKN(·): 41, #DN (◊): 10

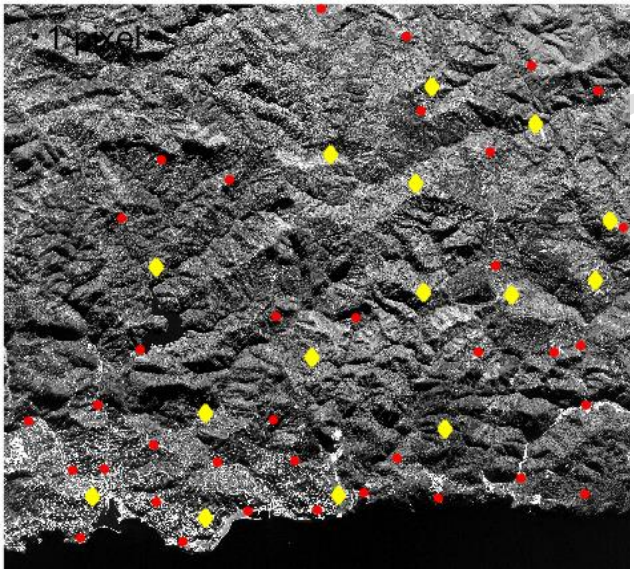


#YKN(·): 36, #DN (◊): 15

**Şekil 2.** Görüntülerin kapladıkları alanlar ve nokta dağılımı.

Her ne kadar üçlü bindirme için görüntüler mevcut olsa da en büyük baza sahip stereoçift olan 82902 ve 83350 numaralı görüntüler için anlamlı sonuçlar üretilebilmiştir. Öncelikle, doğrudan yöneltme sonuçları irdelendiğinde bu değerlerin $m_X = \pm 8{,}53$ m, $m_Y = \pm 11{,}75$ m, $m_h = \pm 4{,}34$ m düzeyinde olduğu ve Arasan et al. (2020) tarafından belirtildiği üzere Telespazio'nun garanti ettiği YKN'siz ±10 m doğruluk değerine ulaşıldığı görülmektedir. Doğrudan yöneltmeye ait hata vektörleri Şekil 3'de görülebilir.

**Çizelge 1.** 3B konum doğrulukları (±m)

| **Model** | | | | | $m_Y$ | $m_X$ | $m_h$ |
|---|---|---|---|---|---|---|---|
| **Doğrudan yöneltme** | | | | | 11.75 | 8.53 | 4.34 |
| | | Nokta takımı-1 #YKN=41, #BDN=10 | | | Nokta takımı-2 #YKN=36, #BDN=15 | | |
| **GeoTransform** (λ=2.27 10-2) | | | | | | | |
| | | $m_Y$ | $m_X$ | $m_h$ | $m_Y$ | $m_X$ | $m_h$ |
| RFM (1°) | YKN | 0.03 | 0.01 | 0.02 | 0.03 | 0.01 | 0.02 |
| | DN | 5.71 | 7.78 | 3.15 | 5.74 | 9.41 | 3.57 |
| **OrthoEngine** | | | | | | | |
| RFM (0°) | YKN | 3.29 | 3.18 | 1.11 | 3.04 | 3.21 | 0.95 |
| | DN | 1.84 | 3.96 | 0.96 | 3.20 | 3.81 | 1.35 |
| RFM (1°) | YKN | 3.23 | 2.97 | 0.89 | 2.98 | 3.06 | 0.83 |
| | DN | 1.88 | 3.72 | 1.04 | 3.32 | 3.48 | 1.10 |
| RFM (2°) | YKN | 3.26 | 2.88 | 0.89 | 2.95 | 2.94 | 0.83 |
| | DN | 1.99 | 3.65 | 1.10 | 3.53 | 3.54 | 1.09 |

Y: Sağa, X: Yukarı, h: Elipsoidal yükseklik

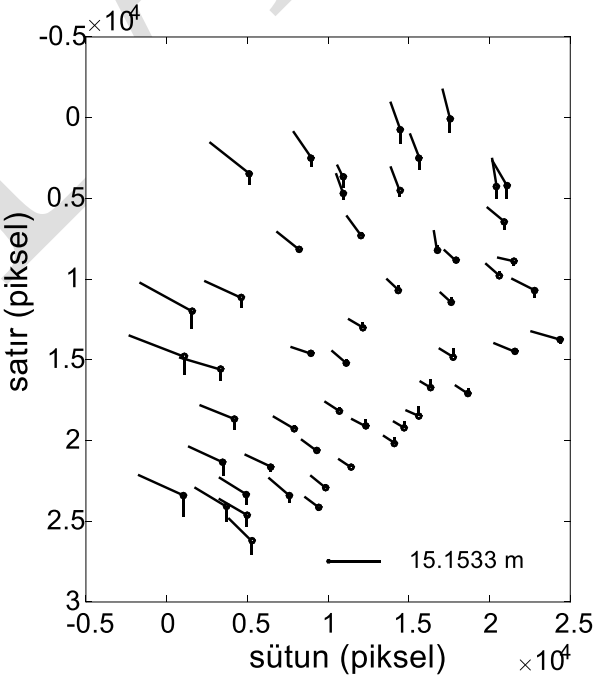


**Şekil 3.** Doğrudan yöneltmeye ait hata vektörleri.

Dengeleme hesabı ile elde edilen sonuçlar irdelendiğinde ise yeter sayıda nokta olduğu ve (21-28) numaralı bağıntılarla verilen yaklaşım ile DN'lerde en iyi sonuçlar elde edilmiş olsa da sadece 1° RFM ile uygun değerler elde edilebilmiştir. YKN'lerde cm düzeyinde doğruluk elde edilebilirken DN'lerde doğruluk değerlerinin beklenen düzeyin (±1 YÖA) üzerinde olduğu görülmektedir. Burada Terlemezoğlu and Topan (2020b) tarafından önerilen yaklaşımla DN'lerin yaklaşık koordinatlarına getirilecek düzeltmelerle ilişkili olan $\underline{N}_{22}$ matrisinin özdeğerlerinden biri (λ=2.27 10-2) Tikhonov katsayısı alınarak köşegene eklenmiştir. Elde edilen hata vektörleri Şekil 4'de gösterilmektedir.

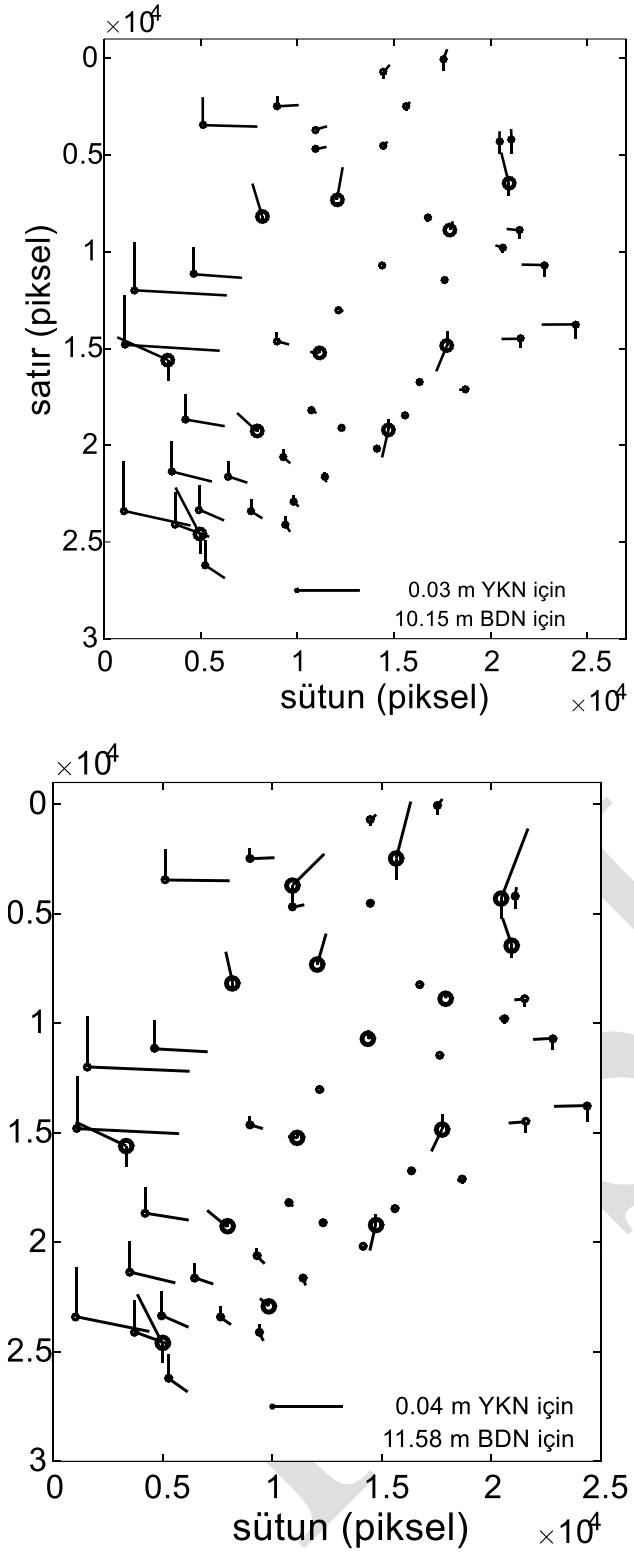


**Şekil 4.** Demet dengeleme sonucu elde edilen hata vektörleri.

OrthoEngine yazılımı 3° haricinde diğer RFM dereceleri için sonuçlar üretmiş ve hem YKN'lerde hem de DN'lerde ±1 YÖA'dan daha kaba sonuçlar elde edilmiştir. GeoTransform sonuçları ile karşılaştırıldığında, özellikle YKN'lerde daha kaba doğruluk sonuçları elde edildiği görülmektedir.

**TARTIŞMA**

Bu bildiride, GeoTransform'a yerden görüntüye RFM yöntemiyle 3B koordinat hesabı özelliğinin kazandırılması ve Göktürk-1 görüntüleriyle örnek bir uygulamaya yer verilmiştir. Her ne kadar RFM yöntemi algılayıcıdan bağımsız bir dönüşüm yöntemi olsa da özellikle polinom derecesi arttıkça sayısal çözümleme açısından uğraştırıcı bir yöntemdir. Bu nedenle RPC'lerin tümünün yerine bazılarının dengeleme hesabında bilinmeyen olarak ele alındığı klasik veya yapay sinir ağları temelli yaklaşımların yanı sıra kötü şartlı veya seyrek matris yapılarının uygun düzenlileştirme yöntemleriyle çözümlendiği yaklaşımlar da geliştirilmiştir. Yine algılayıcıya bağımlı RFM'de karşılaşılan kestirim yanlılığı (bias) düzeltmesi ve ağırlıklı dolaylı ölçüler dengelemesi yaklaşımının da sonuçları iyileştirebileceği düşünülmektedir. Son olarak uyuşumsuz ölçü testi ile uyuşumsuz noktalar belirlenip doğruluk sonuçları irdelenmelidir.

**SONUÇ**

Görüntülerden konum bilgisi elde etme ve doğruluk araştırmaları genellikle kullanılan matematik modele, dengeleme hesabına ve görüntüleme sistemi ile taşıyıcı sistemin geometrik özelliklerine bağlıdır. Özellikle dengeleme hesabı sonucu elde edilen 3B konum doğruluğunun öncelikle görüntünün geometrik yapısına bağlı olduğu düşünülse de özellikle kullanılan matematik model, dengeleme hesabındaki matris yapıları ve ters alma yaklaşımları sonuçları önemli ölçüde değiştirebilmektedir. Bu durumda, RFM gibi genel ve pek çok yazılımda yer alan matematiksel modellerle çalışırken arka planda hesapların nasıl yapıldığının bilinmesi gerekmektedir. Bu nedenle, 2000'lerden itibaren yüksek çözünürlüklü uydu görüntüleri için önerilen RFM yöntemi bu bildiride konu edildiği gibi yeniden ele alınmıştır. Tartışma bölümünde açıklandığı üzere genel olarak RFM ile 3B koordinat hesabı yapılması yeterli değildir. RFM hakkında yapılan çalışmaların irdelenerek GeoTransform'a ek özelliklerin kazandırılması gerekmektedir.

**TEŞEKKÜR**

Yazarlar, Göktürk-1 görüntüler için Hava Kuvvetleri Komutanlığı'na, nokta takımı için yürütülen arazi çalışmalarına destekleri için AirBus Savunma ve Uzay Şirketine, TÜBİTAK'a (Proje No: 114Y380) ve BEÜN'e (Proje No: 2014-47912266-01), nokta takımı için yürütülen arazi çalışması için Dr. Gürsu Aytekin'e, Catalyst OrthoEngine yazılımındaki uygulama için Öğr. Gör. Murat Oruç'a, deg2utm Matlab fonksiyonu için Rafael Palacios'a, dengeleme hesabındaki Matlab fonksiyonu için Yük. Müh. Ali Cam'a teşekkür eder.

**Yazar Katkı Oranı**

Onur Erişik: Uygulama, genel metin yazımı ve gözden geçirilmesi.
Hüseyin Topan: GeoTransform'un geliştirilmesi, yöntem, genel metin yazımı ve gözden geçirilmesi.

**Çıkar Çatışması/Çakışması**

Yazarlar arasında herhangi bir çıkar çatışması ve çakışması bulunmamaktadır.

**Araştırma ve Yayın Etiği Beyanı**

Bu çalışma birinci yazarın yüksek lisans tezinden üretilmiştir. Araştırma için etik kurul iznine gereksinim bulunmamaktadır.

**KAYNAKÇA**

Arasan, G., Yılmaz, A., Firat, O., Avşar, E., Güner, H., Ayğan, K., & Yüce, D. (2020). Accuracy Assessment of GÖKTÜRK-1 Satellite Imagery. *International Journal of Engineering and Geosciences, 5*(3), 160-168. doi: 10.26833/ijeg.650899

Aytekin, G., & Topan, H. (2024). Unlocking the 3D Georeferencing Accuracy Potential of Göktürk-1 Tri-Stereo Panchromatic Level 2A Images by Sensor-Dependent Orientation Model. *Proceedings of the Romanian Academy, Series A, 25*(4/2024), 347–358. doi: 10.59277/PRA-SER.A.25.4.11

Leprince, S., Barbot, S., Ayoub, F., & Avouac, J. P. (2007). Automatic and precise orthorectification, coregistration, and subpixel correlation of satellite images, application to ground deformation measurements. *IEEE Transactions on Geoscience and Remote Sensing, 45*(6), 1529-1558. doi: Doi 10.1109/Tgrs.2006.888937

OGC. (1999). The OpenGIS® Abstract Specification Topic 6: The Coverage Type and its Subtypes Version 4.

Poli, D., & Toutin, T. (2012). Review of Developments in Geometric Modelling for High Resolution Satellite Pushbroom Sensors. *The Photogrammetric Record, 27*(137), 58-73. doi: 10.1111/j.1477-9730.2011.00665.x

Tao, C. V., & Hu, Y. (2002). 3D Reconstruction methods Based on the Rational Function Model. *Photogrammetric Engineering & Remote Sensing, 68*(7), 705-714.

Terlemezoğlu, B., & Topan, H. (2020a). Eigenvalue-Based Approaches for Solving an Ill-Posed Problem Arising in Sensor Orientation. *IEEE Transactions on Geoscience and Remote Sensing, 58*(3). doi: 10.1109/TGRS.2019.2950693

Terlemezoğlu, B., & Topan, H. (2020b). Eigenvalue-Based Approaches for Solving an Ill-Posed Problem Arising in Sensor Orientation. *IEEE Transactions on Geoscience and Remote Sensing, 58*(3), 1920-1930. doi: 10.1109/TGRS.2019.2950693

Wolf, P. R., & Dewitt, B. A. (2000). *Elements of Photogrammetry: with Applications in GIS* (3rd ed.): McGraw-Hill.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Metaveri, ISO 19115, HGM Metaveri Profili ve HGM-Geoportal

**Nurettin Çağlar DURDU**[*1] **Dijle BOYACI**[2]

[1]*MSB, Harita Genel Müdürlüğü, Coğrafi Veri Merkezi Müdürlüğü, Ankara, Türkiye*
[2]*MSB, Harita Genel Müdürlüğü, Coğrafi Veri Merkezi Müdürlüğü, Ankara, Türkiye*

**Anahtar Kelimeler**
Metaveri,
ISO 19115,
HGM Metaveri Profili,
HGM-Geoportal

**ÖZET**

1990'larda, coğrafi verilerin dijitalleşmesi ve internet üzerinden paylaşımının artmasıyla birlikte, verilerin nasıl tanımlanacağı ve yönetileceği konusunda standartlara ihtiyaç duyuldu. Farklı kurumlar ve ülkeler, kendi metaveri formatlarını geliştirmeye başladı. Ancak bu durum, veri entegrasyonunu zorlaştırıyordu. Bu karmaşayı çözmek için uluslararası bir standart oluşturma çalışmaları başladı. Günümüzde ise metaveri bazında yaygın olarak kullanılan standartlar; ISO 19115-1, ISO 19115-2, ISO 19119, ISO 19139-1; CSW için OGC CSW standartlarıdır. Gelişen bu süreçle beraber Harita Genel Müdürlüğü (HGM), arşivinde yer alan çeşitli sayısal coğrafi verilere ilişkin metaverileri ISO standartlarına uygun olarak toplamış ve OGC standardına uygun bir CSW servisi ile https://geoportal.harita.gov.tr/ (HGM-Geoportal) adresi üzerinden sunmaktadır. Bu çalışmada; metaveri, ISO 19115 ve HGM metaveri profili konularında genel bilgi verildikten sonra, HGM-Geoportalın teknik altyapısı, yetenekleri, içerdiği metaveriler anlatılmış ve HGM-Geoportalın ilerleyen süreçte ne gibi yeteneklerin kazandırılması gerektiğinden bahsedilmiştir. Ayrıca, kullanımda olan geoportal ve benzeri diğer uygulamalar için tecrübe ve bilgilerin aktarılması amaçlanmıştır.

# Metadata, ISO 19115, HGM Metadata Profile and HGM-Geoportal

**Keywords**
Metadata,
ISO 19115,
HGM Metadata Profile,
HGM-Geoportal

**ABSTRACT**

In the 1990s, with the digitization of geographic data and the increasing sharing of data over the internet, there emerged a need for standards to define and manage this data. Various institutions and countries began developing their own metadata formats. However, this led to difficulties in data integration. To address this confusion, efforts to establish an international standard were initiated. Today, the widely used metadata standards include ISO 19115-1, ISO 19115-2, ISO 19119, ISO 19139-1, and for CSW (Catalog Service for the Web), the OGC CSW standards. As part of this evolving process, Directorate General for Mapping (HGM) has collected metadata for various digital geographic datasets in its archive in compliance with ISO standards and made them available through an OGC-compliant CSW service via the HGM-Geoportal at https://geoportal.harita.gov.tr/. In this study, general information is provided on metadata, ISO 19115, and the HGM metadata profile, followed by an explanation of the technical infrastructure, capabilities, and metadata content of the HGM-Geoportal. Additionally, the study discusses potential future enhancements for the HGM-Geoportal and aims to share experiences and knowledge for other geoportals and similar applications currently in use.

## GİRİŞ

Coğrafi Bilgi Sistemleri (CBS), günümüzde pek çok sektörde (şehir planlama, çevre yönetimi, savunma, tarım vb.) kritik bir rol oynamaktadır. Bu sistemlerin etkin kullanımı için coğrafi verilerin doğru şekilde tanımlanması, paylaşılması ve yönetilmesi gereklidir. İşte bu noktada The International Standards Organisation (ISO) 19115 metaveri standardı devreye girmektedir. Bu makalede, ISO 19115'in ne olduğu, neden önemli olduğu,

temel bileşenleri ve uygulama alanları detaylı bir şekilde ele alınacaktır. Sonrasında HGM Metaveri profilinin ortaya çıkışı ve ardından Harita Genel Müdürlüğü (HGM) tarafından üretilen tüm coğrafi verilerin ve aktif olarak hizmet veren coğrafi web servislerinin sorgulanarak bulunmasını, onlarla ilgili tanımlayıcı ve açıklayıcı bilgilere (metaverilere) ulaşılmasını sağlayan HGM-Geoportal'ın özellikleri, sunduğu hizmetler ve kullanım alanları bu makalede ele alınacaktır.

**YÖNTEM**

Bu çalışmada, Metaverinin tanımı yapılmış olup, ISO 19115 metaveri standardı temel özellikleri ve tarihçesi, HGM Metaveri profili, HGM-Geoportal uygulamasının temel özellikleri ve kullanım alanları incelenmiştir.

**Metaveri**

Veri ISO/IEC 2382 de "Veri, bilginin iletilmesi, yorumlanması veya işlenmesi için uygun bir biçimde temsil edilmiş halidir" olarak tanımlanmıştır.

Verinin anlaşılır, erişilebilir ve yönetilebilir olması gerekmektedir. Burada metaveri kavramı devreye girmektedir. Verinin değerinin anlaşılması ve kullanılabilmesi için, veri içeriği hakkında tanımlayıcı ve açıklayıcı bilgiye ihtiyaç duyulmaktadır.

Metaverinin farklı tanımlarına bakacak olursak;

"Metaveri en genel tanımıyla veri hakkındaki veridir." (Ahronheim, 1998; Coyle, 2005).

"Metaveri, bir bilgi kaynağını tanımlayan, açıklayan, yerini belirten ya da yönetimini kolaylaştıran yapısallaştırılmış bilgidir." (Hodge, 2001; Yonaitis, 2002).

Veri kullanıcıları açısından metaveri, uygun veri setlerini araştırmak için önemlidir. Veri kullanıcıları her şeyden önce sorgulayabilecekleri metaveri bilgileri ile ilgilenirler. Metaveri, bir organizasyondaki kullanılabilir veri veya katalog hizmetleriyle dış kaynaklardan elde edilebilecek mevcut veri hakkında bilgi almayı sağlar. Metaveri sadece aranan veriyi bulmaya yardım etmez, ayrıca bu verinin nasıl yorumlanacağını ya da kullanılabileceğini de söyler. Ayrıca metaverinin internet ortamında yayınlanması veri paylaşımını kolaylaştırır (Yonaitis, 2002).

Metaveriyi kullanıcı gözüyle inceleyecek olursak; metaveri içerisinde yer alan bilgiler, verinin birçok özelliği hakkında kullanıcılara bilgi sunmaktadır. Metaveriler ile beraber kullanıcılar doğru veriye minimum iş gücüyle ve minimum zamanda ulaşır. Doğru metaveri ile toplanıp analize uygun hale getirilen veri, kullanıcısı ile beraber bilgiye ve stratejik kararlara dönüşebilmektedir.

Günümüzde ise metaveri, veriyi kullanıcı ve yazılıma açıklayan, tanımlayan, anlamlandıran, kalitesini, standartlarını, kaynağını, formatını ve bunlar gibi değişkenleri açıklayan ve ortak bir paydada toplayan bilgiler topluluğudur.

**ISO 19115**

Coğrafi metaveri ihtiyacının doğuşunun arkasındaki sebep, coğrafi verilerin karmaşıklığı ve bu alanda standartlaştırılmış metaveri sistemlerine olan ihtiyaçtır. Bu ihtiyacın karşılanması maksadı ile kurumlar tarafından üretilen haritaların, uydu görüntülerinin ve CBS verilerinin uyumlu bir şekilde paylaşılabilmesi için ISO 19115 standardı geliştirilmiştir.

ISO 19115 standardının amacı;

Coğrafi veri kümelerinin tutarlı şekilde tanımlanmasını sağlamak, veri paylaşımını kolaylaştırmak ve farklı sistemler arasında birlikte çalışabilirliği sağlamaktır.

ISO 19115 uluslararası bir metaveri standardı olup, ilk versiyonu 2003 yılında yayınlanmıştır. 2014'te revize edilerek ISO 19115-1:2014 olarak güncellenmiştir.

**Çizelge1.** ISO 19115 Yaşam Döngüsü

| Standart | Durumu |
|---|---|
| ISO 19115:2003 | Geri Çekildi |
| ISO 19115:2003/Cor 1:2006 | Geri Çekildi |
| ISO 19115-1:2014 | Yayında |
| ISO 19115-1:2014/Amd 1:2018 | Yayında (Değişiklik) |
| ISO 19115-1:2014/Amd 2:2020 | Yayında (Değişiklik) |
| ISO/AWI 19115-1 | Taslak |

ISO 19115-1:2014 standardı, coğrafi bilgilerin ve hizmetlerin metadatayla tanımlanması için gerekli şemayı belirler. Son yayınlanan standart ile birlikte ISO 19115 standardı coğrafi verilere ve sunulan hizmetlere ilişkin tanımlayıcı bilgiler, kapsam, kalite, mekansal ve zamansal özellikler, içerik, referans sistemleri, görselleştirme, dağıtım ve diğer temel özellikler olmak üzere 9 temel başlık hakkında bilgi verir.

ISO 19115 standardının kullanım amacı içerisinde, tüm kaynak türlerinin kataloglanması, veri havuzu oluşturma faaliyetleri, veri setlerinin ve hizmetlerinin tam tanımlanması, coğrafi hizmetler, coğrafi veri setleri, veri serileri, bireysel coğrafi nesneler ve özellikleri uygulama alanları yer alır.

ISO 19115 standardı, coğrafi veri ve hizmetlerinin tanımlanması, yönetimi ve paylaşımı için temel metaveri şemasını standartlaştırır. Metaveri içeriğinin gösterimi ve formatına ilişkin herhangi bir bilgi içermemektedir. Görüntü verileri (imagery) ve ızgara (grid) tabanlı veriler için genişletilmiş metaveri kuralları için ISO 19115-2 standardına, web servisleri ve veri işleme hizmetlerinin nasıl tanımlanacağı, sınıflandırılacağı ve belgeleneceği için ISO 19119 standardına ve metaveri modellerinin XML tabanlı uygulama kuralları ile ilgili bilgiye ihtiyaç duyulduğunda ISO 19139-1 standardına bakılması gerekmektedir.

**HGM Metaveri Profili**

ISO 19115 genel maksatlı bir standart olduğundan, çok fazla sayıda metaveri ve bu metaverilere ilişkin oldukça fazla detay içermektedir. Kurumlar, organizasyonlar ve ülkeler, veri içeriğine ve hedeflenen kullanım alanlarına bağlı olarak bu standartlardan seçim yapmaktadırlar. Bu seçimlerinin sonrasında kendi profillerini oluşturmaktadırlar.

HGM metaveri profili oluşturulurken, metaveri toplayan birimler için öncelikle kurum içerisinde sonrasında da ulusal ve uluslararası platformlarda veri paylaşımının ISO 19115 standardına uygun yapılabilmesini hedeflemiştir.

Profil oluşturulurken HGM içerisinde farklı birimlerle toplantılar yapılmış, kurumsal olarak hangi metaveri elemanlarına ihtiyaç olduğu tespit edilmiştir. HGM tarafından üretilen tüm ürünler, üretim süreçleri dikkate alınarak incelenmiş ve hangi metaverilerin toplanması gerektiğine karar verilmiştir.

TASLAK

Metaveriler belirlenirken ne sadece veriyi tanımlayamaya yetecek kadar az sayıda ne de metaveri toplayan birimlerin gereğinden fazla iş gücünü alacak kadar çok sayıda olmamasına yönelik metaveri seçimi yapılmıştır. Profil elemanları seçilirken mümkün olduğunca haritacılık açısından önemli elemanlar seçilmiştir. Bu kapsamda oluşturulan profil, ISO standardını temel alarak kendi kurum ve kuruluşu için metaveri profili oluşturacak olanlara da örnek olacağı değerlendirilmektedir.

Yapılan hazırlıklar sonucunda 7 ana başlık altında yer alan 97 metaveri elemanından oluşan HGM metaveri profili oluşturulmuştur.

HGM Metaveri Profili aşağıdaki sınıflardan (ana başlıklardan) oluşmaktadır.

1. Metaveri Hakkında Bilgi (Metadata Entity Set)
2. Kimlik Bilgisi (Identification Information)
3. Kısıtlama Bilgisi (Constraint Information)
4. Bakım ve Güncelleme Bilgisi (Maintenance Information)
5. Referans Sistemi Bilgisi (Reference System Information)
6. Veri Kalitesi Bilgisi (Data Quality Information)
7. Dağıtım Bilgisi (Distribution Information)(Araz,2013)

**HGM-Geoportal**

HGM-Geoportal Harita Genel Müdürlüğü tarafından üretilen tüm coğrafi verilerin ve aktif olarak hizmet veren coğrafi web servislerinin sorgulanarak bulunmasını, onlarla ilgili tanımlayıcı ve açıklayıcı bilgilere (metaverilere) ulaşılmasını sağlayan portaldır. HGM-Geoportal uygulamasına https://geoportal.harita.gov.tr/ adresinden ulaşılabilmektedir.

HGM-Geoportal ile amaçlanan; Harita Genel Müdürlüğünün geniş ve zengin coğrafi ürün arşivi içerisinde, ihtiyaç duyulan verinin tespitini yapmaktır.

Portallerin faydaları; ilgili veriye/bilgiye ulaşımı sağlama, mükerrer işleri engelleme, bilgi paylaşımını kolaylaştırma ve arttırma, verim artışı ve maliyet düşüşü sağlama, son kullanıcıya zamandan tasarruf sağlama, daha iyi ve hızlı karar vermeyi sağlama, kullanıcıların varlığından haberdar olmadığı bilgilere erişmelerini sağlama, veri/servis sağlayıcıların ürünlerini çok geniş bir kullanıcı kitlesine ulaştırabilmelerini sağlama olarak sıralanabilir. (Şehsuvaroğlu,2017)

**Sayısal Arşiv Sistemi Yazılımı (SASY)**

HGM-Geoportal Uygulama Yazılımı'nın metaveri ve veri kaynağı Sayısal Arşiv Sistemi Yazılımı'dır.

Sayısal Arşiv Sistemi Yazılımı (SASY), MSB Harita Genel Müdürlüğünün sayısal verilerini metaverileri ile birlikte veri depoları olarak arşivleyen, ihtiyaç duyulduğu zaman yetkili kullanıcıların verileri sorgulamalarını ve/veya indirmelerini sağlayan ve sayısal arşiv bünyesinde yürütülen tüm faaliyetlerin izlenmesine ve yönetimine imkân veren bir uygulama yazılımıdır.

SASY, HGM bünyesinde yer alan depo sorumlusu personellerin yalnızca kendisine yetki verilen veri depolarına veri/metaveri ekleme, düzenleme ve silme faaliyetlerine izin verilmektedir.

SASY içerisinde verinin yaşam döngüsü metaverisinin toplanmasıyla başlamaktadır. Öncelikle, SASY veri deposu yetkili kullanıcısı verinin metaverisini toplamaktadır. Daha sonrasında, bu metaveri ile veri bir bütün olarak SASY uygulamasına yüklenmektedir. SASY yükleme işlemi esnasında verinin tipi ve öznitelik bilgisinin kontrolü gerçekleştirilmektedir. Yazılım, hatalı verilerin depolanmasını engelleyerek yetkili kullanıcıyı hatasının bulunduğu noktayı işaret ederek bilgilendirmektedir. Veri yükleme işlemi başarı ile gerçekleşmesini müteakip yetkili kullanıcı çeşitli sorgulama yöntemleri ile yetkili olduğu veri depolarında sorgulama ve analiz yapma imkânına kavuşmaktadır. Yetkili kullanıcı öznitelik bilgilerinden ya da harita üzerinden sorgulama ve analiz işlemlerini gerçekleştirebilmektedir. Kullanıcı, bu sorguları daha sonra tekrar kullanmak üzere kayıt altına alabilmektedir. Yetkili kullanıcı sorumlu olduğu veriler için yönetici personelin onayına sunmak üzere, güncelleme ve silme isteklerini arayüz vasıtasıyla oluşturabilmektedir. Sorgulama ve analizler sonrasında veri ve metaveri bir bütün olarak ya da ayrı ayrı olacak şekilde tek veya toplu bir şekilde indirebilmektedir. Bu işlemler sonrası yönetici kullanıcılar verinin yaşam döngüsünü SASY yönetim panellerinden takip edebilmektedir.

**Özellikleri**

HGM-Geoportal, kapsamlı bir CBS verisi ve coğrafi web servisi arama kataloğudur.

Metaveriler, ISO 19115 standardı esas alınarak geliştirilmiş HGM metaveri profiline uygun olarak toplanmıştır.

OGC (Open Geospatial Consortium)'nin Web Katalog Servis CSW (Catalog Service for the Web) 2.0.2 standardı kullanılmaktadır.

Altlık görüntü olarak herhangi bir Coğrafi Web Servisi görüntülenebilmektedir.

HGM-Geoportal metaveri indirme (harvest) yeteneğine sahiptir.

Metaveriler vasıtasıyla HGM'ye ait güncel ve tarihi coğrafi veriler sorgulanarak bulunmakta ve bu verilere ait tanımlayıcı ve açıklayıcı bilgilere ulaşılmaktadır.

**Yetenekleri**

HGM-Geoportal Türkçe ve İngilizce görüntüleme seçeneklerine sahiptir. İngilizce dili seçildiğinde; menüler, sorgulama pencereleri ve metaveri elamanlarının adları İngilizce olmaktadır.

HGM-Geoportal içerisinde altlık harita olarak https://atlas.harita.gov.tr/ nin sunmuş olduğu Temel, Hava Fotoğrafı, Siyasi, Topoğrafik ve Gece altlık haritalarını kullanmaktadır. Seçilen altlık haritalar üzerinde harita penceresi üzerinde çizgi, poligon, dikdörtgen ve işaret dairesi çizim araçları vasıtası ile sorgulama gerçekleştirilebilmektedir. Gerçekleştirilen sorgu sonuçları tespit edilen metaverilerin kapsadığı coğrafi alanlar harita penceresi üzerinde görüntülenmektedir. Sorgulamalar sonrasında kullanıcı "Sorgu Geçmişi" menüsü yardımı ile geçmiş sorgulamalarına geri dönebilmektedir.

Kullanıcı sorgulama işlemi sonrasında 25 ve 50 adet görüntüleme seçenekleri ile sorgulama sonuçlarını harita penceresinde görüntüleyebilmektedir. Sorgu sonuçları menüsünde sonuç sorgu depoları ve sonuç sayfaları arasında geçiş yapılabilmektedir. Bulunan

sonuçlar üzerinden metaveri veri elamanları vasıtası ile filtreleme işlemi gerçekleştirilebilmektedir. Sorgu sonuçları Excel formatında indirilebilmektedir. Kullanıcı, harita penceresi üzerinde görüntülenen sonuçları işaretleyebilmekte ya da gizleyebilmektedir. Detaylara göz at seçeneği ile metaveri bilgi kartı görüntülenebilmektedir.

HGM-Geoportal Basit Sorgulama, Ekrandan Konumsal Sorgulama, Koordinat ile Sorgulama ve Ayrıntılı Sorgulama(Metaveri Bilgileri ile Arama) olmak üzere sorgu seçeneklerine sahiptir.

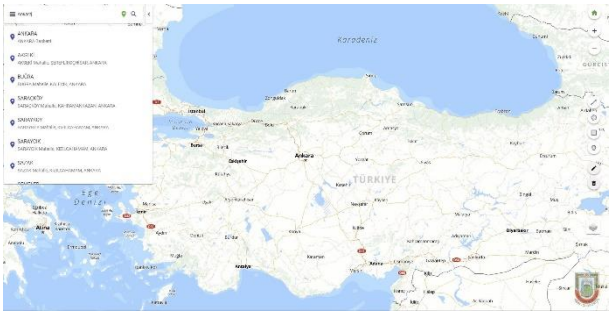

**Şekil 1.** Basit Sorgulama

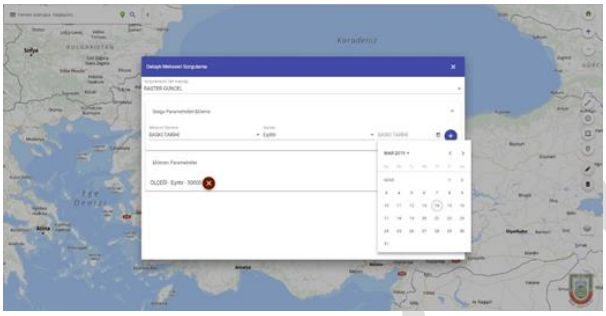

**Şekil 2.** Ayrıntılı Sorgulama (Metaveri Bilgileri ile Arama)

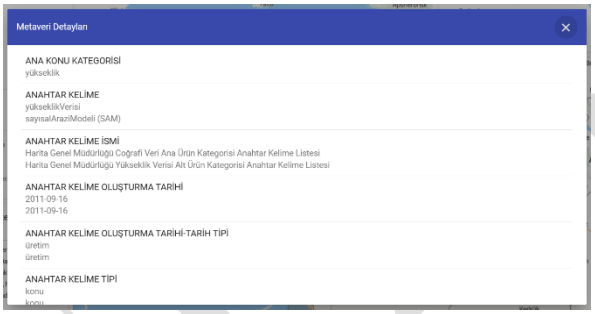


**Şekil 3.** Metaveri Bilgi Kartı

## Metaveri İçeriği

HGM-Geoportal teknolojisini belirleyen en önemli unsur verinin kaynağıdır. HGM-Geoportal'ın sunmuş olduğu başlıca metaveri kaynakları;

1. Raster Haritalar
2. Vektör Haritalar
3. Hava Fotoğrafları
4. Yükseklik Verileri
5. Jeodezik Veriler

HGM-Geoportal içerisinde, 16 (on altı) metaveri deposu ile yaklaşık 2.050.000 (iki milyon elli bin) metaveri yer almaktadır.

## BULGULAR

HGM-Geoportal, HGM'ye ait güncel ve tarihi coğrafi verilerin metaverilerini sunan bir entegrasyon platformudur. Bu portal, standartlara uygun metaveri sorgulama ve görüntüleme imkânı sunar. Vatandaşlar, akademisyenler ve kamu kurumları için metaveri sorgu kaynağıdır.

1. Ankara ili Altındağ ilçesinde gerçekleştirilecek yol çalışması için; en güncel tarihli hava fotoğrafı tarihi nedir? Bölgeye ait üretilmiş vektör veri var mı?
2. Kadastro Mahkemesinin görev alanı içerisinde, bir davayı çözmek için ihtiyaç duyduğu, dava konusu alana ait 1978-1988 yılları arasında çekilmiş hava fotoğrafı ve 1/25.000 ölçekli topoğrafik harita var mı varsa ürüne ilişkin bilgiler neler?
3. Üniversitenin yürüttüğü bir projede ihtiyaç duyduğu ortofoto ve sayısal yükseklik modeli, HGM tarafından üretilmiş midir? Üretildiyse bu verilerin çözünürlükleri nedir ve konum doğruluğunu belirlemede kullanılan ölçümler nelerdir?

Yukarıda ki örneklerde olduğu gibi çeşitli isteklerin karşılanması HGM-Geoportal uygulaması ile sağlanabilmektedir.

## TARTIŞMA

HGM-Geoportal ISO 19115 standardı esas alınarak inşa edilmiş kullanıcı dostu bir arayüz sunmaktadır.

HGM-Geoportal yapısı gereği dolaylı olarak veriye bağımlıdır. Verinin güncelleme ve kontrol sıklığına bağlı olarak metaverinin güncelleme sıklığı yetersiz kalabilmektedir. Aynı şekilde metaveri içeriği kurumlar arasında farklılık göstereceğinden geoportal uygulamaları metaveri kalitesinde farklılaşmalar görülebilmektedir. Farklılaşmalar dikkate alındığında metaveri üretici kurum ve kullanıcılara ilişkin eğitim çalışmalarının arttırılması gerektiği değerlendirilmektedir.

Kullanıcılar gelişen teknoloji ile beraber ürünleri çevrimiçi bir şekilde temin etmek istemektedirler. Bu çerçevede sanal ortamda veriye ulaşma ve ürün satın alma isteklerini karşılayabilmek adına e-satış alt yapısının kurulmasına ihtiyaç duyulmaktadır.

## SONUÇ

Metaveri, gelişen teknoloji ve sayısal ürünlere olan talebin artması ile beraber bilgi yönetiminin vazgeçilmez bir parçası haline gelmiştir. Özellikle coğrafi veri alanında ISO 19115, küresel ölçekte standartlaşmayı sağlayarak veri paylaşımını ve iş birliğini kolaylaştırmıştır. Gelecekte, Coğrafi veri alanında daha da gelişecek olan metaveri sistemleri, veriye dayalı karar alma süreçlerini daha verimli hale getirecektir.

ISO 19115 standardı ve HGM Metaveri Profili, Türkiye'de tutarlı ve erişilebilir metaveri paylaşımını sağlamaktadır. HGM-Geoportal ise bu altyapıyı kullanıcılara sunarak önemli bir hizmet vermektedir. Ancak, veri güncelliği, kalite kontrolü ve kullanıcı bilinçlendirme çalışmalarının geliştirilmesi, sistemin etkinliğini daha da artıracaktır.

Bu çalışma, metaveri standartlarının ve HGM-Geoportal'ın önemini vurgulayarak, geoportal kullanıcılarının bilinçlendirerek katkı sağlamayı amaçlamaktadır.

## TEŞEKKÜR

Bu çalışma sürecinde bilgi birikimi, yönlendirmeleri ve teknik desteği ile katkı sağlayan komutanlarıma teşekkür ederim. Ayrıca, teknik ve yazılım konusunda destek veren Harita Genel Müdürlüğü'ne minnettarlığımı sunarım.

**Yazar Katkı Oranı**

Yazarların katkıları şu şekildedir: Durdu N.Ç. makale yazımında öncülük etmiştir, Boyacı D. ise son metni inceleyip onaylamıştır.

**Çıkar Çatışması/Çakışması**

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

**Araştırma ve Yayın Etiği Beyanı**

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

**KAYNAKÇA**

**Makale**

**Kitap**

Yonaitis ve Robert B., 2002. Understanding accessibility: a guide to achieving compliance on web sites and intranets, HiSoftware Publisihing, New Hampshire.

Hodge ve Gail, 2001. Metadata made simpler: a guide for libraries, Bethesda.

**Bildiri**

Şehsuvaroğlu M.S., 2017. Harita Genel Komutanlığı Coğrafi Veri Bilgi Kapısı, 9. TUFUAB Teknik Sempozyumu, 27-29 Nisan, Afyon. https://fenbildergi.aku.edu.tr/wp-content/uploads/2017/11/2711_sabriseyh-190-203.pdf

**Tez**

Araz, A.(2013). Metaveri Standartlarının İrdelenmesi Ve Harita Genel Komutanlığı İçin Bir Metaveri Profili Oluşturulması (Yüksek Lisans Tezi), Aksaray Üniversitesi, Aksaray

**Mevzuat**

Fikir ve Sanat Eserleri Kanunu (FSEK), Resmî Gazete 7981 (13 Aralık 1951), Kanun No. 5846, md. 35/4.

**İnternet adresi**

https://www.iso.org/standards.html [Erişim tarihi: 17.04.2025].

**İnternetten alıntı yapılan bir yazar varsa:**

Coyle, K. (2005). Understanding metadata and its purpose. NISO Press. https://www.niso.org/publications/understanding-metadata: [Erişim tarihi: 17.04.2025].

**İnternetten alıntı yapılan bir yazar yoksa:**

TUFUAB, (2024). Tarihçe, Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB), Ankara, [Erişim tarihi: 05.12.2024], https://www.tufuab.org.tr/tarihce/sayfa/3

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Harita Genel Müdürlüğünce Üretilen Coğrafi Verilerin Paylaşılması

**Murat BÖLME** [*1], **Dijle BOYACI** [2]

[1]*Milli Savunma Bakanlığı, Harita Genel Müdürlüğü, Coğrafi Veri Merkezi Müdürlüğü, Ankara, Türkiye*
[2]*Milli Savunma Bakanlığı, Harita Genel Müdürlüğü, Coğrafi Veri Merkezi Müdürlüğü, Ankara, Türkiye*

**Anahtar Kelimeler**
Coğrafi veri
Coğrafi Veri Merkezi (CVM)
Türkiye Ulusal Coğrafi Bilgi Sistemi (TUCBS)
Coğrafi Veri Talebi
Örün Servisleri

**ÖZET**

Harita Genel Müdürlüğü (HGM); yurt içi ve yurtdışında, farklı ölçeklerde, uluslararası standartlarda, güncel bilimsel yöntemlerle jeodezik, fotogrametrik ve kartoğrafik veri üreten ve bu coğrafi verileri ülkemizin kalkınma, savunma ve güvenlik projeleri için farklı kurumlar ve disiplinler ile paylaşan, iki asırlık kurumsal hafızası ve tecrübesi olan Türkiye'nin millî haritacılık kurumudur. Harita Genel Müdürlüğü tarafından üretilen her türlü harita, harita bilgisi ve coğrafi veriler, yaklaşık 450 farklı ürün grubu olarak kamu kurum ve kuruluşları, mahkemeler, belediyeler, üniversiteler ile gerçek ve tüzel kişiler ile paylaşılmaktadır. Verilerin paylaşılması hususunda verinin gizlilik derecesi önem arz etmektedir. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı bünyesindeki "Türkiye Ulusal Coğrafi Bilgi Sistemi (TUCBS)"nin en önemli, en büyük harita ve coğrafi veri desteği, ülkemizin coğrafya hazinesini elinde bulunduran HGM tarafından sağlanmaktadır. Bu çalışmada HGM'lüğünce üretilen coğrafi verilerin geçmiş beş yıllık süreçte kullanıcıları, mevcut paylaşım süreçleri ve kullanım alanları açıklanmış, bu konuda gelecekteki hedeflerinden bahsedilmiştir.

# Sharing Of Geographical Data Produced By The Directorate General For Mapping

**Keywords**
Geographical data
Geographic Data Center (GDC),
Türkiye National Geographic Information System,
Geographic data request
Web services

**ABSTRACT**

The Directorate General for Mapping (DGM) is the national mapping institution of Turkey, which produces geodetic, photogrammetric and cartographic data with international standards, current scientific methods and at different scales and in country and abroad and shares these geographical data with different institutions and disciplines for the development, defense and security projects of our country, with an institutional memory and experience of two centuries. Various types of maps, cartographic information, and geospatial data produced by the Directorate General for Mapping are disseminated to approximately 450 distinct user groups, including public institutions and organizations, judicial bodies, municipalities, universities, and both natural and legal persons. The integrity and accuracy of the distributed data are ensured through standardized methodologies. Notably, the Ministry of Environment, Urbanization and Climate Change is among the institutions benefiting from these data. Within the context of the "Türkiye National Geographic Information System (TUCBS)," the Directorate General for Mapping serves as the primary provider of comprehensive mapping and geospatial data support, thereby playing a critical role in advancing geospatial infrastructure across the country. In this study, the users of the geographical data produced by the HGM in the past five years, current sharing processes and areas of use are explained, and future goals in this regard are mentioned.

## GİRİŞ

Harita, konum bilgisi, coğrafi bilgi; savunma ve kalkınmanın en önemli girdisi, 21'inci yüzyıldaki teknolojik ve dijital dönüşümünün en önemli paydaşıdır.

Hiçbir faaliyet/ürün/sistem/proje/çalışma (Muhabere sahası, yapay zekâ, silah ve savunma sistemleri, komuta kontrol sistemleri, bilgi sistemleri, yönetim sistemleri, AR-GE çalışmaları, altyapı ve kalkınma çalışmaları, uzay çalışmaları, mühendislik projeleri, bilimsel çalışmalar, yapay zekâ uygulamaları, navigasyon, vd) harita/koordinat/coğrafi veri/konum olmaksızın sonuca ulaşamaz.

HGM ürünlerinin kullanım alanları/amaçları ana başlıklar halinde aşağıdaki listede verilmiştir.

* Ülke savunması, terörle mücadele, istihbarat, emniyet ve güvenlik,

* Orman meşcere haritalarının üretilmesi, ağaç gelişiminin takibi, orman yangınlarının önlenmesi ve

TASLAK

hasar tespiti, yangın alanlarının rehabilitasyonu ve izlenmesi,

* Deprem sonrası hasar tespiti, yıkık binaların tespiti, sel, taşkın, heyelan, müsilaj olaylarının önlenmesi ve hasar tespiti,

*Havaalanı, karayolu, demiryolu, enerji nakil hattı gibi altyapı projelerinin planlanması,

* Su akarsu, göl, baraj havzalarının belirlenmesi, makro ve mikro havza değişiminin izlenmesi, su kalitesinin belirlenmesi,

* Belediyecilik hizmetleri, imar planlarının oluşturulması, kentsel alan gelişiminin takip edilmesi, şehir planlama, kaçak yapılaşmanın tespiti,

* Madencilik, petrol/doğal gaz arama ve üretimi, kuyu lokasyonu belirleme, kuyu sondajı, kuyu çevresi yapılaşma çalışması,

* Tarımsal üretimlerin planlanması, ekim alanlarının kontrol edilmesi, yasa dışı ekim alanlarının tespit edilmesi, kışlık ve yazlık ekim alanlarının belirlenmesi, haşhaş ekim alanlarının ölçüm, kontrol ve veriminin hesaplanması, uyuşturucu ile mücadele,

* Enerji nakil hatlarının planlanması, projelendirilmesi ve hayata geçirilmesi, rüzgâr enerji santrallerinin fizibilitesi, boru hattı projelendirmesi, inşaat ve boru hattı döşemesi,

* Karstik çöküntü alanlarının belirlenmesi,

* Arkeolojik ve tarihi sit alanlarının tespiti ve izlenmesi,

* Kadastral faaliyetler

* Mahkemelerin taşınmaz, sınır anlaşmazlıkları davaları,

* Bilimsel araştırmalar,

* TÜİK çalışmaları,

* Toprak koruma ve arazi kullanımı

* Navigasyon

HGM bünyesinde; HGM tarafından üretilen her türlü coğrafi verinin diğer kişi/kurumlar ile sunulması/paylaşılmasını sağlayan "Coğrafi Veri Merkezi (CVM)" yer almaktadır.

Harita Genel Müdürlüğü tarafından üretilen ve kamu kurum ve kuruluşları, mahkemeler, belediyeler, üniversiteler ile gerçek ve tüzel kişiler ile paylaşılan yaklaşık 450 farklı coğrafi ürün grubu olup, bu ürünlere ilişkin fiyat ve diğer detaylı bilgilere HGM web sitesi üzerinden (www.harita.gov.tr) ulaşılabilmektedir.

Şekil 1'de Harita Genel Müdürlüğünce üretilen harita, harita bilgisi ve coğrafi verilere ait 2025 yılı fiyat listesi görülmektedir.

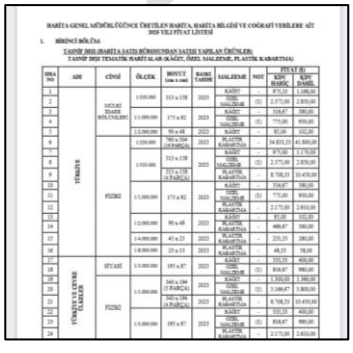

**Şekil 1.** HGM 2025 Yılı Fiyat Listesi (https://www.harita.gov.tr/uploads/files/pricelist/fiyat-listesi-1654.pdf)

## YÖNTEM

Harita Genel Müdürlüğüne yapılan coğrafi ürün talepleri dört kategoride değerlendirilmekte olup bunlar;

- Türk silahlı kuvvetlerinin harita ve harita bilgisi talepleri,
- Kamu kurumları, üniversiteler ve belediyelerin harita ve harita bilgisi talepleri,
- Mahkemelerin harita ve harita bilgisi talepleri,
- Gerçek ve tüzel kişilerin harita ve harita bilgisi talepleridir.

HGM envanterinde bulunan (raf ürün veya halihazırda üretimi bulunan) harita, harita bilgisi ve coğrafi veriler yukarıda belirtilen dört kategoride yer alan kurum/kuruluş ve kişiler ile gizlilik derecelerine göre paylaşılmaktadır.

Söz konusu talepler, 14 Şubat 2020 tarihli ve 7221 sayılı Coğrafi Bilgi Sistemleri ile Bazı Kanunlarda Değişiklik Yapılması Hakkında Kanun, Harita ve Harita Bilgileri Temin ve Kullanma Yönetmeliği, MSB Coğrafi Ürünler İkmal Yönergesi ve yayımlanan uygulama emirleri esaslarına göre her yıl belirlenen fiyat listesine göre karşılanmaktadır.

7221 Coğrafi Bilgi Sistemleri ile Bazı Kanunlarda Değişiklik Yapılması Hakkında Kanun sorumluluk matrisinde belirtilen ve envanterimizde bulunan veriler, söz konusu kanun sorumluluk matrisinde yer alan kamu kuruluşları ile taşınabilir veri depolama ortamında veya örün (web) servisi olarak ücretsiz karşılanmaktadır.

### Yürürlükteki Mevzuat ve Uygulama Emirlerinde Belirtilen Esaslar Kapsamında Talep Karşılama Süreçleri

Harita Genel Müdürlüğünden veri temini için;

- Gerçek ve tüzel kişiler şahsen başvuru, elektronik posta ya da yazı ile,
- Kamu kurumları, üniversiteler ve belediyeler resmi yazı ile,
- Mahkemeler örün sayfası (http://mahkeme.harita.gov.tr/login) üzerinden harita bilgi sorumlularının talep girişi ile talep yapabilmektedir.

Harita Genel Müdürlüğünden veri temini için izlenecek işlem adımları HGM web sitesinde (https://www.harita.gov.tr/harita-bilgilerini-temin-satin-alma-yontemi/sayfa/27) detaylı bir şekilde yer almaktadır.

Alınan taleplerle ilgili ücret, ilgili verinin tarih aralığı, kapsama alanı, kopyalama için gerekecek disk hacmi, örün servisi abonelik bilgileri gibi detaylar için talep makamı ile yazılı olarak iletişime geçilmektedir.

Ödemesi alınan ve işlemleri biten talepler için, verinin hazırlanması, hazırlanan ürünlerin veri depolama birimlerine kopyalanması ve ürünün HGM'den talep sahibine gönderilmesinin sağlanması (Şahsen teslim, PTT kargo, Mutemet ile teslim) işlemleri yapılmaktadır.

Şekil 2'de gerçek ve hukuk tüzel kişiler ile, Şekil 3'te Kamu Kurumları ile, Şekil 4'te Mahkemeler ile coğrafi veri paylaşımı için işlem akış şeması görülmektedir.

TASLAK

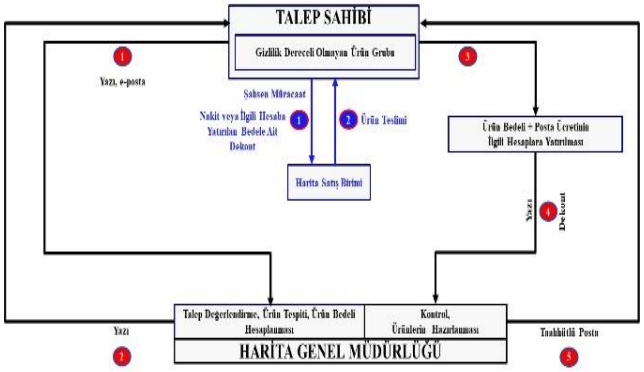


**Şekil 2.** Gerçek ve Hukuk Tüzel Kişisi ile Coğrafi Veri Paylaşımı




**Şekil 3.** Kamu Kurumları ile Coğrafi Veri Paylaşımı




**Şekil 4.** Mahkemeler ile Coğrafi Veri Paylaşımı

**BULGULAR**

Harita Genel Müdürlüğü, 1895 yılından bugüne savunma, kalkınma ve eğitim amaçlı birçok alanda veri taleplerini karşılamaktadır.

7221 Coğrafi Bilgi Sistemleri ile Bazı Kanunlarda Değişiklik Yapılması Hakkında Kanun'un yürürlüğe girdiği tarihten itibaren;

*2020 yılında 113.535.989,40 TL,
*2021 yılında 93.485.136,00 TL,
*2022 yılında 1.019.872.821,80 TL,
*2023 yılında 1.433.595.516,97 TL,
*2024 yılında 3.160.993.122,94 TL,

olmak üzere toplam 5.821.482.586,34 TL tutarındaki sayısal coğrafi veri kamu kurum ve kuruluşları, belediyeler ve üniversiteler ile bedelsiz paylaşılmıştır.

*2020 yılında 1.766.423,03 TL,
*2021 yılında 2.577.062,49 TL,
*2022 yılında 3.013.564,39 TL,
*2023 yılında 7.164.757,36 TL,
*2024 yılında 11.071.161,65 TL,

olmak üzere toplam 25.592.968,92 TL tutarındaki sayısal coğrafi veri gerçek ve tüzel kişiler, mahkemeler, kamu kurum ve kuruluşları, belediyeler ve üniversiteler ile bedelli olarak paylaşılmıştır.

2020-2024 yılları arasında kamu kurumları, üniversiteler ve belediyeler ile yapılan veri paylaşımına ilişkin talep sayıları Şekil 5'te, verilerin TL cinsinden değerine ilişkin istatistik Şekil 6'da gösterilmektedir.

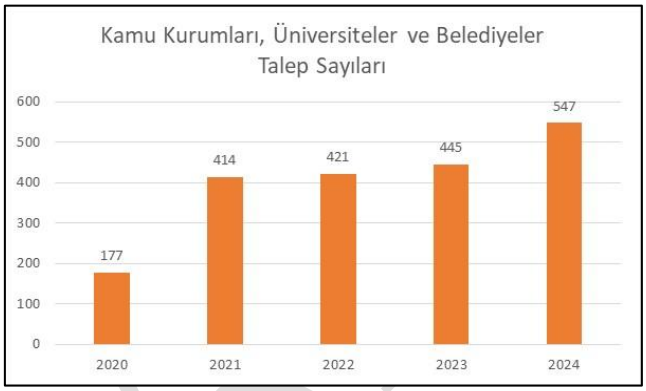


**Şekil 5.** Talep Sayısına Göre Kamu Kurumları ile Coğrafi Veri Paylaşımı

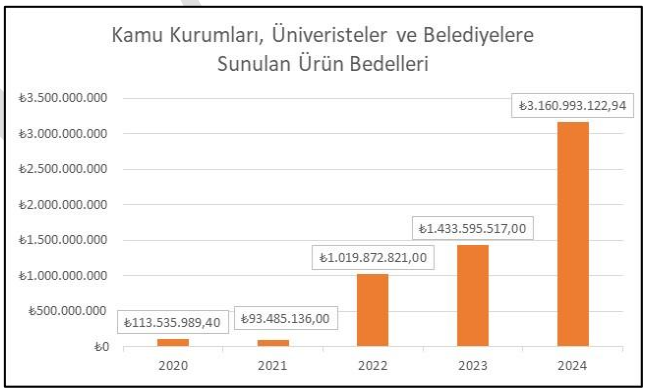


**Şekil 6.** TL Cinsinden Kamu Kurumları, Üniversiteler ve Belediyeler ile Coğrafi Veri Paylaşımı

2020-2024 yılları arasında gerçek ve hukuk tüzel kişileri ile veri paylaşımına ilişkin talep sayıları Şekil 7'de, verilerin TL cinsinden değerine ilişkin istatistik Şekil 8'de gösterilmektedir.

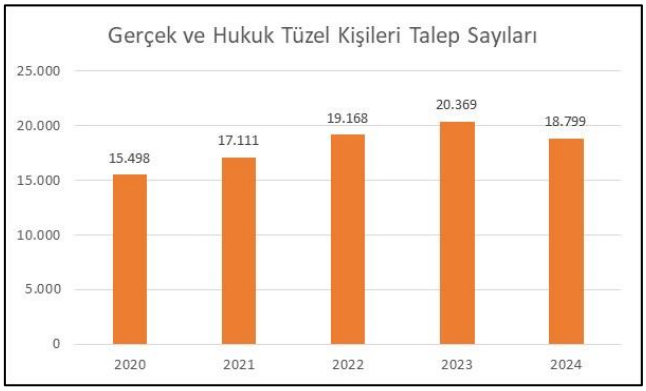

**Şekil 7.** Talep Sayısına Göre Gerçek ve Hukuk Tüzel Kişiler ile Coğrafi Veri Paylaşımı

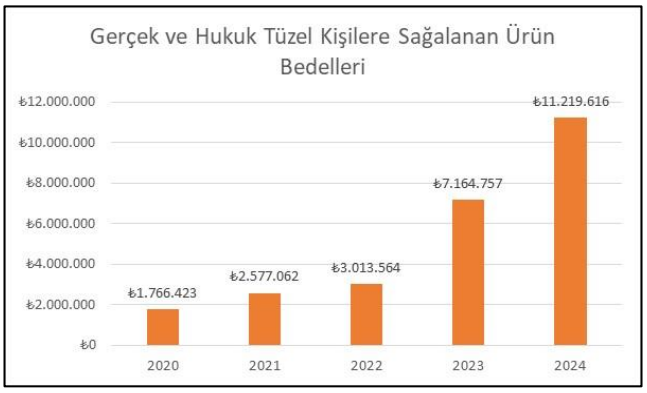


**Şekil 8.** TL Cinsinden Göre Gerçek ve Hukuk Tüzel Kişiler ile Coğrafi Veri Paylaşımı

Harita Genel Müdürlüğünce kamu kurum ve kuruluşları, üniversiteler ve belediyelere, 73 Örün Harita Servisi (WMS), 16 Örün Detay Servisi (WFS), 20 Örün Kapsam Servisi (WCS), 58 datum bağlantılı mareograf verileri (TUDES) aboneliği ve 89 HGM Atlas APİ hizmeti sağlanmaktadır. Ayrıca özel sektörden 7 kuruluşa WMS, 1 kuruluşa WFS, 17 kuruluşa TUDES aboneliği hizmeti sağlanmaktadır.

**TARTIŞMA**

HGM, artan coğrafi veri ihtiyaçlarının karşılanmasında bürokrasinin azaltılması, teknolojik imkan ve yeteneklerin kullanılması, internet üzerinden talep yapılması, raster ve vektör verilerin örün servisleri ile sunumu, gizlilik dereceli olmayan sayısal coğrafi ürünlerin bilgi güvenliği, siber güvenlik mevzuatına uygun olarak ağ üzerinden teslim edilmesi, ürün bedeli tahsilatın mali mevzuat esaslarında ağ üzerinden yapılması, zaman, personel tasarrufu sağlanması, fiziki koşullardan kaynaklı zayiatın önlenmesi amacına yönelik sistemlerin kurulabilirliği konularında mevcut altyapısını geliştirmeye devam etmektedir.

HGM verileri bir kere kullanılmamakta, ilgili çok sayıda projenin girdisi olarak tekrarlı kullanım yapılmakta, her güncelleme aşamasında yeniden talep edilmektedir.

Sunulan harita ve coğrafi veriler, kamu kurumlarının tek bir birimi tarafından kullanıldığı gibi, kendileri tarafından tüm alt birimlerine de dağıtılabilmektedir. Bu durumda, harita ve coğrafi verilerin birden fazla birimde kullanıldığı değerlendirilmektedir.

HGM ürünlerinin, 14 Şubat 2020 tarihli 7221 sayılı Kanunu ile kamuya bedelsiz sunulmasının kamuya sağladığı katma değer olumlu değerlendirilmektedir.

HGM kurumlar arası coğrafi veri paylaşımı ile güç birliği yaparak, müşterek çalışma ve koordinasyon ile ülke kaynaklarının etkin kullanımı için işbirliğine daima hazırdır.

**TEŞEKKÜR**

Bu çalışma sürecinde bilgi birikimi, yönlendirmeleri ve teknik desteği ile katkı sağlayan komutanlarıma ve çalışma arkadaşlarıma teşekkür ederim. Ayrıca, mensubu bulunduğum Harita Genel Müdürlüğü'ne minnettarlığımı sunarım.

**Yazar Katkı Oranı**

Çalışmaya yazarlar eşit oranda katkı sağlamıştır.

**Çıkar Çatışması/Çakışması**

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

**Araştırma ve Yayın Etiği Beyanı**

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

**KAYNAKÇA**

**Mevzuat**

14 Şubat 2020 tarihli ve 7221 sayılı Coğrafi Bilgi Sistemleri ile Bazı Kanunlarda Değişiklik Yapılması Hakkında Kanun

Harita ve Harita Bilgileri Temin ve Kullanma Yönetmeliği

MSB Coğrafi Ürünler İkmal Yönergesi

**İnternet adresi**

T.C. Harita Genel Müdürlüğü. (2025). Harita Genel Müdürlüğünce Üretilen Harita, Harita Bilgisi ve Coğrafi Verilere Ait 2025 Yılı Fiyat Listesi, T.C. Milli Savunma Bakanlığı, Ankara [Erişim tarihi: 25.04.2025], https://www.harita.gov.tr/uploads/files/pricelist/fiyat-listesi-1654.pdf

T.C. Harita Genel Müdürlüğü. (2025). Harita Bilgilerini Temin/Satın Alma Yöntemi, T.C. Milli Savunma Bakanlığı, Ankara [Erişim tarihi: 25.04.2025], https://www.harita.gov.tr/harita-bilgilerini-temin-satin-alma-yontemi/sayfa/27

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# TOPOVT Vektör Verilerinin Konumsal Doğruluklarının Araştırılması

**Talat AĞDAŞ*[1], Levent KUYUMCU[2], Abdullah SAYGILI[3]**

[1, 2, 3] *MSB, Harita Genel Müdürlüğü, Fotogrametri Dairesi Başkanlığı, Ankara, Türkiye*

**Anahtar Kelimeler**
Vektör Veri,
CBS,
Konum,
Coğrafi Veritabanı,

**ÖZET**

Fotogrametrik yöntemle kıymetlendirilen, topoğrafik bütünleme çalışmaları ile de arazide kontrol edilerek varsa hataları düzeltilen, eksiklikleri tamamlanan ve öznitelik bilgileri güncel duruma getirilen vektör veriler, TOPOVT coğrafi vektör veritabanı içerisinde dinamik ve sürekli bir yapıda bulunmaktadır. Başta savunma ve güvenlik amaçlı olmak üzere; kamu kurum kuruluşları, belediyeler ve üniversitelerin çeşitli kalkınma ve araştırma çalışmalarında aktif olarak kullanılmaktadır. Bu çalışmada tüm ülkeyi ve yakın çevresini kapsayan TOPOVT içerisindeki vektör verilerin konumsal doğruluklarının araştırılması hedeflenmiştir. Araştırma çalışmaları için 2024 yılı topoğrafik bütünleme çalışma bölgelerinden birisi olan 1:250.000 ölçekli KARAMAN pafta alanı belirlenmiştir. Bu kapsamda, kaba ve düzensiz hataları en aza indirmek maksadıyla çalışma alanına homojen dağılmış keskin detay noktaları seçilmiş olup bu noktalar fotogrametrik kıymetlendirme ve topoğrafik bütünleme çalışmalarıyla elde edilmiştir. Söz konusu keskin detay noktalarına TUSAGA AKTİF CORS sistemi kullanılarak GNSS alıcısıyla konum ölçmeleri gerçekleştirilmiştir. Elde edilen veriler irdelenerek doğrulukları analiz edilmiştir.

# Investigation of the Spatial Accuracy of TOPOVT Vector Data

**Keywords**
Spatial data,
GIS,
Position,
Geo-Database

**ABSTRACT**

The vector data produced by photogrammetric evaluation methods which are also examined and controlled for attribute and data completeness through integration studies, are in a dynamic and continuous structure within the geographic vector database, TOPOVT. Initially used for defense and security purposes, these data are actively used within public institutions, municipalities, and universities for various development and research projects within the framework of protocols. This study aims to investigate the positional accuracy of the vector data within TOPOVT which covers the entire country and its surrounding area. For the research the 1:250,000 scale KARAMAN map sheet area which is one of the 2024 topographic integration study regions, has been selected. In this context, sharp detail points that are homogeneously distributed across the study area have been chosen to minimize gross error and irregular errors. These points have been obtained through photogrammetric evaluation and topographic integration studies. The positions of these sharp detail points have been measured using the TUSAGA AKTİF CORS method with a GNSS receiver. The obtained data have been examined, and Mean Square Error values have been calculated.

* **Sorumlu Yazar**

*(talat.agdas@harita.gov.tr) ORCID ID 0000–0002–9522–7472
(levent.kuyumcu@harita.gov.tr) ORCID ID 0009–0002–5270–0298
(abdullah.saygili@harita.gov.tr) ORCID ID 0009-0008-5527-3467

**Kaynak Göster (APA):**

Ağdaş, T. & Kuyumcu, L. & Saygılı A. (2025). TOPOVT Vektör Vektör Verilerinin Konumsal Doğruluklarının Araştırılması. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

TASLAK

## 1. GİRİŞ

Topoğrafik Vektör Veritabanı (TOPOVT), topoğrafik detayların, topolojik vektör verilerle, topoğrafyanın ise eş yükseklik eğrileri ile temsil edildiği, mevki isimlerini ve yerleşim yeri isimlerini de içeren, 131 detay sınıfı ve 368 alttipi bünyesinde barındıran tüm ülkeyi ve yakın çevresini kapsayan vektör veritabanıdır.

Topoğrafik vektör veriler, stereo hava fotoğraflarından oluşturulan modellerle 3 boyutlu veya true ortofotolar ile 2 boyutlu olarak fotogrametrik kıymetlendirme metoduyla elde edilmiştir. Söz konusu vektör veriler, topoğrafik bütünleme ve veri yapılandırma çalışmaları ile topolojik ve veri tamlığı açısından kontrol edildikten sonra TOPOVT veritabanı içerisinde varlığını sürdürmektedir.

"Bütünleme", topoğrafik detayların fotogrametrik yöntemlerle kıymetlendirilmesiyle ve/veya diğer kaynaklardan öznitelikleri ile birlikte temin edilen vektör ve öznitelik verilerinin derlenmesiyle üretilen vektör verilerin, arazide kontrol edilerek varsa hatalarının düzeltilmesi, eksikliklerinin tamamlanması ve öznitelik bilgilerinin güncel duruma getirilmesi faaliyetine verilen isimdir.

## 2. MATERYAL VE YÖNTEM

Araştırma çalışmalarının yapılacağı test bölgesi Karaman ili ile Ayrancı, Karapınar, Emirgazi, Ereğli, Halkapınar, Altunhisar ve Ulukışla ilçelerini kapsayan Şekil 1'de gösterilen 1:250K ölçekli KARAMAN pafta alanıdır.

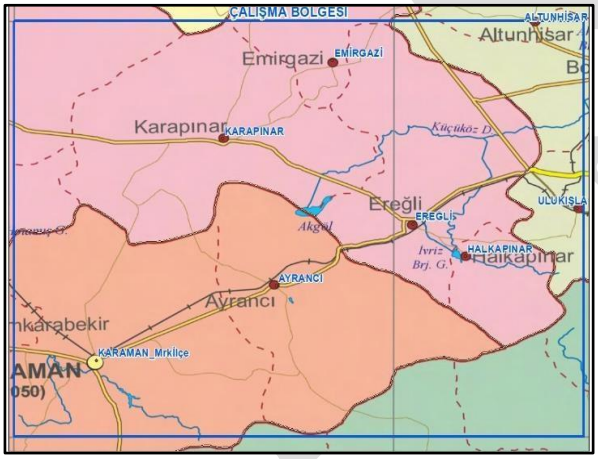


**Şekil 1**. Çalışma Bölgesi.

Söz konusu bölgeye ait 30 cm yer örnekleme aralıklı hava fotoğrafları %80 enine %35 boyuna bindirmeli olacak şekilde Harita Genel Müdürlüğü tarafından 2023 yılında çekilmiş olup hava fotoğraflarına ait dengeleme sonuçları Çizelge 1'de, Yer Kontrol Noktalarının dağılımı ise Şekil 2'de sunulmuştur.

**Çizelge 1.** Hava fotoğraflarına ait dengeleme sonuçları.

| Yer Kontrol Nokta Sayısı | X Ort. (m) | X Maks. (m) | Y Ort. (m) | Y Maks. (m) | KOH (m) Planimetrik |
|---|---|---|---|---|---|
| 30 | 0.00 | 0.21 | -0.00 | 0.17 | 0.11 |

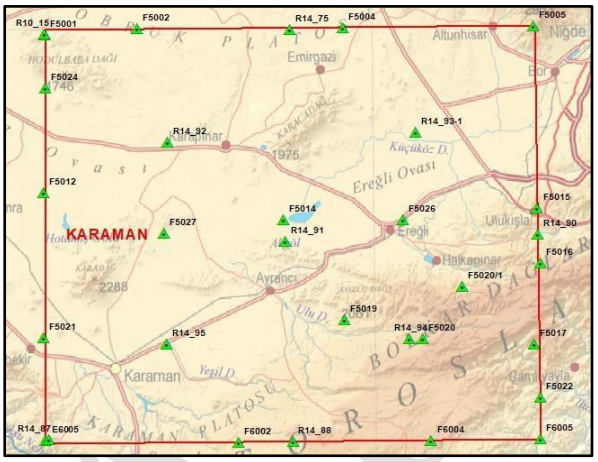


**Şekil 2.** Yer Kontrol Noktası dağılımı.

Çalışma bölgesi içerisinde yer alan vektör veriler: arazi topoğrafyasındaki yükseklik farklarından kaynaklanan yer değiştirmeler ile algılayıcı yöneltme hatası, mercek bozulmaları ve yeryüzünün küreselliğinden kaynaklanan hataların giderildiği ve topoğrafya üzerindeki nesnelerin (binalar, köprüler ve benzeri) yüksekliklerinden kaynaklanan hataların giderilerek nesnelerin gerçek düzlemsel konumlarında gösterildiği görüntüler olan ***true (gerçek) ortofotolar*** üzerinden fotogrametrik kıymetlendirme metoduyla üretilmiştir.

Araştırma çalışmalarında 1 adet GNSS alıcı ve 1 adet topoğrafik bütünleme seti kullanılmıştır. Şekil 3'te gösterilen bütünleme seti, taşınabilir bilgisayar içerisine, CBS programı ve GNSS alıcısını entegre şekilde içinde barındıran bir donanım ve elektronik pusula özellikli lazer mesafe ölçerden oluşmaktadır.



**Şekil 3.** Bütünleme seti.

Arazi öncesi hazırlık çalışmaları kapsamında fotogrametrik yöntemle kıymetlendirilen Şekil 4'te gösterilen, 1283 adet keskin detay ve topografik bütünleme çalışmaları ile arazide ölçülen 147 adet detay noktası olmak üzere toplam 1430 adet keskin detay noktası veri kümesi olarak belirlenmiştir. Daha sonra GNSS alıcısı ile TUSAGA-AKTİF CORS sistemiyle, belirlenen keskin detaylarda konum ölçmeleri gerçekleştirilmiştir.

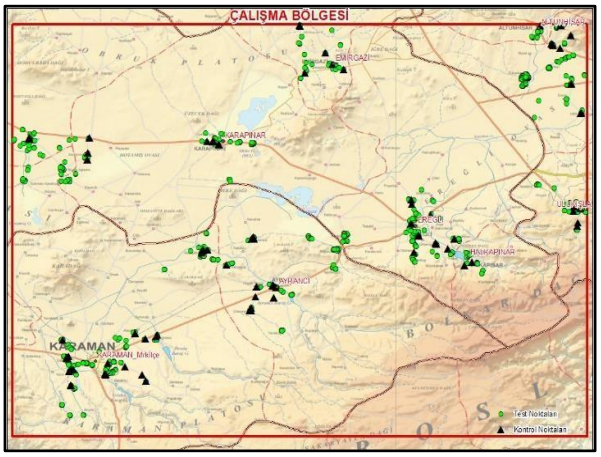


**Şekil 4.** Nokta Dağılımı.

Konum ölçmeleri için fotogrametrik kıymetlendirme ve topoğrafik bütünleme çalışmalarında aktif görev almayan ancak söz konusu teknik konularda uzmanlık bilgisine haiz tarafsız bir çalışma ekibi görevlendirilmiştir.

## 3. BULGULAR

1430 adet keskin detay noktasında konum ölçmeleri gerçekleştirilmesinin ardından yapılan ölçü verilerinin değerlendirilmesi neticesinde;

Topoğrafik bütünleme noktalarından 6 adet, fotogrametrik kıymetlendirme noktalarından 191 adet olmak üzere toplam 203 adet noktaya ait ölçümler kaba hata ve/veya mükerrer ölçü olması münasebetiyle analiz çalışmalarına dâhil edilmemiştir.

Bu kapsamda 1233 adet noktaya ait ölçüm verilerinden KOH (Karesel Ortalama Hata) hesaplaması yapılmıştır. Değerlendirme aşamasında 3Σ (sigma) yöntemine göre uyuşumsuz bulunan 209 adet nokta ölçüleri analiz çalışmaları dışında tutulmuştur. Söz konusu noktalara ait Δx ve Δy dağılımları sırasıyla Şekil 5, Şekil 6'da ve Şekil 7'de, $\sigma_X$ ve $\sigma_y$ dağılımları sırasıyla Şekil 8 ve Şekil 9'da gösterilmiştir.

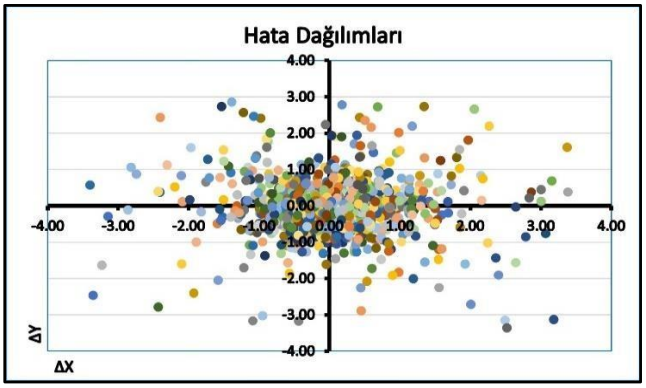


**Şekil 5.** Δx ve Δy dağılımları.

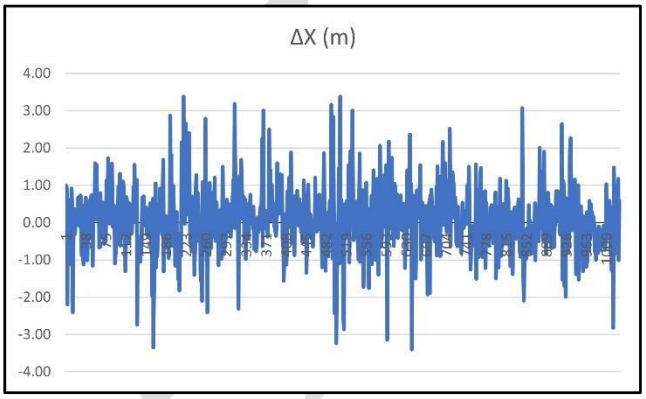


**Şekil 6.** Δx değerlerinin gösterimi.

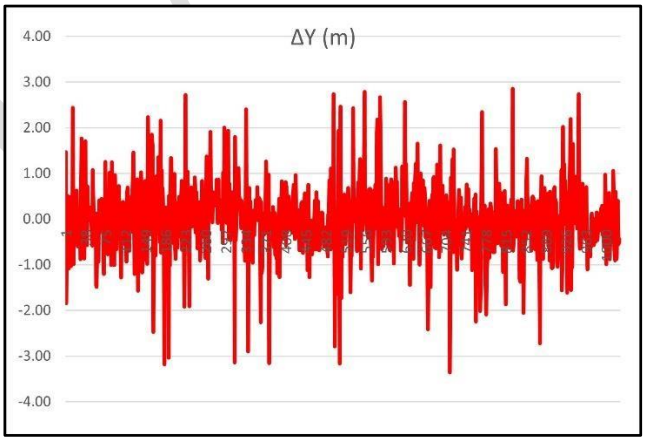


**Şekil 7.** Δy değerlerinin gösterimi.

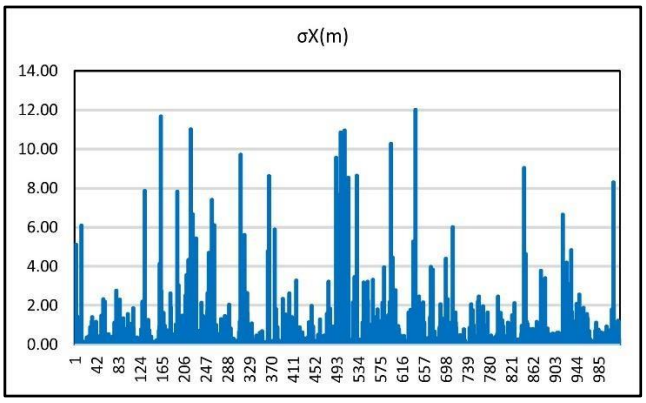


**Şekil 8.** σx değerlerinin gösterimi.

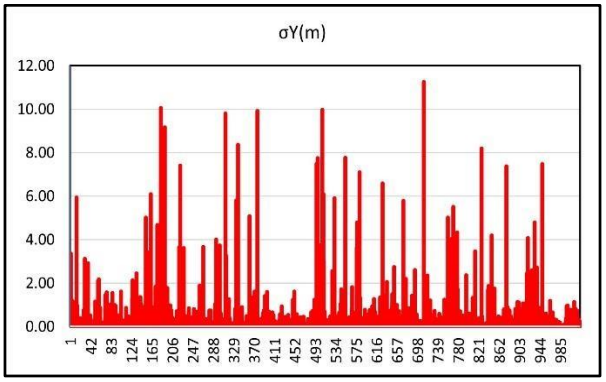


**Şekil 9.** σy değerlerinin gösterimi.

Analize ait sayısal bilgiler Çizelge 2'de sunulmuştur.

**Çizelge 2.** Analiz sonuçlarına ait sayısal bilgiler.

| Nokta Sayısı | X Ort. (m) | X Maks.(m) | Y Ort. (m) | Y Maks.(m) |
|---|---|---|---|---|
| 1024 | 0.07 | 3.40 | -0.01 | 3.36 |

## 4. SONUÇ

Araştırma çalışmasında elde dilen nokta ölçüm verilerinin değerlendirilmesi neticesinde Karesel Ortalama Hata değeri,

$$KOH(m) = \pm\sqrt{\frac{[\varepsilon\varepsilon]}{n}} \quad (1)$$

±1.13m doğrulukta olduğu hesaplanmıştır. Hesaplanan KOH(m) değeri %90 güven aralığına taşınmış olup Çizelge 3'te gösterilmiştir.

**Çizelge 3.** KOH ve CE90 değerleri.

| **KOH (m)** Planimetrik | **CE90 (m)** |
|---|---|
| ±1.13 | ±1.72 |

**Çizelge 4.** NATO STANAG2215 Topoğrafik Harita Üretim Standartları.

| | Sonuç (Ürün) Ölçeğinde Ölçüm | Harita Ölçeği veya Eşdeğer Sayısal Veri Çözünürlüğü | | | | |
|---|---|---|---|---|---|---|
| Derece | | 1:25.000 | 1:50.000 | 1:100.000 | 1:200.000 | 1:250.000 |
| A | 0.5 mm | 12.5 m | 25 m | 50 m | 100 m | 125 m |
| B | 1.0 mm | 25 m | 50 m | 100 m | 200 m | 250 m |
| C | 2.0 mm | 50 m | 100 m | 200 m | 400 m | 500 m |
| D | >2.0 mm | C Derecesinden daha düşük | | | | |
| E | | Belirlenmedi | | | | |

Çizelge 4'te gösterilen NATO STANAG 2215 Topoğrafik harita üretim standartlarına göre TOPOVT vektör verileri 1:25.000 ölçekli harita üretimi için A seviyede olduğu tespit edilmiştir.

**Çizelge 5.** ASPRS Coğrafi Verilerin Konum Doğruluk Standartları.

| Planimetrik KOH Doğrulukları (m) | Harita Ölçeği |
|---|---|
| 0.0125 | 1:50 |
| 0.025 | 1:100 |
| 0.050 | 1:200 |
| 0.125 | 1:500 |
| 0.25 | 1:1.000 |
| 0.50 | 1:2.000 |
| 1.00 | 1:4.000 |
| 1.25 | 1:5.000 |
| 2.50 | 1:10.000 |
| 5.00 | 1:20.000 |

Çizelge 5'te gösterilen Amerikan Fotogrametri ve Uzaktan Algılama Birliği (American Society for Photogrammetry and Remote Sensing-ASPRS) coğrafi vektör verilerin doğruluk standartlarında verilen limit değerleri içerisinde kaldığı tespit edilmiştir.

Bu kapsamda yapılan araştırma ve uluslararası harita üretim standartları incelendiğinde, TOPOVT vektör verilerinin konumsal doğruluklarının 1:25.000 ölçekli topoğrafik harita üretimi için son derece yeterli olduğu teyit edilmiştir.

### Yazar Katkı Oranı

Çalışmaya yazarlar eşit oranda katkı sağlamıştır.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

### Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

### KAYNAKÇA

Federal Geographic Data Committee, Geospatial Positioning Accuracy Standards, Virginia USA, 1998.

Harita Genel Müdürlüğü, Topoğrafik Vektör Veritabanı Arazi Bütünleme Talimatı, Ankara, 2020.

NATO Standardardization Agency Agence Otan de Normalisation, Evalution of Land Maps, Aeronautical Charts and Digital Topographic Data, Brussels, Belgiumi, 2010

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Makine Öğrenmesi ile Uzaktan Algılama Verilerinde Yüksek Doğruluklu Detay Sınıflandırması Uygulaması

**Mikail ODACI**[*1], **Burak TAVUKCU**[*1]

[1]*MSB, Harita Genel Müdürlüğü, Fotogrametri Dairesi Başkanlığı, Ankara, Türkiye*

**Anahtar Kelimeler**
Makine Öğrenmesi, Sınıflandırma, Uzaktan Algılama, Ortofoto, Arazi Örtüsü

**ÖZET**

Uzaktan algılama yöntemleri ile elde edilen görüntüler, detay çıkarımı, fotogrametrik kıymetlendirme çalışmaları, arazi kullanımı ve arazi örtüsünün belirlenmesi, ormancılık, tarım ve şehir planlaması gibi alanlarda önemli bir rol oynamaktadır. Bu tür analizler genellikle uzman operatörler tarafından yürütülmektedir. Son yıllarda yaygın olarak kullanılan makine öğrenmesi, derin öğrenme gibi teknikler sayesinde, sınıflandırma ve ardından gelen sayısallaştırma işlemleri otomatikleştirilebilmekte ve böylece zaman ve işgücü tasarrufu sağlanabilmektedir. Ancak derin öğrenme ve makine öğrenmesi çalışmalarında etiketleme çalışmaları uzun süreler alan, hassas şekilde yapılması gereken bir süreçtir. Bununla birlikte oluşturulacak modellerin eğitimi, yüksek donanım özellikleri ve uzun işlem süreleri gibi problemlerle karşılaşılmaktadır. Bu çalışmanın amacı, makine öğrenmesi algoritmaları kullanılarak basit etiketler ile hızlı sonuç alınabilen, uzaktan algılama yöntemleri ile elde edilen tüm raster veri setleri üzerinde, beş alan detay sınıfında yüksek doğruluk oranlarıyla sınıflandırma ve sayısallaştırma işlemlerinin otomatik hale getirilmesidir. Çalışmada, sınıflandırma uygulamalarında yaygın olarak kullanılan makine öğrenmesi yöntemlerinden Karar Ağacı (Decision Tree), Rastgele Ormanlar (Random Forest), Uyarlanabilir Artırma (Adaptive Boosting), Ekstra Ağaçlar (Extra Trees) ve Gradyan Artırmalı Sınıflandırma (Gradiant Boosting) algoritmaları tercih edilmiştir. Veri seti olarak; 12 bantlı, 10 metre çözünürlüklü Sentinel-2 uydu görüntüleri ile 30 cm çözünürlüğe sahip hava fotoğraflarından üretilen dört bantlı (kırmızı, yeşil, mavi, yakın kızılötesi) ortofoto görüntüler kullanılmıştır. Algoritmaların daha ayırt edici detayları tespit edebilmesi için, bölgeye ait yükseklik verisi ve görüntü bantlarından türetilmiş çeşitli spektral indeksler de yardımcı veri olarak kullanılmıştır. Söz konusu ortofoto görüntüler ve yardımcı veriler üzerinde testler gerçekleştirilerek sonuçları değerlendirilmiştir.

# An Application of High-Accuracy Detail Classification in Remote Sensing Data Using Machine Learning

**Keywords**
Machine Learning, Classification, Remote Sensing, Orthophoto, Land Cover

**ABSTRACT**

Images obtained through remote sensing methods play an important role in fields such as feature extraction, photogrammetric evaluation studies, land use and land cover determination, forestry, agriculture, and urban planning. These types of analyses are generally carried out manually by expert operators. Thanks to techniques such as machine learning and deep learning, which have become widespread in recent years, classification and the subsequent vectorization processes can be automated, thereby saving time and labor. However, in deep learning and machine learning studies, annotation processes are time-consuming and must be performed with precision. In addition, problems such as high hardware requirements and long processing times are encountered during the training of the models to be created. The aim of this study is to make classification and vectorization processes automatic with high accuracy rates across five polygon details classes on all raster datasets obtained through remote sensing methods, by using simple annotations through machine learning algorithms. In the study, commonly used machine learning methods for classification problems Decision Tree, Random Forest, Adaptive Boosting, Extra Trees, and Gradient Boosting algorithms were preferred. As a dataset, 12-band, 10-meter resolution Sentinel-2 satellite images and 4-band (red, green, blue, near-infrared) orthophoto images produced from aerial photographs with 30 cm resolution were used. In order for the algorithms to detect more distinctive details, regional elevation data and various spectral

* **Sorumlu Yazar**

*(mikail.odaci@harita.gov.tr) ORCID ID 0009-0009-5263-1908
(burak.tavukcu@harita.gov.tr) ORCID ID 0000-0002-5531-4803

**Kaynak Göster (APA):**

Odaci, M. & Tavukçu, B. (2025). Makine Öğrenmesi ile Uzaktan Algılama Verilerinde Yüksek Doğruluklu Detay Sınıflandırması Uygulaması. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, 18-20 Haziran 2025, Zonguldak, Türkiye

indices derived from the image bands were also used as auxiliary data. Tests were carried out on the mentioned orthophoto images and auxiliary data, and the results were evaluated.

## GİRİŞ

Dünya genelinde artan nüfus ve şehirleşmenin genişlemesiyle birlikte, ormanlar ve su kaynakları gibi doğal kaynakların yoğun kullanımı sonucu arazi örtüsünde meydana gelen değişimler, geçmişte hiç olmadığı kadar belirgin hâle gelmiştir. Bu kapsamda, arazi kullanımı ve arazi örtüsünün doğru bir şekilde tespit edilmesi; şehir planlamasından tarımsal üretime, orman yönetiminden çevresel korumaya kadar birçok alanda kritik bir rol oynamaktadır. Uydu ve hava görüntüleri gibi veriler aracılığıyla gerçekleştirilen arazi sınıflandırmaları, planlama, yönetim ve uygulama süreçlerini etkin bir şekilde desteklemektedir. Bu tür sınıflandırma işlemlerinde, geleneksel yöntemlerin yerini son yıllarda makine öğrenmesi temelli yaklaşımlar almaya başlamıştır. Özellikle yüksek çözünürlüklü görüntülerin artmasıyla birlikte, bu algoritmalar otomatik bir şekilde daha hızlı ve doğru sonuçlar üretebilme kapasitesine ulaşmıştır.

Bu çalışmada; açık kaynaklı, çok bantlı ve düşük uzamsal çözünürlüğe sahip Sentinel-2 uydu görüntüleri ile dört bantlı ve 30 cm yer örnekleme aralığına sahip hava fotoğraflarından elde edilen ortofotolar kullanılmıştır. Karar Ağacı (DTC), Rastgele Ormanlar (RFC), Uyarlanabilir Artırma (ABC), Ekstra Ağaçlar (ETC) ve Gradyan Artırmalı Sınıflandırma (GBC) gibi makine öğrenmesi algoritmaları kullanılarak; çıplak arazi, ağaç, çayır, yerleşim yeri ve su yüzeyleri olmak üzere beş sınıfta alan detay olarak sınıflandırma yapılmıştır. Sınıflandırma doğruluğunu artırmak amacıyla, yardımcı veri olarak bölgeye ait yükseklik verileri ve görüntü bantlarından türetilen çeşitli spektral indeksler değerlendirilmiştir. Son olarak, elde edilen sınıflandırma sonuçları sayısallaştırılmıştır.

## YÖNTEM

Bu çalışmada kullanılan görüntülerin makine öğrenmesi ile sınıflandırma algoritmalarına uygun hale getirilmesi için eğitim verisi hazırlanmıştır. Ek olarak, spektral ve yapısal farkları daha belirgin hale getirmek için çeşitli türetilmiş veri katmanları kullanılmıştır. Bu bölümde, veri hazırlık sürecinde izlenen yöntemler detaylı şekilde açıklanmıştır.

### Veri Seti

Çalışmada sınıflandırma doğruluğunu test etmek ve yöntemin farklı kullanım amaçlarına uygunluğunu değerlendirebilmek amacıyla birden fazla görüntü kaynağı kullanılmıştır. İlk olarak yüksek mekânsal çözünürlüğe sahip, 4 bantlı hava fotoğrafından üretilmiş ortofotolar kullanılmıştır. Buna ek olarak 12 bantlı fakat düşük mekânsal çözünürlüğe (10 metre) sahip Sentinel-2 uydu görüntüleri kullanılmıştır. Algoritmaların sınıflandırma performansını karşılaştırmalı olarak analiz edebilmek amacıyla iki ayrı test bölgesi belirlenmiştir. İlk test alanı bölgesinde hem Sentinel-2 hem de hava fotoğrafı verileri kullanılarak sınıflandırma gerçekleştirilmiştir. İkinci test alanında ise yalnızca hava fotoğrafına dayalı sınıflandırma yapılmış ve sonuçlar bu doğrultuda değerlendirilmiştir. Bu yaklaşım, yöntemin farklı çözünürlük ve veri tiplerine karşı gösterdiği performansın karşılaştırmalı olarak analiz edilmesine olanak tanımaktadır.

Bunlara ek olarak, yerleşim yerlerinin net bir şekilde ayırt edilebildiği üç bantlı yüksek çözünürlüklü bir hava fotoğrafı görüntüsü kullanılarak, algoritmaların yerleşim yeri tespitindeki performansını değerlendirebilmek amacıyla üçüncü bir test bölgesi çalışmaya dahil edilmiştir.

Yardımcı veri olarak görüntülerde mevcut olan bantlardan spektral indeksler türetilmiştir. Ek olarak ortofoto üretimi sırasında nokta eşleme algoritmalarıyla üretilmiş 30 cm çözünürlüklü sayısal yüzey modeli ile sayısal arazi modeli arasındaki fark alınarak yükseklik değişimini temsil eden Normalize Edilmiş Sayısal Yüzey Modeli (NDSM) elde edilmiştir. NDSM sınıflandırma sürecine ek bir girdi olarak dahil edilerek sınıflar arası ayrımın güçlendirilmesi hedeflenmiştir.

### Veri Hazırlık Süreci

Makine öğrenmesini algoritmalarının eğitilmesi amacıyla görüntülerden her sınıfa ait Doğru-Yanlış referans poligonları oluşturulmuş ve bu poligonlar yardımıyla raster verideki pikseller sınıf etiketleri ile işaretlenmiştir. Veri seti %80 eğitim %20 test olacak şekilde model eğitimi yapıldıktan sonra tüm raster görüntü üzerinde sınıflandırma tahminleri gerçekleştirilmiştir.

Sınıflandırma sürecinde Python programlama dili kullanılmıştır. Modellerin eğitimi ve tahmin işlemleri, yaygın olarak kullanılan scikit-learn kütüphanesi aracılığıyla gerçekleştirilmiştir. Bu süreçte eğitim verileri, her test bölgesi için ayrı ayrı hazırlanmış ve her bölgeye özgü model çıktıları değerlendirilmiştir.

### Makine Öğrenmesi Algoritması

Bu çalışmada farklı makine öğrenmesi algoritmaları kullanarak en iyi sonuç elde edilmek istenmiştir.

Karar ağacı algoritması seçimleri ve bunların sonuçlarını bir ağaç şeklinde temsil eden bir modeldir. Her düğümde veri en yakın sınıfa yönlendirilerek son düğüme kadar devam eder. Kolay modellenir fakat aşırı yükleme yapıldığında kötü tahminlerde bulunabilir (Quinlan, 1986).

Rastgele Ormanlar algoritması karar ağacı prensibine dayanır, ancak birden fazla karar ağacından oluşan bir orman oluşturur. Bu orman, daha doğru ve güvenilir tahminler yapmak için birden fazla modelin birleşiminden faydalanır (Breiman, 2001).

Ekstra ağaçlar algoritması rastgele ormanlar algoritmasına benzer şekilde çalışır ancak rastgelelik oranı yüksek bir modeldir. Bu rastgelelik, modelin öğrenme süresini hızlandırırken aynı zamanda genelleme kabiliyetini de artırabilir (Geurts vd., 2006).

Uyarlanabilir Artırma zayıf sınıflandırıcılarla başlayarak güçlü bir tahmin modeli oluşturan bir makine öğrenmesi modelidir. Her tekrarlamada, bir önceki modelin yanlış sınıflandırdığı örneklere daha fazla ağırlık verilir ve bu yüzden sonraki model bu hatalı sınıflara odaklanır. Sonuç tahmin, tüm zayıf modellerin ağırlıklı değerlendirilmesine dayanır (Freund & Schapire, 1997).

Gradyan Artırmalı Sınıflandırma yöntemi, hataları aşamalı olarak azaltmayı hedefleyen güçlü bir topluluk

öğrenme yöntemidir. Model, ardışık olarak eğitilen karar ağaçları sayesinde karmaşık sınıflandırma problemlerinde yüksek doğruluk sağlamaktadır. Her bir yeni öğrenici, önceki adımlarda yapılan hataları minimize edecek şekilde eğitilerek genel başarım artırılmaktadır (Friedman, 2001).

**Spektral İndeksler**

Araştırma çalışmasında doğal ve yapay unsurları ayırt edebilen ayrıca bitki örtüsü, çıplak arazi alanları ve su yüzeylerini daha iyi yansıtan spektral indeksler kullanılmıştır. Kullanılan indeksler "Çizelge 1"de gösterilmiştir. Normalize Edilmiş Bitki Örtüsü İndeksi (NDVI), bitki örtüsünün yoğunluğunu ölçmek için yaygın olarak kullanılan bir spektral indekstir (Rouse vd., 1973). Normalize Edilmiş Su İndeksi (NDWI), su yüzeylerini ayırt etmek amacıyla geliştirilmiş bir spektral indeks olup, yeşil ve yakın kızılötesi bantlar kullanılarak hesaplanır (Gao, 1996). Toprak Düzeltmeli Bitki Örtüsü İndeksi (SAVI), çıplak arazi etkisini azaltarak bitki örtüsü yoğunluğunu daha doğru şekilde belirlemek amacıyla geliştirilmiş bir indekstir (Huete, 1988).

**Çizelge 1**.Spektral İndeksler

| İndeksler | Formül |
|---|---|
| NDVI | $(Nir - Red)/(Nir + Red)$ |
| NDWI | $\frac{Green - Nir}{Green + Nir}$ |
| SAVI | $\frac{Nir - Red}{Nir + Red + 0.5} * (1 + 0.5)$ |

**Doğruluk Analizi**

Sınıflandırma tahminlerinin doğruluğunun değerlendirilmesinde kullanıcı doğruluğu, üretici doğruluğu ve F1 skoru gibi istatistiksel metrikler kullanılmıştır. Kullanıcı doğruluğu, modelin pozitif olarak tahmin ettiği örnekler içerisindeki gerçekten doğru olanların oranını ifade eder ve fazla tahminlerin etkisini ortaya koyar. Üretici doğruluğu ise, sınıfa ait tüm gerçek örneklerden kaç tanesinin doğru şekilde tahmin edildiğini gösterir; eksik tahminlerin model üzerindeki etkisini değerlendirir. F1 skor ise ikisinin harmonik ortalamasının hesaplanmasıyla bulunur ve genel başarımını ifade eder (Saito & Rehmsmeier, 2015).

$$Kullanıcı\ Doğruluğu = \frac{TP}{TP + FP} \quad (1)$$

$$Üretici\ Doğruluğu = \frac{TP}{TP + FN} \quad (2)$$

TP: Doğru Pozitif tahmin
FP: Yanlış Pozitif Tahmin
FN: Yanlış Negatif Tahmin

$$F_1 = 2 * \frac{Kullanıcı\ Doğruluğu * Üretici\ Doğruluğu}{Kullanıcı\ Doğruluğu + Üretici\ Doğruluğu} \quad (3)$$

**BULGULAR**

Bu çalışmada beş adet alan detay sınıfının tespiti amacıyla sınıflandırmada yaygın olarak kullanılan beş adet makine öğrenmesi algoritmaları kullanılmıştır. Model tahminleri doğruluğu operatör tarafından çizilen referans veri ile karşılaştırılarak F1 skor oranı elde edilmiştir. İlk olarak test alanı-1 için Sentinel-2 uydu görüntüsü "Şekil 1"ve hava fotoğrafları" Şekil 4" üzerinde sınıflandırma işlemleri yapılmıştır. Test bölgesine ait operatör tarafından çizilen referans veri ile "Şekil 2" ve "Şekil 5" algoritmaların tahmin ettiği sonuç veriler "Şekil 3" ve "Şekil 6" değerlendirilmiştir.

Test Alanı-1 için eğitim verisinde kullanılan alanların metre kare cinsinden değerleri, Sentinel-2 için "Çizelge 2" de hava fotoğrafından elde edilen görüntü için "Çizelge 4" de görülmektedir. Detay sınıflarına göre en yüksek doğruluk oranına sahip model ve bu modele ait F1 skorları sırasıyla "Çizelge 3" (Sentinel-2) ve "Çizelge 5" (hava fotoğrafı) içerisinde sunulmuştur.

**Çizelge 2**. Test Alanı-1 Sentinel-2 uydu görüntüsünden toplanan detaylara ait Doğru-Yanlış alanları

| Detay Sınıfı | Doğru ($m^2$) | Yanlış ($m^2$) | Toplam alan($m^2$) |
|---|---|---|---|
| Su yüzeyleri | 12068 | 13680 | 192364 |
| Çıplak arazi | 78329 | 80584 | 1170229 |
| Yerleşim yeri | 12780 | 117537 | 354051 |
| Çayır | 18360 | 69069 | 341716 |
| Ağaç | 6077 | 23072 | 242062 |

**Çizelge 3**. Test Alanı-1 Sentinel-2 12 bantlı uydu görüntüsünün sınıflandırılması sonucu en iyi sonucu veren model ve F1 skoru.

| Detay Sınıfı | F1 Skor (%) | Model |
|---|---|---|
| Su yüzeyleri | 94.81 | DTC |
| Çıplak arazi | 95.13 | ETC |
| Yerleşim yeri | 86.23 | DTC |
| Çayır | 88.88 | DTC |
| Ağaç | 88.76 | DTC |



**Şekil 1.** Test alanı-1 Sentinel-2 görüntüsü



**Şekil 2.** Test alanı-1 (Sentinel-2) operatör tarafından sınıflandırılması, referans veri.



**Şekil 3.** Test Alanı-1 (Sentinel-2) makine öğrenmesi algoritmaları ile sınıflandırmış görüntüsü.
Ağaç (koyu yeşil), Çayır (açık yeşil), Yerleşim yeri, Su, Çıplak arazi.

**Çizelge 4**. Test Alanı-1 hava fotoğrafı görüntüsünden toplanan detaylara ait Doğru-Yanlış alanları

| Detay Sınıfı | Doğru ($m^2$) | Yanlış ($m^2$) | Toplam alan($m^2$) |
|---|---|---|---|
| Su yüzeyleri | 11513 | 14155 | 188533 |
| Çıplak arazi | 20346 | 59555 | 307147 |
| Yerleşim yeri | 8245 | 34311 | 48700 |
| Çayır | 35393 | 38269 | 537096 |
| Ağaç | 3324 | 29544 | 156627 |

**Çizelge 5**. Test Alanı-1 hava fotoğrafı sınıflandırılması sonucu en iyi sonucu veren model ve f1 skoru.

| Detay Sınıfı | F1 Skor (%) | Model |
|---|---|---|
| Su yüzeyleri | 94.02 | RFC |
| Çıplak arazi | 94.17 | RFC |
| Yerleşim yeri | 87.41 | RFC |
| Çayır | 90.05 | DTC |
| Ağaç | 84.63 | RFC |



**Şekil 4.** Test Alanı-1 Ortofoto

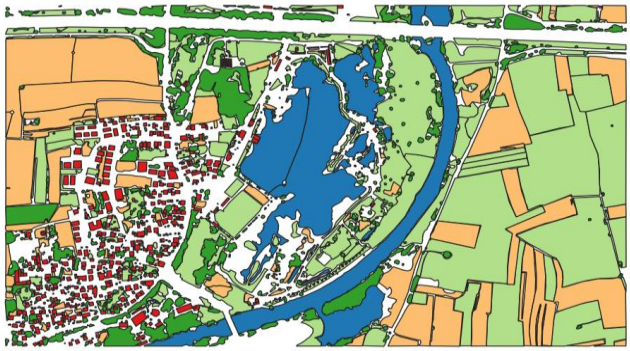

**Şekil 5.** Test Alanı-1 (Ortofoto) operatör tarafından sınıflandırılması, referans veri.



**Şekil 6.** Test Alanı-1 (Ortofoto) makine öğrenmesi algoritmaları ile sınıflandırmış görüntüsü.
Ağaç (koyu yeşil), Çayır (açık yeşil), Yerleşim yeri, Su, Çıplak arazi.

Sınıflandırma doğruluğunun performansını değerlendirebilmek amacıyla, ikinci test alanında yalnızca ortofoto görüntüleri "Şekil 7" kullanılarak sınıflandırma işlemleri gerçekleştirilmiştir. Test Alanı-2 için eğitim verisinde kullanılan alanların metre kare cinsinden değerleri "Çizelge 6" da görülmektedir. Operatör tarafından çizilen referans veri "Şekil 8" ve algoritmalar tarafından elde edilen veri "Şekil 9" değerlendirilmiştir. Bu alana ait en iyi sonucu veren model ve ilgili F1 skorları "Çizelge 7" de sunulmaktadır.

**Çizelge 6**. Test Alanı-2 hava fotoğrafı görüntüsünden toplanan detaylara ait Doğru-Yanlış alanları

| Detay Sınıfı | Doğru ($m^2$) | Yanlış ($m^2$) | Toplam alan($m^2$) |
|---|---|---|---|
| Su yüzeyleri | 2326 | 1041 | 33260 |
| Çıplak arazi | 11064 | 12767 | 241974 |
| Yerleşim yeri | 9098 | 15168 | 152055 |
| Çayır | 4859 | 7259 | 110650 |
| Ağaç | 2364 | 4170 | 74875 |

**Çizelge 7**. Test Alanı-2 hava fotoğrafı sınıflandırılması sonucu en iyi sonucu veren model ve f1 skoru

| Detay Sınıfı | F1 Skor (%) | Model |
|---|---|---|
| Su yüzeyleri | 95.2 | ETC |
| Çıplak arazi | 90.54 | DTC |
| Yerleşim yeri | 88.84 | ETC |
| Çayır | 93.36 | DTC |
| Ağaç | 89.51 | DTC |



**Şekil 7.** Test Alanı-2 Ortofoto



**Şekil 8.** Test Alanı-2 operatör tarafından sınıflandırılması, referans veri.

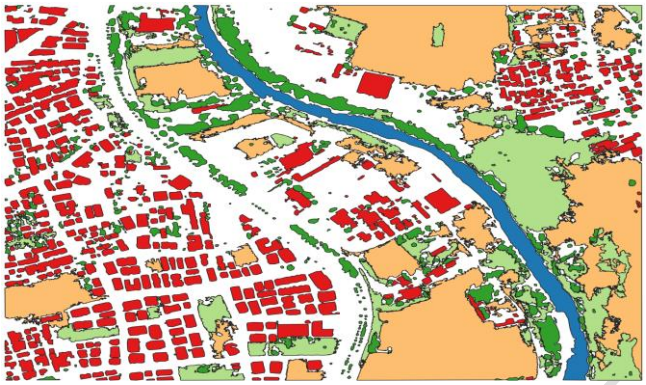

**Şekil 9.** Test Alanı-2 makine öğrenmesi algoritmaları ile sınıflandırmış görüntüsü.
Ağaç (koyu yeşil), Çayır (açık yeşil), Yerleşim yeri, Su, Çıplak arazi.

Diğer test alanlarında yerleşim yeri tespitiyle ilgili elde edilen sonuçlar, yapıların üzerine düşen ağaç dalları, gölgede kalan alanlar, küçük ölçekli yerleşim birimleri ve belirgin olamayan çatı yüzeyleri gibi faktörlerden olumsuz etkilenmiştir. Bu durum, algoritmaların yerleşim yeri detayını net bir şekilde sınıflandıramamasına neden olmuştur. Bu nedenle, algoritmaların yerleşim yeri tespiti konusundaki performanslarını daha açık bir yüzeyde ve daha belirgin yapı geometrileri üzerinde değerlendirebilmek amacıyla yalnızca yerleşim yeri sınıfı için üçüncü bir test alanı "Şekil 10" belirlenmiştir. Test Alanı-3 için eğitim verisinde kullanılan alanların metre kare cinsinden değerleri "Çizelge 8" de detaylı şekilde sunulmaktadır. Bu alana ait sınıflandırma çalışmaları "Şekil 11" ve "Şekil 12" de görülmektedir. Elde edilen performans değerleri ise "Çizelge 9"' de sunulmuştur.

**Çizelge 8**. Test Alanı-3 Hava fotoğrafı görüntüsünden toplanan detaylara ait Doğru-Yanlış alanları

| Detay Sınıfı | Doğru ($m^2$) | Yanlış ($m^2$) | Toplam alan($m^2$) |
|---|---|---|---|
| Yerleşim yeri | 2613 | 8469 | 73288 |



**Şekil 10.** Test Alanı-3 Ortofoto



**Şekil 11.** Test alanı-3 operatör tarafından sınıflandırılması, referans veri.

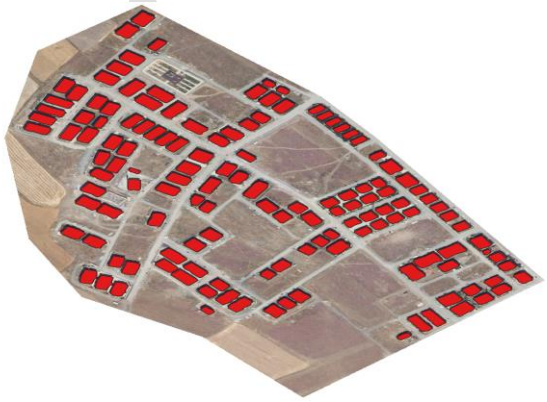

**Şekil 12.** Test alanı-3 makine öğrenmesi algoritmaları ile sınıflandırmış görüntüsü.

**Çizelge 9**. Test Alanı-3'te yerleşim yeri detayının sınıflandırılmasına ait performans sonuçları

| Değerlendirme Kriteri | F1 Skor (%) | Model |
|---|---|---|
| Genel Alan Bazlı | 96,16 | ETC |
| %80 ve Üzeri Alan Uyuşmasıyla Kabul | 99.82 | ETC |

**TARTIŞMA**

Üç farklı test alanın farklı uzaktan algılama görüntüleri üzerinde makine öğrenmesi algoritmaları ile sınıflandırma işlemleri gerçekleştirilmiştir. Test Alanı-1'de Sentinel-2'nin 12 bantlı görüntüsü üzerinde yapılan sınıflandırma sonucunda en yüksek doğruluk oranı

%95,13 F1 skoru ile çıplak arazi sınıfında elde edilmiştir. Bu veri setiyle yapılan çalışmalarda, karar ağacı yönteminin genel olarak yüksek doğruluklu sonuçlar verdiği gözlemlenmiştir. Daha basit verilerle ve sınırlı sayıda eğitim örneğiyle yapılan sınıflandırmalarda da karar ağaçlarının hem hızlı hem de doğru sonuçlar verdiği değerlendirilmiştir. Aynı test alanında daha yüksek mekânsal çözünürlüğe sahip hava fotoğrafları kullanılarak yapılan sınıflandırmada ise rastgele ormanlar modeli, su yüzeyleri (%94,02), çıplak arazi (%94,17) ve yerleşim yeri (%87,41) sınıflarında en yüksek başarıyı göstermiştir. Bu durum, çözünürlük artışının özellikle kentsel detaylar üzerindeki olumlu etkisini ortaya koymaktadır. Daha yüksek çözünürlükte tekil ağaç gibi daha kapsamlı bir şekilde sınıflandırma yapılmasının daha başarılı olduğu gözlemlenmiştir.

Test Alanı-2 üzerinde yalnızca ortofoto görüntüsü kullanılarak yapılan sınıflandırmalarda genel doğruluk değerleri tatmin edici seviyelere ulaşmıştır. Çayır, çıplak arazi ve ağaç detayları arasında sınırlı sayıda karışma gözlemlense de genel doğruluk değerleri tatmin edici seviyededir. Test Alanı-1'de de görüldüğü gibi yerleşim yeri tespitinde görece daha düşük değerler görülmektedir. Bunun sebebinin yapıların üzerine düşen ağaç dalları, gölgede kalan alanlar, küçük ölçekli yerleşim birimleri ve belirgin olamayan çatı yüzeyleri gibi faktörlerden kaynaklı olduğu tespit edilmiştir.

Test Alanı-3'te ise yalnızca yerleşim yeri sınıfına odaklanarak, önceki test alanlarında karşılaşılan gölgeleme, örtüleme ve yapı boyutu gibi sınıflandırma hatalarının etkisini azaldığı görülmektedir. Sonuçlar, tüm algoritmaların yüksek doğruluk değerlerine ulaştığını özellikle Ekstra Ağaçlar algoritmasının yerleşim yeri tespitinde oldukça yüksek doğruluk sağladığını (F1 = %96,16) ve alan bazlı değerlendirmede %99,82 oranında başarıya ulaştığını göstermektedir. Bu test alanı, yerleşim yeri sınıfı gibi yapısal öğelerin tespitinde açık net geometrili ve engelsiz görüntü alanlarının model performansını ciddi oranda arttırdığı ortaya koymuştur.

Sınıflandırma doğruluğunu artırmak amacıyla hava fotoğrafını sınıflandırırken yardımcı verilerden olan spektral indeksler ve NDSM tüm sınıflarda model performansına önemli ölçüde katkı sağlamıştır. Spektral indeksler, özellikle ağaç sınıfı ile çayır sınıfı ayrımına yaparken veya çıplak arazi ile çayır sınıfını ayırırken sınıflar arası spektral farkların belirginleştirilmesinde etkili olmuştur. NDSM ise, yükseklik farkına dayalı olarak benzer spektral değerlere yol ile yerleşim sınıfını ve özellikle ağaç detayı ile çayır detay ayrımında daha doğru şekilde tahmin edilmesine olanak tanımıştır. Bu yardımcı veriler ile modellerin özellikle karmaşık ya da sınır değeri belirsiz alanlarda daha isabetli tahminler yapabilmesini mümkün kılmıştır.

Ağaç detayı tespitinde doğruluk oranını etkileyen en önemli faktörlerden birinin, tekil ağaçların doğru bir şekilde belirlenmesinin zorluğundan kaynaklandığı tespit edilmiştir. Yapılan sınıflandırma sonuçlarında, modellerin özellikle gölgeli alanlar ile çayır ve ağaç sınıflarının sınırlarında ayrım yapmakta zorlandığı ve bu durumun yanlış sınıflandırmalara yol açtığı gözlemlenmiştir. Buna karşın, yoğun ormanlık alanlarda modelin daha belirgin spektral özellikler sayesinde yüksek doğrulukla sınıflandırma gerçekleştirdiği belirlenmiştir.

## SONUÇ

Bu çalışmada, uzaktan algılama verilerinden elde edilen görüntüler üzerinde farklı makine öğrenmesi algoritmaları kullanılarak beş adet alan detay sınıfında otomatik sınıflandırma ve sayısallaştırma işlemleri gerçekleştirilmiştir. Kullanılan Sentinel-2 uydu görüntüleri ve yüksek çözünürlüklü hava fotoğrafları üzerinde yapılan testlerde, genel olarak yüksek doğruluk oranları elde edilmiş ve uygulanan yöntemlerin farklı veri kaynakları üzerinde etkili biçimde çalışabildiği ortaya konmuştur.

Sınıflandırma sürecinde; Karar Ağaçları, Rastgele Ormanlar, Uyarlanabilir Artırma, Ekstra Ağaçlar ve Gradyan Artırmalı Sınıflandırıcı gibi algoritmalar test edilmiş ve her sınıf için en iyi sonuç veren model belirlenmiştir. Elde edilen sonuçlar, spektral olarak benzer sınıfların ayrımında model seçiminin kritik olduğunu ve doğruluk oranlarının sınıfa göre farklılık gösterdiğini ortaya koymuştur.

Yardımcı veri olarak kullanılan spektral indeksler ve NDSM, sınıflar arası ayrımı belirginleştirerek modellerin doğruluk oranlarını anlamlı ölçüde artırmıştır. Bu veriler, özellikle ağaç–çayır ve çıplak arazi–çayır gibi spektral olarak yakın sınıfların ayrımında etkili olurken; NDSM, yükseklik farkına dayalı olarak ağaç ve yerleşim yeri sınıflarının daha hassas şekilde tespit edilmesini mümkün kılmıştır.

Sonuç olarak, bu çalışma makine öğrenmesi algoritmalarının uzaktan algılama verileri üzerinde, sınırlı etiketleme ile dahi yüksek doğruluklu sınıflandırmalar gerçekleştirebildiğini ortaya koymuştur.

## TEŞEKKÜR

Bu çalışma sürecinde bilgi birikimi, yönlendirmeleri ve teknik desteği ile katkı sağlayan komutanlarıma teşekkür ederim. Ayrıca, analizlerde kullanılan veri setlerinin temininde destek veren Harita Genel Müdürlüğü'ne minnettarlığımı sunarım.

### Yazar Katkı Oranı

Çalışmaya yazarlar eşit oranda katkı sağlamıştır.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

### Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

## KAYNAKÇA

Breiman, L. (2001). Random forests. Machine Learning, 45(1), 5–32. doi: 10.1023/A:1010933404324.

Freund, Y., & Schapire, R. E. (1997). A decision-theoretic generalization of on-line learning and an application to boosting. Journal of Computer and System

Sciences, 55(1), 119–139. doi: 10.1006/jcss.1997.1504.

Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. Annals of Statistics, 29(5), 1189–1232. doi: 10.1214/aos/1013203451

Gao, B. C. (1996). NDWI: A normalized difference water index for remote sensing of vegetation liquid water from space. Remote Sensing of Environment, 58(3), 257–266. doi: 10.1016/S0034-4257(96)00067-3

Geurts, P., Ernst, D., & Wehenkel, L. (2006). Extremely randomized trees. Machine Learning, 63(1), 3–42. doi: 10.1007/s10994-006-6226-1

Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). Remote Sensing of Environment, 25(3), 295 309. doi: 10.1016/0034-4257(88)90106-X

Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1973). Monitoring vegetation systems in the Great Plains with ERTS. NASA Special Publication, 351, 309–317.

Saito, T., & Rehmsmeier, M. (2015). The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. PLOS ONE, 10(3), e0118432. doi: 10.1371/journal.pone.0118432.

Quinlan, J. R. (1986). Induction of decision trees. Machine Learning, 1(1), 81–106. doi: 10.1007/BF00116251

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Arazi Örtüsü ve Arazi Kullanımı Sınıflandırmasında Landsat-9 Multispektral ve Pixxel TD-1 Hiperspektral Veri Setlerinin Karşılaştırmalı Analizi

**Fatih Fehmi Şimşek** [*1], **Mustafa Üstüner** [2] **Kaan Kalkan** [1]

[1] *TÜBİTAK Uzay Teknolojileri Araştırma Enstitüsü , Ankara 06800, Türkiye*
[2] *Samsun Üniversitesi, İklim Bilimi ve Meteoroloji Mühendisliği Bölümü, Samsun, 55060, Türkiye*

**Anahtar Kelimeler**

Makine Öğrenimi,
Landsat,
Pixxel TD-1,
Sınıflandırma

**ÖZET**

Bu çalışma, Landsat-9 multispektral (çok bantlı) uydu görüntüleri ile Pixxel TD-1 hiperspektral uydu görüntülerinin, arazi kullanımı ve arazi örtüsü (AKAÖ) sınıflandırmasındaki performansını karşılaştırmayı amaçlamaktadır. Çalışma alanı olarak, Türkiye'nin önemli tarım alanlarından birisi olan Çukurova Ovası seçilmiş ve çalışma kapsamında Landsat-9 ve Pixxel TD-1 uydu görüntülerinin, AKAÖ amacıyla sınıflandırılması işlemi gerçekleştirilmiştir. Çalışmada, veri ön işleme aşamasında Pixxel TD-1 hiperspektral görüntülerine Minimum Gürültü Fraksiyonu (MNF) dönüşümü ve Temel Bileşenler Analizi (TBA) yöntemleri uygulanmıştır. Görüntülerin sınıflandırma işlemlerinde ise Aşırı Gradyan Artırma (XGBoost) yöntemi tercih edilmiştir. Deneysel çalışmamızda, Pixxel TD-1 hiperspektral verilerinin (%91,8) Landsat-9 multispektral verilerine (%87,1) kıyasla daha yüksek sınıflandırma başarımına sahip olduğu görülmüştür. Özellikle sulak alanlar, çıplak toprak ve mera gibi spektral olarak karışabilen sınıflarda TD-1 verilerinin belirgin bir iyileşme sağladığı tespit edilmiştir. Bu çalışma, hiperspektral verilerin, arazi örtüsü sınıflandırmasında sağladığı avantajları vurgulamakta ve hiperspektral teknolojilerin potansiyel kullanım alanlarına ışık tutmaktadır.

# Comparative Analysis of Multispectral Landsat-9 and Hyperspectral Pixxel TD-1 Datasets in Land Cover and Land Use Classification

**Keywords**

Machine Learning,
Landsat,
Pixxel TD-1,
Classification

**ABSTRACT**

This study aims to compare the performance of Landsat-9 multispectral images and Pixxel TD-1 hyperspectral images in land use and land cover (LULC) classification. Çukurova Plain, one of the most important agricultural areas of Turkey, was selected as the study area and Landsat-9 and Pixxel TD-1 satellite images were classified for LULUC classification. In the study, Minimum Noise Fraction (MNF) transformation and Principal Component Analysis (PCA) methods were applied to Pixxel TD-1 hyperspectral images in the data preprocessing stage. The Extreme Gradient Boost (XGBoost) method was preferred for image classification. In our experimental study, it was observed that Pixxel TD-1 hyperspectral data (91.8%) had higher classification performance than Landsat-9 multispectral data (87.1%). Especially for the spectrally intermixed classes such as wetlands, bare soil and pasture, TD-1 data was found to provide a significant improvement. This study highlights the advantages of hyperspectral data in land cover classification and sheds light on the potential uses of hyperspectral technologies.

## GİRİŞ

Uzaktan algılama teknolojileri, arazi kullanımı ve arazi örtüsü (AKAÖ) sınıflandırması gibi çevresel etkiye sahip analizlerde kritik bir rol oynamaktadır. Multispektral (çok bandlı) veriler AKAÖ sınıflandırılması amacıyla yaygın bir şekilde kullanılsa da, daha yüksek spektral çözünürlüğe sahip olan hiperspektral uydu görüntüleri, AKAÖ sınıflandırılması işleminde daha yüksek doğruluk değerlerine ulaşılmasına imkan sağlamaktadır (Green et al., 1988). Landsat programı, özellikle Landsat-8 ve Landsat-9 uyduları ile, orta çözünürlükte çok bantlı spektral veri sağlayarak, arazi örtüsü değişimlerinin izlenmesine önemli katkılar sağlamaktadır (Markham et al., 2016). Landsat-9 uydusu, 15, 30 ve 100 metre mekânsal çözünürlüğe sahip çok bandlı (multispektral) veriler sağlamaktadır ve

Copernicus gibi servislere destek olacak şekilde sistematik veri akışı sunmaktadır. Öte yandan, yeni nesil ticari hiperspektral sistemler, daha dar bant aralıklarında daha çok sayıda spektral bant (kanal) sağladıkları için, özellikle karmaşık ve heterojen arazi örtüsüne sahip alanlarda sınıflandırma doğruluğunu artırmayı vaat etmektedir. Pixxel tarafından geliştirilen TD-1 uydusu ise, 30 metre mekânsal çözünürlükte ve 470-900 nm aralığında 150'den fazla spektral banda sahip hiperspektral veriler sunmaktadır. Pixxel TD-1 uydusunun temel amacı, gelecek yıllarda kurulacak olan daha geniş ölçekli hiperspektral uydu takım yıldızlarının ön testlerini gerçekleştirmektir.

Bu çalışmada, Adana ili Çukurova ovasını kapsayan Landsat-9 multispektral ve Pixxel TD-1 hiper spektral uydu görüntülerinin, AKAÖ sınıflandırılmasındaki başarımları karşılaştırmalı olarak analiz edilmiştir. Veri ön işleme adımlarında, Pixxel TD-1 hiperspektral verisine, Minimum Gürültü Fraksiyonu (MNF) dönüşümü (Green et al., 1988) ve Temel Bileşenler Analizi (PCA) (Jolliffe, 2002) yöntemleri uygulanmıştır. Veri önişleme adımlarının ardından, sınıflandırma işlemine geçilmiş ve bu işlem adımında ise yüksek doğruluk elde etme potansiyeli nedeniyle yeni nesil makine öğrenme algoritmalarından olan aşırı gradyan artırma (extreme gradient boosting; XGBoost) yöntemi tercih edilmiştir (Chen & Guestrin, 2016). Çalışmanın temel amacı, Landsat-9 ve Pixxel TD-1 uydu görüntülerinin, AKAÖ sınıflandırmasındaki başarımlarını karşılaştırmak ve sınıf bazlı karışımlarda hiperspektral verinin üstünlüklerini ortaya çıkarmaktır. Elde edilen deneysel sonuçlar, hem toplam sınıflandırma doğruluğu hem de sınıf bazlı doğruluklar (F1 skor değerleri) değerlendirilerek analiz edilmiştir.

## ÇALIŞMA ALANI VE MATERYAL

Bu bölümde, çalışma alanı tanıtılacak ve deneysel çalışmamız kapsamında kullanılan multispektral ve hiperspektral verilerin teknik detayları anlatılacaktır.

### Çalışma Alanı

Çalışma alanı (35°16'-35°75' E, 37°16'-36°29' N), Türkiye'nin güneyinde, Adana İli Çukurova bölgesinde yer almaktadır (Şekil 1). Çukurova ovası, sulama ile desteklenen yoğun tarımsal faaliyetlerin yürütüldüğü, Türkiye'nin en verimli tarım bölgelerinden birisi olup, bölgede Akdeniz iklimi hakimdir.

Çalışma alanında, arazi örtüsü sınıfları açısından tarım arazileri ağırlıklı olmakla birlikte, kentsel alan, sanayi ve ormanlık alanlarda mevcuttur. Ceyhan ve Seyhan nehirleri, bölgedeki tarımsal üretimi destekleyen başlıca doğal unsurlardır.

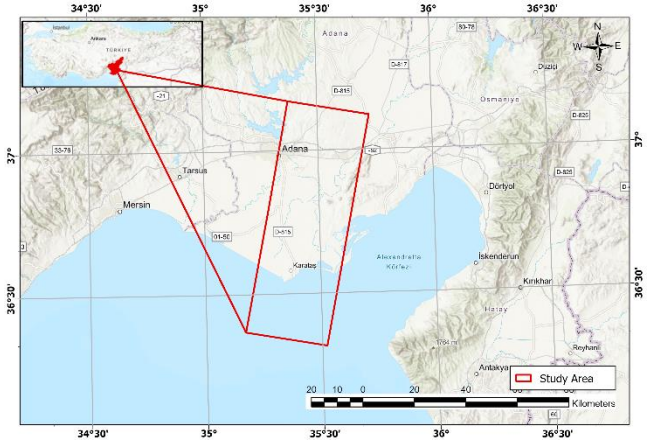


**Şekil 1.** Çalışma alanı

### Landsat 9

Landsat-9, 27 Eylül 2021 tarihinde NASA ve Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu (USGS) iş birliğiyle fırlatılan bir yer gözlem uydusudur. Landsat programının dokuzuncu uydusu olan Landsat-9, yer yüzeyinin orta çözünürlüklü görüntülerini sağlamakta ve bu sayede arazi örtüsündeki değişimlerin izlenmesi ile doğal kaynakların yönetilmesine önemli katkılar sunmaktadır (Markham et al., 2016). 11 adet spektral banta sahip olup farklı mekansal çözünürlüklerde (15, 30 ve 100 metre) veri toplayabilen Landsat-9 uydusu, her bir görüntü alımında yaklaşık olarak 185 kilometre genişliğinde bir alanı taramaktadır. Landsat-9 verilerinin işleme seviyeleri arasında yer alan L2SP (Level-2 Science Products), yüzey yansıması ve arazi yüzey sıcaklığı bilgilerini içeren spektral kanallara (bantlara) sahiptir. Atmosferik düzeltmeleri yapılmış olan bu veriler, arazi kullanımı ve arazi örtüsündeki değişikliklerin izlenmesi ve modellenmesi amacıyla yaygın olarak kullanılmaktadır ve L2SP ürünleri, herhangi bir önişleme adımına ihtiyaç duymamaktadır (Montanaro et al., 2022). Sınıflandırma gibi analizlerde direkt olarak kullanılabilmektedir.

### Landsat 9

Pixxel, hiperspektral uydu görüntüleme alanında faaliyet gösteren Hindistan merkezli bir uzaktan algılama şirketi olup, şirketin ilk uydusu Tech Demo-1 (TD-1)'dir ve bu uydu 1 Nisan 2022 tarihinde uzaya gönderilmiştir. Yaklaşık 30 metre mekansal çözünürlüğe ve 150'den fazla spektral banda sahip hiperspektral bir görüntüleme sensörü taşıyan TD-1, Pixxel'in gelecekte oluşturmayı planladığı ticari uydu takımyıldızının teknolojik altyapısını test etmek ve doğrulamak amacıyla geliştirilmiştir. TD-1 tarafından sağlanan veriler, beş farklı işlenme seviyesinde sunulmaktadır: L0, L1A, L1B, L1C ve L2A. Görüntü işleme süreci dört temel aşamadan oluşmaktadır: radyometrik düzeltme, geometrik düzeltme, atmosferik düzeltme ve kalite analizi. İlk aşamada, uydudan indirilen ham veriler uzun süreli depolama için L0 seviyesine dönüştürülmektedir. Ardından, radyometrik düzeltme işlemi gerçekleştirilmekte; bu aşamada dijital sayılar (digital number) radyansa çevrilmekte ve temel şeritler ile yüksek frekanslı gürültüler giderilmektedir. Bu işlem sonucunda elde edilen veriler L1A seviyesinde saklanmaktadır. L1A verilerine geometrik düzeltme modeli uygulanarak veriler coğrafi olarak referanslanmakta ve ortorektifikasyon sağlanarak L1B seviyesine ulaşılmaktadır. Bunu takiben, Pixxel'in geliştirdiği atmosferik düzeltme modeli kullanılarak, atmosferin üst reflektansı (top-of-atmosphere) (L1C) ve atmosferin alt reflektansı (surface reflectance-yüzey yansıması) (L2A) seviyelerinde veriler üretilmektedir. Bu çalışma kapsamında, L2A seviyesindeki hiperspektral uydu görüntüleri kullanılmıştır.

### Yer doğruluk verisi (CORINE)

CORINE (Coordination of Information on the Environment), Avrupa Birliği tarafından, arazi örtüsü ve arazi kullanımı hakkında tutarlı ve karşılaştırılabilir veriler sağlamak amacıyla başlatılan bir programdır (Rossi ve Bianchi, 2019). CORINE programı kapsamında, farklı çözünürlüklerdeki uydu görüntüleri kullanılarak

1990, 2000, 2006, 2012 ve 2018 yıllarına ait arazi örtüsü haritaları üretilmiştir. Bu çalışmada sınıflandırma işleminde, referans veri olarak CORINE 2018 verileri kullanılmıştır. Söz konusu veriler, Copernicus programı kapsamında Sentinel-1 ve Sentinel-2 uydularından elde edilen görüntülerin görsel yorumlanması ve bilgisayar destekli sınıflandırılması yoluyla üretilmiştir. CORINE 2018 verisi, 44 tematik sınıf içeren hiyerarşik bir sınıflandırma sistemine dayanmaktadır (Pazur et al., 2024). Çalışma alanı için yer doğrulama verilerinin oluşturulması aşamasında, CORINE 2018 verilerindeki detaylı sınıflamalar, ana kategoriler (tarım, orman, yapay alanlar ve su kütleleri) altında tekrar gruplanmıştır. Bu ana kategoriler, çalışma alanı genelinde homojen bir dağılım göstererek, sınıflandırma doğrulama süreci için uygun bir referans veri setini sağlamıştır.

## METODOLOJİ

### Veri ön işleme

Landsat-9 (L2SP) ve TD-1 (L2A) görüntüleri yüzey reflektans değerlerini temsil ettiğinden, ek bir atmosferik düzeltme işlemi uygulanmamıştır. Bununla birlikte, ön işleme aşamasında TD-1 hiperspektral görüntülerine Minimum Gürültü Oranı (minimum noise fraction) dönüşümü uygulanmıştır (Wang et al., 2024). Bu yöntem, sinyal bileşenlerini korurken verideki gürültüyü en aza indirir ve hiperspektral görüntülerin daha etkin bir şekilde analiz edilmesini sağlar. MNF dönüşümü, hiperspektral verilerin yüksek boyutluluğu ve spektral bantlar arasındaki yüksek korelasyon nedeniyle ortaya çıkan hesaplama karmaşıklığını azaltmak açısından kritik bir ön işleme adımıdır (Green et al., 1988). Özellikle sınıflandırma, hedef algılama ve anomali tespiti gibi uygulamalarda, MNF dönüşümü verilerin daha anlamlı ve yorumlanabilir hale gelmesini sağlamaktadır. Bu bağlamda, MNF kullanımı veri kalitesini artırarak daha doğru ve güvenilir analiz sonuçlarına katkı sunmaktadır (Boardman ve Kruse, 1994). Bu çalışmada, TD-1 hiperspektral görüntülerine MNF dönüşümü ENVI 5.3 yazılımı kullanılarak uygulanmıştır.

### Temel Bileşenler Analizi

Hiperspektral veriler, çok sayıda spektral bant içermeleri nedeniyle yüksek veri boyutu ve hacmine sahiptir; bu durum, verilerin işlenmesi ve analiz edilmesini zorlaştırmaktadır. Bu nedenle, boyut indirgeme tekniklerinin uygulanması, verileri daha yönetilebilir ve anlamlı hale getirmek açısından önem arz etmektedir. Temel Bileşen Analizi (TBA), yüksek boyutlu verilerin boyutunu indirgemek ve verilerdeki temel yapıları ortaya çıkarmak amacıyla kullanılan bir istatistiksel yöntemdir. TBA, orijinal değişkenlerin doğrusal kombinasyonları olan ve temel bileşenler (principal components) olarak adlandırılan yeni değişkenler üretir (Jolliffe ve Cadima, 2016; Hidalgo et al., 2021). Bu temel bileşenler, verilerdeki en yüksek varyansı temsil eden ve birbirine dik (ortogonal) olan eksenlerdir. TBA ile birlikte, yüksek boyutlu bir veri kümesi olan hiperspektral veri, daha az sayıda bileşenle temsil edilmiş ve böylece verinin analiz işlemleri daha hızlı ve kolay bir hale gelmiştir (Jolliffe, 2002; Mohan et al., 2007). TBA'nın temel kullanım amacı, orijinal verilerde yüksek korelasyon nedeniyle oluşan bilgi tekrarlarını ortadan kaldırmaktır (Üstüner, 2023).

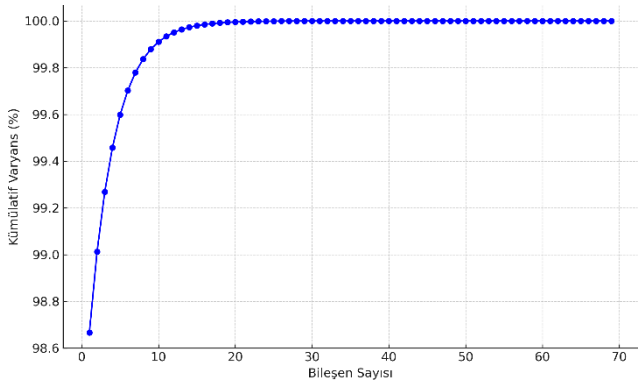


Şekil 2. Temel bileşen analizi

Bu süreçte her bir temel bileşen, diğer bileşenlerle 90° açı yapacak şekilde ortogonaldir ve bu sayede spektral bilgi fazlalığı azaltılmış olur (Hidalgo et al., 2021). PCA işleminin sonucunda, en fazla varyansı taşıyan ilk 30 ana bileşen seçilmiş ve sınıflandırma sürecinde kullanılmak üzere analizlere dahil edilmiştir (Şekil 2)

### Sınıflandırma (Aşırı Gradyan Artırma)

Bu çalışma kapsamında, yüksek doğruluk elde etme potansiyeli nedeniyle yeni nesil makine öğrenme algoritmalarından olan aşırı gradyan artırma (extreme gradient boosting; XGBoost) yöntemi tercih edilmiştir. Aşırı gradyan artırma (XGBoost), gradyan artırma (gradient boosting) algoritmasının geliştirilmiş ve ölçeklenebilir bir versiyonu olup, büyük veri kümeleri üzerinde yüksek doğrulukla çalışabilen bir makine öğrenmesi yöntemidir (Chen ve Guestrin, 2016). Veri bilimi yarışmalarında sıklıkla üstün performans gösteren bu algoritma, hesaplama verimliliği açısından yaygın bir şekilde tercih edilmektedir.

XGBoost, ağaç tabanlı modelleri adım adım optimize ederek hata oranını minimize etmeyi amaçlar (Farid et al., 2013). Her bir yeni ağaç, önceki ağaçların hatalarını azaltmak amacıyla oluşturulur (Mitchell ve Frank, 2017). Ağaçların karmaşıklığı farklı düzenleme teknikleriyle kontrol edilerek modelin aşırı öğrenmesi (overfitting) engellenir ve bu sayede performansı artırılır (Patrous, 2018). XGBoost, yüksek esnekliği sayesinde kullanıcıların modele yeni parametreler eklemesine ve farklı optimizasyon kriterleri tanımlamasına olanak tanır. Ayrıca, yüksek boyutlu ve düzensiz verilerle çalışmada başarı göstermekte olup, endüstriyel uygulamalar, internet arama motorları ve finansal hizmetler gibi birçok alanda kullanılmaktadır. Çalışmamız kapsamında kullanılan hiperspektral veri kümesinin yüksek bant sayısına sahip oluşu ve çalışma alanındaki arazi örtüsünün karmaşıklığı gözönüne alındığında, XGBoost algoritmasının uygun bir seçim olduğu görülmektedir.

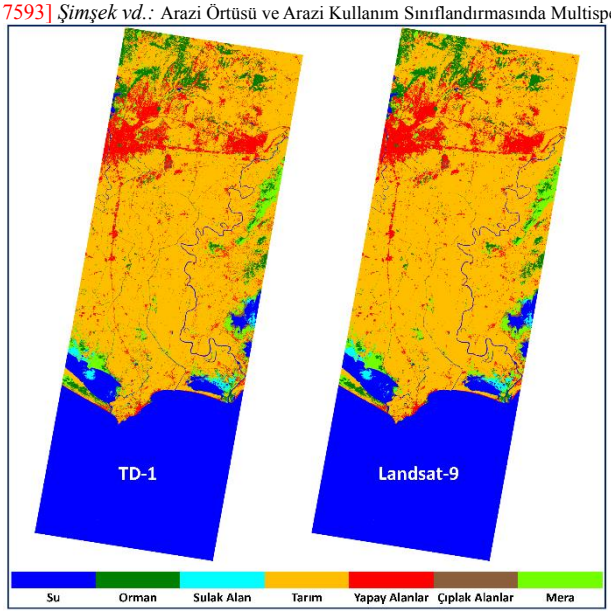


**Şekil 3.** Sınıflandırma sonucu (TD-1 / Landsat 9)

XGBoost algoritmasının temel avantajları arasında; paralel ağaç yapısı oluşturabilme, derin önceliklendirme yöntemiyle ağaç budama, önbellek farkındalığı ve çekirdek dışı hesaplama gibi özellikler yer almaktadır (Chen et al., 2019). Bununla birlikte, algoritmanın bazı dezavantajları da bulunmaktadır. Çok sayıda ağaç üretilmesi nedeniyle hesaplama sürelerinin uzaması, aşırı öğrenmeye yatkınlık ve veri dağılımındaki küçük değişimlere karşı hassasiyet bu dezavantajlar arasında sayılabilir (Fitriah et al., 2017). Parametre optimizasyonu sürecinde, literatürde yaygın olarak kullanılan iki yöntem olan grid tarama (grid search) ve rastgele arama (random search) yöntemleri incelenmiş; çalışmamız kapsamında grid tarama yöntemi tercih edilmiştir (Bort Escabias, 2017). Grid tarama yöntemiyle, belirlenen parametre aralıkları içerisinde tüm olası kombinasyonlar denenerek en uygun parametre seti belirlenmiştir.

## BULGULAR VE TARTIŞMA

Sınıflandırma işlemlerine ait toplam doğruluk değerleri incelendiğinde (Tablo 1), Landsat-9 ve TD-1 veri setlerinin AKAÖ sınıflandırmasındaki performansları arasında dikkate değer bir fark olduğu açık bir şekilde görülmektedir.

| SINIFLAR | Landsat-9 | Pixxel(TD-1) |
|---|---|---|
| | F1 Skor | F1 Skor |
| **Su** | 0.92 | 0.94 |
| **Orman** | 0.78 | 0.85 |
| **Sulak Alan** | 0.65 | 0.84 |
| **Tarım** | 0.93 | 0.94 |
| **Yapay Alanlar** | 0.76 | 0.86 |
| **Çıplak Alanlar** | 0.59 | 0.83 |
| **Mera** | 0.62 | 0.76 |
| **Toplam Doğruluk (Overall Accuracy)** | **%87.1** | **%91.8** |

Landsat-9 ile, %87.1'lik toplam doğruluk değeri elde edilirken, TD-1 ile bu değerin %91,8 olduğu tespit edilmiştir. Bu durum, TD-1'in sunduğu yüksek spektral çözünürlüğün sınıflandırma başarımını artırmadaki etkisini açıkça göstermektedir. Su sınıfı için, her iki görüntüde yüksek doğruluk değerleri elde edilmiş, ancak TD-1 (F1 skoru: 0,94), Landsat-9'a (F1 skoru: 0,92) kıyasla daha üstün bir performans göstermiştir. Sulak alanlar sınıfında da benzer şekilde sınıf bazında daha yüksek F1 skoru değeri elde edilmiştir (TD-1: 0.84), Landsat-9: 0.65). Özellikle, çıplak alanlar ve mera sınıfları için, Landsat-9 görüntüsünün sınıflandırılmasında her iki sınıf için de F1 skoru 0.65 değerinin altında kalmıştır. TD-1 hiperspektral verisinin sınıflandırılmasında ise, çıplak alanlar için 0.83 ve mera sınıfı için 0.76 F1 skoru değerleri elde edilmiştir.

Sınıf bazlı F1 skorları incelendiğinde, TD-1'in hiperspektral görüntüleme yeteneklerinin, özellikle spektral özellikleri birbirine yakın olan ve spektral olarak birbiri ile karışan arazi örtüsü sınıflarının ayrımında daha başarılı olduğu görülmektedir. Elde edilen deneysel sonuçlar, hiperspektral verilerin AKAÖ sınıflandırmasında sağladığı detaylı spektral bilgi sayesinde Landsat-9 gibi multispektral görüntülere kıyasla daha yüksek performans gösterdiğini ortaya koymuştur.

## SONUÇ

TD-1 veri setinden elde edilen deneysel bulgular, hiperspektral görüntülerin, multispektral görüntülere kıyasla AKAÖ sınıflandırmasında, sınıflandırma doğruluğunu anlamlı düzeyde artırdığını ortaya koymuştur. Hiperspektral sensörler, geniş bir elektromanyetik spektrum aralığını kapsayarak, spektral olarak birbiri ile karışan arazi örtüsü türleri arasında daha ince farklılıkların tespit edilmesine olanak sağlamaktadır. Bu durum, özellikle bitki örtüsü, sulak alanlar ve yapay yüzeyler gibi arazi örtüsü sınıfları arasında daha yüksek doğrulukla ayrım yapılmasına imkan vermektedir. Deneysel çalışmamızda, TD-1 verileri ile sulak alan, çıplak alanlar ve mera gibi spektral olarak birbiri ile karışan sınıfların ayırt edilmesinde, Landsat-9 verisine kıyasla, daha yüksek başarım değerleri (F1 skoru değerleri) elde edilmiştir. Hiperspektral görüntülerin kullanımı, daha zengin spektral bilgi sağlamaları nedeniyle, sınıflar arası spektral karışmayı azaltmakta ve böylece sınıflandırma performansını önemli ölçüde artırmaktadır. Zengin spektral bilgi içeriği sayesinde hiperspektral görüntüler, sınıflandırma algoritmalarının daha doğru ve güvenilir tahminlerde bulunmasına imkan sağlamaktadır.

### Yazar Katkı Oranı

**Fatih Fehmi ŞİMŞEK :** Literatür Taraması, Veri Analizi, Metodoloji Geliştirme, Yazım . **Mustafa ÜSTÜNER :** Literatür Taraması, Metodoloji Düzenleme, Revizyon

TASLAK

**Kaan KALKAN :** Literatür Taraması, Sonuçların Analiz Edilmesi, Revizyon

**Çıkar Çatışması/Çakışması**

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

**KAYNAKÇA**


Boardman, J. W., & Kruse, F. A. (1994). Automated spectral analysis: A geological example using AVIRIS data, north Grapevine Mountains, Nevada. In *Proceedings of the Tenth Thematic Conference on Geologic Remote Sensing* (pp. I-407).

Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794).

Chen, X., Wang, Z. X., & Pan, X. M. (2019). HIV-1 tropism prediction by the XGBoost and HMM methods. *Scientific Reports, 9*(1), 9997.

Escabias, C. (2017). Tree boosting data competitions with XGBoost (Master's thesis, Universitat Politècnica de Catalunya).

Farid, D. M., Maruf, G. M., & Rahman, C. M. (2013). A new approach of boosting using decision tree classifier for classifying noisy data. In *Proceedings of the 2013 International Conference on Informatics, Electronics and Vision (ICIEV)* (pp. 1–4).

Fitriah, N., Wijaya, S. K., Fanany, M. I., Badri, C., & Rezal, M. (2017). EEG channels reduction using PCA to increase XGBoost's accuracy for stroke detection. In *AIP Conference Proceedings, 1862*(1).

Green, A. A., Berman, M., Switzer, P., & Craig, M. D. (1988). A transformation for ordering multispectral data in terms of image quality with implications for noise removal. *IEEE Transactions on Geoscience and Remote Sensing, 26*(1), 65–74.

Hidalgo, D. R., Cortés, B. B., & Bravo, E. C. (2021). Dimensionality reduction of hyperspectral images of vegetation and crops based on self-organized maps. *Information Processing in Agriculture, 8*(2), 310–327.

Jolliffe, I. T. (2002). *Principal component analysis*. Springer Series in Statistics. Springer-Verlag.

Jolliffe, I. T., & Cadima, J. (2016). Principal component analysis: A review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, 374*(2065), 20150202.

Markham, B. L., Jenstrom, D., Masek, J. G., Dabney, P., & Pedelty, J. A. (2016). Landsat 9 Thermal Infrared Sensor 2 (TIRS-2) stray light mitigation and assessment. *IEEE Transactions on Geoscience and Remote Sensing*.

Mitchell, R., & Frank, E. (2017). Accelerating the XGBoost algorithm using GPU computing. *PeerJ Computer Science, 3*, e127.

Mohan, A., Sapiro, G., & Bosch, E. (2007). Spatially coherent nonlinear dimensionality reduction and segmentation of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters, 4*(2), 206–210.

Montanaro, M., McCorkel, J., Tveekrem, J., Stauder, J., & Mentzell, E. (2022). Landsat 9 Thermal Infrared Sensor 2 (TIRS-2) stray light mitigation and assessment. *IEEE Transactions on Geoscience and Remote Sensing*.

Patrous, Z. S. (2018). Evaluating XGBoost for user classification by using behavioral features extracted from smartphone sensors (Master's thesis, KTH Royal Institute of Technology).

Pazúr, R., Nováček, J., Bürgi, M., Kopecká, M., Lieskovský, J., Pazúrová, Z., & Feranec, J. (2024). Changes in grassland cover in Europe from 1990 to 2018: Trajectories and spatial patterns. *Regional Environmental Change, 24*(2), 51.

Rossi, M., & Bianchi, L. (2019). Assessing urban sprawl in Mediterranean cities using CORINE land cover data. *Journal of Land Use Science, 14*(3), 221–235.

Üstüner, M. (2023). Çekirdek tabanlı aşırı öğrenme makinesi ile hiperspektral görüntü sınıflandırma. *Türk Uzaktan Algılama ve CBS Dergisi, 4*(2), 198–212.

Wang, H., Yu, G., Cheng, J., Zhang, Z., Wang, X., & Xu, Y. (2024). Fast hyperspectral image classification with strong noise robustness based on minimum noise fraction. *Remote Sensing, 16*(20), 3782.


.

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Gerçek-Zamanlı Mobil Artırılmış Gerçeklik Sistemlerinde Konumsal Entegrasyonun Fotogrametrik Yaklaşımlarla Sağlanması

**Burak TAVUKÇU[1], Sefa TAVUKÇU[2]**

*[1]MSB Harita Genel Müdürlüğü, Fotogrametri Dairesi Başkanlığı, Ankara, Türkiye*
*[2]Universität Leipzig, Institute for Earth System Science and Remote Sensing, Earth System Data Science and Remote Sensing, Leipzig, Germany*

**Anahtar Kelimeler**
Fotogrametri,
Artırılmış Gerçeklik,
Sensörler,
Mobil Uygulama

**ÖZET**

Bu çalışmada, mobil cihazların dahili sensörlerinden elde edilen veriler kullanılarak geliştirilen, fotogrametrik temelli ve gerçek zamanlı bir artırılmış gerçeklik (AR) uygulaması sunulmaktadır. Geliştirilen uygulama, geleneksel AR uygulamalarında yaygın olarak kullanılan dış oyun motorları, hazır 3B modeller ya da ticari yazılımlar yerine, tamamen cihaz içi verilerle çalışmakta ve sade yapısı sayesinde taşınabilir, ekonomik ve bağımsız bir çözüm olarak öne çıkmaktadır. Uygulamanın temel amacı, mobil cihazın konum, yönelim ve kamera bilgileri gibi mevcut sensör verilerinden yararlanarak, gerçek dünya ile dijital katmanları bir araya getiren konumsal farkındalık sağlayan bir görselleştirme sunmaktır. Kullanıcıya, bulunduğu konumla ilişkili sanal noktaların, mobil cihaz ekranı üzerinden sahaya uygun şekilde gösterilmesi sağlanmaktadır. Hesaplamalar arka planda otomatik olarak gerçekleştirilmekte ve kullanıcıya sade bir arayüzle sunulmaktadır. Uygulama, mobil ortamlarda çalışacak şekilde Python diliyle geliştirilmiş ve cihazın sensör verileriyle doğrudan etkileşim kurabilecek esneklikte tasarlanmıştır. Kullanıcı arayüzü hem harita görünümü hem de kamera görünümü arasında geçiş yapılabilecek şekilde hazırlanmıştır. Çalışma, herhangi bir dış bağımlılık olmaksızın, yalnızca mobil cihazın sunduğu olanaklarla artırılmış gerçeklik deneyiminin sağlanabileceğini ortaya koymaktadır. Bu yönüyle, özellikle eğitim, arazi çalışmaları, harita destekli analizler, coğrafi bilgi sistemleri ve konuma dayalı veri sunumu gibi pek çok alanda kullanım potansiyeli taşımaktadır. Ayrıca uygulamanın düşük donanım gereksinimi ve açık kaynak geliştirilebilir yapısı sayesinde, benzer projelerde kullanılabilecek esnek ve sürdürülebilir bir altyapı sunmaktadır.

# Photogrammetric Approaches to Achieving Spatial Integration in Real-Time Mobile AR Systems

**Keywords**
Photogrammetry,
Augmented Reality,
Sensors,
Mobile Application

**ABSTRACT**

This study presents a photogrammetry-based and real-time augmented reality (AR) application developed using data obtained from the internal sensors of mobile devices. The developed application operates entirely with on-device data, avoiding the use of external game engines, pre-built 3D models, or commercial software commonly used in traditional AR applications. With its simple structure, it stands out as a portable, economical, and independent solution. The primary aim of the application is to provide spatial awareness visualization by integrating real-world and digital layers using available sensor data such as the mobile device's location, orientation, and camera information. The system enables the display of virtual points related to the user's current location on the mobile device screen in alignment with the real-world scene. Calculations are performed automatically in the background and presented to the user through a simple interface. The application is developed in Python to operate in mobile environments and is designed with the flexibility to directly interact with the device's sensor data. The user interface allows switching between map view and camera view. The study demonstrates that an augmented reality experience can be achieved solely through the capabilities provided by the mobile device, without any external dependencies. In this respect, it holds significant potential for use in various fields such as education, field studies, map-assisted analyses, geographic information systems, and location-based data presentation. Additionally, due to its low hardware requirements and open-source, extensible structure, the application provides a flexible and sustainable infrastructure that can be utilized in similar projects.

## GİRİŞ

Günümüzde taşınabilir teknolojilerin hızla ilerlemesiyle birlikte, çevresel verilerin anlık olarak analiz edilip görselleştirilebildiği artırılmış gerçeklik uygulamalara olan ihtiyaç artmıştır. Artırılmış gerçeklik uygulamaları fotogrametrik açıdan değerlendirildiğinde problemin çözümü için gerekli olan temel bilgiler; konum bilgisini elde edebileceğimiz bir GNSS alıcısı, dönüklük açılarını elde edebileceğimiz bir ivme ölçer sensörü ve kullanılacak kameraya ilişkin iç yöneltme bilinmeyenleridir. Günümüzde mobil cihazların sahip olduğu yerleşik sensörler gelişen teknoloji ile birlikte bu bilgileri dışarıdan herhangi bir bileşene ihtiyaç duymadan elde edebilmemizi sağlamaktadır. Sonuç olarak çevre ile etkileşim kurabilen sistemlerin geliştirilmesi mümkün hale gelmiştir. Bu durum hem kullanıcı deneyimini sadeleştirmiş hem de birçok alanda dijital çözümler sunma potansiyelini artırmıştır.

Bu çalışma, mobil sistemlerin sahip olduğu sensörlerden yararlanarak fiziksel ortamla dijital bilgilerin bütünleşmesini sağlayan özgün bir sistem geliştirilmiştir. Geliştirilen uygulama, kullanıcının bulunduğu noktayı referans alarak çevresindeki belirli noktaları dijital ortamda konumlandırmakta ve bu noktaların görsel olarak kamera görüntüsünde nerede yer aldığına dair bilgi üretmektedir. Uygulamanın çalışması esnasında tüm işlemler cihaz üzerinde gerçekleştirilmekte, dış kaynaklı yazılımlara veya ek donanımlara gereksinim duyulmamaktadır.

Hazırlanan uygulama, kullanıcıya hem harita görünümü hem de kamera görüntüsü üzerinde izleme imkânı sunarak konuma bağlı bilgi üretimini daha erişilebilir hale getirmektedir. Sade bir arayüz ile donatılan yapı, kullanıcının çevresindeki unsurları daha iyi anlamasına yardımcı olmakta ve çeşitli mesleki ya da akademik kullanım senaryolarına uyarlanabilir bir altyapı sunmaktadır. Bu yönüyle, özellikle saha çalışmaları, eğitim amaçlı uygulamalar ve coğrafi analiz gerektiren durumlar için yenilikçi ve pratik bir araç niteliğindedir.

## YÖNTEM

Bu çalışmada haritacılıkta kullanılan matematiksel modeller ile artırılmış gerçeklik uygulamasının geliştirilmesi amaçlanmıştır. Geliştirilen sistem, mobil cihazlarda yer alan sensör verilerini esas alarak çevresel nesne ve hedeflerin dijital ortamda konum temelli olarak sunulmasını amaçlamaktadır. Gerçek çevreyle dijital bilgileri bir araya getiren bu yapı, ek donanım ya da dış yazılım gerektirmeksizin çalışacak şekilde planlanmıştır. Uygulama; hareket bilgisi, coğrafi konum ve kamera görüntüsünü birlikte değerlendirerek, kullanıcıya konum ilişkili görsel içerikler sağlamaktadır.

Kodlama sürecinde esnekliği ve platform bağımsızlığıyla öne çıkan bir geliştirme yaklaşımı benimsenmiştir. Arayüz hem harita tabanlı incelemeye hem de kamera üzerinden sahaya yönelik izleme senaryolarına olanak sağlayacak şekilde düzenlenmiştir. Sistem, kullanıcı tarafından belirlenen noktaları referans alarak bu noktaların uzamsal konumlarını sahada işaret edebilmekte ve görüntü üzerinde bilgi sunabilmektedir.

### Yöntemlerin Belirlenmesi

İlk olarak bir artırılmış gerçeklik uygulaması için gerekli olan veriler;

- Cihazın Anlık X, Y, Z koordinat değerleri,
- Omega(ω), Phi(φ), Kappa(κ): Sırasıyla X, Y ve Z eksenleri etrafındaki dönüklük açıları,
- Kamera iç yöneltme elemanları.

Bu üç ana bilgi kullanılarak doğrudan coğrafi konumlandırma ile bir artırılmış gerçeklik uygulaması oluşturulabilir. Mobil cihazdan elde edilen verilerin konumsal doğruluğunu artırmak ve sanal nesnelerin sahaya uygun şekilde yerleştirilmesini sağlamak amacıyla fotogrametrik prensiplerden yararlanılabilmektedir. Doğrudan coğrafi konumlandırma ile elde edilen dış yöneltme parametreleri ve kolinearite denklemi, cihazın mekânsal konumunun ve yönelimi hesaplanabilir.

Bir görüntünün dış yöneltmesi, o görüntüyü oluşturan optik merkezin (kamera veya cihazın) dünya koordinat sistemine göre konumu ve yönelimini ifade eder. Bu bağlamda:

- X0,Y0,Z0: Kamera merkezinin dünya koordinatlarıdır.
- ω,φ,κ: Sırasıyla X, Y ve Z eksenleri etrafındaki dönme açılarıdır ve kameranın yönelimini tanımlar.

Bu parametreler yardımıyla, görüntü düzlemindeki bir noktanın dünya üzerindeki konumu ile olan geometrik ilişkisi kurulabilir.

Görüntü oluşum süreci, bir cismin görüntüsünü oluşturan ışınların, kamera merkezinden geçerek görüntü düzlemine düşmesi prensibine dayanır. Bu ilişki, kolinearite denklemleri ile matematiksel olarak ifade edilir. Denklem aşağıdaki gibidir;

$$x = -c\,\frac{a_{11}(X-X_0)+a_{12}(Y-Y_0)+a_{13}(Z-Z_0)}{a_{31}(X-X_0)+a_{32}(Y-Y_0)+a_{33}(Z-Z_0)} \qquad (1)$$

$$y = -c\,\frac{a_{21}(X-X_0)+a_{22}(Y-Y_0)+a_{23}(Z-Z_0)}{a_{33}(X-X_0)+a_{32}(Y-Y_0)+a_{33}(Z-Z_0)}$$

Bu denklemler, sanal bir nesnenin dünya üzerindeki konum bilgileri bilindiğinde, bu nesnenin görüntü düzleminde hangi piksel koordinatında görüneceğini hesaplamak için kullanılır. Bu sayede, artırılmış gerçeklik uygulamasında sanal objelerin sahada doğru konumda gösterimi sağlanır.

Ancak mobil bir cihazda, söz konusu bilgilerden sadece X, Y, Z koordinat değerleri ile dönüklük açılarından omega ve phi açıları doğrudan elde edilebilmektedir. Kamera iç yöneltme elemanlarından ise sadece odak uzaklığı ve sensör boyutları bilinmektedir. Asal nokta kayıklığı ve distorsiyon hataları bilinmemektedir, aynı zamanda kameranın odaklama yapması sebebiyle odak uzaklığında değişiklik olabilmektedir. Kamera iç yöneltme elemanlarından asal nokta kayıklığı ve distorsiyon hatalarının sonuca etkisi çok az olacağından göz ardı edilmiştir. Ancak odak uzaklığındaki değişimi engellemek için uygulamada kamera odaklama işlemi engellenerek kamera görüntüsü alınmıştır.

Kappa açısı ise pusula sensöründen elde edilen manyetik kuzey açısı ve GNSS alıcısından elde edilen

TASLAK

konum bilgisi kullanılarak bulunulan konum için geçerli düzeltme değeri eklenerek gerçek kuzey açısı elde edilebilmektedir.

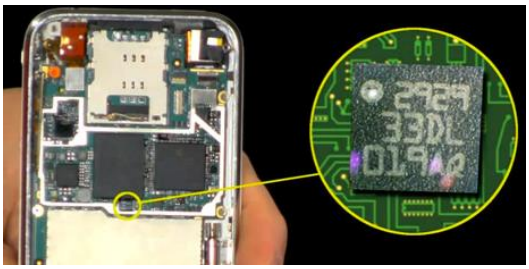

**Şekil 1.** İvme Ölçerin Konumlandırılması (Telefonda Bulunan İvme Ölçer Nedir Ne İşe Yarar, 2025)

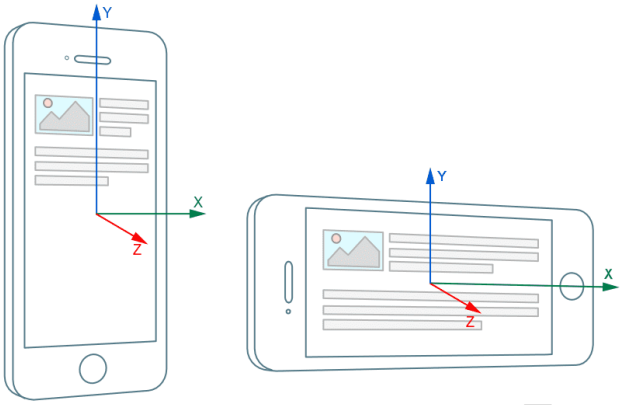


**Şekil 2.** İvme Ölçer Yönleri (Sensors For The Web, 2025)

Mobil cihazın üzerinde pusula ve ivme ölçer sensörleri "Şekil 1"de görüldüğü şekilde yatay bir biçimde konumlandırılmıştır. Bu nedenle sensörlerden gelen veriler cihaz yer ile paralel olduğu durumda doğru değerler vermektedir. Ancak mobil cihazların normal kullanım konumu veya farklı bir konumda kullanıldığında "Şekil 2"de görüldüğü sensörlerden gelen verilerin eksenleri değişmektedir.

Eğer mobil cihazın yere paralel konumda kullanırsak elimizdeki mevcut bilgiler ile kolinearite denklemini kullanarak doğrudan coğrafi konumlandırma ile sanal olarak eklenen koordinatları kamera ekranı üzerinde görselleştirilebilir. Ancak bunun kullanımı günlük hayatta pek mümkün değildir, sadece bir hava platformunda mobil cihazın yere paralel olacak şekilde konumlandırılarak kullanılabilir.

**Kullanılan Yöntem**

Mobil cihazların normal kullanım konumu, "Şekil 2"nin ilk bölümünde gösterildiği gibi dik konumda kullanımdır. Bu kullanım konumuna uygun olarak artırılmış gerçeklik uygulaması geliştirmek için, cihazın baktığı istikametin gerçek kuzey açısına, kamera odak uzaklığı ve sensör boyutlarına, GNSS alıcısından elde edilen X, Y, Z koordinat değerlerine ve cihazın X, Y, Z eksenlerindeki dönüklük açılarına ihtiyaç duyulmaktadır.

Mobil cihazlarda sensörler yatay biçimde konumlandırıldığından ve dik kullanım durumu X ekseni üzerinde olduğundan dolayı roll açısı (sağa-sola yatıklık) cihazın Z ekseni üzerindeki dönüklük açısını vermektedir, ancak bu açı değerini doğrudan kullanmak hatalı olacaktır. "Şekil 1" ve "Şekil-2" Yine benzer bir şekilde manyetik kuzey istikametini gösteren pusula sensörü cihaz dik konumda iken hassasiyeti ve doğruluğu azalmaktadır. İlk olarak manyetik kuzey açısının cihazın kamera doğrultusunda doğru değerleri verebilmesi için sensör verilerinden elde ettiğimiz roll, pitch ve yaw açılarını da kullanarak pusula sensöründen gelen değerlerin bileşke kuvvetinin hesaplanması gerekmektedir. Hesaplanan değerin hassasiyeti pusula sensörünün doğruluğuna ve pitch açısından doğrudan etkilenmektedir.

Sensörlerden gelen verilerin doğruluğunu artırmak maksadıyla iki aşamalı bir filtreleme yöntemi uygulanmıştır. İlk olarak pusula ve ivme ölçer sensörlerinden gelen değerlerde %10'luk sapmanın üzerinde olan değerler elimine edilerek filtrelenmiştir, bu şekilde ivme ölçer sensöründen gelen roll pitch ve yaw değerleri ile pusula sensöründen gelebilecek gürültülü değerler elimine edilmiştir. Daha sonra manyetik kuzey açısını hesaplamak için kullandığımız roll, pitch ve yaw açılarına ve hesaplanan manyetik kuzey değerine Kalman Filtresi (Kalman,1960) uygulanarak manyetik kuzey değerleri ile roll, pitch ve yaw açılarındaki gürültülerin giderilmesi amaçlanmıştır. Sensör verileri sürekli olarak dinlendiği için cihaz hareketsiz bir şekilde sabitlense dahi sensörlerden gelen verilerde gürültüler mevcuttur. İlk aşamada bu gürültüler azaltılmıştır, ikinci aşamada uygulanan Kalman Filtresi ile kullanıcının gerçekleştireceği ani hareketlerin sensör üzerindeki etkisi azaltılmıştır. Daha sonra bulunulan coğrafi konuma bağlı olarak gerçek kuzey açısına dönüşüm sağlanmıştır.

Bu aşamada elimizde cihazın kamerasının baktığı istikametin gerçek kuzey açısı, GNSS sensörlerinden elde edilen X, Y, Z değerleri ile roll, pitch ve yaw açıları hassas bir şekilde hesaplanmıştır.

Cihaz kamerasının asal nokta kayıklığı olmadığı varsayımı ile enine ve boyuna görüş açıları bilinen bir kamera görüntüsü üzerinde, gerçek kuzey açısı ve pitch açılarını kullanarak koordinatları daha önceden girilen bir noktanın kamera görüntü üzerinde resim koordinatları hesaplanmıştır. Bu hesaplamada ilk olarak, hedef nokta koordinatları ve bulunan nokta koordinatları kullanılarak hedef noktaya olan açı değeri hesaplanmış, hesaplanan açı ile gerçek kuzey açısının aynı olduğu anda cihazın Y ekseni üzerinde ekran merkezine; hedef nokta ile aynı yükseklik değerine sahip ve pitch açısı 90° olduğunda cihazın X ekseni üzerinde ekran merkezine belirlenen sanal nesneler ile işaretleme gerçekleştirilmiştir. Kamera görüş açılarından yararlanarak, hedef noktaların görüş açılarına girdiği zamanlarda belirlenen sanal nesneler ve hedef noktaya olan mesafeler bilgi olarak ilgili görüntü koordinatları üzerinde görselleştirilmesi sağlanmıştır.

Kamera görüntüsü üzerine görselleştirilen sanal nesneler, kullanıcı sahada ilerledikçe yeniden konumlandırılır ve güncellenir. Böylece statik olmayan, dinamik bir artırılmış gerçeklik deneyimi sunulmuş olur.

Görselleştirme iki ana arayüz üzerinden sağlanmaktadır:

- **Harita Modu:** Kullanıcının ve hedef noktaların kuşbakışı görünümü. "Şekil-3"

- **Kamera Modu:** Gerçek dünya görüntüsünün üzerine, hedef noktaların ekran düzlemindeki izdüşümünün bindirilmesi. "Şekil-4"

Her iki mod arasında geçiş yapılabilmekte, kullanıcı konumunu veya görüntüyü referans alarak sahayı farklı açılardan analiz edebilmektedir. Nokta tanımlama işlemi ise hem tek tek nokta olarak girilebilmekte hem de harici bir dosya (örneğin .txt vb.) üzerinden toplu olarak sisteme yüklenebilmektedir. Bu sayede, uygulama hem önceden belirlenmiş saha verileriyle hem de anlık kullanıcı girişiyle çalışabilecek esnekliğe sahiptir.

Bu yapısıyla sistem, sadece konum gösterimi değil, aynı zamanda konumsal farkındalık oluşturarak sahadaki fiziksel ve dijital unsurların bütünleşik bir biçimde algılanmasına katkı sunmaktadır.

**BULGULAR**

Saha testleri sırasında geliştirilen artırılmış gerçeklik uygulaması, mobil cihazın yerleşik sensörlerinden elde edilen verilerle hedef noktaların başarılı şekilde görselleştirildiğini ortaya koymuştur. Farklı çevresel koşullarda yapılan denemeler, sistemin hem kamera hem de harita modlarında konumsal tutarlılığı sağlayabildiğini göstermektedir.



**Şekil 3.** Harita Modu

Gerçek dünya ile sanal katmanların uyumu; cihazın konumu, yönelimi ve kamera açısıyla bütünleşik olarak hesaplanan sanal hedeflerin, kullanıcı bakış doğrultusuna göre dinamik şekilde yerleştirilmesiyle sağlanmıştır. Kullanıcı ekranında yer alan mesafe etiketleri, uygulamanın hedef noktaları doğru yön ve ölçekle gösterilmiştir.

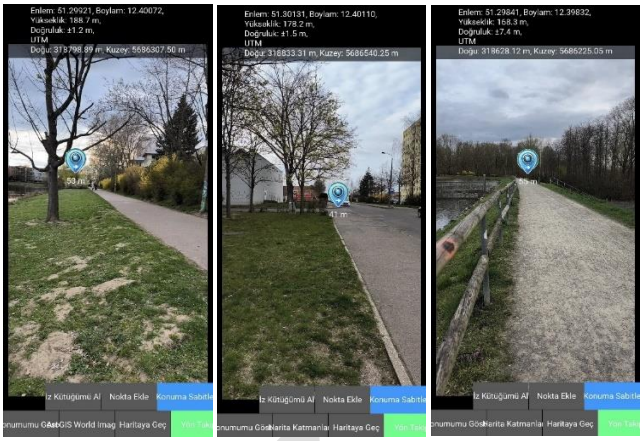

**Şekil 4.** Kamera Modu

Özellikle açık alanlarda elde edilen sonuçlar, sistemin oldukça istikrarlı çalıştığını göstermektedir. Ancak şehir içi veya ağaçlık alanlar ile kapalı alanlarda GNSS sinyal kalitesine bağlı olarak konumsal sapmalar gözlemlenmiştir. Bu sapmalar, çoğunlukla uygulamanın genel işlevselliğini etkileyecek düzeyde olmamış ve ekran üzerindeki sanal gösterim, çevresel bağlamla örtüşmeyi sürdürebilmiştir.

**TARTIŞMA**

Uygulamanın temel çıkış noktası olan cihaz-içi fotogrametrik temeller kullanılarak, harici yazılım veya donanım gereksinimi olmadan artırılmış gerçeklik deneyimi sunulabileceğini net şekilde ortaya koymuştur. Sistem, mobil cihazlarda yerleşik bulunan GNSS, ivme ölçer, pusula ve kamera verilerini entegre ederek gerçek zamanlı bir uzamsal farkındalık mekanizması oluşturmuştur.

Sensör verilerinin güvenilirliği, özellikle yönelim bilgilerinde belirleyici olmuştur. Cihazın dik konumda tutulduğu senaryolarda, pusula verisinin doğruluğunda bir miktar azalma görülmüş, ancak bu durum roll, pitch ve yaw açı değerleriyle birlikte değerlendirildiğinde filtreleme yoluyla büyük ölçüde dengelenebilmiştir. İki aşamalı filtreleme yapılması, sistemin kararlılığını artırıcı bir etki göstermiştir.

Kullanıcıya sunulan çift modlu arayüz (kamera ve harita) uygulamanın kullanım esnekliğini artırırken, sistemin dinamik olarak güncellenmesi sayesinde konum ve yönelime dayalı görsel çıktılar sahadaki hareketlilikten olumsuz etkilenmemiştir.

**SONUÇ**

Bu çalışma, yalnızca mobil cihazların sunduğu donanımla çalışan, harici yazılım veya sistemlere ihtiyaç duymayan fotogrametrik temeller üzerine kurulan özgün bir artırılmış gerçeklik uygulamasının sahada kullanılabilirliğini göstermektedir.

Geliştirilen sistem:

- Gerçek zamanlı konumsal görselleştirme sunmakta,
- Mobil sensörlerle fotogrametrik hesaplamaları sahaya uyarlamakta,
- Mobil cihazın bir hava aracına entegre edilmesi durumunda harici bir sensör veya algılayıcıya

ihtiyaç duymadan fotogrametrik çalışmalarda kullanılabileceği,
- Konuma bağlı bilgi sunumu açısından sade, erişilebilir ve esnek bir çözüm olarak öne çıkmaktadır.

Gelecekteki çalışmalarda sistemin farklı cihaz platformlarına yada gerekli sensörlerin entegre edilebildiği herhangi bir sisteme uygulanabileceği değerlendirilmektedir.

**Yazar Katkı Oranı**

Tüm yazarlar çalışmaya eşit düzeyde katkı sağlamıştır.

**Çıkar Çatışması/Çakışması**

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır

**Araştırma ve Yayın Etiği Beyanı**

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

**KAYNAKÇA**

Kalman, R. E. (1960). A new approach to linear filtering and prediction problems.

Sensors For The Web, [Erişim tarihi: 08.04.2025], https://developer.chrome.com/docs/capabilities/web-apis/generic-sensor

Telefonda Bulunan İvme Ölçer Nedir Ne İşe Yarar, [Erişim tarihi: 08.04.2025], https://teloji.com/telefonda-bulunan-ivmeolcer-nedir-ne-ise-yarar/

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Filyos Serbest Bölgesindeki Arazi Değişiminin Rastgele Orman (RF), Destek Vektör Makinesi (SVM), Sınıflandırma ve Regresyon Ağaçları (CART) Makine Öğrenme Algoritmalarıyla Karşılaştırmalı İncelenmesi

**Rüveyda Tercan KÖSE [1], Hakan AKÇIN [*2]**

[1]*Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Geomatik Mühendisliği ABD, Zonguldak, Türkiye*
[2] *Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fak., Harita Müh. Böl. Zonguldak, Türkiye*

**Anahtar Kelimeler**

Makine Öğrenmesi,
Destek Vektör Makineleri (SVM),
Rastgele Orman (RF),
Sınıflandırma ve Regresyon Ağaçları (CART),
Landsat-8,
Filyos Serbest Bölgesi.

**ÖZET**

Ülkemizin Batı Karadeniz bölgesinde Zonguldak İli sınırları içerisinde ve Filyos Irmağı'nın Çaycuma İlçesi ile Karadeniz'e döküldüğü delta arasında yer alan Filyos Serbest Bölgesi, yeni inşaa edilen limanı, hava alanı ve Karadeniz doğal gazının karasal kesimde değerlendirildiği entegre tesisleri ile diğer sanayi tesisleri içinde barındıran bir bölgedir. Serbest bölgenin, gün geçtikçe artan nüfus ile birlikte bölgenin arazi kullanımında ve arazi örtüsünde zamanla önemli değişiklikler meydana gelmesine neden olduğu bu çalışma ile belirlenmiştir. Geniş alanlardaki bu değişimin izlenmesi ve değerlendirilmesi açısından, Landsat-8 uydusu uzaktan algılama verilerine dayalı olarak makine öğrenme algoritmaları kullanılarak bir sınıflandırma çalışması gerçekleştirilmiş ve arazi değişimi incelenmiştir. Çalışmada Rastgele Orman-RF, Destek Vektör Makineleri-SVM, Sınıflandırma ve Regresyon Ağaçları- CART olmak üzere üç farklı makine öğrenme algoritmasına dayalı olarak Filyos Serbest bölgesinin 2018 ile 2022 yılları arasındaki 5 yıllık arazi değişimi incelenmiştir. Makine öğrenme algoritmalarından üretilen sınıflara ait doğruluk değerlendirmesi için genel doğruluk, kullanıcı doğruluğu, üretici doğruluğu ve Kappa değerleri hesaplanmış ve sonuçları karşılaştırılarak Landsat-8 performans değerlendirmesi de yapılmıştır. Uygulamada; 2018 ve 2022 yıllarına ilişkin olarak genel doğrulukta RF %92 ve %93 ile kappa değeri açısından da 0.90 ve 0.91 değerleri ile en iyi performansı göstermiştir. Bu sonuçlar, RF sınıflandırıcılarının doğruluk açısından hem SVM hem de CART sınıflandırıcılarından daha iyi performans gösterdiğini ortaya koymuştur. Arazi değişimi açısından 2012 -18 yılları arasında majör bir değişim söz konusu değil iken 2018-22 yılları arasında yerleşim alanlarında, tarımsal alanlarda ve çorak arazi olarak inşaat sahalarında oldukça önemli alansal büyüme görülürken, orman alanlarında ise önemli derecede küçülme saptanmıştır.

# Comparative Investigation of Land Change in Filyos Free Zone with Random Forest (RF), Support Vector Machine (SVM), Clasification and Regression Trees (CART) Algorithms

**Keywords**

Machine learning,
Support Vector Machines (SVM),
Random Forest (RF),
Clasification And Regression Trees (CART),
Landsat-8,
Filyos Free Zone.

**ABSTRACT**

Filyos Free Zone, located within the borders of Zonguldak Province in the Western Black Sea region of our country and between Çaycuma District of Filyos River and the delta where it flows into the Black Sea, is a region that includes the newly constructed port, airport and integrated facilities where the natural gas of the black sea is utilized in the terrestrial sector and other industrial facilities. It has been determined in this study that the free zone, together with the increasing population, has caused significant changes in the land use and land cover of the region over time. In order to monitor and evaluate this change in large areas, a classification study was carried out using machine learning algorithms based on Landsat-8 satellite remote sensing data and land change was analysed. In the study, the 5-year land change of Filyos Free Zone between 2018 and 2022 was analysed based on three different machine learning algorithms, namely Random Forest-RF, Support Vector Machines-SVM, Clasification And Regression Trees- CART. For the accuracy evaluation of the classes produced by machine learning algorithms, overall accuracy, user accuracy, producer accuracy and Kappa values were calculated and Landsat-8 performance evaluation was also performed by

comparing the results. In the application; RF showed the best performance with 92% and 93% in terms of overall accuracy and 0.90 and 0.91 in terms of kappa value for the years 2018 and 2022. These results revealed that RF classifiers outperformed both SVM and CART classifiers in terms of accuracy. In terms of land change, while there was no major change between 2012-18, between 2018-22, there was a significant areal growth in residential areas, agricultural areas and construction sites as wasteland, while there was a significant shrinkage in forest areas.

## GİRİŞ

Filyos Nehri 312 km uzunluğa sahiptir. Havza alanı 13.300 km²'dir ve beş ili kapsamaktadır. Havzanın kıyı bölgelerinde yıllık ortalama yağış 1200 mm'dir ve iç bölgelerinde 600 mm'dir (Küçükali 2019). Filyos nehri; Yenice Irmağı, Köroğlu Dağları, Bolu Dağları ve Ilgaz Dağlarından gelen ırmaklardan beslenerek, kolların Zonguldak'ın Gökçebey İlçesinde birleşmesiyle oluşan nehirdir. Nehir, Hisarönü beldesinden Karadeniz'e dökülür. Filyos Vadisi Projesi, diğer adıyla Filyos Serbest Bölgesi'nin yasal düzenlemelerine tabi olan havzanın kuzeyindeki alan, şu anda hızlı bir gelişme göstermekte ve ekolojik bozulmanın yanı sıra akarsu ve su taşkınları riski altında olan geniş bir sanayi bölgesine dönüşmektedir (Akcin ve Köse 2024).

Filyos Serbest Bölge Projesi; Zonguldak'ın Çaycuma İlçesi sınırları içerisinde Filyos nehri boyunca bir kilometre genişliğindeki alanın serbest bölge ve endüstri bölgesi olarak en son Resmi Gazete Karar Sayısı: 2010/975 ilanı ile hayata geçirilmiştir.

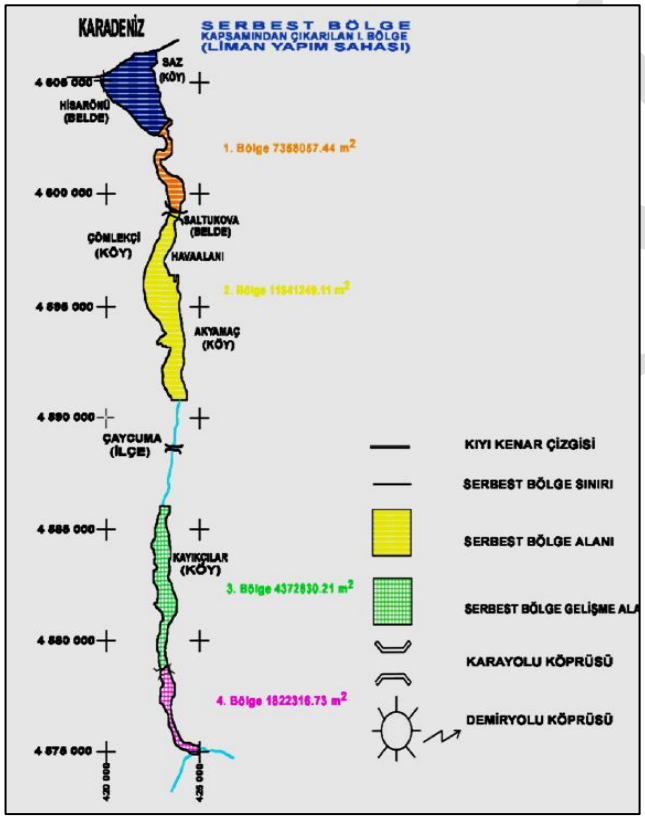


**Şekil 1.** Filyos Serbest Bölgesinin 2010/975 Sayılı Bakanlar Kurulu Kararı Ekinde sunulan harita.

Serbest bölge kapsamı dışına çıkartılmış olan liman bölgesi ile birlikte oluşturulan yeni düzenleme kapsamında Filyos Serbest Bölgesinde; Filyos Endüstri Bölgesi, Filyos Limanı ile birlikte diğer sanayi alanları, depolama alanları, konut dışı kentsel çalışma alanları ve çeşitli taşkın koruma yapıları ile birlikte bütünleşik bir proje oluşturulmuştur. Projenin, bölge ekonomisine katkı sağlayarak bölgenin önemli bir ticaret merkezi ve lojistik üssü durumuna gelmesi için çalışmalar sürdürülmektedir. Proje kapsamında, 3 bin metre rıhtım boyu, 2 bin 450 metre mendirek ile Türkiye'nin üçüncü büyük limanı özelliğine sahip olan 25 milyon ton/yıl kapasiteli Filyos Limanı'nın inşası tamamlanmıştır. Şekil 1'de proje detayları sunulmuştur.

Bu çalışma, Filyos Serbest Bölgesi proje alanındaki arazi kullanımı ve değişimini kapsayacak şekilde sınırlandırılmıştır. Günümüzde arazi kullanımı ve arazi kullanım haritaları üretebilmek için gerekli algoritmalar sayesinde uzaktan algılama yoluyla elde edilen görüntüler sınıflandırılmakta ve bu sayede sürdürülebilir arazi yönetimi sağlanabilmektedir. Uydu görüntüleri üzerinden bilgi toplayabilmemiz için kullanılan en yaygın yöntemlerden biri olan görüntü sınıflandırması sayesinde elde edilecek bilginin güvenirliği, sınıflandırma doğruluğu ile ilişkilidir ve sınıflandırma doğruluğu; eğitim/test verilerinin dağılımı, kullanılan bantların spektral ve mekânsal çözünürlüğü, sınıflandırma algoritmasının karakteristik özelliği gibi birçok parametreye bağlıdır (Kavzoglu, 2009).

Makine öğrenmesi yöntemleri ise geçmişteki verileri kullanarak, verinin ve yapılacak işlemin niteliğine göre (sınıflandırma, regresyon) en uygun modeli hesaplamayı amaçlar. Bu çalışma kapsamında son yıllarda uydu görüntülerinin sınıflandırılmasında sıklıkla kullanılan ve başarılı sonuçlar veren üç farklı makine öğrenme algoritması RF, SVM ve CART sınıflandırma yöntemleri kullanılmıştır. Çalışma alanında; Orman alanları, Sulak alanlar, Kentsel alanlar, Çorak alanlar ve Tarım Alanları olmak üzere beş farklı sınıf belirlenmiştir. Çalışma kapsamında Google Earth Engine (GEE) platformundaki web CBS uygulamalarıyla, Landsat-8 uydu görüntüleri sınıflandırılmıştır.

## YÖNTEM

### Çalışma Alanı ve Sınıflandırma

Çalışma alanı Karadeniz iklim bölgesinde bulunmaktadır. Bu bölgede dağların denize bakan yamaçlarında yağış miktarı 600-1200 mm'ye çıkmaktadır. Sıcaklık farkı yıl içerisinde fazla olmamakla birlikte en fazla yağış aldığı mevsim sonbahardır (Atalay, 2011; Yılmaz 2021). Filyos nehri deltası ve çevresi önemli değerleri barındırmaktadır. Delta alanı tarımsal potansiyeli yüksek arazilere sahiptir. Filyos nehrinin batısında Filyos kuş cenneti bulunmakta ve çok sayıda canlıya ev sahipliği yapmaktadır. Yine aynı bölgede Romalılardan kalma Tios antik kenti ve Filyos nehrinin doğusunda yapımı halen süren Filyos Vadi Projesi bulunmaktadır (Atış ve Çelikoğlu, 2019).

Bu çalışmada ele alınan bölge ikibinli yılların başından bu yana bir çok araştırmaya ve özellikle uydu görüntüleri kullanılarak sınıflama ve arazi değişimi belirleme uygulamalarına konu olmuştur. bu uygulamalardan bazıları şunlardır; Büyüksalih vd. 2005, Seker vd. 2005, Akyüz vd. 2014, Yılmaz 2021, Duran 2021, Turoğlu ve Duran 2021, Akcin ve Köse 2024.

Çalışmada arazi değişimlerinin belirlenmesine ilişkin uydu görüntülerinin sınıflandırma işlemi GEE platformunun web CBS analizleriyle gerçekleştirilmiştir. GEE, bulut tabanlı coğrafi veri işleme platformudur. Geniş kapsamda veri kataloğu ve birçok kolaylık sunan bu teknoloji platformu, 2010 yılının sonlarına doğru Google tarafından geliştirilmiş ve Birleşmiş Milletler tarafından desteklenmiştir (Gorelick, 2013). GEE ile ücretsiz olarak temin edilebilen uydu görüntüleri kullanılır. İstemci kitaplıkları JavaScript'te oluşturulur ve Python kod düzenlemesiyle işlem gerçekleştirir. Google destekli platformda bulunan ve toplanan veriler herkesin erişimine açık olarak sunulmaktadır. Platform veri sunmakla kalmayıp aynı zamanda web CBS analizi yapmayı sağlayan oldukça güçlü araçlar içermektedir (Mirelva ve Nagasawa, 2019). GEE ile elde edilen görüntülerin sınıflandırılmasında, sıklıkla kullanılan ve başarılı sonuçlar veren üç farklı makine öğrenme algoritması denetimli öğrenme yöntemi kapsamında kullanılmıştır. Filyos deltası ve çevresinin sınıflandırma analizi gerçekleştirilip sonuçlar karşılaştırılmıştır.

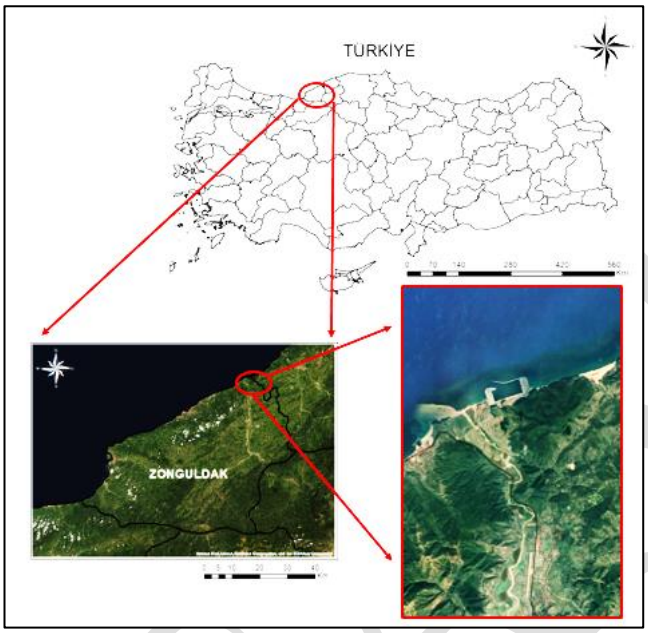


**Şekil 2.** Çalışma alanı ve kullanılan görüntü.

Çalışmada 2018-07-01, 2022-07-01 tarihlerine ait iki farklı Landsat-8 uydu görüntüsü ve 2012-2018 Corine arazi sınıflaması meta veri katmanları kullanılmıştır. Şekil 2'de çalışma alanının konumu ve bu alanın Landsat-8 görüntüsü verilmiştir. Landsat- 8 uydusu, görünür, yakın-infrared, kısa dalga infrared ve termal infrared aralıklarında görüntü almakta olup, 185 km'lik (115 mil) bir alan boyunca 15 metrelik pankromatik ve 30 metrelik multispektral uzamsal çözünürlüklere sahiptir (Landsat-8, 2022; Landsat-8, 2, 2022). Uygulamada kullanılan görüntünün teknik özellikleri Çizelge 1'de özetlenmiştir.

Uzaktan algılama teknolojisi ile arazi örtüsü ve kullanım sınıflarının tespiti, hızlı ve yüksek doğruluk ile gerçekleştirilebilmektedir. Bu çalışmada GEE'den Amerikan Jeoloji Servisi (USGS)'e bağlantı kurularak sağlanan Landsat-8 görüntüleri sayesinde üç farklı sınıflandırma algoritmasından elde edilen sonuçlar karşılaştırılmıştır. Bu çalışmada elde edilen uydu görüntüsü filtrelenmiş olup bu işlem için "*çalışma alanı seçimi*", "*istenilen zaman aralığı*" ve "*bulutsuzluk yüzdesi*" değişkenleri kullanılmıştır. Bu işlemi takiben; örnek alanlar seçilmiş, kullanılacak sınıflandırma algoritmaları belirlenmiş ve hata matrisi oluşturularak sonuç değerler karşılaştırılmıştır. Uygulamanın iş akış şeması Şekil 3'de gösterilmiştir.

**Çizelge 1.** Landsat-8 görüntülerinin spektral özellikleri [9]

| Bant Numaraları | Dalgaboyu (µm) | Çözünürlük (m) |
|---|---|---|
| Bant 1 (Kıyı / Aerosol) | 0.43-0.45 µm | 30 |
| Bant 2 (Mavi) | 0.45-0.51 µm | 30 |
| Bant 3(Yeşil) | 0.53-0.59 µm | 30 |
| Bant 4(Kırmızı) | 0.64-0.67 µm | 30 |
| Bant 5 (Yakın kızılötesi) | 0.85-0.88 µm | 30 |
| Bant 6 (Kısa dalga boylu kızılötesi) | 1.57-1.65 µm | 30 |
| Bant 7 (Kısa dalga boylu kızılötesi) | 2.11-2.29 µm | 30 |
| Bant 8 (Pankromatik) | 0.52-0.90 µm | 15 |
| Bant 9 (Sirrus) | 1.36-1.38 µm | 15 |
| Bant 10 (Termal Kızılötesi) | 10.60-11.19 µm | 30 |
| Bant 11 (Termal Kızılötesi) | 11.50-12.51 µm | 30 |

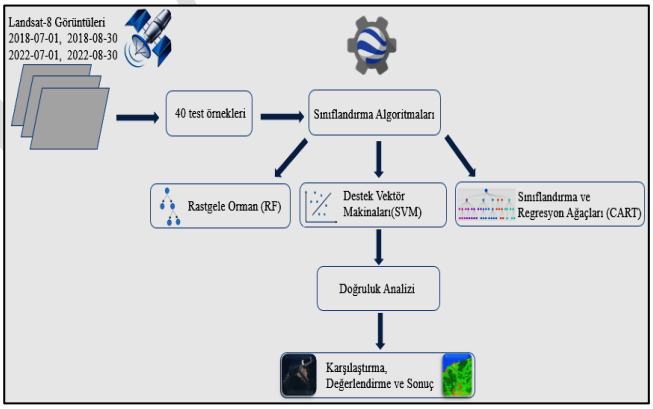


**Şekil 3.** Çalışma yönteminin iş akışı.

Elde edilen landsat-8 görüntüleri İkinci adımda sınıflandırma işlemine tabi tutulmuştur. Bu kapsamda her bir görüntü için 40 adet çokgen şeklinde test örnek alanı seçilmiş ve makine öğrenme algoritmalarının eğitiminde kullanılmıştır. Üçüncü adımda istenilen Sınıflandırma algoritmaları için doğruluk analizi gerçekleştirilmiştir. Son adımda ise nihai sonuçlar karşılaştırılmış ve değerlendirilmiştir. Oluşturulan arazi sınıflarından toplanan örneklemler; Şekil 4'ten de görüldüğü gibi 2018 ve 2022 görüntüleri için orman alanları, sulak alanlar, kentsel alanlar, çorak alanlar ve tarım alanları şeklinde seçildikten sonra sınıflandırma işlemi gerçekleştirilmiştir. Uygulamalar ayrıca 2012 ve 2018 Corine arazi sınıflaması uygulamalarıyla da karşılaştırılmıştır. Şekil 5'te çalışma alanının 2018 Corine Arazi sınıflaması verilmiştir.

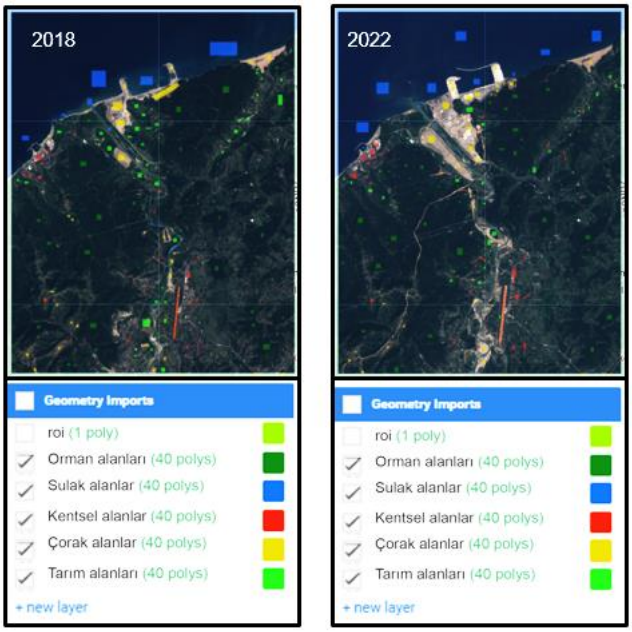


**Şekil 4.** (a) GEE'de oluşturulan 2018-07-01 tarihine ait arazi örtüsü sınıfı örnekleri ve (b) 2022-07-01 tarihine ait arazi örtüsü sınıfı örnekleri.

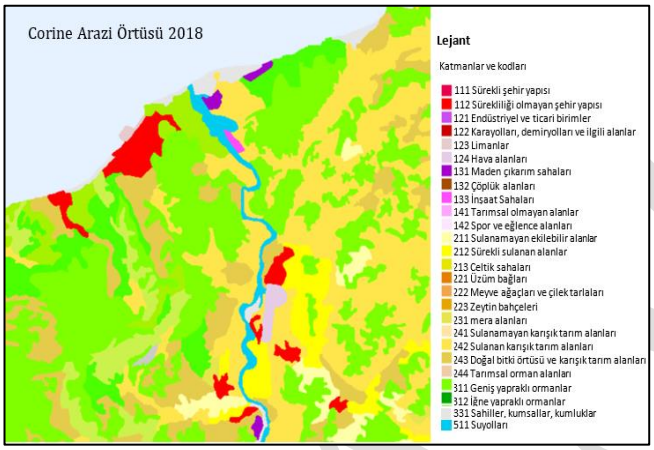


**Şekil 5.** 2018 yılına ilişkin bölgenin Corine arazi sınıfları (Copernicus Land Monitoring Service, 2025).

## Makine Öğrenme Algoritmaları

Makine öğrenme algoritmaları geçmişteki verileri kullanarak, verinin ve yapılacak işlemin niteliğine göre (sınıflandırma) en uygun modeli hesaplamayı amaçlar. Makine öğrenmesi algoritmaları, karmaşık veri kümelerini belirleme, analiz etme ve bunları anlamlandırmada yardımcı olan kod parçacıklardır (Microsoft Azure, 2025). Algoritmalar, makinenin belirlenen hedefi gerçekleştirmeye yönelik ilerleyen yönerge kümeleridir. Makine öğrenme modelinde temel hedef, sonuçları tahmin etmek ya da bilgileri sınıflara ayırmak için kullanabilecek desenleri oluşturmaktır. Şekil 6'da makine öğrenme algoritmalarına ilişkin örnekler verilmiştir. Makine, bu uygulamaları gerçekleştirirken denetimli, denetimsiz ve pekiştirmeye dayalı teknikler kullanır. Denetimli öğrenmede seçilmiş örnekler üzerinden tahmin yapılır. Denetimsiz öğrenmede yöntem, verileri düzenler ya da bunların yapısını açıklayarak ilgili piksel verisini sınıfa atar. Pekiştirmeye dayalı öğrenmede ise, sonuçlardan öğrenen ve gerçekleştirilecek bir sonraki eylemi kararlaştıran algoritmalar kullanılır. Yöntem, her uygulamadan sonra seçeneğin doğru, nötr veya yanlış mı olduğunu saptayan bir geri bildirim alır. Örneğin sınıflamadan beklenen sonuç için bir standart eşik doğruluk değeri varsa, her pekiştirme sonunda sınır değer için kontrol yapılarak makinenin otonom olarak öğrenmesi sağlanır.

RF topluluk öğrenme algoritmasıdır, dolayısıyla birden fazla karar ağacını oluşturur ve daha doğru, istikrarlı bir tahmin elde etmek için onları birleştirir ve nihai tahmin yapılır. Sınıflandırma yaparken birden çok karar ağacı üzerinden her bir karar ağacını farklı bir gözlem örneği üzerinde eğiterek çeşitli modeller üretip, sınıflandırma oluşumu sağlanmaktadır. RF yüksek sınıflandırma doğruluğuna sahiptir ve verilerdeki aykırı değerlerden fazlaca etkilenmez (Liu vd., 2012). Çalışmalarda en yaygın kullanılan sınıflandırıcı RF sınıflandırıcısıdır. Mevcut çalışmada RF sınıflandırmasını uygulamak için "*Classifier smile Random Forest*" tekniği kullanılmıştır. SVM, sınıflandırmada kullanılan oldukça basit ve etkili bir algoritma olup, kullanılacak verileri analiz eden, değişkenler arasındaki ilişkileri belirleyen makine öğrenme yöntemidir (SVM, 2022). SVM algoritması ile hiperdüzlem oluşturulup veriler iki sınıfa ayrıştırılır (Qian vd., 2015). SVM sınıflandırması yapmak için GEE platformunda yer alan "Classifier libsvm" tekniği kullanılmıştır.

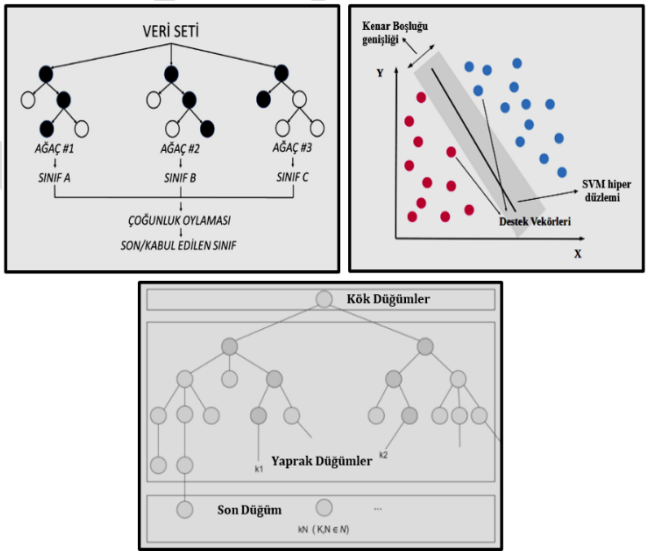


**Şekil 6.** RF örneği (Jagannath, 2020), SVM örneği (Liu., Wang ve Zhang, 2012), CART örneği (CART, 2022).

CART, RF'ye benzer karar ağacı sınıflandırıcısı olmasına karşın, modelin yorumlanmasını kolay hale getirir. Karar ağacı inşa edildiğinde, verileri bölmek için hangi değişkeni ve hangi değere sahip olduğunu ve sonucu hızlı bir şekilde tahmin eder. Öte yandan, RF algoritması modelleri karar ağaçlarının kombinasyonları olduğundan fazlaca karmaşıkdır ve RF algoritması modeli oluştururken, kaç edet ağaç oluşturulacağı ve her düğüm için kaç değişkenin gerekli olduğu tanımlanmalıdır (Talari 2022). CART, ağacın her bir düğümünde verileri alt kümelere böler. Karar ağacı, çok düzeyli ve çok yapraklı düğümlerden oluşur (Praticò vd., 2021). CART, basit, hızlı, iyi sonuçlar verdiği ve yüksek boyutlu büyük veri kümelerini işleyebildiği için uzaktan algılama görüntülerini sınıflandırmak için sıklıkla

kullanılan bir yöntemdir. Ancak, tek başına kullanıldığında farklı arazi kullanım türlerini doğru bir şekilde ayırt etmekte zorlanır (Qu vd., 2019). CART sınıflandırması yapmak için GEE platformunda yer alan "Classifier smile CART" tekniği kullanılmıştır.

### 2.3. Doğruluk Değerlendirmesi

Makine öğrenme algoritmalarıyla görüntülerin sınıflandırılması işlemlerinde sonra sonucun doğruluk analizini yapmak, en önemli aşamalardan biridir. Bu işlemin amacı, piksellerin arazi örtüsü ve kullanımı üzerinde ne kadar etkili örneklendiğinin belirlenmesidir (Rwanga ve Ndambuki, 2017). Uygulamanın doğruluğunu belirlemeye yönelik olarak hata matrisi yöntemi kullanılır. Hata matrisi üretimi GEE üzerinden gerçekleştirilebilmektedir. Uydu görüntüsü üzerinden seçilen pikseller ile bunlara karşılık gelen referans veriler karşılaştırılıp, program kodlaması yapılarak hata matrisi oluşturulmuştur. Hata matrisinden her bir sınıfın doğruluğunu ölçmek için genel doğruluk, kappa değeri, üretici doğruluğu ve kullanıcı doğruluğu hesaplanır.

**BULGULAR**

Landsat-8 uydusu kullanılarak Filyos nehri deltası ve serbest bölgeyi de kapsayan çevresinin sınıflandırma çalışmaları gerçekleştirilip doğruluğu analiz edilmiştir. Şekil 7'de 2018.07.01 tarihli görüntünün ve Şekil 8'de de 2022.07.01 tarihli görüntünün RF, SVM ve CART sınıflandırma algoritmaları ile oluşturulan görüntüleri verilmiştir. Elde edilen görüntülerin doğruluk değerlendirmesi işlemi GEE üzerinden hata matrisi kullanılarak gerçekleştirilmiştir. Genel doğruluk, kappa değeri, üretici doğruluğu ve kullanıcı doğruluğu için elde edilen değerleri Çizelge 2, 3, 4, 5, 6 ve 7'de gösterilmiştir. Corine arazi sınıflandırmasına ait 2012 ile 2018 yılları arasındaki değişim ise Şekil 9'da gösterilmiştir.

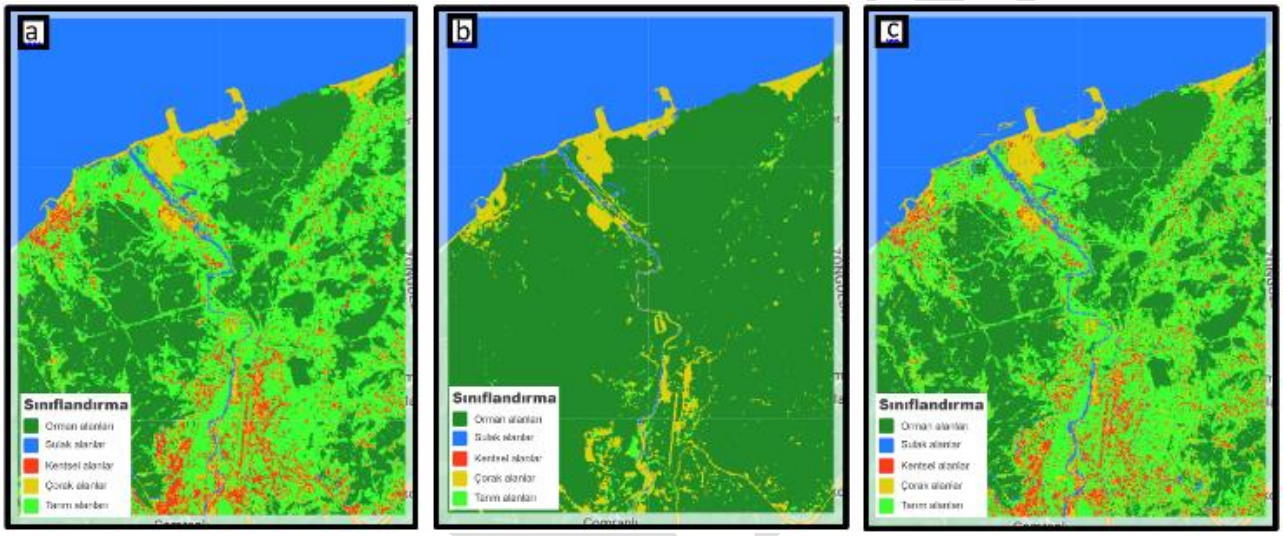


**Şekil 7**. 2018 yılına ait (a) RF sınıflandırıcısı, (b) SVM sınıflandırıcısı, (c) CART sınıflandırıcısı sonuç görüntüleri.

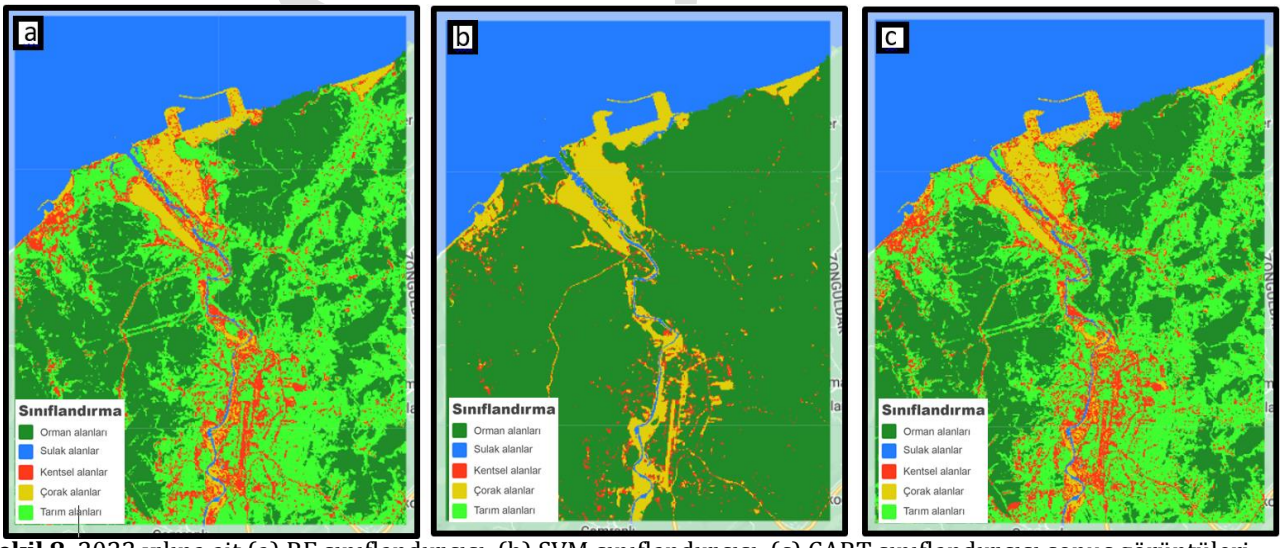


**Şekil 8.** 2022 yılına ait (a) RF sınıflandırıcısı, (b) SVM sınıflandırıcısı, (c) CART sınıflandırıcısı sonuç görüntüleri

**Çizelge 2.** Landsat-8 2018.07.01 tarihli görüntünün RF sınıflandırıcısı doğruluk sonuçları.

| RF | Kullanıcı Doğruluğu | Üretici Doğruluğu | Genel Doğruluk | Kappa Değeri |
|---|---|---|---|---|
| Orman Alanları | 0.97 | 0.97 | 0.92 | 0.90 |
| Sulak Alanlar | 0.99 | 0.98 | | |
| Kentsel Alanlar | 0.75 | 0.75 | | |

| | | | | |
|---|---|---|---|---|
| Çorak Alanlar | 0.87 | 0.87 | | |
| Tarım Alanları | 0.89 | 0.90 | | |

**Çizelge 3.** Landsat-8 2018.07.01 tarihli görüntünün SVM sınıflandırıcısı doğruluk sonuçları.

| SVM | Kullanıcı Doğruluğu | Üretici Doğruluğu | Genel Doğruluk | Kappa Değeri |
|---|---|---|---|---|
| Orman Alanları | 0.52 | 1.00 | 0.73 | 0.64 |
| Sulak Alanlar | 0.96 | 0.98 | | |
| Kentsel Alanlar | 0.00 | 0.00 | | |
| Çorak Alanlar | 0.70 | 0.85 | | |
| Tarım Alanları | 0.61 | 0.09 | | |

**Çizelge 4.** Landsat-8 2018.07.01 tarihli görüntünün CART sınıflandırıcısı doğruluk sonuçları.

| CART | Kullanıcı Doğruluğu | Üretici Doğruluğu | Genel Doğruluk | Kappa Değeri |
|---|---|---|---|---|
| Orman Alanları | 0.96 | 0.96 | 0.91 | 0.88 |
| Sulak Alanlar | 0.97 | 0.98 | | |
| Kentsel Alanlar | 0.70 | 0.62 | | |
| Çorak Alanlar | 0.85 | 0.87 | | |
| Tarım Alanları | 0.87 | 0.88 | | |

**Çizelge 5.** Landsat-8 2022.07.01 tarihli görüntünün RF sınıflandırıcısı doğruluk sonuçları.

| RF | Kullanıcı Doğruluğu | Üretici Doğruluğu | Genel Doğruluk | Kappa Değeri |
|---|---|---|---|---|
| Orman Alanları | 0.99 | 1.00 | 0.93 | 0.91 |
| Sulak Alanlar | 0.99 | 1.00 | | |
| Kentsel Alanlar | 0.72 | 0.82 | | |
| Çorak Alanlar | 0.92 | 0.79 | | |
| Tarım Alanları | 0.89 | 0.94 | | |

**Çizelge 6.** Landsat-8 2022.07.01 tarihli görüntünün SVM sınıflandırıcısı doğruluk sonuçları.

| SVM | Kullanıcı Doğruluğu | Üretici Doğruluğu | Genel Doğruluk | Kappa Değeri |
|---|---|---|---|---|
| Orman Alanları | 0.65 | 1.00 | 0.78 | 0.70 |
| Sulak Alanlar | 0.98 | 1.00 | | |
| Kentsel Alanlar | 0.71 | 0.18 | | |
| Çorak Alanlar | 0.67 | 0.91 | | |
| Tarım Alanları | 0.00 | 0.00 | | |

**Çizelge 7.** Landsat-8 2022.07.01 tarihli görüntünün CART sınıflandırıcısı doğruluk sonuçları.

| CART | Kullanıcı Doğruluğu | Üretici Doğruluğu | Genel Doğruluk | Kappa Değeri |
|---|---|---|---|---|
| Orman Alanları | 0.99 | 1.00 | 0.91 | 0.88 |
| Sulak Alanlar | 0.99 | 1.00 | | |
| Kentsel Alanlar | 0.65 | 0.68 | | |
| Çorak Alanlar | 0.88 | 0.78 | | |
| Tarım Alanları | 0.82 | 0.90 | | |




TASLAK

**Şekil 9.** 2012 ve 2018 tarihleri arası Corine arazi sınıflamasından arazi kullanım alanlarındaki değişimler, mor renkli alanlar maden kazı alanlarıdır (Copernicus Land Monitoring Service, 2025).

**TARTIŞMA**

2012 ile 2018 yılları arası değişim Corine arazi sınıflandırması ile incelendiğinde sadece üç yerde yeni maden sahası açıldığı belirlenmişken, 2018'den 2022'ye kadar olan süreçte sınıflandırma sonucu elde edilen tematik haritalar ve Corine arazi sınıflama haritası incelendiğinde yıllar içerisinde bitki örtüsünde, nehirin her iki kenarında ve sahil kıyı kesiminde değişikliklerin olduğu gözlemlenmiştir. Bu sınıflandırma çalışması ile tarım arazilerinin azaldığı ve kentsel alanların zaman içinde arttığı saptanmıştır. Her iki farklı tarihe ilişkin uydu görüntülerin makine öğrenme algoritmalarıyla sınıflandırma işleminde gerçek arazi yapısına en yakın sonucun RF algoritmasıyla elde edilen sınıflandırmanın verdiği anlaşılmıştır. SVM, kentsel alanları kesinlikle belirleyememiştir ve doğruluk oranı sıfırdır, ayrıca CART algoritması da kentsel alanları çıkarabilme başarısı sınırda kalmıştır. SVM tarım alanlarını neredeyse hiç belirleyememiştir. Ayrıca, SVM yapılaşmış alanların çoğunu ve havaalanı çevresini çorak arazi sınıfında çıkarmıştır. Ancak tüm algoritmalar ormanlık alanları, çorak alanları ve sulak alanları son derece başarılı bir şekilde belirleyebilmiştir. RF ve CART sınıflandırma sonuçları, sürdürebilir arazi yönetimi için oluşturulacak CBS uygulamalarının veri alt yapısını oluşturacak kalitedir.

**SONUÇ**

Uzaktan Algılama, çok geniş alanları görüntüleyebilme yeteneğinden dolayı farklı bilim dalları tarafından yoğun olarak kullanılmaktadır. Uydular tarafından elde edilen görüntülerin yorumlanabilmesi ve sürdürülebilir arazi yönetimi için veri alt yapısının oluşturulmasındaki en önemli adım sınıflandırma işlemidir. Sınıflandırma işlemi sonucu ortaya çıkan sınıflara ait bilgilerin doğruluğu, sınıflandırma işlemi için seçilecek algoritmayla doğrudan ilişkilidir. Dolayısıyla yapılan çalışmanın niteliğine ve veri durumuna göre kullanılacak algoritmaların doğru olarak seçimi büyük önem taşımaktadır.

Bu çalışmadan elde edilen bulgulara göre; çalışmada kullanılan üç farklı makina öğrenme algoritması ile 2018.07.01 ve 2022.07.01 tarihli görüntülerin sınıflandırmalarının doğruluk değerlendirilmesi gerçekleştirilmiştir. Değerlendirmilere göre ve değerlendirme sonucunda elde edilen tematik haritalara göre aşağıda belirtilen sonuçlara ulaşılmıştır.

- 2018 yılında RF, SVM ve CART sınıflandırıcılarının ortalama genel doğruluğu sırasıyla %92, %73 ve %91 dir.
- 2018 yılındaki çalışmada RF, SVM ve CART sınıflandırıcılarının kappa değeri 0.90, 0.64, 0.88 olarak hesaplanmıştır.
- 2022 yılında RF, SVM ve CART sınıflandırıcılarının ortalama genel doğruluğu sırasıyla %93, %78 ve %91 dir.
- 2022 yılındaki çalışmada ise kappa değerleri 0.91, 0.70, 0.88 olarak hesaplanmıştır.
- Sonuçlara bakıldığında RF algoritmasının SVM ve CART algoritmalarına göre göre her iki tarihte de daha yüksek doğrulukla iyi performans gösterdiği belirlenmiştir.
- SVM, kentsel yapılaşmış alanları ve tarim arazilerini neredeyse hiç belirleyememiş ve başarısız olmuştur. CART algoritmasının yapılaşmış alanları belirleme başarısı tam sınırda kalmıştır. RF ise yüksek başarı oranıyla kentsel yapılaşmış alanlardaki binaları, yolları, havaalanını vb. belirleyebilmiştir.
- 2018'den 2022'ye kadar olan süreçte RF sınıflandırma sonucu elde edilen tematik haritalar sayesinde yıllar içerisinde bitki örtüsünde özellikle yoğun ormanlık alanlarda, ırmağın her iki kenarında ve sahil kıyı kesiminde değişikliklerin olduğu gözlemlenmiştir. Bu sınıflandırma çalışması ile tarım arazilerinin azaldığı, çorak alanlar ve kentsel alanların zaman içinde arttığı da belirlenmiştir.
- 1/100.000 ölçek seviyesinde Sentinel-2 ve Landsat-8 görüntüleri kullanıllanılmış Corine arazi sınıflaması çalışmalarının arazideki değişimleri yeterli derecede belirleyemediği, özellikle Türkiye'nin en büyük 3. Limanın inşaatına ilişkin değişimleri saptayamadığı görülmüştür. Bu nedenle, bu tür arazi içerikli değişimlere ilişkin çalışmalarda güncel uydu görüntüleri üzerinden makine öğrenme algoritmalarının kullanımının zorunluluğu çok net olarak anlaşılmaktadır.
- Bu çalışma ile RF ve CART makine öğrenme algoritmalarının Landsat-8 uydu görüntüleri üzerinden arazi örtüsü ve kullanımının sınıflandırılmasında etkin bir şekilde kullanılabileceği ve yüksek sınıflandırma doğruluğu elde edilebileceği saptanmıştır.

**TEŞEKKÜR**

Yazarlar, bu çalışmanın özgür bir şekilde gerçekleştirilmesini ve ücretsiz veri teminini sağladığından dolayı GEE platformuna, Amerikan Jeoloji Servisi (USGS)'e ve Copernicus Land Monitoring Service'e teşekkür eder.

**Yazar Katkı Oranı**

Yazarların makaleye katkıları eşit orandadır.

**Çıkar Çatışması/Çakışması**

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunmamaktadır.

**Araştırma ve Yayın Etiği Beyanı**

Çalışmanın araştırma ve yayın etiği hakkında açıklanması gereken herhangi bir bilgi bulunmamaktadır.

**KAYNAKÇA**


Akcin, H. and Köse, R.T. (2024) Disaster Risk Assessment of Fluvial and Pluvial Flood Using the Google Earth Engine Platform: a Case Study for the Filyos River Basin. PFG–Journal of Photogrammetry, Remote Sensing and Geoinformation Science (2024) 92:353–366, https://doi.org/10.1007/s41064-024-00277-z

Akyüz, D.E., Kaya, S., Seker, D.Z., Kabdasli, S. (2014) Definition of floodrisky areas with calculation of stream water velocity via using numerical model: case study of Filyos River, Turkey. Fresenius Environ B 23:3022–3028

Atalay, İ. (2011) Türkiye Coğrafyası ve Jeopolitiği. Meta Basım Matbaacılık Hizmetleri, İzmir.

Atış, E., Çelikoğlu, Ş. (2019) Sosyo-Ekonomik ve Çevresel Yönleriyle Filyos Vadi Projesi." International Social Sciences Studies Journal, 5(29): 49-68

Büyüksalih, İ., Akçın, H., Sefercik, U. G., Karakış, S., ve Marangoz, A. M. (2005). Batı Karadeniz Sahil Bölgesindeki Filyos Nehri ve Deltasındaki Değişimlerin Zamansal CBS İle İncelenmesi. Ege CBS Sempozyumu, İzmir.

CART (2022) [Erişim tarihi: 10.10.2022], https://en.wikipedia.org/wiki/Decision_tree_learning

Duran A. (2021) Gelik Deresi (Zonguldak) – Bartın Çayı (Bartin) Arasının Uygulamalı Kıyı Jeomorfolojisi Etüdü (Yüksek Lisans Tezi), İstanbul Üniversitesi, İstanbul.

Gorelick N. (2013) Google Earth Engine, In EGU General Assembly Conference Abstracts, 11997.

Jagannath, V. (2020) Random Forest Template for TIBCO Spotfire® - Wiki Page TIBCO Community. https://community.tibco.com/wiki/random-foresttemplate-tibco-spotfire

Kavzoglu, T. (2009) Increasing the accuracy of neural network classification using refined training data, Environmental Modelling & Software. 24 (7): 850-858.

Küçükali, S. (2019) Statistical investigation of Filyos river physical water quality parameters. Anatol Environ Animal Sci 4 (3): 519–524. https://doi.org/10.35229/jaes.636576

Landsat-8 (2022) [Erişim tarihi: 03.06.2022] https://www.usgs.gov/landsat-missions/landsat-8

Landsat-8, 2 (2022) [Erişim tarihi: 03.06.2022] https://developers.google.com/earth-engine/datasets/catalog/LANDSAT_LC08_C02_T1_TOA#bands

Liu, Y., Wang, Y., & Zhang, J. (2012) New machine learning algorithm: Random forest. In International Conference on Information Computing and Applications, pp. 246-252. Springer, Berlin, DOI:10.1007/978-3-642-34062-8_32

Microsoft Azure (2025) [Erişim Tarihi:21.04.2025], https://azure.microsoft.com/tr-tr/resources/cloud-computing-dictionary/what-are-machine-learning-algorithms

Mirelva P. R. and Nagasawa R. (2019) Application of Sentinel-1 data for classifying croplands using Google Earth Engine. Int. J. Geoinformatics, 15 (3).

Praticò, S., Solano, F., Di Fazio, S., & Modica, G. (2021). Machine learning classification of mediterranean forest habitats in google earth engine based on seasonal sentinel-2 time-series and input image composition optimisation. Remote Sensing, 13(4), 586. https://doi.org/10.3390/rs13040586

Qian, Y., Zhou, W., Yan, J., Li, W., & Han, L. (2015) Comparing machine learning classifiers for objectbased land cover classification using very high resolution imagery. Remote Sensing, 7 (1): 153-168. https://doi.org/10.3390/rs70100153

Qu, L., A., Chen, Z., Li, M. (2019) CART-RF Classification with Multifilter for Monitoring Land Use Changes Based on MODIS Time-Series Data: A Case Study from Jiangsu Province, China. Sustainability, 11 (20): 5657. https://doi.org/10.3390/su11205657

Rwanga, S., Ndambuki J. (2017) Accuracy assessment of land use/land cover classification using remote sensing and GIS. International Journal of Geosciences, 8 (04): 611-622. DOI:10.4236/ijg.2017.84033

Seker, D.Z., Kaya, S., Musaoglu, N., Kabdasli, M.S., Yuasa, A., Duran, Z. (2005) Investigation of meandering in Filyos River by means of satellite sensor data. Hydrol Process 19:1497–1508. https://doi.org/10.1002/hyp.5593

SVM (2022) [Erişim tarihi: 04.06.2022] https://en.wikipedia.org/wiki/Support-vector_machine

Talari, S., (2022) Random Forest and Decision Tree: Key Differences. [erişim tarihi: 20.04.2025], https://www.kdnuggets.com/2022/02/random-forest-decision-tree-key-differences.html

Turoğlu, H., Duran, A. (2021). Filyos Çayı Deltasında (Karadeniz) kıyı çizgisi değişiklikleri ve yakın geleceğe yönelik göstergeler. Türk Coğrafya Dergisi (78), 61-74. https://doi.org/10.17211/tcd.1016928

Yılmaz, Y. (2021) Filyos Deltasi Kumul Vejetasyonu (Yüksek Lisans Tezi), Karabük Üniversitesi, Karabük.


© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU

https://tufuab2025.beun.edu.tr

# Eğirdir Gölü Su Seviyesi Değişimlerinin Sentinel-2 Uydu Görüntüleri ile NDWI Tabanlı Zamansal ve İstatistiksel Analizi

**Onur Kayaoğlu*[1], Nevin Betül Avşar[1], Mehmet Güven Koçak[1], Osman Sami Kırtıloğlu[1]**

[1]*İzmir Kâtip Çelebi Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Harita Mühendisliği Bölümü, İzmir, Türkiye*

**Anahtar Kelimeler**
Uzaktan algılama,
Su seviyesi değişimi,
Eğirdir Gölü,
NDWI,
Zaman serisi analizi

**ÖZET**

Bu çalışma, Türkiye'nin en büyük tatlı su kaynaklarından biri olan Eğirdir Gölü'nde, 2017–2024 yılları arasında meydana gelen yüzey suyu değişimlerini zamansal ve mekânsal boyutlarıyla değerlendirmeyi amaçlamaktadır. Artan kuraklık, azalan yağış miktarları ve insan faaliyetlerinin birleşik etkileri, gölde son yıllarda ciddi bir su kaybına yol açmıştır. Çalışmada, Avrupa Uzay Ajansı'na (ESA) ait Sentinel-2A ve Sentinel-2B uydularının Level-2A yüzey yansıma verileri kullanılarak Google Earth Engine (GEE) platformu üzerinden zamansal analizler gerçekleştirilmiştir. Her yılın Haziran–Eylül dönemine ait atmosferik olarak en uygun ve bulutsuz görüntüler seçilmiş; bu görüntüler üzerinden Normalize Edilmiş Su Fark İndeksi (NDWI) hesaplanmıştır. NDWI değerleri eşiklenerek yıllık su varlığı haritaları oluşturulmuş, yüzey alanları piksel sayısına göre kilometrekare cinsinden hesaplanmıştır. NDWI fark haritaları, histogramlar, kutu grafikler ve Z-skor analizleri ile desteklenen değerlendirmeler sonucunda, 2017 yılına kıyasla gölün yüzey suyu alanında %90,7 oranında dramatik bir azalma meydana geldiği belirlenmiştir. Bu kayıp, yalnızca göl ekosisteminin sürdürülebilirliğini değil, aynı zamanda bölgedeki tarımsal üretim, içme suyu temini ve diğer suya bağımlı faaliyetleri de doğrudan tehdit etmektedir. Ayrıca, CHIRPS veri setinden elde edilen aylık toplam yağış verileri ile NDWI eğilimleri karşılaştırılarak, su kaybının iklimsel değişkenliklerle olan ilişkisi ortaya konmuştur. Bu analiz, uzaktan algılama tekniklerinin ve bulut tabanlı hesaplama gücünün bir arada kullanılmasıyla sulak alanlardaki değişimlerin etkin şekilde izlenebileceğini göstermektedir.

# NDWI Based Temporal and Statistical Analysis of the Eğirdir Lake Level Change Using Sentinel-2 Satellite Images

**Keywords**
Remote sensing,
Water level change,
Eğirdir Lake,
NDWI,
Time series analysis

**ABSTRACT**

This study aims to assess the temporal and spatial dynamics of surface water changes in Lake Eğirdir, one of Turkey's largest freshwater bodies, between the years 2017 and 2024. The combined effects of increasing drought, decreasing precipitation, and human activities have resulted in a significant loss of water in the lake in recent years. Multi-temporal analyses were conducted on the cloud-based Google Earth Engine (GEE) platform using Level-2A surface reflectance data from the Sentinel-2A and Sentinel-2B satellites provided by the European Space Agency (ESA). For each year, atmospherically optimal and cloud-free images from the June–September period were selected. Based on these images, the Normalized Difference Water Index (NDWI) was calculated. NDWI values were thresholded to produce annual surface water maps, and the total surface area was computed in square kilometers based on pixel counts. The evaluation, supported by NDWI difference maps, histograms, boxplots, and Z-score analyses, revealed a dramatic 90.7% decrease in surface water area compared to 2017. This loss poses a direct threat not only to the sustainability of the lake's ecosystem but also to agricultural production, potable water supply, and other water-dependent activities in the region. Furthermore, monthly total precipitation data from the CHIRPS dataset were compared with NDWI trends, highlighting the relationship between water loss and climatic variability. This analysis demonstrates that the integration of remote

TASLAK

sensing techniques with cloud computing power offers an effective approach for monitoring changes in wetland ecosystems.

## 1. GİRİŞ

Tatlı su gölleri, yalnızca ekolojik çeşitliliği destekleyen habitatlar değil, aynı zamanda içme suyu temini, tarımsal sulama, hidroelektrik üretimi, turizm ve bölgesel iklim regülasyonu gibi çok sayıda ekonomik ve sosyal işlevi bir arada barındıran karmaşık hidro-sosyal sistemlerdir (Wetzel, 2001; Kummu ve Varis, 2011). Küresel ölçekte artan nüfus baskısı, tarımda su tüketiminin büyümesi ve iklim değişikliğine bağlı olarak bozulan yağış rejimleri, bu hassas sistemlerin sürekliliğini tehdit etmektedir. Özellikle Akdeniz Havzası gibi yarı kurak bölgelerde yer alan kapalı havza gölleri, bu değişkenlere karşı oldukça kırılgan bir yapı sergilemektedir (Sabater ve Tockner, 2010; IPCC, 2021). Son yıllarda, dünya genelinde çok sayıda iç su kaynağında dramatik yüzey alanı kayıpları yaşanmakta ve bu durum, "sulak alan kaybı" olgusunu yalnızca biyolojik değil, aynı zamanda jeopolitik bir kriz başlığı hâline getirmektedir. Pekel vd. (2016), 1984–2015 döneminde küresel ölçekte sürekli su alanlarının %90'ının daralma gösterdiğini ortaya koyarken; Donchyts vd. (2016), birçok gölde bu azalmanın %70'in üzerinde olduğunu saptamıştır. Türkiye'de ise özellikle Burdur, Tuz, Seyfe ve Eğirdir gibi iç göllerin yüzey alanlarında ciddi küçülmeler rapor edilmiştir (Ekercin ve Örmeci; 2008; Pınarlık vd., 2023; Kale ve Erişmiş, 2024). Bu bağlamda, değişimin hem nicel hem de mekânsal olarak izlenmesi, çevresel sürdürülebilirlik açısından hayati önem taşımaktadır. Türkiye'nin ikinci büyük tatlı su gölü olan Eğirdir Gölü, Isparta ili sınırlarında yer almakta ve hem yerel halkın içme suyu ihtiyacını karşılamakta hem de çevresindeki tarım alanlarına sulama desteği sağlamaktadır. Ancak son yıllarda gölde gözlenen çekilme, yalnızca su miktarındaki azalma ile sınırlı kalmamakta; göl çevresinde tarımsal üretimde düşüş, yeraltı suyu rezervlerinde azalma ve biyolojik çeşitlilikte gerileme gibi sonuçları da beraberinde getirmektedir. Su seviyesi değişimleri, bölgesel ölçekte hidrolojik ve ekolojik istikrarsızlıklara yol açmakta, aynı zamanda sosyo-ekonomik kırılganlıkları artırmaktadır. Bu risklerin zamanında tespiti ve etkili izlenmesi için geleneksel yer ölçümü teknikleri yetersiz kalmaktadır. Göl alanlarında sürekli, geniş alan kapsayan ve tekrarlanabilir veri üretimi ihtiyacı, uzaktan algılama teknolojilerini bu alanda vazgeçilmez bir araç hâline getirmiştir (Schwatke vd., 2020).

Bu bağlamda, Sentinel-2 gibi yüksek uzamsal ve zamansal çözünürlüğe sahip uydu sistemleri, yüzey suyu alanlarını izlemek için oldukça elverişli bir platform sunmaktadır (Lekhak vd., 2023; Atasever ve Abbas, 2024). Özellikle yeşil ve yakın kızılötesi bantlar arasındaki yansıma farkına dayanan Normalize Edilmiş Su Farkı İndeksi (NDWI), göl varlığının zamansal değişimini nesnel olarak değerlendirmek için yaygın biçimde kullanılan bir spektral göstergedir (McFeeters, 1996; Xu, 2006). NDWI endeksinin zaman serisi analizi ile entegre biçimde kullanımı, sadece göl yüzeyinin mevcut durumunu değil, aynı zamanda kuraklık sinyallerini, sezonluk dalgalanmaları ve olağandışı anomalileri de ortaya koyma kapasitesine sahiptir. Bu potansiyel, özellikle Google Earth Engine (GEE) gibi bulut tabanlı jeo-bilişim platformlarıyla birleştirildiğinde, geniş ölçekli çevresel izleme çalışmalarının düşük maliyetle gerçekleştirilmesini mümkün kılmaktadır (Gorelick vd., 2017). GEE sayesinde, çok bantlı uydu görüntülerine dinamik erişim sağlanabilmekte, atmosferik düzeltme işlemleri otomatikleştirilebilmekte ve yüksek zaman çözünürlüğüne sahip analizler kod tabanlı algoritmalarla yürütülebilmektedir.

Bu çalışma, 2017–2024 yılları arasında Eğirdir Gölü'nde meydana gelen yüzey suyu değişimlerini Sentinel-2 uydu görüntüleri ve NDWI zaman serisi aracılığıyla izlemeyi amaçlamaktadır. Göl yüzeyindeki azalmaların büyüklüğü, istatistiksel anlamlılığı ve mekânsal dağılımı farklı analiz araçlarıyla ortaya konacak; ayrıca CHIRPS veri seti kullanılarak iklimsel değişkenlerle olan ilişkiler değerlendirilecektir. Bu bağlamda çalışmanın temel katkısı, NDWI zaman serilerinin göl ekosistemlerindeki bozulmaları erken dönemde tespit etme kapasitesini ortaya koyması ve Türkiye ölçeğinde sürdürülebilir iç su izleme politikalarına bilimsel zemin sunmasıdır.

## 2. YÖNTEM

Bu çalışmada, Eğirdir Gölü'nün 2017–2024 yılları arasındaki yüzey suyu değişimlerinin zamansal ve mekânsal olarak analiz edilmesi amacıyla çok bantlı uydu görüntüleri ve istatistiksel analiz yöntemleri entegre bir biçimde kullanılmıştır. Analiz süreci dört ana aşamada yürütülmüştür: (1) Uydu verilerinin temini ve ön işleme adımları, (2) NDWI hesaplaması ve su/kara sınıflandırması, (3) zaman serisi analizleri ile anomali tespiti ve (4) istatistiksel ve görsel değerlendirmeler.

### 2.1. Uydu Görüntülerinin Temini ve Ön İşlem Süreci

Çalışmada Avrupa Uzay Ajansı (ESA) tarafından Copernicus programı kapsamında sunulan Sentinel-2A ve Sentinel-2B uydularına ait Level-2A yüzey yansıma (surface reflectance) ürünleri kullanılmıştır. Bu ürünler, atmosferik düzeltmeleri içeren ve su spektral indeksleri için uygun olan işlenmiş görüntülerdir. Veriler, Google Earth Engine (GEE) platformu üzerinden çekilmiş ve JavaScript tabanlı bir GEE algoritmasıyla işlenmiştir. Her yılın Haziran–Eylül ayları arasındaki dönem, mevsimsel bulutsuzluk ve göl seviyesi stabilitesi açısından tercih edilmiştir. Bu dönem aynı zamanda tarımsal sulama faaliyetlerinin en yoğun olduğu zaman aralığına denk geldiği için, insan etkisiyle oluşan seviye değişimleri açısından da duyarlıdır. Görüntü seçimi sırasında bulut oranı < %10 olan sahneler tercih edilmiş; bulut ve bulut gölgesi etkilerinden arındırmak amacıyla Sentinel-2'nin "QA60" maskesi ve GEE içindeki cloudMasking fonksiyonları kullanılmıştır (Gorelick vd., 2017).

### 2.2. Sentinel-2 Uydu Verisi ve NDWI Hesaplaması

Yüzey suyu tespiti için NDWI hesaplanmıştır. Bu indeks, su kütleleri üzerinde yeşil banttan (B3 – 560 nm) güçlü yansıma ve yakın kızılötesi bantta (B8 – 842 nm) zayıf yansıma özelliklerine dayanır. NDWI, su varlığının belirlenmesinde yaygın olarak kullanılan bir spektral indekstir ve aşağıdaki matematiksel ifadeler ile tanımlanır (McFeeters, 1996):

$$\mathrm{NDWI} = \frac{\mathrm{B3} - \mathrm{B8}}{\mathrm{B3} + \mathrm{B8}} \quad (1)$$

$$\mathrm{NDWI} = \frac{Green - NIR}{Green + NIR} \quad (2)$$

(1) eşitliğinde B3 yeşil bant, B8 ise yakın kızılötesi (NIR) banttır. (2) eşitliğinde, Sentinel-2 için yeşil bant (Green) B3 (560 nm), yakın kızılötesi bant (NIR) ise B8 (842 nm) olarak kullanılmıştır. NDWI değeri pozitif olduğunda su varlığına, negatif veya sıfıra yakın olduğunda ise kara yüzeyine işaret etmektedir.

**2.3. Su/Kara Sınıflandırması ve Fark Haritası**

Su/kara ayrımı, literatürde yaygın biçimde kullanılan NDWI > 0,1 eşik değeri ile gerçekleştirilmiştir (Xu, 2006; Rokni vd., 2014). Bu değer, görsel doğrulama ve histogram eşik testi (Otsu yöntemi) ile de desteklenmiştir. NDWI < 0,1 değerleri kara yüzeyleri olarak tanımlanmış, yıllık su maskeleri binary raster olarak kaydedilmiştir. 2017 yılı referans yılı olarak kabul edilerek, 2024 yılına ait NDWI haritası ile piksel bazında karşılaştırma yapılarak fark haritaları oluşturulmuştur. Bu fark analizleri, göl alanında yıllar içinde meydana gelen kümülatif değişimin mekânsal örüntüsünü ortaya koymayı amaçlamaktadır.

**2.4. Z-Skor Anomali Analizi**

NDWI zaman serisi verileri üzerinde yıllık düzeyde anomalilerin belirlenmesi amacıyla Z-skor analizi uygulanmıştır. Bu yöntem, her bir yılın NDWI ortalamasının, genel ortalamadan standart sapma cinsinden ne kadar saptığını hesaplamaktadır. Elde edilen Z-skorları ile, çalışılan dönemde olağandışı kurak ya da nemli yıllar belirlenmiş; yıllık sapmaların zamansal dağılımı yorumlanmıştır.

$$\mathrm{Z} = \frac{X - \mu}{\sigma} \quad (3)$$

Burada $X$, ilgili yılın NDWI ortalamasını; $\mu$, tüm dönem boyunca hesaplanan genel ortalamayı; $\sigma$ ise standart sapmayı temsil etmektedir. Z-skoru > +1 olan yıllar ortalamanın üzerinde nemliliğe sahip olup "normalden daha nemli" olarak değerlendirilmiştir. Buna karşılık, Z-skoru < -1 olan yıllar istatistiksel olarak anlamlı şekilde ortalamanın altında değerler göstermekte olup "aşırı kurak" yıllar olarak sınıflandırılmıştır (Hyndman ve Athanasopoulos, 2018). Bu eşikler, su varlığına ilişkin anormal yılların belirlenmesinde temel bir ölçüt olarak kullanılmıştır.

**2.5. Yağış Verilerinin Entegrasyonu**

NDWI zaman serisi ile karşılaştırılmak üzere, CHIRPS (Climate Hazards Group InfraRed Precipitation with Stations) veri setinden aylık toplam yağış değerleri alınmıştır (Funk vd., 2015). Bu veriler, GEE üzerinden indirilen raster formatındaki zaman serileriyle uyumlu olacak şekilde göl sınırları içinde ortalama alınarak zamansal düzeye indirgenmiştir.

Bu karşılaştırma ile NDWI ile yağış arasındaki korelasyon yorumlanmış, yüzey suyu değişiminin iklimsel duyarlılığı değerlendirilmiştir.

**2.6. Görsel ve İstatistiksel Analizler**

NDWI tabanlı zaman serisi analizlerinden elde edilen sonuçların anlamlı ve yorumlanabilir hâle getirilebilmesi için çok sayıda görsel ve sayısal değerlendirme aracı birlikte kullanılmıştır. Bu araçlar, hem NDWI değerlerinin yıllar içindeki eğilimini hem de bu eğilimin gölün fiziksel ve istatistiksel özelliklerine nasıl yansıdığını çok boyutlu olarak ortaya koymaktadır. İlk olarak, yıllık NDWI ortalamalarına dayalı zaman serisi grafikleri oluşturulmuştur. Bu grafikler, göl yüzeyindeki su varlığının yıllar içindeki artış veya azalış eğilimlerini açıkça görselleştirmekte ve eğilim doğrultusunun istatistiksel olarak da test edilmesine olanak sağlamaktadır. Zaman serisi içerisindeki trend doğrusal regresyon modeli ile modellenmiş ve eğilim katsayısı ile birlikte belirli yıllardaki kırılma noktaları belirlenmiştir.

Göl yüzeyindeki su/kara ayrımının yıllık olarak ne ölçüde değiştiğini göstermek amacıyla, NDWI > 0,1 eşik değerini aşan piksel oranlarına dayalı olarak su yüzeyi yüzdesi eğrisi oluşturulmuştur. Bu eğri, her yıl göl yüzeyinin ne kadarının açık su olarak kaldığını sayısal olarak göstermekte, fiziksel daralmanın yıllık boyutlarını karşılaştırmalı şekilde sunmaktadır. Yıllık NDWI verileri için kutu grafikleri (boxplot) kullanılmış, her yılın medyan değeri, çeyrekler arası açıklık, minimum ve maksimum değerleri, ayrıca olası aykırı değerler belirlenmiştir. Bu grafikler, yalnızca NDWI değerlerinin merkezî eğilimini değil, aynı zamanda varyans ve dağılım yapısındaki değişimleri de ortaya koymuştur. Göl ekosistemindeki homojenleşme, su yığılmaları ya da kuruma alanlarındaki süreklilik kaybı gibi değişkenlikler bu grafiklerle görsel olarak desteklenmiştir. Histogram analizleri, hem piksel bazında NDWI fark rasterlarının dağılımını hem de yıllara göre NDWI değer yoğunluklarını ortaya koymak için kullanılmıştır. Özellikle 2024–2017 arasındaki fark histogramları, su kaybının şiddetini ve bu kaybın göl çevresinde ne denli yaygın olduğunu istatistiksel olarak yorumlama imkânı sağlamıştır.

Bu görsel analizlerin ötesinde, NDWI zaman serisinin yıllık ortalamaları üzerinden Z-skor analizi yapılmıştır. Bu analiz ile her bir yılın ortalama NDWI değeri, genel ortalamadan standart sapma düzeyinde ne kadar saptığına göre derecelendirilmiş ve olağandışı kurak ya da nemli yıllar belirlenmiştir. Z-skoru, yalnızca mutlak farkları değil, aynı zamanda sapmanın istatistiksel anlamlılığını da sunduğundan, göldeki su dinamiklerinin ekstrem yıllar bazında değerlendirilebilmesi açısından güçlü bir araç olarak kullanılmıştır. Son olarak, CHIRPS yağış verileri ile NDWI zaman serisi karşılaştırılmış, iki zaman serisinin örtüşen eğilimleri değerlendirilmiş ve Pearson korelasyon katsayısı hesaplanarak istatistiksel ilişki düzeyi ortaya konmuştur. Yağışlar ile NDWI arasındaki bu ilişki, göldeki su seviyesinin iklimsel değişkenliklere olan duyarlılığını doğrulamak açısından kritik bir gösterge niteliğindedir. Tüm bu analizler Python programlama dili ile gerçekleştirilmiş; matplotlib, seaborn ve pandas gibi kütüphaneler kullanılarak hem istatistiksel hesaplamalar yapılmış hem de grafiksel sunumlar hazırlanmıştır. Ayrıca, Google Earth Engine'in ui.Chart

modülü ile dinamik çevrimiçi grafik ön izlemeleri oluşturulmuş ve doğrulama süreçleri desteklenmiştir.

## 3. BULGULAR

### 3.1. NDWI Zaman Serisi ve Su Kaybı Eğilimi

Şekil 1, 2017–2024 dönemine ait Normalize Edilmiş Su Farkı İndeksi (NDWI) zaman serisi analizleri, Eğirdir Gölü'nde uzun vadeli ve belirgin bir yüzey suyu kaybı eğilimini ortaya koymaktadır. 2017 yılında ortalama 0,25 düzeyinde ölçülen NDWI değeri, zamanla istikrarlı bir şekilde azalarak 2021 yılı itibarıyla -0,02 seviyelerine kadar gerilemiştir. Bu düşüş, gölde yüzey suyu varlığının ciddi şekilde azaldığına ve ekosistem üzerinde potansiyel baskıların arttığına işaret etmektedir. 2024 yılında NDWI değerlerinde sınırlı bir artış gözlemlenmiş olsa da bu artış göldeki su varlığının toparlandığını göstermekten uzaktır. 2024 yılına ait ortalama NDWI değeri hâlâ 2017 yılına kıyasla önemli ölçüde düşük kalmaktadır. Bu durum, Eğirdir Gölü'nün su seviyesi dinamiklerinin iklimsel koşullar ve insan kaynaklı etmenlerle birlikte şekillendiğini göstermektedir. Zaman serisi eğrisine bakıldığında, genel eğilimin negatif yönde olduğu ve gölün uzun vadeli bir su kaybı süreci içerisinde bulunduğu açıkça görülmektedir. Bu bağlamda NDWI zaman serileri, göldeki hidrolojik stresin erken uyarı göstergesi olarak değerlendirilebilecek nitelikte bir bulgudur.

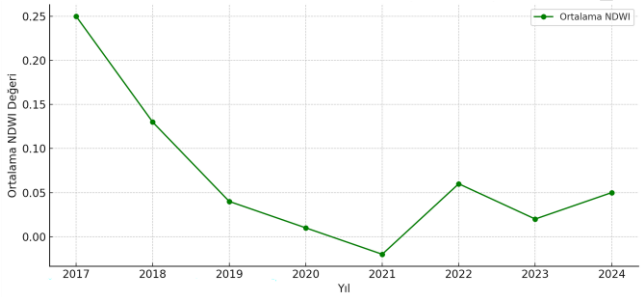


**Şekil 16.** Ortalama NDWI zaman serisi (2017–2024).

### 3.2. Su Alanı Yüzdesi ve Fiziksel Daralma

Bu çalışmada, NDWI > 0,1 eşik değeri kullanılarak su alanları belirlenmiş ve 2017 yılı, referans yıl olarak kabul edilerek diğer yıllarla karşılaştırılmıştır. Elde edilen sonuçlara göre, 2024 yılı itibarıyla göl yüzeyinin yalnızca %9,3'ü suyla kaplıdır. Bu durum, 2017 yılına kıyasla su alanında yaklaşık %90,7 oranında bir azalma yaşandığını göstermektedir. Zaman içerisinde su yüzeyindeki bu azalma eğilimi, özellikle son yıllarda belirginleşmiştir. Su alanındaki yıllık değişim oranları ve trend, Şekil 2'de görsel olarak sunulmuş olup, bu görselde yıllara göre su yüzeyi değişimlerinin net bir şekilde izlendiği gözlemlenmektedir. Bu bulgular, gölde meydana gelen fiziksel daralma sürecinin ciddi boyutlara ulaştığını ve bu durumu izlemek için yapılan NDWI tabanlı analizlerin etkinliğini ortaya koymaktadır.

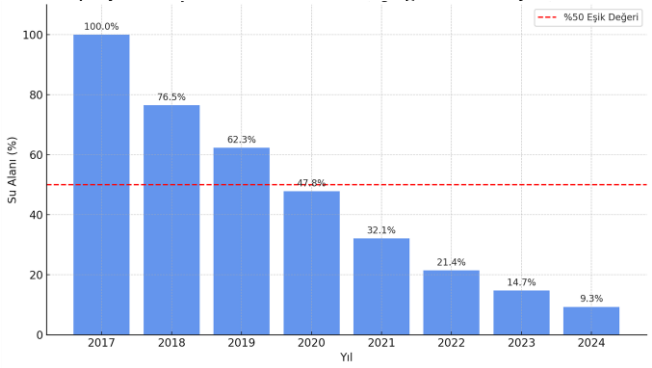


**Şekil 17.** 2017'ye göre su alanı yüzdesi (Eğirdir Gölü, 2017–2024).

### 3.3. Piksel Bazlı NDWI Kümülatif Değişimi

Şekil 3, 2017 ile 2024 yılları arasındaki NDWI değer farklarının piksel bazında dağılımını göstermektedir. Histogram, simetrik olmayan ve sola çarpık bir dağılım sergileyerek, göl çevresindeki çok sayıda pikselde belirgin negatif NDWI değişiminin yaşandığını ortaya koymaktadır. Histogramda en yoğun değişim, yaklaşık -0,5 değerinde yoğunlaşmış olup, bu durum, göldeki su varlığının yaygın ve ciddi bir şekilde azaldığını işaret etmektedir. Negatif NDWI değişimlerinin yoğun olduğu bölgeler, su seviyesindeki azalmayı doğrudan yansıtan alanlar olarak öne çıkmaktadır. Bu bulgu, göl ekosistemindeki su kaybının geniş bir alana yayıldığını ve bunun çevresel etkilerinin önemli olabileceğini göstermektedir. Histogram analizi, su kaybı sürecinin mekânsal olarak da yaygınlaştığını gözler önüne sererek, gelecekteki araştırmalar için önemli bir veri sağlamaktadır.

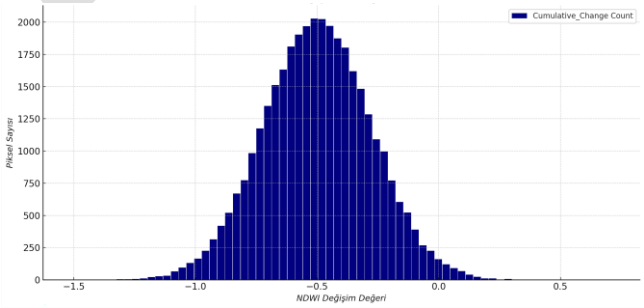


**Şekil 18.** NDWI kümülatif değişim histogramı (2024–2017).

### 3.4. NDWI Histogramlarının Yıllık Karşılaştırması

Şekil 4, 2024 ve 2017 yıllarına ait NDWI değerleri arasındaki farkların frekans dağılımını sunmaktadır. Yatay eksende NDWI fark değerleri, dikey eksende ise her bir fark değerine sahip piksel sayısı yer almaktadır. Histogramda en yoğun dağılım, yaklaşık -1,26 ile -1,23 arasındaki değer aralığında gözlemlenmektedir. Bu durum, çok sayıda pikselin 2017 yılına kıyasla NDWI değerinin yaklaşık 1,25 birim azaldığını göstermektedir. Histogramın simetrik olmayan yapısı, göl genelinde homojen bir su kaybı yaşandığını ve bu kaybın neredeyse tüm yüzeyde eşit şekilde dağıldığını işaret etmektedir. Ayrıca, pozitif farklara sahip piksel sayısının oldukça düşük olması, genel eğilimin negatif ve yaygın kuruma yönünde olduğunu açıkça ortaya koymaktadır. Bu

veriler, su kaybının yalnızca belirli noktalarda değil, gölün büyük bir kısmında gözlemlendiğini göstermektedir. Şekil 4, yüzey suyu kaybının mekânsal yaygınlığını ve şiddetini istatistiksel olarak destekleyen güçlü bir kanıt olarak değerlendirilebilir. Bu bulgular, göl çevresindeki su kaybı sürecinin büyük ölçüde homojen olduğunu ve genel olarak geniş bir alanı etkilediğini ortaya koymaktadır. Bu tür bir mekânsal dağılım, çevresel faktörlerin göldeki su seviyesindeki değişimlere olan etkisini anlamada önemli bir veri sunmaktadır.

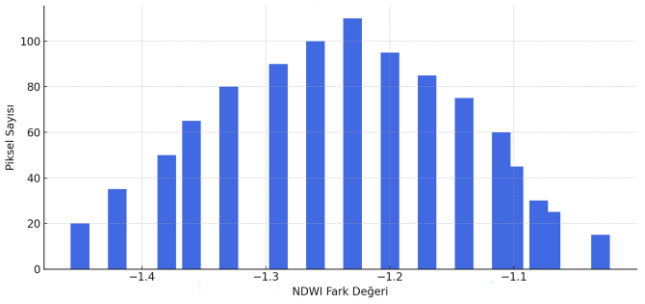


**Şekil 19.** NDWI histogramı (2024 – 2017).

### 3.5. Kutu Grafiği ve Değişkenlik Yorumları

NDWI değerlerine ait yıllık kutu grafiklerinin incelenmesi, göldeki yüzey suyu miktarının zamanla nasıl değiştiğini ve bu değişimin istatistiksel dağılıma nasıl yansıdığını ortaya koymaktadır. 2017 yılına ait kutu grafiği, daha geniş bir dağılım aralığına ve daha yüksek bir medyan değere sahiptir. Bu durum, ilgili yılda göl çevresindeki su varlığının hem miktar hem de mekânsal çeşitlilik açısından daha yüksek olduğunu göstermektedir. Ancak sonraki yıllarda, kutu grafiklerinde gözlemlenen dağılım belirgin şekilde daralmış ve hem medyan hem de ortalama NDWI değerlerinde düşüş gözlenmiştir. Bu daralma, su varlığının yalnızca azalmakla kalmayıp aynı zamanda daha homojen, düşük değerlere doğru kaydığını ve göl çevresinde farklı alanlar arasında su yoğunluğu bakımından artık daha az farklılık bulunduğunu göstermektedir.

Bu bulgular, göl sisteminde hem nicel (miktar) hem de nitel (değişkenlik) açıdan ciddi bir bozulmanın yaşandığını ortaya koymaktadır. Kutu grafikleri, su kaybının sadece alan olarak değil, aynı zamanda istatistiksel dağılım özellikleri açısından da önemli ölçüde değiştiğini göstermesi bakımından kritik bir değerlendirme aracıdır. Bu durum, göldeki su dinamiklerinin zaman içinde giderek durağanlaştığını ve suyun daha sınırlı, daha düşük değerlerde yoğunlaştığını ifade etmektedir (Şekil 5).

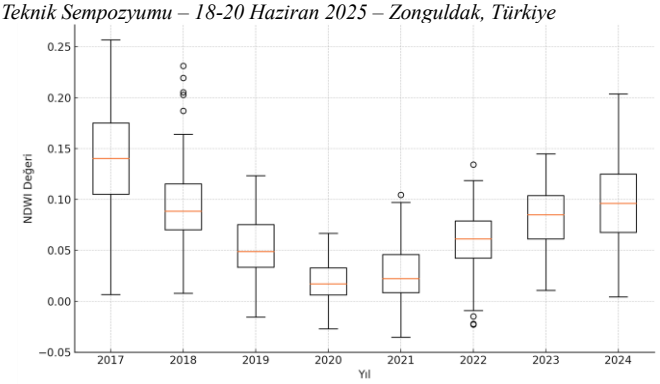


**Şekil 20.** NDWI değerlerinin kutu grafiği.

### 3.6. Z-Skor Anomali Analizi

NDWI zaman serisine uygulanan Z-skor analizi, göldeki yıllık su varlığındaki olağandışı değişimleri belirlemek amacıyla kullanılmıştır. Z-skorları, her yılın NDWI ortalamasının tüm zaman serisine göre standart sapmadan ne kadar saptığını göstererek, istatistiksel olarak anlamlı sapmaların tespit edilmesini sağlamaktadır. Şekil 6'da sunulan yıllık Z-skor sapmaları, analiz dönemindeki su varlığı anomalilerini açıkça ortaya koymaktadır. Analiz sonuçlarına göre, 2017 yılı +1,5'lik Z-skoru ile en yüksek pozitif sapmaya sahip olup, bu yılın göl açısından en su zengini dönem olduğunu göstermektedir. Öte yandan, 2020 yılı -1,2'lik Z-skoruyla en düşük negatif sapmayı göstermekte ve bu yönüyle analiz döneminin en kurak yılı olarak öne çıkmaktadır. Bu durum, 2020 yılında göldeki yüzey suyu miktarının ortalamanın oldukça altında olduğunu ortaya koymaktadır. 2021 yılına gelindiğinde, Z-skorunun hafifçe pozitife yönelmesi görece bir toparlanmaya işaret etse de bu toparlanmanın sürdürülebilir olmadığı anlaşılmaktadır.

2022–2024 yılları arasında Z-skor değerlerinin ±0,3 aralığında dalgalanması, su varlığının bu dönemde istikrarsız ve belirsiz bir seyir izlediğini göstermektedir. Bu dalgalı yapı, göldeki su dengesinin dış çevresel faktörlerden kolayca etkilenebildiğini ve sistemin artık daha kırılgan hale geldiğini düşündürmektedir. Z-skor analizi, sadece yıllık ortalamalardaki mutlak değişimleri değil, aynı zamanda bu değişimlerin ne ölçüde olağandışı olduğunu da göstermesi açısından oldukça önemli bir göstergedir. Bu bağlamda, gölün su rejimindeki yapısal bozulmayı ortaya koymakta ve gelecekteki kuraklık risklerine karşı erken uyarı niteliği taşımaktadır.

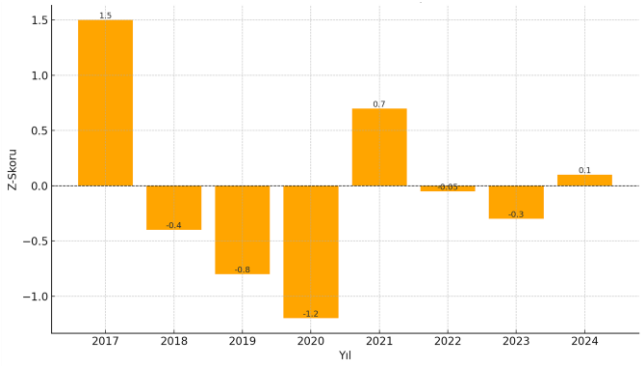


**Şekil 21.** NDWI Z-skoru (anomali tespiti).

### 3.7. NDWI ve Yağış Karşılaştırması

NDWI zaman serisi ile CHIRPS veri setinden elde edilen aylık toplam yağış değerlerinin karşılaştırılması, göldeki yüzey suyu varlığının iklimsel faktörlere olan duyarlılığını değerlendirmek amacıyla gerçekleştirilmiştir. Bu karşılaştırma, su seviyesindeki değişimlerin yalnızca yüzeysel gözlemlere değil, aynı zamanda meteorolojik verilere dayalı olarak da analiz edilmesini mümkün kılmıştır. Yapılan analiz sonucunda, NDWI değerlerinin genel olarak yağış eğilimlerini büyük ölçüde takip ettiği gözlemlenmiştir. Özellikle 2020–2021 döneminde hem yağış miktarlarında hem de NDWI seviyelerinde eş zamanlı ve belirgin düşüşlerin meydana gelmesi, göl yüzeyindeki su varlığının doğrudan iklimsel koşullara bağımlı olduğunu açıkça ortaya koymaktadır. Bu eş zamanlılık, göldeki su kaybının temel nedenlerinden birinin azalan yağış rejimi olduğunu düşündürmektedir. Şekil 7'de sunulan grafik, NDWI ile yağış verileri arasındaki paralel hareketi açık biçimde ortaya koymakta; her iki parametredeki iniş-çıkışların zaman içinde büyük ölçüde örtüştüğünü göstermektedir. Bu durum, NDWI'nın iklim değişkenliklerine karşı oldukça duyarlı bir gösterge olduğunu ve yüzey suyu izleme çalışmalarında güvenilir bir erken uyarı sistemi olarak kullanılabileceğini göstermektedir.

Sonuç olarak, NDWI ile yağış arasındaki bu yüksek düzeyli korelasyon, göldeki hidrolojik değişimlerin değerlendirilmesinde yalnızca mekânsal değil, aynı zamanda zamansal çözümlemelerin de önem taşıdığını ortaya koymakta ve bu yaklaşımın entegre su yönetimi stratejilerine katkı sağlayabileceğini göstermektedir.

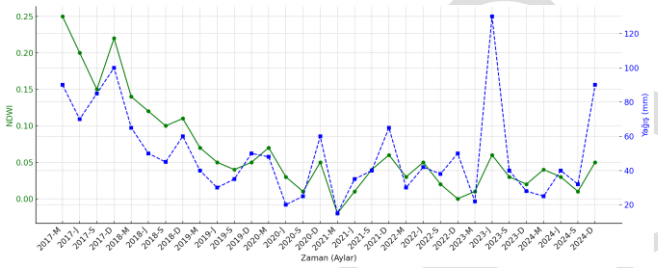


**Şekil 22.** NDWI ve yağış verisinin karşılaştırmalı analizi.

## 4. TARTIŞMA

Bu çalışmada, Eğirdir Gölü'nün yüzey suyu varlığında 2017–2024 yılları arasında meydana gelen değişimler NDWI analiziyle ayrıntılı şekilde ortaya konmuştur. Bulgular, gölde yalnızca yüzey alanı bakımından değil, aynı zamanda spektral yansıtma özellikleri ve istatistiksel değişkenlik açısından da belirgin bir gerileme yaşandığını göstermektedir. Bu zamansal değişim haritaları Şekil 8'de sunulmakta olup 2017'ye kıyasla ciddi bir spektral bozulmayı ortaya koymaktadır. NDWI zaman serisinde gözlenen istikrarlı düşüş (Şekil 23), göldeki su seviyesinin uzun vadeli bir azalma eğilimi gösterdiğini işaret etmektedir. Özellikle 2020 yılında gözlenen negatif Z-skor değeri, gölün o yıl olağanüstü kurak koşullar altında kaldığını açıkça ortaya koymaktadır. Bu durum, hem iklimsel koşulların hem de göl çevresindeki insan faaliyetlerinin (örn. yeraltı suyu çekimleri, tarımsal sulama baskısı) etkilerini bir arada düşündürmektedir. Histogram ve kutu grafiği analizleri, NDWI değerlerindeki homojen olmayan ve genellikle negatif yönlü değişimi nicel olarak desteklemektedir. Bu dağılımlar, yalnızca miktar olarak değil, aynı zamanda göl çevresindeki su dağılımının mekânsal sürekliliğinde de ciddi bir azalmayı göstermektedir. CHIRPS yağış verileri ile yapılan karşılaştırma, NDWI indeksinin iklimsel değişkenliklere yüksek duyarlılık gösterdiğini kanıtlamaktadır. NDWI ve yağış eğrileri arasındaki benzerlik, göl su seviyesinin büyük ölçüde yağış rejimine bağlı olduğunu ortaya koymakta; bu durum, iklim değişikliğinin etkilerini daha hassas şekilde izlemek için NDWI tabanlı zaman serilerinin güçlü birer gösterge olduğunu düşündürmektedir. Literatürde benzer çalışmalarda da (McFeeters, 1996), NDWI'nin göl seviyesi değişimlerini izleme konusundaki başarısı ortaya konmuştur. Bu çalışma, benzer bir metodolojik çerçeveyi Türkiye özelinde uygulayarak hem çevresel riskleri belgelemekte hem de bulut tabanlı analiz ortamlarının (GEE) etkinliğini göstermektedir.

Sonuç olarak, Eğirdir Gölü'ndeki yüzey suyu gerilemesinin çok yönlü nedenlere dayandığı, bu gerilemenin ileriye dönük olarak sürdürülebilirlik ve ekosistem bütünlüğü açısından ciddi tehditler barındırdığı görülmektedir.

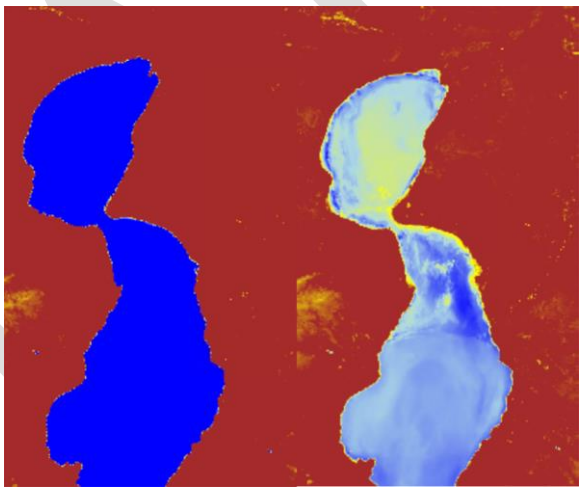

2017 2024

**Şekil 24.** NDWI tabanlı zamansal değişim haritası: göl varlığının azalması.

## 5. SONUÇ

Bu çalışma, Eğirdir Gölü'nde 2017–2024 yılları arasında meydana gelen yüzey suyu değişimlerini NDWI tabanlı zaman serisi ve istatistiksel analizler aracılığıyla ortaya koymuştur. Sentinel-2 uydu verileri ve Google Earth Engine platformu kullanılarak gerçekleştirilen analizler, gölde yaklaşık %90,7 oranında su alanı kaybı yaşandığını göstermiştir. Bu dramatik azalma, göl ekosistemi açısından kritik bir alarm durumu oluşturmaktadır. NDWI zaman serisinde gözlenen sürekli düşüş ve 2020 yılında belirlenen negatif Z-skoru, gölün en stresli yılını yansıtmaktadır. NDWI histogramı ve kutu grafikleri, su varlığının yalnızca miktar değil, dağılım ve süreklilik açısından da bozulduğunu göstermektedir. Ayrıca, NDWI ve CHIRPS yağış verileri arasındaki paralellik, göl seviyesinin iklimsel değişkenliklere yüksek duyarlılık gösterdiğini doğrulamaktadır.

Elde edilen sonuçlar, uzaktan algılama ve açık kaynaklı analiz ortamlarının çevresel değişimlerin izlenmesinde yüksek potansiyel sunduğunu ortaya koymaktadır. Eğirdir Gölü özelinde elde edilen bu

bulgular, sadece yerel düzeyde değil, benzer iç su kaynakları için de izleme ve yönetim stratejilerinin geliştirilmesine katkı sağlayabilir.

**KAYNAKÇA**


Atasever, Ü. H., & Abbas, H. H. (2024). Drought Monitoring in Burdur Lake Using Sentinel-2 Images. Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, 13(3), 882-891. https://doi.org/10.28948/ngumuh.1411803

Donchyts, G., Baart, F., Winsemius, H., Gorelick, N., Tieskens, K., & van de Giesen, N. (2016). Earth's Surface Water Change Over the Past 30 Years. Nature Climate Change, 6(9), 810–813. https://doi.org/10.1038/nclimate3111

Ekercin, S. & Örmeci, C. (2008). Tuz Gölü'ndeki Su Rezervi Değişiminin Çok Zamanlı LANDSAT Uydu Görüntüleri Ve Eş-Zamanlı Yersel Ölçmeler İle Analizi. İTÜ Dergisi/d.

European Commission, (2024). Copernicus Sentinel-2 Surface Reflectance Dataset. Retrieved from https://developers.google.com/earth-engine/

Funk, C., Peterson, P., Landsfeld, M., Pedreros, D., Verdin, J., Shukla, S., ... & Michaelsen, J. (2015). The Climate Hazards Infrared Precipitation With Stations—A New Environmental Record for Monitoring Extremes. Scientific Data. 2, 150066. https://doi.org/10.1038/sdata.2015.66

Google Earth Engine Documentation. (2024). Retrieved from https://developers.google.com/earth-engine/

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. Remote Sensing of Environment, 202, 18–27. https://doi.org/10.1016/j.rse.2017.06.031

Hyndman, R. J., & Athanasopoulos, G. (2018). Forecasting: Principles and practice (2nd ed.). OTexts. https://otexts.com/fpp2/

Kale, M. M., & Erişmiş, M. (2024). Eğirdir Gölü Alansal Değişiminin Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Yardımıyla Analizi. International Journal of Geography and Geography Education (IGGE), *52*, 122-140. https://doi.org/10.32003/igge.1380588

Kummu, M., & Varis, O. (2011). The world's road to water scarcity: Shortage and stress in the 20th century and pathways towards sustainability. Environmental Science & Policy, 14(8), 778–785. https://doi.org/10.1016/j.envsci.2011.04.005

Lekhal, K., Pawan, R., & Budha, P. B. (2023). Extraction of water bodies from Sentinel-2 imagery in the foothills of Nepal Himalaya, International Journal of Environment and Geoinformatics (IJEGEO), 10(2): 070-081. doi. 10.30897/ijegeo.1240074

Pickens, A. H., Hansen, M. C., Hancher, M., Stehman, S. V., Tyukavina, A., Potapov, P., ... & Sherani, Z. (2020). Mapping and sampling to characterize global inland water dynamics from 1999 to 2018 with full Landsat time-series. Remote Sensing of Environment, 243, 111792.

McFeeters, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. International Journal of Remote Sensing, 17(7), 1425–1432. https://doi.org/10.1080/01431169608948714

Pekel, J. F., Cottam, A., Gorelick, N., & Belward, A. S. (2016). High-resolution mapping of global surface water and its long-term changes. Nature, 540(7633), 418–422. https://doi.org/10.1038/nature20584

Pınarlık, M., İbiş, A., & Selek, Z. (2023). İklim Değişikliği Etkisi Altında Burdur Gölü Su Seviyesi Değişimlerinin İstatistiksel Olarak İncelenmesi. Mühendislik Bilimleri ve Tasarım Dergisi, 11(1), 81-93. https://doi.org/10.21923/jesd.1144586

Rodell, M., Famiglietti, J. S., Wiese, D. N., Reager, J. T., Beaudoing, H. K., Landerer, F. W., & Lo, M. H. (2018). Emerging trends in global freshwater availability. Nature, 557(7707), 651–659. https://doi.org/10.1038/s41586-018-0123-1

Rokni, K., Ahmad, A., Selamat, A., & Hazini, S. (2014). Water feature extraction and change detection using multitemporal Landsat imagery. Remote Sensing, 6(5), 4173–4189. https://doi.org/10.3390/rs6054173

Sabater, S., & Tockner, K. (2009). Effects of hydrologic alterations on the ecological quality of river ecosystems. Water scarcity in the Mediterranean: Perspectives under global change, 15-39.

Schwatke, C., Dettmering, D., Bosch, W., & Seitz, F. (2015). DAHITI–an innovative approach for estimating water level time series over inland waters using multi-mission satellite altimetry. Hydrology and Earth System Sciences, 19(10), 4345-4364.

UCSB CHIRPS, (2024). Climate Hazards Group InfraRed Precipitation with Station Data (CHIRPS). Retrieved from https://www.chc.ucsb.edu/data/chirps

Wetzel, R. G. (2001). Limnology: Lake and river ecosystems (3rd ed.). Academic Press.

Xu, H. (2006). Modification of normalized difference water index (NDWI) to enhance open water features in remotely sensed imagery. International Journal of Remote Sensing, 27(14), 3025–3033. https://doi.org/10.1080/01431160600589179


© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# TUFUAB Veri Havuzuna Ait Göktürk-1 Bindirmeli Pankromatik Seviye 2A Görüntülerinin Algılayıcıya Bağımlı Yöneltme Yöntemi İle 3B Konum Doğruluğunun Araştırılması

**Hüseyin Topan*[1], Onur Erişik[2], Murat Oruç[1]**

[1]*Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Zonguldak, Türkiye*
[2]*Hava Kuvvetleri Komutanlığı, Ankara, Türkiye*

**Anahtar Kelimeler**
3B Koordinat Hesabı,
Algılayıcıya Bağımlı Yöneltme
Geo3o1,
Göktürk-1

**ÖZET**

Bu bildiride, Kahramankazan (Ankara) ilçesinde oluşturulan TUFUAB veri havuzuna ait Göktürk-1 bindirmeli pankromatik seviye 2A görüntülerinin (50 cm yer örnekleme aralıklı) üç boyutlu konum doğruluğu, Göktürk-1'in algılayıcı geometrisine uyan yöneltme yöntemiyle değerlendirilmiştir. Yer doğruluğu, Harita Genel Müdürlüğünce ölçümü gerçekleştirilen noktalarla sağlanmıştır. Elde edilen bulgular ışığında, doğrudan yöneltme doğruluğu ±13.71 m olarak elde edilmiş, ön ve demet dengeleme sonucunda yer kontrol noktalarında ±14.05 $10^{-4}$ m ve ±26.88 $10^{-3}$ m, denetim noktalarında ise ±1.92 m doğruluğa ulaşılmıştır. Noktaların, özellikle fotogrametrik çalışmalara uygun şekilde tesis edilmiş olmasından kaynaklanan zorluklar nedeniyle, Göktürk-1 pankromatik görüntülerinin yer örnekleme aralığına uygun bir nokta seçim önerisinde bulunulmuştur.

# 3D Georeferencing of Göktürk-1 Stereo Panchromatic Images Using RFM Method With Type of Ground to Image

**Keywords**
3D Georeferencing Accuracy,
Sensor Dependent Orientation,
Geo3o1
Göktürk-1

**ABSTRACT**

This paper subjected the 3D georeferencing accuracy of Göktürk-1 stereo panchromatic level 2A images with a ground sampling distance of 50 cm. These images belonged to the TUFUAB data pool and covered Kahramankazan in Ankara. The examination used a sensor-dependent orientation model. The ground truth was provided by the General Directorate of Mapping. Direct georeferencing accuracy was found to be ±13.71 m, while the accuracy at the ground control points was found to be ±14.05×$10^{-4}$ m and ±26.88×$10^{-3}$ m, respectively. Following pre- and bundle adjustment, the accuracy at the checkpoints was found to be ±1.92 m. The points used in this study were originally collected for aerial photogrammetric applications. Therefore, it is recommended that a suitable point set be used for Göktürk-1's ground sampling distance.

## GİRİŞ

Uydu görüntülerinden 3B konum belirleme, temelde görüntü koordinatlarının yer (nesne) koordinatlarına dönüştürülmesiyle sağlanır. Dönüşüm doğruluğu kullanılan matematik modele, yardımcı verilerin doğruluğuna, kontrol noktalarının, çizgilerinin veya yüzeylerinın kalitesine bağlı olarak değişkenlik gösterir (Wolf & Dewitt, 2000). Bu amaçla genellikle iki tür algılayıcıya bağımlı yöntem kullanılır. Birincisi algılayıcı sistemin iç ve dış yöneltme ögelerini kullanan ve algılayıcıya göre farklılıklar gösterebilen yöntemler, diğeri ise algılayıcıya bağımlı RFM'dir (Rational Function Model – Rasyonel İşlev Modeli).

Riazanoff (2004) tarafından SPOT 1-5 uyduları için geliştirilen algılayıcıya bağımlı yöneltme yöntemi daha sonra Airbus Defence and Space (2012) tarafından Pléiades 1A/1B uydularına uyarlanmıştır. Aynı yöntem, Göktürk-1 görüntüleri için de geçerli olup Zonguldak test alanına ait üçl-bindirmeli görüntüler Aytekin and Topan (2022b), Aytekin and Topan (2022a), Aytekin (2023) ve Aytekin and Topan (2024) tarafından 3B konum doğruluğu araştırmasına konu edilmiştir.

Bu bildiride ise, Harita Genel Müdürlüğü (HGM) tarafından Kahramankazan'da (Ankara) oluşturulan test alanına ait Göktürk-1 bindirmeli pankromatik seviye 2A görüntülerinin (50 cm yer örnekleme aralıklı), yine HGM tarafından sağlanan kontrol noktaları yardımıyla 3B konum doğruluğunun belirlenmesi amaçlanmaktadır.

Araştırmada sırasıyla, i) algılayıcıya bağımlı yöneltme yöntemi, ii) kullanılan veriler ve çalışma alanı, iii) doğrudan yöneltme ile ön ve demet dengeleme ile

elde edilen doğruluklar, iv) tartışma ve v) sonuç verilecektir.

**YÖNTEM**

Göktürk 1 için kullanılan algılayıcıya bağımlı yöneltme yönteminin ayrıntılarına Aytekin and Topan (2022b), Aytekin and Topan (2022a), Aytekin (2023) ve Aytekin and Topan (2024) kaynaklarından ulaşılabilir. Burada kullanılan yöntem, Riazanoff (2004) tarafından SPOT 1-5 uyduları için geliştirilen ve daha sonra Airbus Defence and Space (2012) tarafından Pléiades 1A/1B uydularına uyarlanana yöntemdir. Yazarların katkısı ise, Topan (2009) tarafından geliştirilen GeoSpot aracında uygulandığı üzere demet dengeleme öncesinde bir ön dengeleme yaparak iç yöneltme ögelerinin düzeltilmesi ve öge anlamlılık testinin yapılmasıdır. Topan and Maktav (2014) tarafından iç ve dış yöneltme ögelerinin hem kendi aralarında hem de karşılıklı doğrusal bağımlılıkları hesaplanarak çalışma geliştirilmiş; Terlemezoğlu (2019) tarafından önerilen iki yaklaşımla olası kötü şartlı matris sorunu giderilmiştir. Airbus Defence and Space (2012) ve Airbus Defence and Space (2013) tarafından sırasıyla Pléiades 1A/1B ve SPOT 6/7 için geliştirilen algılayıcıya bağımlı yöntem Geo3o1'in temelini oluşturmakta ve yukarıda anılan dengeleme hesabı, öge anlamlılık ve doğrusal bağımlılık testleri ile kötü şartlı matrislerin düzenlileştirmesi işlemlerini gerçekleştirebilmektedir.

**UYGULAMA**

Uygulamada Kahramankazan (Ankara) ilçesinde oluşturulan TUFUAB Veri Havuzuna ait 27.10.2024 tarihli bir çift bindirmeli Göktürk-1 pankromatik seviye 2A görüntüsü kullanılmıştır. Görüntülerin yer örnekleme aralığı 50 cm'dir. Toplam 49 adet nokta kullanılmıştır. Görüntülerin kapladıkları alanlar ve nokta dağılımı Şekil 1'de gösterilmektedir. Tüm hesaplamalar Geo3o1 (https://github.com/geoetrim/Geo3o1_Matlab) ile gerçekleştirilmiştir. Elde edilen sonuçlar Çizelge 1'de görülebilir.

**Çizelge 1.** Doğruluk sonuçları (±m)

| Nokta | Doğrudan yöneltme | | | Ön dengeleme *(×10⁻⁴ YKN için)* | | | Demet dengeleme *(×10⁻³ YKN için)* | | |
|---|---|---|---|---|---|---|---|---|---|
| | $m_X$ | $m_Y$ | $m_Z$ | $m_Y$ | $m_Z$ | $m_Z$ | $m_X$ | $m_Y$ | $m_Z$ |
| YKN | 9.30 | 6.47 | 7.72 | 10.50 | 8.51 | 3.87 | 20.87 | 2.74 | 16.72 |
| DN | | | | 1.68 | 0.75 | 0.56 | 1.68 | 0.75 | 0.56 |

Sonuçlar irdelendiğinde, yer kontrol noktalarında (YKN) beklenen (±1 YÖA, ±50 cm) doğruluk sağlanırken, denetim noktalarında (DN) beklenenin altında bir doğruluk elde edilebilmiştir. Doğrudan yöneltme sonuçları beklenen düzeydedir. Ön ve demet dengeleme sonuçları arasında YKN'lere ait doğruluklardaki fark, demet dengelemede dengeleme bilinmeyeni olarak seçilen dış yöneltme ögesine (burada $t_{referans}$) göre oluşturulan Jakobiyen matristir. Zira YKN'lerde doğruluk değiştiği halde DN'lerde değişmemiştir. Burada sınırlayıcı unsur, arazide noktaların fotogrametrik çalışmalara uygun şekilde seçilmiş olmasıdır. Zira Şekil 2'de de görülebileceği üzere bazı YKN'lerde hata vektörleri diğerlerine göre daha büyüktür. Bu da uyuşumsuz ölçüler testi ile kesin olarak belirlenmek üzere uyuşumsuz olabilecekleri anlamına gelmektedir.

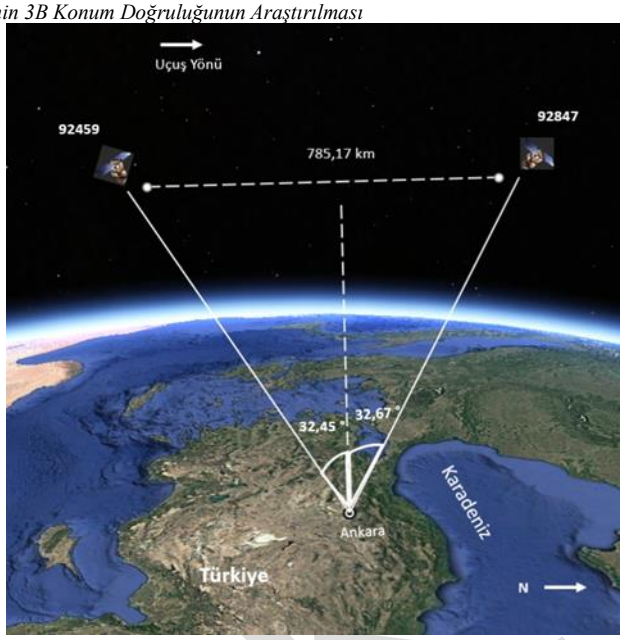


Görüntü çekim durumu

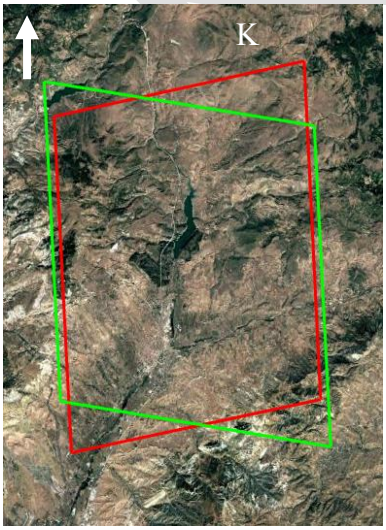


92459 ve 92847 numaralı görüntü sınırları

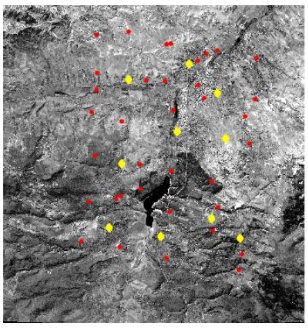

92459'da nokta dağılımı

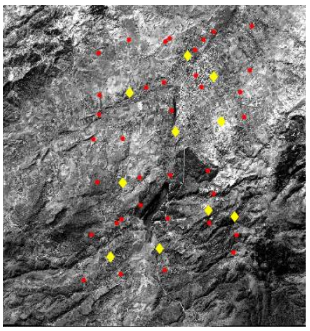

92847'de nokta dağılımı

**Şekil 1.** Görüntü çekimi, kapladıkları alanlar ve nokta dağılımı. #YKN(·): 39, #DN (◊): 10

**TARTIŞMA**

Bu bildiride temel kısıtlar, HGM tarafından sağlanan noktaların fotogrametrik çalışmalar için üretilmiş olmasından kaynaklanmaktadır. Zira noktaların Göktürk-1 görüntülerindeki dağılımı sınırlı bir bölgede kalmış; ayrıca bazı noktalar, uydu görüntülerinde tespiti zor olan kaya vb. yapılarda tesis edilmiştir. Bununla birlikte, ağırlıklı dengeleme hesabı için yer koordinatlarının doğruluk değerlerine de gereksinim vardır.

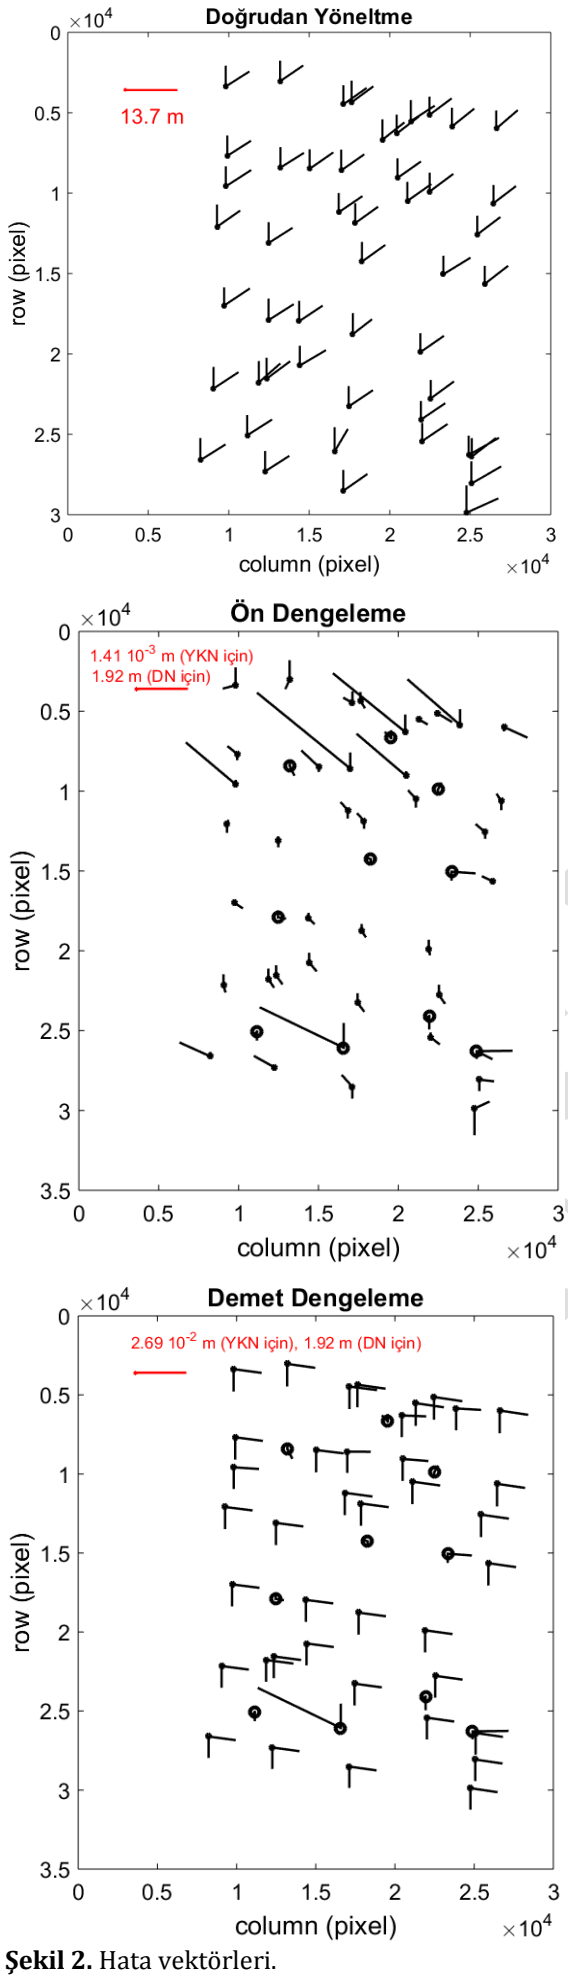


**Şekil 2.** Hata vektörleri.

## SONUÇ

Algılayıcıya bağımlı yöneltme yöntemiyle gerçekleştirilen doğruluk araştırmaları sadece incelenen görüntülerin 3B konum doğruluğunu değil, günümüzde yüksek çözünürlüklü uydu görüntülerinin koordinatlandırılmasında yaygın olarak kullanılan RFM (Rational Function Model – Rasyonel İşlev Modeli) için gerekli olan RPC'lerin (Rational Polynomial Coefficients – Rasyonel Polinom Katsayıları) hesaplanması, ortogörüntü ve sayısal yüzey modeli üretimi ile görüntüleme sisteminin iç yöneltme (doğrusal dizinin yerleşimi, odak uzaklığı vb.) ve dış yöneltme (uydu konumu, yönelimi vb.) ögelerinin doğruluk sonuçları üzerindeki anlamlılıkları da belirlenebilir. Hedeflenen doğruluğa ulaşmada bu ögelerin etkisi belirlenerek uydu tasarımları (kullanılacak cihazların doğrulukları ve hassasiyetleri) belirlenebilir.

Bu bildiride değerlendirilen Göktürk-1 bindirmeli pankromatik seviye 2A görüntülerinin konuma bağlı uygulamalarda kullanılabilmesi için mevcut nokta dağılımı ve seçiminin uygunluğu temelinde bir araştırma gerçekleştirilmiştir. Araştırma sonucunda, HGM'ye yeni bir nokta takımı önerisi yapılması gerektiği ortaya çıkmıştır.

## TEŞEKKÜR

Yazarlar, Göktürk-1 görüntüleri ve nokta tesisleri için Harita Genel Müdürlüğüne teşekkür eder.

### Yazar Katkı Oranı

Hüseyin Topan: Geo3o1'in geliştirilmesi, yöntem, genel metin yazımı ve gözden geçirilmesi.
Onur Erişik: Nokta seçimi, genel metin yazımı ve gözden geçirilmesi.
Murat Oruç: Nokta seçimi, genel metin yazımı ve gözden geçirilmesi.

### Çıkar Çatışması/Çakışması

Yazarlar arasında herhangi bir çıkar çatışması ve çakışması bulunmamaktadır.

### Araştırma ve Yayın Etiği Beyanı

Bu çalışma birinci yazarın yüksek lisans tezinden üretilmiştir. Araştırma için etik kurul iznine gereksinim bulunmamaktadır.

## KAYNAKÇA

Airbus Defence and Space. (2012). *Pléiades Imagery User Guide* (V 2.0 ed.).

Airbus Defence and Space. (2013). *SPOT 6 & SPOT 7 Imagery User Guide* (SI/DC/13034-v1.0 ed.).

Aytekin, G. (2023). *Algılayıcıya Bağımlı Yöneltme Modeli İle Üçlü Bindirmeli Görüntülerin Konum Doğruluğunun Belirlenmesi (Georeferencing Accuracy Assessment of Tri-Stereo Satellite Images by Sensor Dependent Orientation Model).* (PhD), Zonguldak Bülent Ecevit University, Zonguldak. Tez database.

Aytekin, G., & Topan, H. (2022a). *Göktürk-1 Uydu Görüntülerinin Konum Doğruluğunun Algılayıcıya Bağımlı Yöneltme Modeli ile Belirlenmesi*. Paper presented at the XI. Türkiye

Ulusal Fotogrametri ve Uzaktan Algılama Birliği (TUFUAB) Teknik Sempozyumu, Mersin, Türkiye.

Aytekin, G., & Topan, H. (2022b). Üçlü Bindirmeli Göktürk-1 Uydu Görüntülerinin Konum Doğruluğunun Zonguldak Test Alanında Algılayıcıya Bağımlı Yöneltme Modeli ile Belirlenmesi. *Harita Dergisi, 168*, 13-27.

Aytekin, G., & Topan, H. (2024). Unlocking the 3D Georeferencing Accuracy Potential of Göktürk-1 Tri-Stereo Panchromatic Level 2A Images by Sensor-Dependent Orientation Model. *Proceedings of the Romanian Academy, Series A, 25*(4/2024), 347–358. doi: 10.59277/PRA-SER.A.25.4.11

Riazanoff, S. (2004). *SPOT 123-4-5 Geometry Handbook*. (GAEL-P135-DOC-001, Issue 1 Revision 4). France: Spot Image.

Terlemezoğlu, B. (2019). *Optik Uydu Görüntülerinin Yöneltmesinde Oluşan Kötü Şartlı Matrislerin İyileştirilmesi (Regularization of the Ill-Conditioned Matrix Arising in Orientation of Optical Spaceborne Images).* (PhD), Zonguldak Bülent Ecevit University, Zonguldak. Retrieved from https://tez.yok.gov.tr/UlusalTezMerkezi/TezGoster?key=as2oTjW5jfr9IKSvmCdJYtEb-CaJtFhMOOoUmLsWkBSE9rnMF9uih_Um-TtKwkmh Tez database.

Topan, H. (2009). *Geometric Analysis of High Resolution Space Images Using Parametric Approaches Considering Satellite Orbital Parameters.* (PhD), Istanbul Technical University, İstanbul.

Topan, H., & Maktav, D. (2014). Efficiency of Orientation Parameters on Georeferencing Accuracy of SPOT-5 HRG Level-1A Stereoimages. *IEEE Transactions on Geoscience and Remote Sensing, 52*(6), 3683-3694. doi: 10.1007/s12524-013-0273-4

Wolf, P. R., & Dewitt, B. A. (2000). *Elements of Photogrammetry: with Applications in GIS* (3rd ed.): McGraw-Hill.



© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TASLAK

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Dijital İkiz Üretiminde Filtreleme, Obje Tespiti ve 3B Modelleme

**Yiğitcan Cığır[1], Berkay Serhan Selvi[1], Feridun Tolga Solak[1], Umut Yusuf Kınacı[1], Melih Altay[1], Berk Anbaroğlu[1]**

[1]*Hacettepe Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Ankara, Türkiye*

**Anahtar Kelimeler**
Dijital İkiz, Nokta Bulutu, Gürültü Azaltma, İç Mekân Haritalama, Alan Hesabı, Nesne Tespiti

**ÖZET**

Bu çalışma, iç mekânların dijital ikiz modellerinin oluşturulmasında karşılaşılan temel zorlukları ele almakta ve bu zorluklara yönelik sistematik bir çözüm yaklaşımı sunmaktadır. İç mekân haritalama süreçlerinde, dış ortamlara kıyasla daha yoğun gürültü barındıran nokta bulutu verileri, doğru alan hesaplamaları ve nesne tanımlama için önemli engeller oluşturmaktadır. Bu araştırmada, el tipi GeoSLAM ZEB LiDAR cihazı ile toplanan nokta bulutu verilerinin işlenmesi için çok aşamalı bir yöntem geliştirilmiştir. Gürültü azaltımı için z-score analizi ve yoğunluk tabanlı HDBSCAN (Hierarchical Density-Based Spatial Clustering of Applications with Noise) algoritmaları birlikte kullanılarak hibrit bir filtreleme yaklaşımı uygulanmış ve veri kalitesinde %42,96 oranında iyileşme sağlanmıştır. Alan hesaplamalarında, Delaunay üçgenleme ve Shapely kütüphanesi karşılaştırmalı olarak değerlendirilmiş; Delaunay üçgenleme yöntemiyle %96,31 doğruluk oranına ulaşılırken, Shapely ile bu oran %62,05'te kalmıştır. Çalışma ayrıca iç mekân yüzeylerinin tespiti ve oda sınırlarının otomatik belirlenmesi için konumsal kümeleme yöntemlerini de içermektedir. Önerilen DBSCAN tabanlı nesne tanımlama yaklaşımı, masa gibi belirgin nesnelerin tespitinde başarılı sonuçlar verirken, pencere gibi karmaşık geometrik yapıların tanımlanmasında yetersiz kalmıştır. Bu çalışma, özellikle bina yönetimi, iç mekân navigasyonu ve enerji verimliliği uygulamaları için güvenilir dijital ikiz modellerinin oluşturulmasında önemli bir katkı sunmaktadır. Araştırma sürecinde geliştirilen algoritmalar ve iş akışı, iç mekân dijital ikiz üretiminde manuel müdahale gereksinimini azaltarak, daha hızlı ve ölçeklenebilir çözümler sunmaktadır.

# Filtering, Object Detection and 3D Modeling in Digital Twin Production

**Keywords**
Digital Twin, Point Cloud, Noise Reduction, Indoor Mapping, Area Calculation, Object Detection

**ABSTRACT**

This study addresses key challenges in creating digital twin models of indoor spaces and presents a systematic approach to overcome these obstacles. In indoor mapping processes, point cloud data containing higher noise levels compared to outdoor environments poses significant barriers to accurate area calculations and object identification. In this research, a multi-phase methodology was developed for processing point cloud data collected with a handheld GeoSLAM ZEB LiDAR device. A hybrid filtering approach was implemented by combining z-score analysis and density-based HDBSCAN (Hierarchical Density-Based Spatial Clustering of Applications with Noise) algorithms for noise reduction, resulting in a 42.96% improvement in data quality. For area calculations, Delaunay triangulation and the Shapely library were comparatively evaluated; the Delaunay triangulation method achieved 96.31% accuracy, while Shapely remained at 62.05%. The study also incorporates spatial clustering methods for detecting indoor surfaces and automatically determining room boundaries. The proposed DBSCAN-based object identification approach yielded successful results in detecting distinct objects like tables but proved insufficient in identifying complex geometric structures such as windows. This research makes a significant contribution to creating reliable digital twin models particularly for building management, indoor navigation, and energy efficiency applications. The algorithms and workflow developed during the research process provide faster and more scalable solutions by reducing the need for manual intervention in indoor digital twin production.

## GİRİŞ

Dijital ikiz teknolojisi, günümüzde fiziksel varlıkların dijital ortamlarda gerçeğe uygun biçimde modellenmesini sağlayan ve birçok mühendislik alanına yeni ufuklar açan bir yaklaşım olarak öne çıkmaktadır. Özellikle bina yönetimi, enerji verimliliği, güvenlik analizi ve iç mekân yönlendirme sistemlerinde dijital ikizler, karar verme süreçlerini destekleyen temel araçlar haline gelmiştir (Qi vd., 2021; Jones vd., 2020). Ancak, iç mekânların modellenmesi süreci, dış ortamlara kıyasla daha fazla teknik zorluk içermektedir. Bu zorluklar arasında yüksek veri gürültüsü, düşük sinyal-gürültü oranı (SNR), karmaşık geometrik yapılar ve manuel işlem gerekliliği sayılabilir (Li vd., 2023; Shahzad vd., 2022).

İç mekân dijital ikizleri, akıllı binalar kavramının merkezinde yer almakta ve yapıların yaşam döngüsü boyunca karşılaşacağı sorunları öngörmek, enerji tüketimini azaltmak ve kullanıcı konforunu artırmak gibi birçok amaç için kullanılmaktadır (Shao vd., 2021; Bagherieh vd., 2024). Son yıllarda, Bina Bilgi Modellemesi (BIM) ve nokta bulutu verilerinin entegrasyonu ile oluşturulan dijital ikizler, özellikle mevcut yapıların modellenmesinde yaygın olarak kullanılmaya başlanmıştır (Huang vd., 2022). Bu entegrasyon, inşaat sektöründe sürdürülebilirlik ve verimlilik artışı sağlamaktadır (Wang & Cho, 2022).

Bu araştırma, iç mekân dijital ikiz üretimindeki temel zorluklara odaklanarak, nokta bulutu verisinin işlenmesi, gürültü azaltımı ve doğru alan hesaplamaları için sistematik bir yaklaşım geliştirmeyi amaçlamaktadır. Çalışmada, el tipi LiDAR cihazı ile toplanan veriler, z-score analizi ve HDBSCAN algoritması kombinasyonu ile filtrelenerek gürültüden arındırılmış, ardından Delaunay üçgenleme yöntemi ile alan hesaplamaları gerçekleştirilmiştir. Bu süreçte, hem veri kalitesinde hem de alan doğruluğunda önemli iyileştirmeler elde edilmiştir.

Literatürde, iç mekân modelleme çalışmaları genellikle görüntü tabanlı teknikler veya lazer tarama yöntemlerine odaklanmaktadır (Khoshelham & Elberink, 2012; Maboudi vd., 2021). Ancak, bu çalışmaların çoğu, veri gürültüsü ve alan hesaplamaları konusunda bütünleşik bir yaklaşım sunmamaktadır. Lee ve arkadaşları (2022), nokta bulutu verilerinden oda sınırlarının çıkarılması için hibrit bir yaklaşım önermiş, ancak gürültü azaltımı konusunda ayrıntılı bir inceleme sunmamıştır. Benzer şekilde, Zhang ve arkadaşları (2023), oda alanlarının hesaplanması için konveks zarf yöntemini kullanmış, ancak bu yaklaşımın karmaşık geometrilerde yetersiz kaldığını belirtmiştir.

Bu araştırma, hem gürültü azaltımı hem de alan hesaplamaları için optimize edilmiş bir iş akışı önererek literatürdeki bu boşluğu doldurmayı hedeflemektedir. Ayrıca, Chen ve arkadaşlarının (2021) vurguladığı gibi, iç mekân dijital ikizlerinin oluşturulmasında otomatik yöntemlerin geliştirilmesi, modelleme sürecini hızlandırmakta ve manuel müdahale gereksinimini azaltmaktadır.

Araştırmanın temel amacı, iç mekân dijital ikiz üretiminde manuel müdahale gereksinimini azaltacak ve model doğruluğunu artıracak otomatik yöntemler geliştirmektir. Bu bağlamda, çalışmada geliştirilen yaklaşımlar, Lin ve arkadaşlarının (2020) önerdiği otomatik segmentasyon yöntemlerini tamamlayıcı nitelikte olup, bina içi dijital modellerin oluşturulmasında daha hızlı, güvenilir ve ölçeklenebilir çözümler sunmaktadır. Özellikle Anbaroğlu ve Karabay'ın (2024) el tipi LiDAR veri setlerinde DBSCAN algoritması kullanarak iç mekân alan hesaplaması için geliştirdikleri tekrar üretilebilir yaklaşım, bu alandaki otomatik yöntemlere önemli katkı sağlamaktadır. Ayrıca, elde edilen dijital ikiz modelleri, sadece alan hesaplamaları veya nesne tespiti için değil, aynı zamanda Diakité ve Zlatanova'nın (2020) vurguladığı gibi, iç mekân navigasyonu gibi uygulamalar için de temel veri katmanını oluşturmaktadır.

## YÖNTEM

Bu araştırmada, iç mekân dijital ikiz üretimi için çok aşamalı bir metodoloji geliştirilmiştir. Veri toplama, ön işleme, gürültü azaltımı, alan hesaplamaları ve nesne tespiti aşamalarını içeren bu yaklaşım, iç mekân modellemede karşılaşılan temel zorluklara çözüm getirmeyi hedeflemektedir.

### Veri Toplama ve Ekipman

Çalışmada kullanılan veriler, GeoSLAM ZEB el tipi LiDAR cihazı ile toplanmıştır. Bu cihaz, Eş Zamanlı Konum Belirleme ve Haritalama (SLAM - Simultaneous Localization and Mapping) teknolojisini kullanarak, operatörün yürüyüşü sırasında iç mekânların 3B nokta bulutu verilerini oluşturmaktadır (Nikoohemat vd., 2020). SLAM teknolojisi, GPS sinyallerinin ulaşamadığı iç mekânlarda konum belirleme imkânı sağlamakta ve sensör konumunu sürekli güncelleyerek tutarlı bir haritalama gerçekleştirmektedir (Hess vd., 2016). Cihazın teknik özellikleri Çizelge 1'de verilmiştir.

**Çizelge 1.** GeoSLAM ZEB LiDAR Cihazı Teknik Özellikleri

| Özellik | Değer |
|---|---|
| Veri Toplama Hızı | 43,200 nokta/saniye |
| Mesafe | 0.5 m - 30 m (iç mekân) |
| Görüş Alanı | 270° x 360° |
| Tarama Doğruluğu | ±3 cm |
| Tarama Çözünürlüğü | 0.625° yatay, 1.8° dikey |
| Veri Çıktı Formatı | PLY, LAS, LAZ, E57 |

### Veri Ön İşleme

Ham nokta bulutu verisi, Python programlama dili ve açık kaynaklı kütüphaneler kullanılarak işlenmiştir (Virtanen vd., 2020; Harris vd., 2020). Ön işleme aşamasında, veri bütünlüğü kontrolü yapılmış ve eksik veya hatalı noktalar belirlenmiştir. Nokta bulutu, LAS formatında Laspy kütüphanesi yardımıyla okunmuş ve NumPy dizileri olarak işlenmiştir (Van der Walt vd., 2011).

Veri ön işleme adımları şu şekilde sıralanabilir:

1. Veri okuma ve format dönüşümü
2. Koordinat sistemi kontrolü ve düzenleme
3. Nokta sayısı optimizasyonu ve veri boyutu analizi
4. Boşluk tespiti ve veri bütünlüğü kontrolü

Liu ve arkadaşları (2023), nokta bulutu verisinin ön işleme aşamasının, sonraki filtreleme ve segmentasyon işlemlerinin başarısını doğrudan etkilediğini vurgulamıştır. Bu nedenle, veri kalitesinin ve bütünlüğünün başlangıçta değerlendirilmesi kritik öneme sahiptir.

**Gürültü Azaltma**

Gürültü azaltımı için iki aşamalı bir yaklaşım uygulanmıştır. İlk aşamada, z-score analizi ile istatistiksel olarak aykırı noktalar tespit edilmiş ve filtrelenmiştir (Rousseeuw & Hubert, 2018). Z-score değeri, her noktanın yükseklik (Z) değerinin ortalamadan standart sapma cinsinden ne kadar uzakta olduğunu belirlemektedir. Z-score analizi için aşağıdaki formül kullanılmıştır:

$$\boldsymbol{Z = \sigma x - \mu}$$

**Alan Hesaplamaları**

Filtrelenmiş veriler üzerinden odalara ait alanlar Delaunay üçgenleme yöntemi ile hesaplanmıştır. Python'da oluşturulan çokgenler yardımıyla metre kare ($m^2$) cinsinden alanlar elde edilmiştir. Alan doğruluğu, referans ölçümler ile karşılaştırıldığında %96,31 seviyesine ulaşmıştır.

**Oda Yüzeyi ve Modeli Oluşturma**

Filtrelenmiş nokta bulutundan odalara ait sınırlar belirlendikten sonra, bu sınırlar kullanılarak yüzey poligonları oluşturulmuştur. Bu poligonlar birleştirilerek CityGML uyumlu modeller oluşturulmuştur. Elde edilen yüzey verileri, iç mekânların 3B plan görünümünü elde etmek ve dijital ikiz modelleme adımlarına temel teşkil etmek amacıyla kullanılmıştır.

**İç Mekân Yönlendirme**

Çalışmada geliştirilen dijital ikiz modelleri, iç mekân yönlendirme (indoor navigation) sistemleri için gerekli temel veri katmanını oluşturmaktadır. Bu kapsamda:

1. Odalar arası bağlantı noktalarının (kapılar) tespiti (Kim vd., 2021)
2. Geçiş alanlarının belirlenmesi (Diakité & Zlatanova, 2020)
3. Yol ağı (network) modelinin oluşturulması (Chen & Clarke, 2020)
4. İlgi noktalarının (POI - Points of Interest) belirlenmesi (Wu vd., 2022)

adımları gerçekleştirilmiştir. Bu sayede, bina içi yol bulma algoritmaları için gerekli topolojik ve geometrik altyapı hazırlanmıştır. Li ve arkadaşları (2023), dijital ikiz tabanlı iç mekân navigasyon sistemlerinin, kullanıcı konumlandırma doğruluğunu artırdığını ve acil durum tahliyelerinde kritik rol oynadığını vurgulamıştır.

**Nesne Tespiti**

Çalışma kapsamında nesne tespiti işlemleri, doğrudan nokta bulutu verisi üzerinde çalışan DBSCAN algoritması ile gerçekleştirilmiştir (Ester vd., 1996). Bu yaklaşım, özellikle belirli yükseklik aralıklarındaki nesnelerin (örneğin masalar) tespitinde etkili sonuçlar vermektedir.

DBSCAN algoritması için kullanılan parametreler:

- Epsilon (ε): 0.05 m (noktalar arası maksimum mesafe)
- MinPts: 30 (minimum nokta sayısı)

Nesne tespiti işlemi şu adımları içermektedir:

1. Yükseklik Tabanlı Ön İşleme**:** İlk olarak, nokta bulutundaki nesnelerin genellikle belli bir yükseklik aralığında yer aldığı göz önünde bulundurularak bu aralıklar filtrelenir. Bu filtreleme, yer yüzeyine ait zemin verilerinin elenmesini sağlar ve yalnızca belirli yükseklikteki nesnelerin kalmasına olanak tanır (Tran vd., 2022)
2. DBSCAN ile Yoğunluk Tabanlı Kümeleme: Filtrelenmiş nokta bulutu verisine DBSCAN algoritması uygulanır. DBSCAN, yüksek yoğunlukta bulunan noktaları kümelerken, seyrek bölgeleri dışlar (Schubert vd., 2017). Böylece veri içindeki nesne benzeri yapılar ayrı kümeler hâlinde belirlenir.
3. Kümelerin Nesne Sınıflarına Atanması: Elde edilen kümeler, nesne özelliklerine göre sınıflandırılır. Bu işlemde, her küme geometrik şekline, hacmine, yüksekliğine veya nokta yoğunluğuna göre kategorilere ayrılır (Pomerleau vd., 2021). Bu sınıflandırma adımı, masa, sandalye gibi farklı nesne türlerinin ayrıştırılmasına olanak tanır.
4. Nesne Konum ve Boyutlarının Hesaplanması: Son adımda, her bir nesne kümesinin uzaydaki konumu (x, y, z koordinatları) ve boyutları (yükseklik, genişlik, derinlik) hesaplanır. Bu adım, tespit edilen nesnelerin haritalanması ve ölçülmesi için gereklidir (Wang vd., 2022).

Bu yaklaşım, derin öğrenme veya eğitimli modeller gerektirmeden, yalnızca geometrik yapı ve yoğunluk verilerine dayalı olarak nesne tespitini mümkün kılmaktadır. Zhou ve arkadaşları (2021), nokta bulutu verileri üzerinde geometri tabanlı nesne tespit yöntemlerinin, hesaplama maliyeti düşük ve hızlı sonuç veren çözümler sunduğunu belirtmiştir.

**BULGULAR**

Z-score analizi ve HDBSCAN algoritmasının birlikte kullanımı, nokta bulutu verisindeki gürültünün önemli ölçüde azaltılmasını sağlamıştır. Filtreleme öncesi ve sonrası nokta sayıları Çizelge 2'de karşılaştırılmıştır.

**Çizelge 2.** Gürültü Azaltımı Öncesi ve Sonrası Nokta Sayısı Karşılaştırması

| Veri Durumu | Nokta Sayısı | Azalma Oranı |
|---|---|---|
| Filtreleme Öncesi | 3.181.929 | - |
| Filtreleme Sonrası | 1.815.058 | %42,96 |

Filtreleme işlemi sonucunda, toplam nokta sayısında %42,96 oranında azalma sağlanmıştır. Bu azalma, özellikle yapı dışındaki gürültü noktalarının ve iç mekândaki aykırı değerlerin başarılı bir şekilde elimine edildiğini göstermektedir. Şekil 1'de filtreleme öncesi ve sonrası nokta bulutu görselleştirmeleri karşılaştırmalı olarak sunulmuştur. Görselleştirmeler, gürültü azaltımının veri kalitesine olan olumlu etkisini açıkça ortaya koymaktadır.

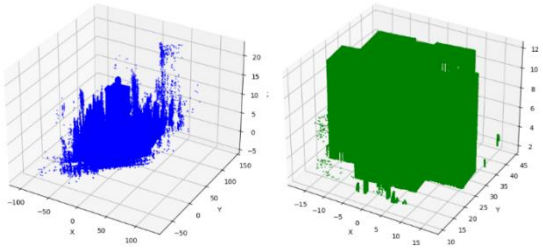

**Şekil 1.** Filtreleme öncesi ve sonrası nokta bulutu karşılaştırması.

Alan hesaplamaları Delaunay üçgenleme yöntemiyle yapılmış, referans alanlar ile karşılaştırıldığında bazı odalarda %96,31'e varan doğruluk seviyelerine ulaşılmıştır. Ancak farklı bir algoritma olan Shapely ile bu doğruluk seviyesi %62.05'e kadar düşmüştür. Bu durum, sınır belirlemenin ve doğru filtrasyonun alan doğruluğu üzerindeki etkisini ortaya koymuştur.

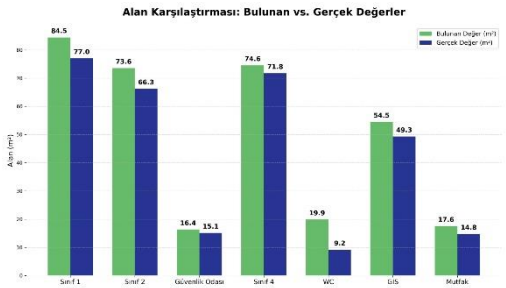


**Şekil 2.** Oda Bazlı Alan Karşılaştırması: Hesaplama Sonucu ile Mimari Proje $m^2$ Karşılaştırması

Buna ek olarak, obje tespiti amacıyla masa gibi iç mekân nesneleri DBSCAN algoritması kullanılarak ayrıştırılmıştır. Nokta bulutunun yükseklik değerleri analiz edilmiş, belirli yükseklik aralığındaki kümeler başarılı şekilde izole edilmiştir. Farklı odalarda yapılan uygulamalarda toplam 17 masa tespit edilmiş, gerçek değerlere göre doğruluk oranı %94.20 olarak hesaplanmıştır. Şekil 3'te oda nokta bulutu, Şekil 4'te ise tespit edilen masalardan biri örnek olarak sunulmuştur.

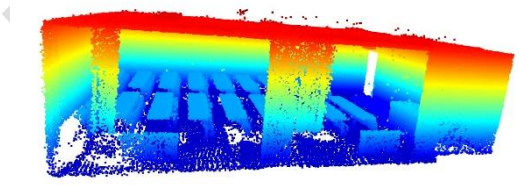

**Şekil 3.** Obje tespiti için kullanılan örnek oda nokta bulutu.

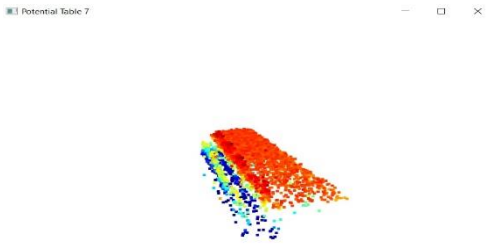


**Şekil 4.** Elde edilen örnek masa nokta bulutu.

**Çizelge 3.** Masa Tespiti Sonuç Özeti

| **Oda No** | **Tespit Edilen Masa** | **Gerçek Masa Sayısı** |
|---|---|---|
| Derslik 1 | 16 | 17 |
| Derslik 2 | 14 | 15 |
| Derslik 3 | 14 | 15 |
| Derslik 4 | 16 | 17 |
| CBS Laboratuvarı | 1 | 1 |
| **Toplam** | 61 | 65 |

Son olarak, gürültüden arındırılmış ve analiz edilmiş nokta bulutu verileri kullanılarak bazı iç mekânlara ait CityGML uyumlu üç boyutlu oda modelleri oluşturulmuştur. Oda yüzeylerinin nokta bulutunun sınırları yardımıyla elde edilen üçgen yüzeyler, kapalı hacimlerin temsilini sağlamış ve dijital ikiz modellemeye temel oluşturmuştur. Şekil 5'te bu modellerden biri örnek olarak sunulmuştur.

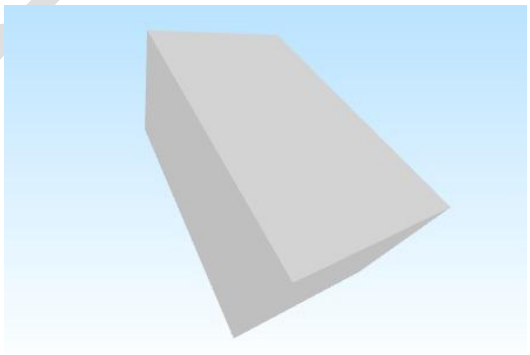

**Şekil 5.** Nokta bulutu verisinden elde edilen örnek oda modeli.

## TARTIŞMA

Bu çalışmada, iç mekânlara ait dijital ikiz üretiminde kullanılan veri işleme algoritmaları ile önemli ölçüde başarı sağlanmıştır. Z-score analizi ve HDBSCAN algoritması birlikte kullanıldığında, nokta bulutu verisinin kalitesi anlamlı şekilde artmıştır. Bu durum, hem daha doğru alan hesaplamalarına hem de daha temiz bir veri kümesine ulaşılmasına olanak sağlamıştır. %42,96 oranında gürültü azaltımı sayesinde veri sadeliği artmış, Delaunay üçgenleme ile yapılan alan hesaplamalarında %96.31 doğruluk oranına ulaşılmıştır.

Ancak farklı bir yöntem olan Shapely'de (%62.05 doğruluk), yapı sınırlarının manuel çizilmesi ve zemin-topoğrafya karmaşası gibi faktörler algoritmanın performansını düşürmüştür. Bu, nokta yoğunluğunun

düşük olduğu alanlarda algoritmaların verimli çalışamadığını göstermektedir.

Pencere tespiti sürecinde kullanılan komşuluk analizine dayalı yöntem, uygulamada yetersiz kalmış ve işlevsel doğruluk istenen seviyeye ulaşamamıştır. Bu durum, pencere gibi karmaşık nesnelerin tespiti için daha sofistike yöntemlere, örneğin makine öğrenmesine dayalı yaklaşımlara ihtiyaç olduğunu ortaya koymaktadır.Ayrıca, mevcut veri iş akışı hâlâ sınırlı düzeyde manuel müdahale gerektirmektedir. Bu durum, iç mekân dijital ikiz üretimi sürecinin tamamen otomatikleştirilmesi yönünde gelişime açık bir alan olduğunu göstermektedir.

Genel olarak, bu proje gürültü azaltımı ve alan hesaplama süreçlerinde başarılı sonuçlar vermiştir. Ancak işlevsel detay tespiti ve tam otomasyon hedefleri için daha gelişmiş yöntemlerin entegrasyonu gerekmektedir. Çalışma doğrudan bir navigasyon sistemi geliştirmese de, elde edilen katmanlar ve modellenen yüzeyler, bina içi yönlendirme uygulamalarına temel oluşturabilecek düzeydedir. Özellikle kat planlarının otomatik çıkarımı ve oda bağlantılarının net olarak belirlenmesi, yönlendirme sistemleri açısından büyük avantaj sunmaktadır.

DBSCAN algoritması ile gerçekleştirilen obje tespiti, düşük hesaplama maliyeti ve model bağımsız yapısı sayesinde başarılı bir örnek oluşturmuştur. Özellikle masa gibi belirgin nesneler yüksek doğrulukla ayrıştırılabilmiş; ancak pencere gibi yüzey ağırlıklı veya kenar tanımlı objelerde bu başarı düşmüştür.

## SONUÇ

Bu çalışmada, iç mekânlara yönelik dijital ikiz üretimi sürecinde karşılaşılan temel zorluklara çözüm getirecek bir yöntem önerilmiştir. Gürültü azaltımı için z-score analizi ve HDBSCAN algoritması birlikte kullanılmış; alan hesaplamaları ise Delaunay üçgenleme yöntemi ile gerçekleştirilmiştir. Elde edilen sonuçlar, nokta bulutu verisinin kalitesinde %42,96 oranında iyileşme ve alan hesaplamalarında %96.31 doğruluk gibi önemli kazanımlar ortaya koymuştur. Ayrıca, odalara ait yüzeylerin nokta bulutundan elde edilmesiyle modelleme sürecinin temel bileşeni başarıyla tamamlanmıştır.

Projenin çıktıları, bina yönetimi, enerji verimliliği ve iç mekân yönlendirme gibi uygulamalarda kullanılabilecek güvenilir dijital ikiz modellerinin üretimine olanak sağlamaktadır. Ancak pencere tespiti gibi detay analizlerinde istenilen doğruluk sağlanamamış, bu da daha gelişmiş tekniklerin kullanılmasının gerekliliğini göstermiştir.

Derin öğrenmeye gerek duymadan, yalnızca yoğunluk ve yükseklik analizine dayalı DBSCAN + Laspy tabanlı obje tespiti yöntemi, masa gibi nesneler üzerinde başarılı sonuçlar vermiştir. Bu yaklaşım, donanım bağımsız ve hızlı iç mekân analizlerine olanak sağlamaktadır.

Oluşturulan dijital ikiz verisi, sadece analiz amaçlı değil, aynı zamanda kapalı alan navigasyon sistemlerinin altyapısını oluşturma potansiyeliyle de değerlendirilebilir. Bu yönüyle çalışma, akıllı bina sistemlerine geçişte önemli bir veri kaynağıdır.

Gelecekte, yapay zekâ tabanlı sınıflandırma yöntemlerinin entegrasyonu ve manuel iş yükünü zaltacak otomatik segmentasyon sistemleri üzerine çalışılması önerilmektedir. Bu sayede, iç mekân dijital ikizlerinin üretimi daha hızlı, doğru ve ölçeklenebilir hale gelebilecektir.

## TEŞEKKÜR

Bu çalışma, **TÜBİTAK 2209-A Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı** kapsamında desteklenmiştir.

### Yazar Katkı Oranı

**Berkay Serhan Selvi:** ConvexHull Algoritması kullanarak yüzey belirleme, modelleme, rapor ve sunum içeriklerinin oluşturulması. **Feridun Tolga Solak:** DBSCAN algoritmasının geliştirilmesi ve z-score analiz süreci. **Umut Yusuf Kınacı:** GeoSLAM ile veri toplama, veri organizasyonu, grafik ve sonuç görselleştirmeleri. **Yiğitcan Cığır:** HDBSCAN algoritasının geliştirilmesi, indoor navigation, alan hesaplama, gürültü temizliği, pencere tespiti algoritmalarının denenmesi. **Melih Altay:** Literatür taramasının yürütülmesi, makale taslağının oluşturulması, içerik düzenlemeleri ve bilimsel revizyonların gerçekleştirilmesi. **Berk Anbaroğlu:** İç mekân navigasyon sistemleri, alan hesaplaması ve gürültü azaltımı konularında metodolojik danışmanlık, LiDAR verisi ile ilgili yönlendirmeler.

Tüm yazarlar bildirinin tüm aşamalarında birlikte çalışmış ve eşit sorumluluk almıştır.

### Çıkar Çatışması/Çakışması

Yazarların bu çalışma kapsamında herhangi bir çıkar çatışması veya çakışması bulunmamaktadır.

### Araştırma ve Yayın Etiği Beyanı

Bu çalışma, bilimsel araştırma ve yayın etiğine uygun olarak yürütülmüştür. Herhangi bir etik ihlal bulunmamaktadır.

## KAYNAKÇA

Anbaroğlu, B., & Karabay, H. (2024). A reproducible approach to estimate indoor space area on a handheld LIDAR dataset using DBSCAN. 8th International Conference on GeoInformation Advances, GeoAdvances 2024, 48, 37-43.

Bagherieh, O., Chen, D., Jin, L., Gupta, D., & Zou, Y. (2024). Digital twins in the built environment: Definition, applications and challenges. ResearchGate.

Chen, J., & Clarke, K. C. (2020). Indoor cartography. Cartography and Geographic Information Science, 47(2), 95-109.

Chen, X., Li, H., Liu, L., Xu, G., & Shi, Z. (2021). Digital twin technologies for enhanced sustainability in the construction industry. ResearchGate.

Diakité, A. A., & Zlatanova, S. (2020). Automatic geo-referencing of BIM in GIS environments using building footprints. Computers, Environment and Urban Systems, 80, 101453.

Ester, M., Kriegel, H. P., Sander, J., & Xu, X. (1996). A density-based algorithm for discovering clusters in large spatial databases with noise. Proceedings of the 2nd International Conference on Knowledge Discovery and Data Mining, 226-231.

Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., ... & Oliphant, T. E. (2020). Array programming with NumPy. Nature, 585(7825), 357-362.

Hess, W., Kohler, D., Rapp, H., & Andor, D. (2016). Real-time loop closure in 2D LIDAR SLAM. 2016 IEEE International Conference on Robotics and Automation (ICRA), 1271-1278.

Huang, Q., Yang, X., & Li, S. (2022). Digital twins for construction assets using BIM standard specifications. ResearchGate.

Jones, D., Snider, C., Nassehi, A., Yon, J., & Hicks, B. (2020). Characterising the digital twin: A systematic literature review. CIRP Journal of Manufacturing Science and Technology, 29, 36-52.

Khoshelham, K., & Elberink, S. O. (2012). Accuracy and resolution of Kinect depth data for indoor mapping applications. Sensors, 12(2), 1437-1454.

Kim, J., Jung, J., & Heo, J. (2021). Automatic generation of indoor networks for 3D indoor navigation using door detection from point cloud. Remote Sensing, 13(5), 1004.

Lee, J., Kim, Y., Hyun, S., & Ahn, J. (2022). Automatic extraction of room boundaries from point cloud data: A hybrid approach. Automation in Construction, 136, 104156.

Li, W., Wang, Z., & Liu, X. (2023). Digital twin technologies for smart building management. Energy Informatics.

Lin, Y., Jiang, M., Yao, Y., Zhang, L., & Lin, J. (2020). Use of UAV oblique imaging for the detection of individual trees in residential environments. Urban Forestry & Urban Greening, 49, 126784.

Liu, Q., Zhang, K., Wu, F., & Ding, X. (2023). A comprehensive review of digital twin: Modeling and twinning enabling technologies. arXiv.

Maboudi, M., Alamouri, A., & Gerke, M. (2021). Surface area estimation using 3D point clouds and Delaunay triangulation. ResearchGate.

Nikoohemat, S., Peter, M., Elberink, S. O., & Vosselman, G. (2020). Exploiting indoor mobile laser scanner trajectories for semantic interpretation of point clouds. ISPRS Journal of Photogrammetry and Remote Sensing, 162, 118-133.

Pomerleau, F., Colas, F., & Siegwart, R. (2021). A review of point cloud registration algorithms for mobile robotics. Foundations and Trends in Robotics, 4(1), 1-104.

Qi, Q., Tao, F., Hu, T., Anwer, N., Liu, A., Wei, Y., ... & Nee, A. Y. (2021). Enabling technologies and tools for digital twin. Journal of Manufacturing Systems, 58, 3-21.

Rousseeuw, P. J., & Hubert, M. (2018). Anomaly detection by robust statistics. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 8(2), e1236.

Schubert, E., Sander, J., Ester, M., Kriegel, H. P., & Xu, X. (2017). DBSCAN revisited, revisited: Why and how you should (still) use DBSCAN. ACM Transactions on Database Systems, 42(3), 1-21.

Shahzad, M., Shafiq, Z., & Douglas, D. (2022). From LiDAR point cloud towards digital twin city: Clustering city objects based on Gestalt principles. ResearchGate.

Shao, G., Mi, L., Qiao, F., Helu, M., & Gupta, S. K. (2021). Digital twin for smart manufacturing: The state of the art and future trends. Procedia Manufacturing, 55, 343-348.

Tran, T. T., Cao, V. T., & Laurendeau, D. (2022). Performance comparisons for Python libraries in parallel computing and physical simulation. ResearchGate.

Van der Walt, S., Colbert, S. C., & Varoquaux, G. (2011). The NumPy array: A structure for efficient numerical computation. Computing in Science & Engineering, 13(2), 22-30.

Virtanen, P., Gommers, R., Oliphant, T. E., Haberland, M., Reddy, T., Cournapeau, D., ... & SciPy 1.0 Contributors. (2020). SciPy 1.0: Fundamental algorithms for scientific computing in Python. Nature Methods, 17(3), 261-272.

Wang, J., & Cho, Y. K. (2022). Construction of indoor physical environment based on digital twin. IEEE Xplore.

Wang, Y., Chen, Q., Zhu, Q., Liu, L., Li, C., & Zheng, D. (2022). A survey on real-time 3D reconstruction with RGB-D cameras. Sensors, 22(3), 1148.

Wu, H., Chen, A., & Zhang, L. (2022). Indoor navigation and positioning: A review of approaches and challenges. Sensors, 22(4), 1532.

Zhang, J., Kan, C., Schwartz, A. G., & Wang, Y. (2023). Automatic 3D reconstruction of indoor scenes from point clouds and images: A comprehensive review. Remote Sensing, 15(2), 456.

Zhou, Y., Tuzel, O., & Sankaranarayanan, A. C. (2021). Object detection in point clouds: A review. IEEE Transactions on Pattern Analysis and Machine Intelligence, 44(10), 6729-6751.

© Yazarlar 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

TUFUAB XIII. TEKNİK SEMPOZYUMU
https://tufuab2025.beun.edu.tr

# Gemi Batıklarının Batimetri Tekniği ile Bulunması; Arvin Gemisi Örneği

**Kurtuluş Sedar Görmüş*[1], Şevki Ünal[2]**

[1]*Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Zonguldak, Türkiye*
[2]*Ünal Harita, Zonguldak, Türkiye*

**Anahtar Kelimeler**
Batimetri,
Çok bimli,
GNSS,
İskandil

**ÖZET**

Dünyadaki ticaret hacmi gün geçtikçe artmaktadır. Bu ticareti hızlı ve güvenilir bir şekilde ulaştırmak için deniz taşımacılığı kullanılır. Günümüzde bu transferin % 90'ından fazlası deniz seyrüseferi ile yapılmaktadır. Deniz seferlerinin artmasına paralel olarak deniz kazalarında da artış yaşanmaktadır. Deniz kazaları, yaşam kaybına, gemi ve sair değerlerin zarara uğramasına ve deniz kirliliğine yol açmaktadır. Çalışmaya konu olan Palau bandıralı Arvin gemisi Bartın ili Güzelcehisar açıklarında kötü hava koşulları sebebi ile batmıştır. Batan geminin lokasyonunun belirlenebilmesi için jeodezik yöntemler kullanılmıştır.

Deniz dibi topografyasının en net şekilde ortaya çıkartılabilmesi için günümüzde akustik iskandil yöntemi kullanılmaktadır. Akustik iskandil yönteminin en gelişmiş versiyonu olan Çok bimli sistemler ile dip topografyası çok detaylı olarak belirlenebilmektedir. Bu çalışmada Arvin gemisinin batığını bulmak için çok bimli sistemler kullanılmıştır. Ayrıca batimetrik gözlemler sonucunda geminin batış senaryosu belirlenmeye çalışılmıştır. Çalışma bölgesinde insansız hava aracı uçurularak gemi batarken denize sızıntı olup olmadığı da belirlenmiştir.

# Identifying Ship Wrecks with Bathymetry Technique; Arvin Ship Example

**Keywords**

Bathymetry,
Multibeam,
GNSS,
Echosounder

**ABSTRACT**

The volume of trade in the world is increasing day by day. Maritime transport is used to transport this trade quickly and reliably. Today, more than 90% of this transfer is made by maritime navigation. In parallel with the increase in maritime voyages, there is also an increase in maritime accidents. Maritime accidents lead to loss of life, damage to ships and other assets, and marine pollution. The Palau-flagged Arvin ship, which is the subject of the study, sank off the coast of Güzelcehisar, Bartın due to bad weather conditions. Geodetic methods were used to determine the location of the sunken ship.

The acoustic echo sounding method is used today to reveal the seabed topography in the clearest way. The bottom topography can be determined in great detail with the most advanced version of the acoustic echo sounding method, the multi-beam systems. In this study, multi-beam systems were used to find the wreck of the Arvin ship. In addition, the sinking scenario of the ship was tried to be determined as a result of bathymetric observations. An unmanned aerial vehicle was flown in the study area to determine whether there was any leakage into the sea while the ship was sinking.

## GİRİŞ

Denizyolu taşımacılığı sağladığı avantajlar nedeniyle kargoculuk yöntemleri arasında dünya ticaretinde büyük paya sahiptir. Bu sayede büyük miktardaki yükler bir yerden bir yere ekonomik ve güvenli bir şekilde taşınabilmektedir. Büyük yüklerin daha kolay taşınması ekonomik anlamda büyük avantajlar sağlarken, konuyu güvenlik ve emniyet açısından da ele almak gerekmektedir.

Uluslararası Denizcilik Örgütü (International Maritime Organisation-IMO) deniz kazalarını önlemek üzere bir takım çalışmalar yapmış ve halen yapmaya devam etmektedir. Ayrıca idareler de denizde emniyeti sağlamaya yönelik yeni yasal düzenlemeler getirmektedir. Tüm bu uğraşlara

rağmen kazaların önüne geçmek mümkün olmamıştır (Wang, Pillay, Kwon, Wall ve Loughran, 2013; Chauvin, Lardjane, Morel, Clostermann ve Langardve, 2013; Chen, Wall, Davies, Yang, Wang ve Chou, 2013; Batalden ve Sydnes, 2014; Uğurlu, Yıldırım, Başar, 2015).

Çalışmaya konu olan Arvin gemisi, 17 Ocak 2021 tarihinde Gürcistan'ın Poti Limanı'ndan Bulgaristan'a giderken fırtınaya yakalanmış ve Bartın limanına sığınmak isterken kırılarak batmıştır. Kaza sonucunda gemideki 1'i Rus, 5'i Ukrayna vatandaşı toplam 6 mürettebat kurtarılırken, 6 kişi de hayatını kaybetmiştir İTU DEFAMED, (2021).




**Şekil 1.** 114 Metrelik Arvin Gemisi İTU DEFAMED, (2021).

Batan geminin teknik özellikleri aşağıda özetlenmiştir.

**Çizelge1.** Arvin teknik Özellikleri.

| | |
|---|---|
| Yapım Yılı | 1975 |
| IMO | 8874316 |
| MMSI | 511315000 |
| Çağrı İşareti | T8A2278 |
| Bayrak | PALAU (PW) |
| Brüt Tonaj | 2516 GRT |
| DWT | 3509 t |
| Draft | 3.8 m |

Gemi batığının bulunması, batma senaryosunun belirlenmesi ve olası çevre kirliliğinin araştırılması amacı ile 23/01/2021 tarihinde Filyos Limanına kayıtlı Albatros3 Survey teknesi ile akustik iskandil yöntemi kullanılarak deniz dibi topografyası ölçülmüş, batık geminin üç boyutlu modeli çıkarılmıştır. Batık konumları, hangar kapakları yerleri bulunarak batış senaryosu üretilmiştir. Ölçümler sırasında insansız hava aracı ile bölgenin görüntüleri çekilmiş ve denize sızıntı olup olmadığı belirlenmiştir.

**YÖNTEM**

Deniz tabanı topografyasını belirleme amaçlı yapılan derinlik ölçme ve haritalama çalışmaları batimetri olarak isimlendirilmektedir (Serbest C., 2021) . Geçmişten günümüze batimetri teknikleri büyük gelişim göstermiştir. Geçmişten günümüze bakıldığında; ip iskandil, lata iskandil, tel iskandil gibi klasik yöntemler ile başlayan süreç günümüzde; sonar, lidar, uydu görüntüleri gibi modern yöntemlere kadar uzanmıştır (Sağdıç, A., 2020).

Özellikle 1950'lerin ortalarından itibaren tek bimli akustik iskandil yöntemleri geliştirilmiş ve bu gelişim çok bimli sistemlerin önünü açmıştır.

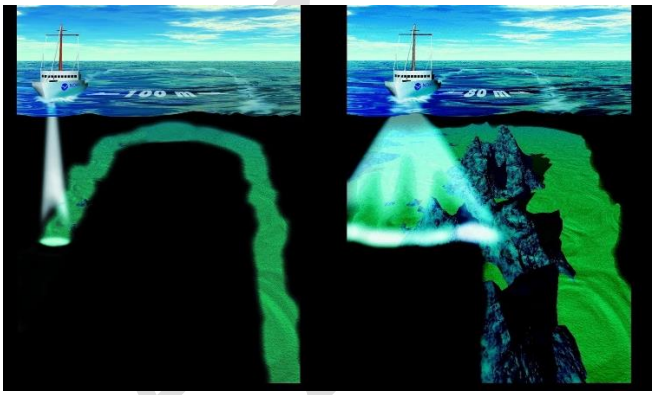

**Şekil 2.** Tek Bimli ve Çok Bimli İskandil Yöntemleri (Yılmaz, E., 2022).

Tek bimli islandil ile yapılan ölçmelerde, deniz tabanına ait daha az sayıda derinlik verisi toplanmaktadır. Ölçme hatları arasında bulunan boşluklar çeşitli enterpolasyon yöntemleri kullanılarak modellendirilir. Çok bimli iskandil yönteminde ise çoklu paralel ışınlar üreterek çok daha yüksek yoğunlukta veri kümesi elde edilebilir.

**BULGULAR**

Batimetri çalışmalarında planlama çok önemlidir. Denizin dalgalı olması durumunda batimetri teknesi yeterince stabil hareket edemeyeceğinden dolayı toplanan verinin kalite ve doğruluğu bu durumdan olumsuz etkilenir. Arazi çalışmalarından önce ölçme günü, yüzey rüzgarı ve dalga yüksekliği ve yönü açısından etüt edilmelidir.

Ölçümün yapıldığı gün önceden tahmin haritalarına bakılarak belirlenmiştir.

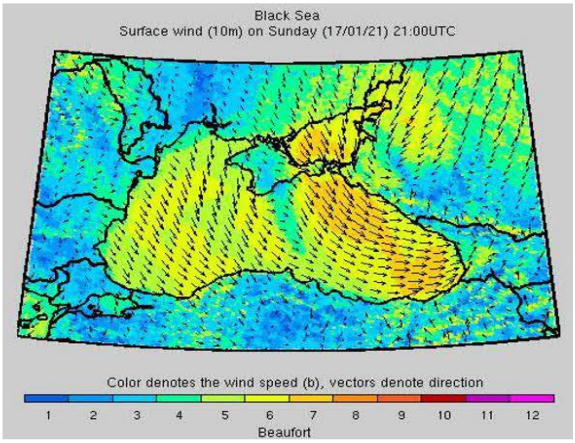


**Şekil 3.** Yüzey Rüzgârı Tahmin Haritası.

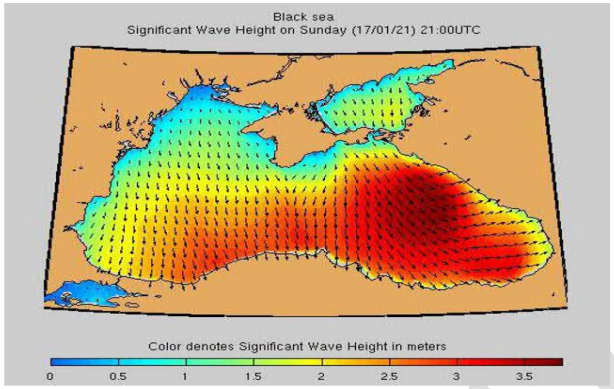


**Şekil 3.** Dalga Yüksekliği ve Yönü Tahmin Haritası.

Yapılan ilk ölçümlerde 114 m uzunluğundaki Arvin gemisinin iki parçaya ayrıldığı, pruva (Baş) ve pupa (Kıç) kısımları arasında 272 m mesafe olduğu tespit edilmiştir.




**Şekil 4.** Arvin Gemisi Batık Belirleme Haritası.

ARVİN gemisinin Pruva kısmının karadan 860 m uzaklıkta, Pupa kısmının karadan 675 m uzaklıkta ve aşağıdaki koordinatlarda olduğu belirlenmiştir.

**Çizelge2.** Arvin Gemisi Batık Koordinatları.

| Bölüm | Enlem | Boylam |
|---|---|---|
| Pruva | 41$^0$39′39.74″ K | 32$^0$′11'26.25"D |
| Pupa | 41$^0$39′30.37″ K | 32$^0$′11'21.03"D |

Geminin pupa kısmı 65 m uzunluğunda olduğu kısımdan kırıldığı, konumsal olarak güney Doğu / Kuzey Batı yönünde 343$^0$ de -17m derinlikte yattığı tespit edilmiştir. Ayrıca geminin dört ambar kapağından ikisinin bu parçada olduğu ve ambarların boşaldığı tespit edilmiştir.

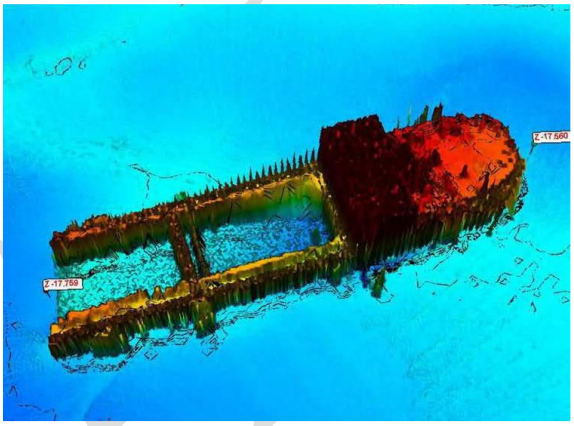

**Şekil 5.** Arvin Batığı Pupa Kısmı.

Geminin pruva kısmı 49 m uzunluğunda olduğu kısımdan kırıldığı, Güney Batı / Kuzey Doğu yönünde 559 de 20 5 m derinlikte yattığı ve Pruva kısmının batarken ters döndüğü ve bu kısımda bulunan diğer iki ambar kapağının açıldığı, ambarların konumlarının aşağı yönde olduğu tespit edilmiştir.

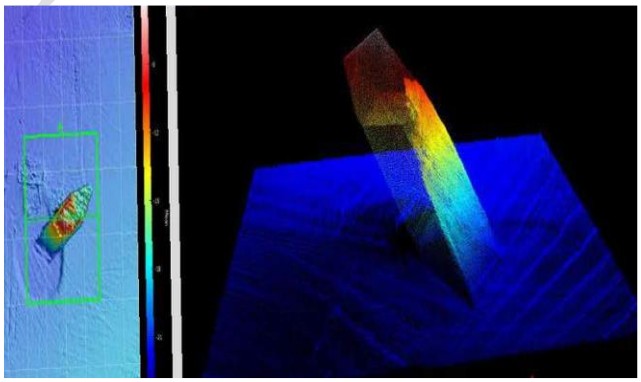

**Şekil 6.** Arvin Batığı Pruva Kısmı.

Yapılan ölçmeler sonucunda geminin dört ambar kapağının lokasyonu da belirlenmiştir

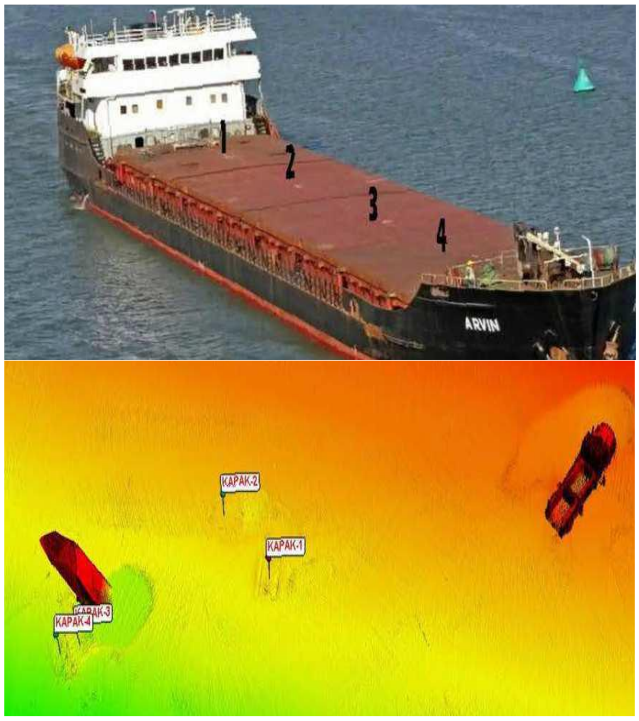


**Şekil 7.** Arvin Batığı Ambar Kapakları Konumları.

Yapılan batimetrik ölçümler sonucunda Arvin batığına ait 1/1000 ölçekli batimetrik harita üretilmiştir.

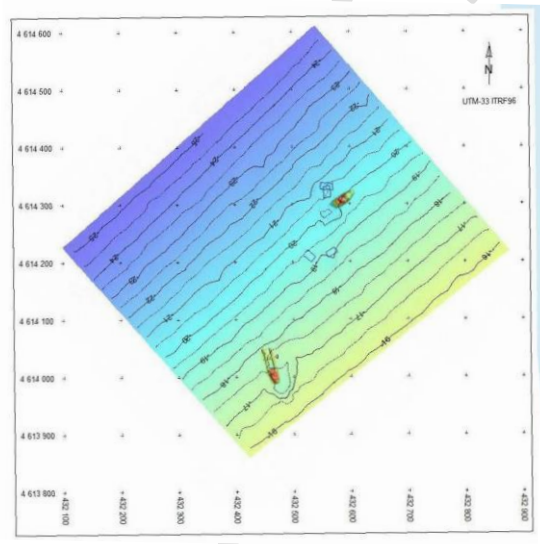

**Şekil 7.** Arvin Batığı 1/1000 Ölçekli Batimetri Haritası.

**Arvin Gemisi Batma Senaryosu ve Sızıntı Analizi**

Geminin battığı gün çevredeki gemilerden çekilen videolardan ve survey ölçümü sonrası bulunan ambar kapaklarının konumlarından anlaşıldığı üzere;

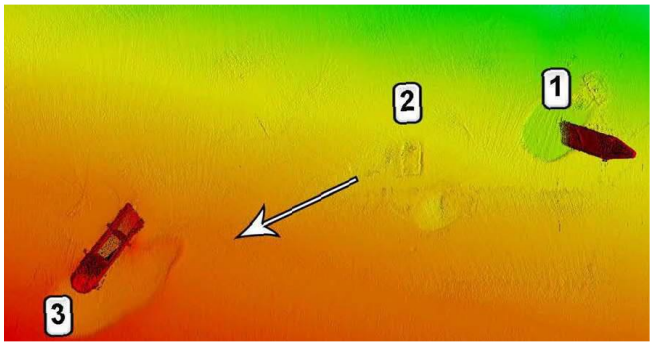


**Şekil 8.** Arvin Batığı Batma Senaryosu Haritası.

- 1 ve 2 numaralı noktaların arasında gemi ikiye ayrılmıştır,
- 1 numaralı noktada geminin pruva kısmı ters dönerek zemine oturmuştur,
- 1 numaralı noktada ters dönen pruva kısmında bulunan 2 adet ambar kapağı üst üste düşerek deniz tabanına oturmuştur,
- 2 numaralı noktada geminin pupa kısmı ters dönmüştür,
- 2 numaralı noktada geminin pupa kısmında bulunan 2 adet ambar kapağı deniz tabanına oturmuştur,
- 2 numaralı noktada ters dönen pupa kısmı ambar kapaklarının düşmesi, ambarların boşalması ve dalga hareketi ile ok yönünde hareket ederek 3 numaralı noktada zemine gemi köprü üste gelecek şekilde tekrar dönerek deniz tabanına oturmuştur.

Batimetrik ölçmeler devam edilirken insansız hava aracı ile batık bölgesinde görüntüler alınmış ve yapılan inceleme sonucunda geminin baş ve kıç kısımlarında yoğun olmayan miktarda yakıt ve yağ sızıntısı tespit edilmiştir.



**Şekil 9.** Arvin Batığı Sızıntı Tespiti.

**SONUÇ**

Klasik anlamda bakıldığında günümüzde batimetri tekniği; liman, marina, tersane yapımı gibi çalışmalarda, köprü, köprüyol yapımı, deniz dibinden geçen petrol ve doğalgaz boru hattı gibi ulaştırma ve altyapı çalışmalarında, kıyı erozyonu takibi, dalgakıran yapımı gibi çevresel konularda sıklıkla kullanılmaktadır.

Bu çalışmada batimetrik ölçümler ile alışılmışın dışında deniz kazalarının belirlenmesinde kullanılmıştır.

Bu bağlamda batimetri tekniğinin en gelişmiş versiyonu olan çok bimli akustik iskandil tekniği tercih edilmiştir. Bu sayede batık bölgesinin çok detaylı batimetrik haritası oluşturulmuş ve batış senaryosu üretilebilmiştir.

Yazarlar deniz dibine ait detay çıkarımı yapılması gerektiğinde tek bimli sistemler yerine detay çıkarımında en üstün yöntem olan çok bimli sistemlerin kullanılması gerektiğini önermektedir.

**TEŞEKKÜR**
Proje/makale/yazar için destek teşekkürleri bu bölümde verilmelidir.

**Yazar Katkı Oranı**

Yazarların makaleye katkıları belirtilmelidir.

**Çıkar Çatışması/Çakışması**

Yazarlar arasında herhangi bir çıkar çatışması/çakışması bulunup bulunmadığı belirtilmelidir.

**Araştırma ve Yayın Etiği Beyanı**

Çalışmanın araştırma ve yayın etiği hakkında varsa açıklanması gereken bilgiler bu bölümde verilmelidir.

**KAYNAKÇA**
Tüm kaynaklar alfabetik sıraya göre yazılmalıdır. Referanslar arasına boş satır koymayınız.

**Makale**

Batalden, B., M. ve Sydnes, A. K., (2014). Maritime safety and the ISM code: a study of investigated casualties and incidents. WMU Journal of Maritime Affairs, 13, 3–25.

Chauvin, C., Lardjane S., Morel G., Clostermann J., P. ve Langard, B., (2013). Human and organisational factors in maritime accidents: Analysis of collisions at sea using the HFACS. Accident Analysis and Prevention, 59, 26– 37.

Chen, S. T., Wall, A., Davies, P., Yang, Z., Wang, J. ve Chou, Y., H., (2013). A Human and Organisational Factors (HOFs) analysis method for marine casualties using HFACS Maritime Accidents (HFACS-MA). Safety Science, 60, 105–114.

Uğurlu, Ö., Yıldırım, U. ve Başar, E., (2015). Analysis of Grounding Accidents Caused by Human Error. Journal of Marine Science and Technology, 23, 5, 748-760.

Wang, J., Pillay, A., Kwon, Y., Wall, A. ve Loughran, C., (2005). An Analysis of Fishing Vessel Accidents. Accident Analysis & Prevention, 37, 6, 1019-1024.

**Tez**

Sağdıç, A. (2020). İnsansız Su Üstü Aracı Ve Uzaktan Algılama Teknikleri Kullanarak Batimetrik Harita Üretimi: Filyos Limanı Örneği. (Yüksek Lisans Tezi), Zonguldak Bülent Ecevit Üniversitesi, Zonguldak.

Serbest, C. (2021). Katamarana Entegre Tek Işınlı Akustik İskandil Yöntemi İle Doğruluk Araştırması. (Yüksek Lisans Tezi), Zonguldak Bülent Ecevit Üniversitesi, Zonguldak.

Yılmaz, E. (2022). Akustik İskandil Ve Uydu Görüntüleriyle Batimetri Haritası Üretimi: Sinop Hurmadibi Örneği. (Yüksek Lisans Tezi), Samsun Ondokuz Mayıs Üniversitesi, Samsun

**İnternet adresi**

İTU DEFAMED, (2021). Denizcilik Dergisi [Erişim tarihi: 10.05.2025], https://www.denizcilikdergisi.com/denizcilik-gundem-haberleri/114-metrelik-arvin-boyle-batti

© Yazar(lar) 2025.
Bu çalışma https://creativecommons.org/licenses/by-sa/4.0 altında dağıtılmaktadır.

# TUFUAB XIII. Teknik Sempozyumu

## Düzenleyenler

## Ana Sponsor

## Platin Sponsor

## Altın Sponsor

## Gümüş Sponsor

## Sponsorlar

## Destekleyenler

tufuab2025.beun.edu.tr – 18-20 Haziran 2025 - Zonguldak