Optik Uydu Görüntü Sınıflandırması için Python Tabanlı Bir Araç Kutusu

Özgün Akçay[1, *]

[1]Çanakkale Onsekiz Mart Universitesi, Mühedislik Fakültesi, Harita Mühendisliği Bölümü, Çanakkale

Özet

Günümüzde birçok çok-spektrumlu optik uzaktan algılama görüntüleri arazi kullanımı tespiti, şehir planlama, çevresel izleme vb. uygulamalarda kullanılmaktadır. Bu uygulamaları gerçekleştirmek için en önemli süreçlerden birisi görüntülerin istatiksel analize dayalı sınıflandırılmasıdır. Günümüz sınıflandırma yazılımları büyük boyutlu olmaları nedeniyle, kurulum ve analiz aşamalarında uzun çalışma süreleri gerektirmektedir. Bu çalışmanın amacı SNAP, QGIS gibi diğer yazılımlara bir alternatif olarak uzaktan algılama görüntülerini hızlı biçimde analiz edebilen, esnek bir komut satırlı araç kutusu geliştirmektir. Bu amaçla, bilimsel veri işleme için günümüz bilimsel hesaplamalı programlama dilleri arasında öne çıkan Python dilinde, Sentinel-2 uydu görüntülerine dayalı kontrollü sınıflandırma ve doğruluk analizini gerçekleştiren Python Sınıflandırma Araç Kutusu (PySA) (Python Classification Toolbox - PyCT) geliştirilmiştir. PySA, Python'a ait mekansal raster ve vektör verileri destekleyen, makine öğrenmesini ve görselleştirmeyi gerçekleştiren farklı kütüphaneler kullanılarak kodlanmıştır. PySA ile yapılan k-En Yakın Komşu kontrollü sınıflandırma uygulaması ile bantlar arasındaki ilişkileri ortaya koyan grafikler üretilmiş, eğitim veri setine bağlı model sonucu tahminlere dayalı hata matrisleri oluşturulmuştur. Sınıflandırma sonucu doğrulama veri seti için genel doğruluk değeri %96.4, test veri seti için genel doğruluk değeri %70.6 elde edilmiştir. Doğruluk denetlemesi sonrası, PySA tarafından çalışma bölgesine ait altı kategoriden oluşan tematik arazi kullanımı haritası başarı ile üretilmiştir.

Anahtar Sözcükler: Uzaktan Algılama, Sınıflandırma, Uydu Görüntüsü, Makine Öğrenmesi, Python Programlama

A Python Based Toolbox for Optical Satellite Image Classification

Abstract

Nowadays many multi-spectral optical remote sensing images are used in land use detection, urban planning, environmental monitoring, etc. applications. One of the most important processes to realize these applications is the classification of images based on statistical analysis. Due to the large size of today's classification software, they require long working times in the installation and analysis stages. The aim of this study is to develop a flexible command line toolbox that can quickly analyze remote sensing images as an alternative to other software such as SNAP, QGIS. For this purpose, Python Classification Toolbox (PyCT), which performs supervised classification and accuracy analysis based on Sentinel-2 satellite images, has been developed in Python language, which stands out among today's scientific computational programming languages for scientific data processing. PyCT is coded using Python's different libraries that support spatial raster and vector data, perform machine learning and visualization. With the k-Nearest Neighbor supervised classification application performed with PyCT, graphs showing the relationships between the bands were produced, and confusion matrices based on predictions were created as a result of the model based on training data set. As a result of the classification, the general accuracy value was 96.4% for the verification data set, and the overall accuracy value was 70.6% for the test data set. After the accuracy inspection, the thematic land use map consisting of six categories of the study area was successfully produced by PyCT.

Keywords: Remote Sensing, Classification, Satellite Image, Machine Learning, Python Programming

1. Giriş

Bilimsel ve teknolojik gelişmelere paralel olarak Uzaktan Algılama ve Coğrafi Bilgi Sistemleri (CBS) kapsamında yazılım geliştirme ihtiyacı günümüzde de artarak devam etmektedir. Özellikle Uzaktan Algılama'da kullanılan daha yüksek çözünürlüklü geometrik, radyometrik ve zamansal hava fotoğrafları ve uydu görüntülerinin hızlı bir şekilde yüksek doğrulukla analizi önemli bir problem teşkil etmektedir. Bu konuda geliştirilen birçok ücretli ve ücretsiz paket program ve bu paket programlar dışında çok özel ihtiyaca yönelik geliştirilmiş araç kutuları mevcuttur. Bu yazılımlarının geliştirilebilir ortamları göz önüne alındığında son dönemde veri biliminde öne çıkan Python programlama dili öne çıkmaktadır (Lutz 2001). Python programlama dilinin kodlama basitliği, çok boyutlu dizilere yönelik hesaplama fonksiyonlarının yaygın olması, zengin kütüphaneleri tercih sebeplerinden bazıları olarak ifade edilebilir.

Birçok uydu görüntü değerlendirmesinin, CBS analizlerinin ihtiyacı olan veriyi sağlamak amacıyla yapılması nedeniyle görüntü işleme içeren bazı çözümler CBS ağırlıklı yazılımlar içerisinde ele alınmıştır. Rahmati vd. (2019) yaptığı çalışmada, Python programlama dili kullanılarak otomatik, kullanıcı dostu bir CBS tabanlı eksik örneklerinin seçimi isimli bir araç geliştirilmiştir. Bu araçta, en yakın komşu ve sıcak nokta analizleri dâhil olmak üzere farklı geo-mekânsal kavramları ele almıştır. QGIS ve GRASS GIS gibi programlar da Python ile geliştirilen araç kutuları ile CBS çalışmalarında ihtiyaç duyulan karmaşık mekânsal işleme ve optimize edilmiş sonuçların sunumuna olanak sağlamaktadır (Lacaze vd. 2018). Xiu ve Yang (2018) ArcGIS platformunun Python ara yüzüne dayanan piksellerin birleştirme

* Sorumlu Yazar: Tel: (0286) 218 0018 Dahili: 20020 E-posta: akcay@comu.edu.tr

yöntemini kullanılarak, uzaktan algılama görüntülerinin mozaiğini elde etmiştir. Görüntü işleme yazılımı ile yapılan karşılaştırmada, bu yöntemin işlem süresini kısalttığı ve verimliliğini artırdığı görülmüştür.

Özellikle uydu görüntülerini işlemeye yönelik geliştirilmiş paketler de günümüz teknolojisinde yer almaktadır. Uzaktan Algılama uydu görüntülerinin en önemli işleme araçlarından bir tanesi SNAP yazılımıdır. ESA, Sentinel-1, Sentinel-2 ve Sentinel-3 görevlerinin bilimsel kullanımı için üç açık kaynaklı araç kutusu sunmaktadır (Zuhlke vd. 2015). Raspaud vd. (2018) yerüyüzü gözlem uydu verilerinin işlenmesini ve verimli paylaşımını kolaylaştırmak için açık kaynaklı, kullanımı kolay PyTroll paketini geliştirmiştir. Uydu bilgilerini hızlı bir şekilde üretebilen ve uluslararası işbirliğini teşvik eden bu yazılımı, hem 7/24 gerçek zamanlı operasyonlar hem de araştırma ve geliştirme için tasarlanmıştır. Uydu görüntülerini ele alan diğer bir çalışmada, Serbin ve Green (2018) İrlanda için bir uzaktan algılama veri kitaplığı sağlamak için açık kaynaklı Python modülünü geliştirmiştir. Bu modül, yüzey yansımasına göre düzeltilmiş Landsat TM / ETM+ / OLI / TIRS verilerini destekleyebilmektedir. Soares vd. (2020) ise zaman serisi özelliklerinin çıkarılmasını sağlayan bir Python paketi olan Stmetrics'i tasarlamıştır. Bu özellikler, Uzaktan Algılama zaman serisi görüntü sınıflandırması ve analizi için kullanılmaktadır.

Görüntü analizine dayalı geo-mekânsal yazılım geliştirme preziyonlu tarım ve ormancılık alanında da yer almaktadır. Chen ve Zhang (2020) hava görüntülerinde tarımsal ürünlerin fenotipine dayalı segmentasyonu ve noktasal tespitini otomatik olarak gerçekleştiren Python paketi GRID (GReenfield Image Decoder)'i geliştirmiştir. GRID ile kullanıcılar, çizim çizgilerini veya çokgenleri manuel olarak çizme gibi yoğun emek gerektiren iş yükünü tamamen otomatize etmeyi başararak tarımsal alan deneylerinin verimliliğini artırmayı hedeflemiştir. Diğer bir çalışmada, Karasiak (2020) geliştirdiği Museo isimli Python aracı ile alan çıkarımı, çapraz doğrulama ile bir model üretimi ve Normalize Edilmiş Bitki Örtüsü ve diğer spektral indekslerin hesaplanması gibi farklı süreçleri basitleştirmeyi amaçlamıştır. Weinstein vd. (2020) ise ormanlık alanların hava görüntüleri ile analiz edilmesi için derin öğrenmeyi kullanarak yüksek çözünürlüklü RGB görüntülerde tek tek ağaçları algılayan yeni bir Python paketi olan DeepForest'i geliştirmiştir.

Son yıllarda ortaya çıkan ve özellikle küresel ölçekte projelerde tercih edilen diğer bir yeni teknoloji ise Google Earth Engine (GEE) dir. GEE, ormansızlaşma, kuraklık, afet, hastalık, gıda güvenliği, su yönetimi, iklim izleme ve çevresel koruma konularında çalışmaya imkân veren bulut tabanlı bir platformdur (Gorelick vd. 2017). Kullanıcılar, Python ve JavaScript için görüntü ve geo-mekânsal nesne içeren kütüphaneleri kullanarak Earth Engine programları yazabilmektedir. GEE, JavaScript API'nin kapsamlı dokümantasyonu ve etkileşimli ara yüzü ile karşılaştırıldığında GEE Python API, etkin dokümantasyondan ve etkileşimli sonuç görselleştirmesi için yeterli işlevselliğe sahip olmadığı görülmektedir. Wu (2020) geliştirdiği Geemap Python paketi ile Python API işlevselliğini arttırmaya çalışmıştır.

Arazi kullanımı çalışmalarında gerekli olan sınıflandırmada Python araçları ile programlama önemli bir çözüm olmuştur. Jasim vd. (2019) yaptığı çalışmada diğer programlara ek olarak yapay sinir ağı algoritmasını Python kullanarak gerekli tematik harita başarı ile üretmiştir. Günümüz sınıflandırma yazılımları büyük boyutlu olmaları nedeniyle, kurulum ve analiz aşamalarında uzun çalışma süreleri gerektirmektedir. Bu çalışmanın amacı SNAP, QGIS gibi diğer yazılımlara bir alternatif olarak uzaktan algılama görüntülerini hızlı biçimde analiz edebilen, esnek bir komut satırlı araç kutusu geliştirmektir. Bu amaçla, bilimsel veri işleme için günümüz bilimsel hesaplamalı programlama dilleri arasında öne çıkan Python dilinde, Sentinel-2 uydu görüntülerine dayalı kontrollü sınıflandırma ve doğruluk analizini gerçekleştiren Python Sınıflandırma Araç Kutusu (PySA) (Python Classification Toolbox - PyCT) geliştirilmiştir.

2. Metot

Bu çalışmada uygulamayı geliştirme aşamasında farklı kütüphaneler kullanılmıştır. Bu kütüphanelerin bazıları hesaplama ve makine öğrenmesi algoritmaları için kullanılırken, bazıları görüntü okuma, işleme, geo-referanslandırma gibi ihtiyaçları karşılamaktadır. Geliştirilen kodlar içerisinde yer alan bazı önemli paketler ve bu paketlerin kullanım amaçları Tablo 1'de görüldüğü gibi açıklanmıştır.

Tablo 1. Uygulamada kullanılan Python kütüphaneleri

Paket adı	**Açıklaması**
rasterio	Uydu görüntüleri veri kümelerini düzenler, depolar ve numpy n-boyutlu dizilere dönüştürür.
fiona	Çok katmanlı GIS formatlarını kullanarak geo-referanslı verileri okuyabilir ve yazabilir.
pycrs	Çeşitli koordinat referans sistemi (CRS) arasında okuma, yazma ve dönüştürme yapar.
numpy	Çok boyutlu dizileri destekleyen bilimsel hesaplama paketidir.
matplotlib	Grafik çizim ve görselleştirme paketidir.
sklearn	İstatistiksel tahminlere dayalı makine öğrenmesi algoritmalarını çalıştırır ve analiz eder.
pandas	Tablosal veri düzenleme ve analiz aracıdır.
seaborn	İstatistiksel veri görselleştirme kütüphanesidir.
PIL	Görüntü okuma, yazma ve işleme aracıdır.

Yukarıda Tablo 1'de bahsedilen Python paketleri ile uyumlu sınıflandırma için yeni bir algoritma geliştirilmiştir (Şekil 1). Algoritma incelendiğinde, öncelikle, JPEG2000 (jp2) formatında bantlara ait görüntü verilerinin ve ESRI shape file (shp) formatında eğitim/test poligonlarının okutularak girdilerin sağlandığı görülmektedir. Daha sonra sınıf sayısına bağlı olarak oluşturulan döngü ile her bir sınıf için eğitim ve test verilerinin kesilerek oluşturulması ve raster verilerinin sayısal matrislere dönüştürülmesi gerçekleştirilmektedir. Döngü sonrası matris formunda elde edilen eğitim ve test verilerine etiket bilgisi eklenmesi sağlanmaktadır. Ayrıca tüm bantların piksel değerleri arasında skaler uyumu sağlamak için normalizasyon işlemi gerçekleştirilmiştir. Bu işlem tüm veri setlerinin piksel değerlerinin 0-1 aralığında yer alacak şekilde yeniden değerlemesi yöntemiyle elde edilmiştir. Bir sonraki adımda, kullanıcının belirleyeceği oran ile girdi verisi eğitim ve doğrulama seti olmak üzere rastlantısal olarak ikiye ayrılır. Bu oranın varsayılan değeri %80 eğitim ve %20 doğrulama verisi olarak belirlenmiştir. Veriler hazırlandıktan sonra eğitimli sınıflandırma yöntemi k-En Yakın Komşuluk (kNN) ile modellenmiştir (Upadhyay vd. 2016). Model sonucu doğrulama verilerinin tahminine dayalı hata matrisi ve doğruluk sonuçları hesaplanmaktadır. Daha sonra eğitim ve doğrulama verilerinden tamamen bağımsız, test verileri tahmin edilerek hata matrisi oluşturulmaktadır.

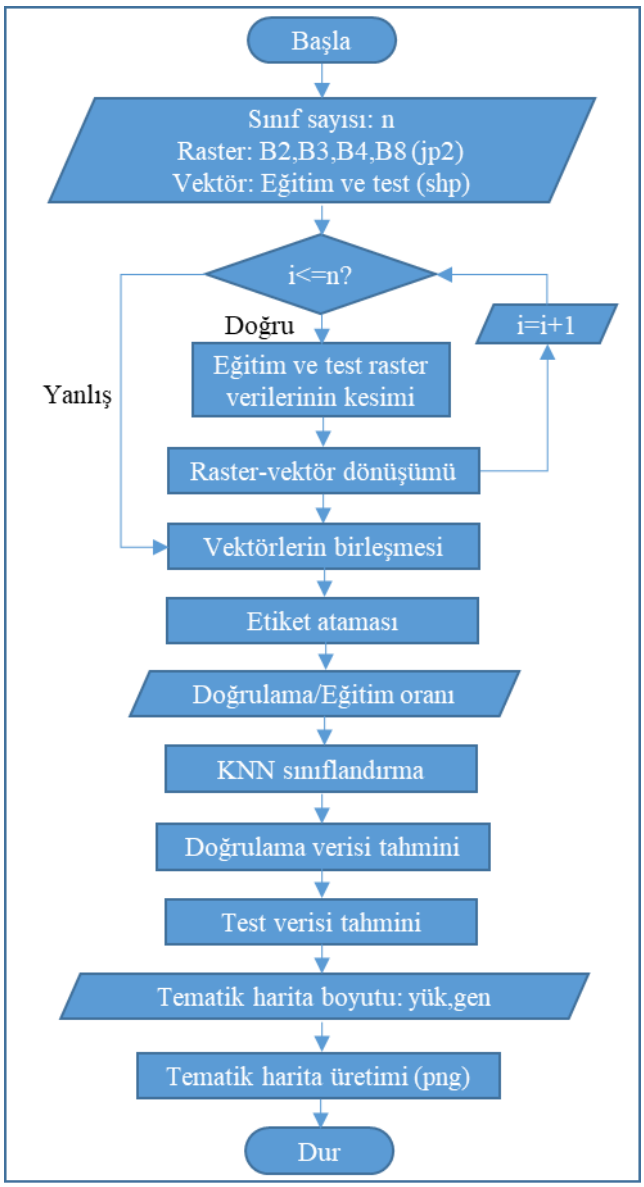

Şekil 1. Geliştirilen algoritma

Kullanıcı, doğruluk değerlerini analiz ettikten sonra yeterli doğruluk değerlerine ulaşılması durumunda tüm görüntünün istenilen dörtgen bölgesine ait tematik haritayı üretebilmektedir. Üretilecek bölgenin dörtgen sınırları ise kullanıcının görüntünün yükseklik ve genişlik boyutlarına bağlı piksel koordinatlarını sırasıyla girmesiyle belirlenir. Arazi kullanımını gösteren tematik harita, kabul edilen sınıflandırma modeline dayalı tahminler ile oluşturulduktan sonra görselleştirme amaçlı png formatında görüntü dosyası üretilerek çalışma klasörüne kaydedilmektedir. Şekil 1 de yer alan

algoritma tümüyle Tablo 1'de yer alan kütüphanelere dayalı olarak Python 3 programlama dilinde kodlanarak oluşturulmuştur.

3. Uygulama ve Tartışma

Bu çalışmada Çanakkale bölgesine ait 24 Ekim 2020 tarihinde çekilen Avrupa Uzay Ajansına ait Sentinel-2 uydu görüntüsü kullanılmıştır. Bu uygulamada yüksek çözünürlüklü bantlar B2, B3, B4 ve B8'e ait jp2 uzantılı dosyalar ele alınmıştır. Daha sonra arazi kullanımı için toplam altı temel sınıf sırasıyla şu şekilde belirlenmiştir: Yerleşim, su, orman, boş arazi, ekili tarım alanı, toprak tarım alanı. Öncelikle görüntü üzerinde altı sınıfa ait eğitim ve test alanları Şekil 2'de görüldüğü gibi ayrı ayrı belirlenerek shp dosyaları üretilmiş ve kaydedilmiştir.



Şekil 2. a. Eğitim alanları b. Test alanları

Gidi verileri oluşturulduktan sonra geliştirilen yazılım ile öncelikle eğitim ve test alanları için raster veriler görsel olarak elde edilmiştir. Şekil 3 de yerleşim alanları için oluşturulan eğitim verilerinin faklı bantlar için görüntüleri görülmektedir. Bu görüntü setleri yazılım tarafından ayrıca gerekli hesaplamalar için sayısal formatta lineer vektörlere dönüştürülmektedir. Tüm sınıflara ait vektörlere uygulanan normalizasyon ve birleştirme işlemi ile eğitim ve test matrisleri elde edilir. Aynı pikseller için Tablo 2 normalizasyon öncesi, Tablo 3 ise normalizasyon sonrası bant değerlerinden bir kesit göstermektedir. Matrisler oluşturulduktan sonra her bir satıra sınıfa aitliğini ifade eden etiket verisi eklenir.

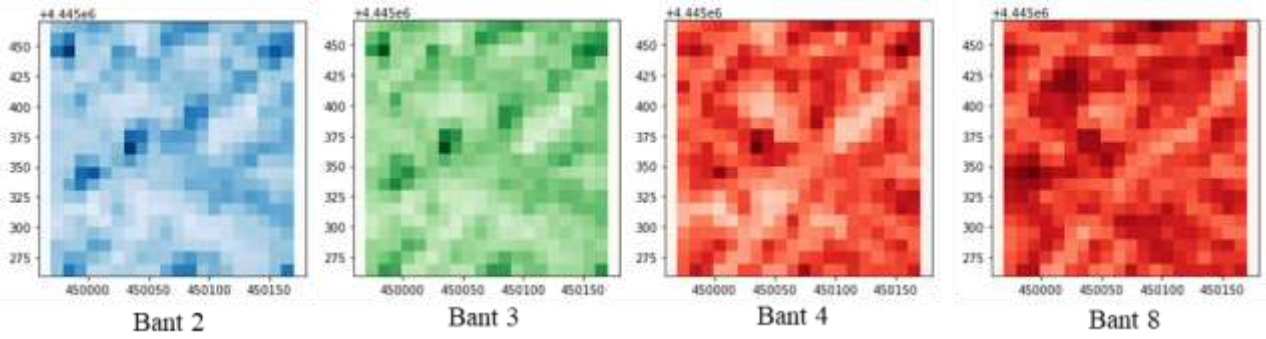

Şekil 3. Yerleşim sınıfına ait oluşturulan eğitim veri setleri

Tablo 2. Normalizasyon öncesi görüntü matrisi

Piksel no	B2	B3	B4	B8
1	988	1050	1470	1802
2	1128	1318	1594	1898
3	1220	1500	1888	2288
4	1438	1690	2076	2632
5	1312	1540	1946	2648
6	1007	1308	1500	2292
7	583	866	822	2372

Tablo 3. Normalizasyon sonrası görüntü matrisi

Piksel no	B2	B3	B4	B8
1	0.322005	0.305644	0.45266	0.453666
2	0.381478	0.400781	0.494145	0.479452
3	0.420561	0.465389	0.592506	0.584206
4	0.513169	0.532836	0.655403	0.676605
5	0.459643	0.479588	0.61191	0.680902
6	0.330076	0.397231	0.462697	0.585281
7	0.149958	0.240327	0.235865	0.606769

Eğitim sonucu oluşan modele dayalı doğrulama verilerinden üretilen tahmin sonuçları ile hata matrisi geliştirilen araç tarafından üretilmiştir. Buna göre komut satırında Şekil 4'te görüldüğü gibi ekran çıktısı elde edilmiştir. Buradaki sonuçlar her sınıf için doğru ve hatalı atamaları göstermektedir. Hata matrisinde yer alan satırlar yukarıda ifade edilen sınıf isimlerinin sırasına göre temsil edilmektedir. Ayrıca genel doğruluk değerleri, prezisyon, duyarlılık ve f1-skoru sonuçları görülebilmektedir. Bu sonuçlara göre genel doğruluk %96.41 olarak hesaplanmıştır.

```
0.9641148325358851
[[73  0  0  3  2  6]
 [ 0 72  0  0  0  0]
 [ 1  0 92  0  0  0]
 [ 0  0  0 50  0  0]
 [ 1  0  0  0 53  1]
 [ 1  0  0  0  0 63]]
              precision    recall  f1-score   support

         1.0       0.96      0.87      0.91        84
         2.0       1.00      1.00      1.00        72
         3.0       1.00      0.99      0.99        93
         4.0       0.94      1.00      0.97        50
         5.0       0.96      0.96      0.96        55
         6.0       0.90      0.98      0.94        64

    accuracy                           0.96       418
   macro avg       0.96      0.97      0.96       418
weighted avg       0.97      0.96      0.96       418
```

Şekil 4. Araç kutusu tarafından üretilen doğrulama veri setine ait doğruluk değerleri

Geliştirilen araç kutusu ayrıca test verileri için de doğruluk değeri ve hata matrisi üretmektedir. Burada elde edilen sonuçlara göre genel doğruluk %70.61 olarak hesaplanmıştır (Şekil 5). Test veri setinde beklenildiği üzere doğrulama veri setine göre daha düşük doğruluk değerleri elde edilmiştir.

```
0.7060825180774138
[[396   0   0   5   1  38]
 [  0 440   0   0   0   0]
 [  0   0 451   0  11   0]
 [290   0   0  33   0   0]
 [108   0   4   0 188   6]
 [214   0  10   0   4 152]]
              precision    recall  f1-score   support

         1.0       0.39      0.90      0.55       440
         2.0       1.00      1.00      1.00       440
         3.0       0.97      0.98      0.97       462
         4.0       0.87      0.10      0.18       323
         5.0       0.92      0.61      0.74       306
         6.0       0.78      0.40      0.53       380

    accuracy                           0.71      2351
   macro avg       0.82      0.67      0.66      2351
weighted avg       0.82      0.71      0.69      2351
```

Şekil 5. Araç kutusu tarafından üretilen test veri setine ait doğruluk değerleri

Doğrulukların analizi yanında bant değerleri ile sınıf atamaları arasındaki ilişki grafik olarak elde edilmektedir. Bu grafikler yardımıyla kullanıcılar bantların ayırıcı özelliklerini değerlendirme imkânına sahip olmaktadır. Bu çalışmada üretilen bant-sınıf ilişkisi grafiği Şekil 6'da görülmektedir. Grafikler incelendiğinde özellikle B8'in sınıf ayırt ediciliğine katkısının yüksek olduğu görülmektedir. B2 ile B3 arasında ise korelasyonun fazla olduğu anlaşılmaktadır.

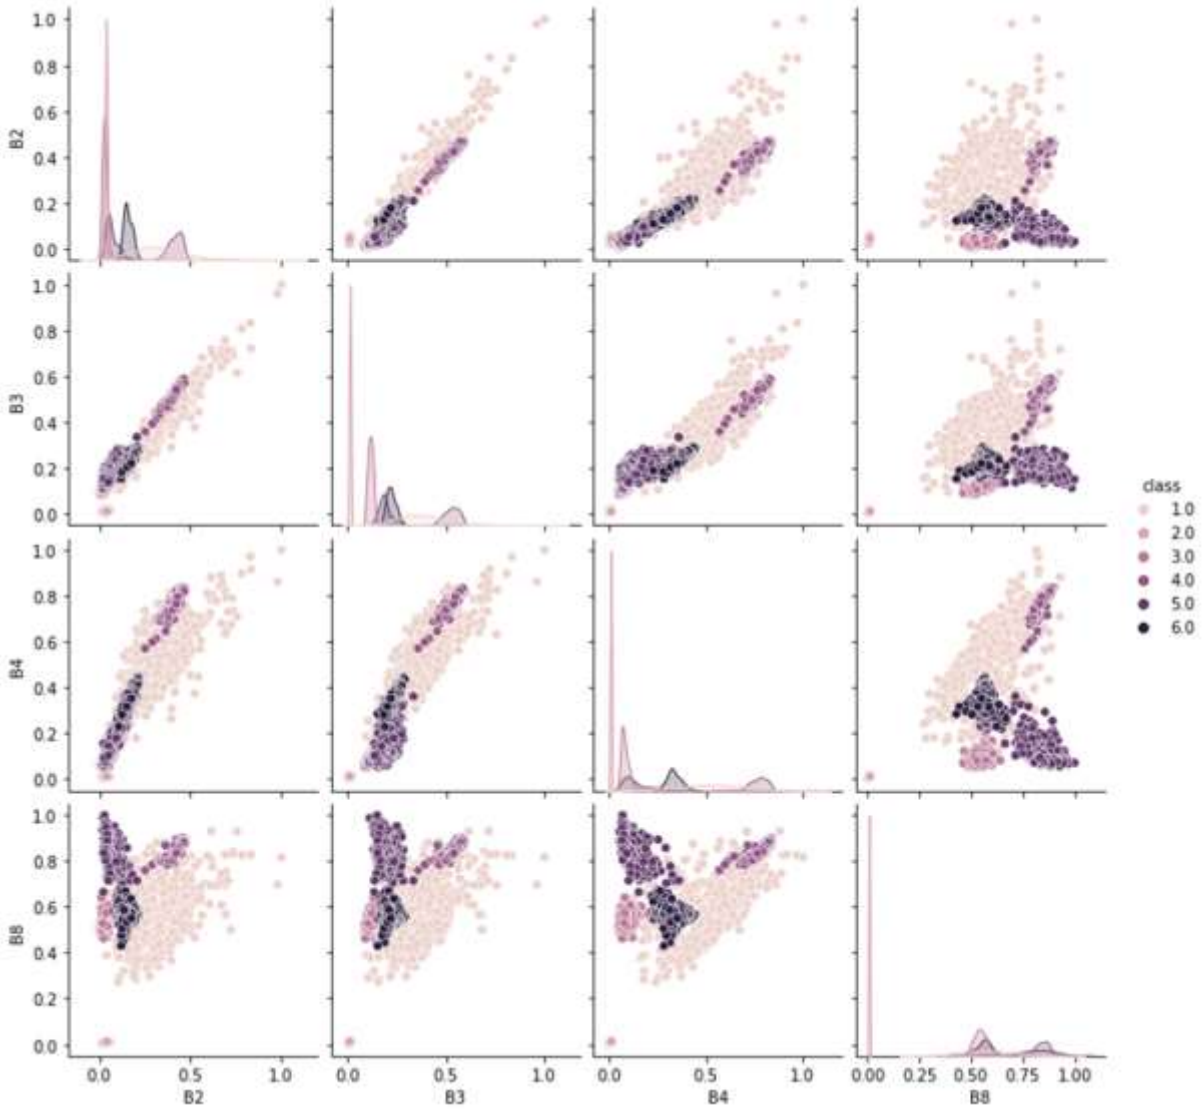

Şekil 6. Araç kutusu tarafından üretilen bant-sınıf ilişkisi grafikleri

Son olarak tematik harita üretimi model tahmine dayalı gerçekleştirilmiştir. Şekil 7'de görüldüğü gibi yükseklik en düşük 4000, en yüksek 60000, düşeyde en düşük 4000 en yüksek 6000 olmak üzere oluşan dörtgen bölge için arazi kullanım haritası png formatında kaydedilmiştir.

3. Uygulama ve Tartışma

Bu çalışmada şu özellikleri sağlayan Python tabanlı bir araç kutusu açıklanmıştır: Bant değerlerini normalize eden, sınıflar arasındaki bant korelasyonlarını gösteren, verileri eğitim ve doğrulama verisi olarak istenen oranda ayırabilen, k-En Yakın Komşu yöntemine göre eğitimli sınıflandırma gerçekleştirilen, tematik tahmin haritası üreten, komut satırlı, kurulumu hızlı küçük boyutlu bir araç kutusu geliştirilmiştir. Bu araç kutusunun en önemli avantajı farklı Uzaktan Algılama problemleri ve görüntüleri için hızlıca adapte edilebilir olmasıdır.

Gelecek çalışmalar için araç kutusuna eğitimsiz sınıflandırma algoritmalarının eklenmesi, k-NN yanında başka eğitimli sınıflandırma algoritmalarının eklenmesi planlanmaktadır. Ayrıca eğitim ve test veri setlerinin otomatik sağlanması için yeni bir modülün geliştirilmesi planlanmaktadır.

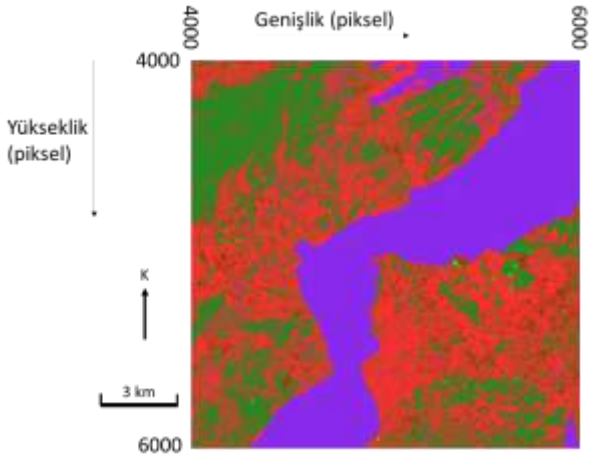

Şekil 7. Üretilen tematik arazi kullanım haritası

Kaynaklar

Chen, C. J., Zhang, Z. (2020). GRID: A Python package for field plot phenotyping using aerial images. *Remote Sensing* 12(11), 1697.

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.

Jasim, O. Z., Hassoon, K. I., Sadiqe, N. E. (2019). Mapping LCLU using python scripting. *Engineering and Technology Journal* 37(4A), 140-147.

Karasiak, N., (2020). Museo ToolBox: A Python library for remote sensing including a new way to handle rasters. *Journal of Open Source Software* 5(48), 1978.

Lacaze, B., Dudek, J., Picard, J. (2018). Grass GIS software with QGIS. N. Baghdadi, C. Mallet, M. Zribi (ed.) *QGIS and generic tools* 1, 67-106.

Lutz, M. (2001). Programming python. O'Reilly Media, Inc.

Rahmati, O., Moghaddam, D. D., Moosavi, V., Kalantari, Z., Samadi, M., Lee, S., Tien Bui, D. (2019). An automated python language-based tool for creating absence samples in groundwater potential mapping. *Remote Sensing* 11(11), 1375.

Raspaud, M., Hoese, D., Dybbroe, A., Lahtinen, P., Devasthale, A., Itkin, M., Hamann, U., Rasmussen, L. Ø., Nielsen, E. S., Leppelt, T., Maul, A., Kliche, C., Thorsteinsson, H. (2018). PyTroll: An open-source, community-driven Python framework to process earth observation satellite data. *Bulletin of the American Meteorological Society* 99(7), 1329-1336.

Serbin, G., Green, S. Open-sourced remote sensing data management with the Irish earth observation (IEO) python module. *Preprints* 2018.

Soares, A. R., Bendini, H. N., Vaz, D. V., Uehara, T. D., Neves, A. K., Lechler, S., Körting, T. S., Fonseca, L. M. (2020). Stmetrics: A python package for satellite image time-series feature extraction. *IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium*, 2061-2064.

Upadhyay, A., Shetty, A., Singh, S. K., Siddiqui, Z. (2016). Land use and land cover classification of LISS-III satellite image using KNN and decision tree. *3rd International Conference on Computing for Sustainable Global Development* 1277-1280.

Weinstein, B. G., Marconi, S., Aubry-Kientz, M., Vincent, G., Senyondo, H., White, E. P. (2020). DeepForest: A Python package for RGB deep learning tree crown delineation. *Methods in Ecology and Evolution* 11(12), 1743-1751.

Wu, Q. (2020). Geemap: A Python package for interactive mapping with Google Earth Engine. *Journal of Open Source Software* 5(51), 2305.

Xiu, H., Yang, F. (2018). Batch processing of remote sensing image mosaic based on python. *International Journal of Online Engineering* 14(9).

Zuhlke, M., Fomferra, N., Brockmann, C., Peters, M., Veci, L., Malik, J., & Regner, P. (2015). SNAP (Sentinel application platform) and the ESA sentinel 3 toolbox. *Sentinel-3 for Science Workshop* 734, 21.