T.C.
ÇANAKKALE ONSEKİZ MART ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

DUYGU-TÜRK: YAZILI VE SÖZLÜ TÜRKÇE METİNLER İÇİN DUYGU ANALİZ YÖNTEMİ

DOKTORA TEZİ

RABİA TİNTİN

Tez Danışmanı
DOÇ. DR. SAİT CAN YÜCEBAŞ

ÇANAKKALE – 2025

T.C.
ÇANAKKALE ONSEKİZ MART ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

DUYGU-TÜRK: YAZILI VE SÖZLÜ TÜRKÇE METİNLER İÇİN DUYGU ANALİZ YÖNTEMİ

DOKTORA TEZİ

RABİA TİNTİN

Tez Danışmanı
DOÇ. DR. SAİT CAN YÜCEBAŞ

ÇANAKKALE – 2025

T.C.
ÇANAKKALE ONSEKİZ MART ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Rabia TİNTİN tarafından Doç. Dr. Sait Can YÜCEBAŞ yönetiminde hazırlanan ve **24/12/2025** tarihinde aşağıdaki jüri karşısında sunulan "**Duygu-Türk: Yazılı ve Sözlü Türkçe Metinler İçin Duygu Analiz Yöntemi**" başlıklı çalışma, Çanakkale Onsekiz Mart Üniversitesi Lisansüstü Eğitim Enstitüsü **Bilgisayar Mühendisliği Anabilim Dalı**'nda **DOKTORA TEZİ** olarak oy birliği ile kabul edilmiştir.

Jüri Üyeleri	**İmza**
Doç. Dr. Sait Can YÜCEBAŞ (Danışman)	……
Prof. Dr. Hayri SEVER	……
Doç. Dr. Engin ŞAHİN	……
Dr. Öğr. Üyesi Enis ARSLAN	……
Dr. Öğr. Üyesi Yonca BAYRAKDAR YILMAZ	……

Tez No : 10600145
Tez Savunma Tarihi : 24/12/2025

……
Prof. Dr. Melis ULU DOĞRU
Enstitü Müdürü

31/12/2025

ETİK BEYAN

Çanakkale Onsekiz Mart Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kuralları'na uygun olarak hazırladığım bu tez çalışmasında; tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi, tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu, tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi, kullanılan verilerde herhangi bir değişiklik yapmadığımı, bu tezde sunduğum çalışmanın özgün olduğunu, bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi taahhüt ve beyan ederim.

(İmza)
Rabia TİNTİN
24/12/2025

TEŞEKKÜR

Bu tezin gerçekleştirilmesinde, çalışmam boyunca benden bir an olsun yardımlarını esirgemeyen saygı değer danışman hocam Doç. Dr. Sait Can YÜCEBAŞ'a, hayatımın her evresinde bana destek olan eşim Bahattin TİNTİN'e, kızlarım Saliha TİNTİN ve Senanur TİNTİN'e sonsuz teşekkürlerimi sunarım."

Rabia TİNTİN

Çanakkale, Aralık 2025

ÖZET

DUYGU-TÜRK: YAZILI VE SÖZLÜ TÜRKÇE METİNLER İÇİN DUYGU ANALİZ YÖNTEMİ

Rabia TİNTİN
Çanakkale Onsekiz Mart Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı Doktora Tezi
Danışman: Doç. Dr. Sait Can YÜCEBAŞ
24/12/2025, 137

İlgili tez çalışmasında, Plutchik'in Duygu Çarkı kuramı temel alınarak, Türkçe yazılı ve sözlü verilerden duygu tespiti yapabilen bütüncül bir yapay zeka sistemi geliştirilmiştir. Çalışmanın ilk aşamasında, yazılı Türkçe metinlerin "pozitif, negatif, nötr, koşullu-pozitif, koşullu-negatif" sınıfının, sekiz temel duygunun, bu duyguların yoğunluk düzeylerinin ve sekiz temel duygunun birleşiminden oluşan ikincil duyguların belirlenmesini sağlayan LSTM derin öğrenme tabanlı yapay zeka modelleri oluşturulmuştur. Bu modellerin eğitimi için, Türkçe diline özgü 136.000 cümlelik etiketlenmiş kapsamlı bir veri kümesi oluşturulmuştur. İkinci aşamada ise konuşma kayıtlarından elde edilen ses sinyalleri üzerinden çeşitli kepstral, prozodik, spektral, zamansal ve özetleyici istatistiksel özellikler çıkarılmış; bu özellikler kullanılarak duyguların yoğunluklarıyla birlikte sınıflandırılabildiği bir başka LSTM derin öğrenme tabanlı yapay zeka modeli geliştirilmiştir. Son aşamada, yazılı ve sözlü analiz modellerinden elde edilen sonuçlar birleştirilerek nihai duygunun daha isabetli bir biçimde tespit edilebildiği hibrit bir model tasarlanmıştır. "Duygu-Türk" adı verilen bu hibrit model hem metin hem de ses tabanlı analizleri bir araya getirerek daha güvenilir bir duygu analizi süreci sunmakta ve tespit edilen duyguyu ise Plutchik'in Duygu Çarkı üzerinde konumlandırarak görselleştirebilmektedir.

Çalışmanın ilk aşamasında yazılı Türkçe metinler için biçim modeli %99,77, anlam modeli %92,84, sevinç modeli %95,37, güven modeli %97,88, korku modeli %96,92, şaşkınlık modeli %97,42, üzüntü modeli %95,86, tiksinme modeli %96,17, öfke modeli %96,08 ve beklenti modeli %96,39 doğruluk başarısı göstermiştir. Çalışmanın ikinci

aşamasında sözlü metinler için anlamsal model %73,02, duygu model %61,08, yoğunluk model ise %76,65 doğruluk başarısı göstermiştir.

Anahtar Kelimeler: Yapay Zeka, Derin Öğrenme, Doğal Dil İşleme, Ses İşleme, Duygu Analizi, Plutchik'in Duygu Çarkı

ABSTRACT

DUYGU-TURK: SENTIMENT ANALYSIS METHOD FOR WRITTEN AND SPOKEN TURKISH TEXTS

Rabia TİNTİN
Çanakkale Onsekiz Mart University
School of Graduate Studies
Doctoral Dissertation in Computer Engineering
Advisor: Doç. Dr. Sait Can YÜCEBAŞ
24/12/2025, 137

In the related thesis study, a comprehensive artificial intelligence system capable of detecting emotions from both written and spoken Turkish data was developed based on Plutchik's Wheel of Emotions theory. In the first phase of the study, an LSTM-based deep learning models were created to identify the class (positive, negative, neutral, conditionally-positive, conditionally-negative), the eight basic emotions, their intensity levels, and the secondary emotions formed by combinations of the basic emotions in written Turkish texts. For training these models, a comprehensive and labeled dataset of 136,000 Turkish sentences was constructed. In the second phase, various cepstral, prosodic, spectral, temporal, and summary statistical features were extracted from audio signals obtained from speech recordings. Using these features, another LSTM-based deep learning model was developed to classify emotions along with their intensity levels. In the final phase, the results obtained from the text and speech analysis models were combined to design a hybrid model that can detect emotions more accurately. This hybrid model, named "Duygu-Türk," offers a more reliable emotion analysis process by integrating both text- and speech-based analyses and is capable of visualizing the detected emotion by positioning it on Plutchik's Wheel of Emotions.

In the first phase of the study, for written Turkish texts, the form model obtained 99.77%, the semantic model 92.84%, the joy model 95.37%, the trust model 97.88%, the fear model 96.92%, the surprise model 97.42%, the sadness model 95.86%, disgust model 96.17%, anger model 96.08%, and expectation model 96.39% accuracy scores. In the second

phase of the study, for verbal texts, the semantic model obtained 73.02%, the emotion model 61.08% accuracy, and the intensity model 76.65% accuracy scores.

Keywords: Artificial Intelligence, Deep Learning, Natural Language Processing, Speech Processing, Emotion Analysis, Plutchik's Wheel of Emotions

İÇİNDEKİLER

Sayfa No

JÜRİ ONAY SAYFASI……. i
ETİK BEYAN……. ii
TEŞEKKÜR…… iii
ÖZET ……..……..…….. iv
ABSTRACT ……... vi
İÇİNDEKİLER ……..…… viii
SİMGELER ve KISALTMALAR…….....…… x
TABLOLAR DİZİNİ…….…. xvi
ŞEKİLLER DİZİNİ……...……...……..…. xiii

BİRİNCİ BÖLÜM
GİRİŞ

İKİNCİ BÖLÜM
ÖNCEKİ ÇALIŞMALAR 5

2.1. Yazılı Metinler için Önceki Çalışmalar ...…….…….. 5
2.1.1. Sözlük Tabanlı Yaklaşımlar ……..……..…..……. 6
2.1.2. Makine Öğrenmesi Yaklaşımları …...……... 9
2.1.3. Hibrit Yaklaşımlar ……...……..…… 23
2.2. Sözlü Metinler için Önceki Çalışmalar …….……....…..…… 25
2.2.1. Geleneksel Makine Öğrenmesi Yaklaşımları ……..... 25
2.2.2. Derin Öğrenme Yöntemleri ……..…… 28
2.2.3. Dikkat Mekanizmaları ……...……..... 40
2.2.4. Topluluk Öğrenmesi …….…… 47

ÜÇÜNCÜ BÖLÜM
MATERYAL YÖNTEM 49

3.1. Plutchik'in Duygu Çarkı Modeli ……..…….…….. 49
3.2. Yazılı Metinler için Materyal ……..…….. 52

3.2.1. Metin Veri Kümesinin Oluşumu 54
3.2.2. Veri Kümesi Etiketleme İşleminde Dikkat Edilen Özellikler 57
3.2.3. Veri Kümesindeki Satırların Karıştırılması (Data Shuffling) 63
3.2.4. Veri Kümesindeki Sınıfların Dağılımları 64
3.2.5. Veri Kümesindeki Cümlelerin Özellikleri 67
3.3. Sözlü Metinler için Materyal 68
3.3.1. BAUM-1 Veri Kümesi 69
3.3.2. RAVDESS Veri Kümesi 69
3.3.3. TESS Veri Kümesi 70
3.4. Yazılı Metinler için Yöntem 70
3.4.1. Veri Ön İşleme 72
3.4.2. Vektör Oluşturma Modülü 73
3.4.3. Hiperparametre Optimizasyonu 87
3.4.4. Derin Öğrenme Modülü 88
3.5. Sözlü Metinler için Yöntem 95
3.5.1. Ses Öz Nitelikleri 97
3.5.2. Hiperparametre Optimizasyonu 105

DÖRDÜNCÜ BÖLÜM
ARAŞTIRMA BULGULARI 107

4.1. Yazılı Metinler için Araştırma Bulguları 107
4.2. Sözlü Metinler için Araştırma Bulguları 113
4.3. Yazılı Metinler için Örnek Çalışma 114
4.4. Hibrit Yaklaşım için Örnek Çalışma 117

BEŞİNCİ BÖLÜM
SONUÇ ve ÖNERİLER 121

5.1. Yazılı Metinler için Sonuç ve Öneriler 121
5.2. Sözlü Metinler için Sonuç ve Öneriler 123
5.3. Hibrit Yaklaşım için Sonuç ve Öneriler 123
KAYNAKÇA 125
EKLER I

SİMGELER VE KISALTMALAR

NLP	Doğal Dil İşleme / Natural Language Processing
NRC	Saif Mohammad and Peter Turney tarafınfan oluşturulan sözlüğe verilen ad
SVM	Destek Vektör Makineleri / Support Vector Machines
Linear SVM	Doğrusal Destek Vektör Makineleri / Linear Support Vector Machines
DT	Karar Ağacı / Decision Tree
RF	Rastgele Orman / Random Forest
RSVM	Random Forest ile Support Vector Machines birlikte
KNN	K-En Yakın Komşu / K-Nearest Neighbors
NB	Naive Bayes
MNB	Multinomial Naive Bayes
LR	Logistic Regression
Linear R	Doğrusal Regresyon / Linear Regression
ME	Maximum Entropy
LDA	Doğrusal Ayrım Analizi / Linear Discriminant Analysis
Doc2Vec	Document to Vector
DBOW	Distributed Bag of Words
DM	Dağıtılmış Bellek / Distributed Memory
PHP	Personal Home Page / Hypertext Preprocessor
WEKA	Waikato Bilgi Analizi Ortamı / Waikato Environment for Knowledge Analysis
GB	Gradyan Artırma / Gradient Boosting
FCM	Bulanık C-Ortalamalar / Fuzzy C-Means
PFCM	Olasılıksal Bulanık C-Ortalamalar / Possibilistic Fuzzy C-Means
CNN	Evrişimli Sinir Ağı / Convolutional Neural Network
RNN	Özyinelemeli Sinir Ağı / Recurrent Neural Network
Bi-RNN	Çift Yönlü Özyinelemeli Sinir Ağı / Bidirectional Recurrent Neural Networks
LSTM	Uzun Kısa Süreli Bellek / Long Short-Term Memory

Bi-LSTM	Çift Yönlü Uzun Kısa Süreli Bellek / Bidirectional Long Short-Term Memory
GRU	Tek yönlü Geçitli Tekrarlayan Birim / Directional Gated Recurrent Unit
Bi-GRU	Çift yönlü Geçitli Tekrarlayan Birim / Bidirectional Gated Recurrent Unit
NN	Yapay Sinir Ağı Mimarisi / Neural Network Architecture
MLP	Çok Katmanlı Algılayıcılar / Multi-Layer Perceptrons
HAN	Hiyerarşik Dikkat Ağı / Hierarchical Attention Network
BERT	Bidirectional Encoder Representations from Transformers
YSA	Yapay Sinir Ağları
GPU	Grafik İşlem Birimi / Graphics Processing Unit
BoW	Bag of Words
TF-IDF	Terim Frekansı-Ters Belge Frekansı / Term Frequency-Inverse Document Frequency
TF	Terim Frekansı / Term Frequency
IDF	Ters Belge Frekansı / Inverse Document Frequency
Word2Vec	Word to Vector
F5	İlk Beş Karakter Yöntemi
MI	Karşılıklı Bilgi / Mutual Information
ELMo	Embeddings from Language Models
XLNET	Extra Long Network
C4	Colossal Clean Crawled Corpus
mC4	Multilingual C4
Bert-T	BERT-Turkish
Bert-M	BERT-Multilingual
Dbert-T	DistilBERT-Turkish
J48	Bir Karar Ağacı Algoritması
RoBERTa	Robustly Optimized BERT Approach
AdaBoost	Adaptive Boosting
GB	Gradient Boosting
OR	Odds Ratio
RF	İlişki Frekansı / Relevance Frequency

BDC	Dengelenmiş Dağılımsal Yoğunluk / Balanced Distributional Concentration
IQF	Ters Soru Frekansı / Inverse Question Frequency
SW	Kısa Metin Ağırlıklandırması / Short Text Weighting
IGM	Ters Yerçekimi Momentumu / Inverse Gravity Moment
RE	Regularized Entropy
STN	SentiTurkNet Türkçe Sözlük
ASDICT	Otomatik Eşanlamlı Sözlüğü
CRF	Koşullu Rastgele Alanlar / Conditional Random Fields
MALLET	Machine Learning for LanguagE Toolkit
KNIME	Konstanz Information Miner
SER	Konuşma Duygu Tanıma / Speech Emotion Recognition
GFA	Global Özellik Algoritması / Global Feature Algorithm
GMM	Gauss Karışım Modeli / Gaussian Mixture Model
RAVDESS	Ryerson Audio-Visual Database of Emotional Speech and Song
EMO-DB	Berlin Database of Emotional Speech
SAVEE	Surrey Audio-Visual Expressed Emotion
EMOVO	EMOtional VOices Database
MFCC	Mel Frekans Kepstral Katsayıları / Mel-Frequency Cepstral Coefficients
MFMC	Mel Frekansı Büyüklük Katsayıları / Mel-Frequency Magnitude Coefficients
DWT	Ayrık Dalgacık Dönüşümü / Discrete Wavelet Transform
ZCR	Sıfır Geçiş Oranı / Zero Crossing Rate
LFPC	Log Frekansı Güç Katsayıları / Log-Frequency Power Coefficients
LPCC	Doğrusal Tahminli Cepstral Katsayılar / Linear Predictive Cepstral Coefficients
TLFMRF	İki Katmanlı Bulanık Çoklu Rastgele Orman Yöntemi / Two-Layer Fuzzy Multiple Random Forest
CASIA	Chinese Academy of Sciences Institute of Automation Speech Database
BPNN	Geri Yayılım Yapay Sinir Ağı / Backpropagation Neural Network
LED	Işık Yayan Diyot / Light Emitting Diode

1D-CNN	Tek Boyutlu Evrişimli Sinir Ağı / 1D Convolutional Neural Network
IEMOCAP	Interactive Emotional Dyadic Motion Capture Database
1D-DCNN	One-dimensional Dilated Convolutional Neural Network
HCI	İnsan-Bilgisayar Etkileşimi / Human-Computer Interaction
MFCCT	Mfccs And Time-Domain Features
1-D DCNN	One-dimensional Deep Convolutional Neural Network
MLT	Çoklu Öğrenme Hilesi / Multi Learning Trick
WPT	Dalgacık Paket Dönüşümü / Wavelet Packet Transform
RMS Energy	Kök Ortalama Kare Enerjisi / Root Mean Square Energy
CREMA-D	Crowd-Sourced Emotional Multimodal Actors Dataset
EC	Duygu İklimi / Emotion Climate
AD	Affect Dynamics
TCNN	Zamansal Evrişimsel Sinir Ağları / Temporal Convolutional Neural Networks
SEWA	Automatic Sentiment Analysis in the Wild
DC Conv	Dilated Causal Convolution
TABs	Temporal Aware Blocks
FCNN	Tam Evrişimli Sinir Ağı / Fully Convolutional Neural Network
LFLBs	Yerel Özellik Öğrenme Blokları
2D	İki Boyutlu / Two Dimensional
WA	Ağırlıklı Doğruluk / Weighted Accuracy
UA	Ağırlıksız Doğruluk / Unweighted Accuracy
WAR	Ağırlıklı Ortalama Recall / Weighted Average Recall
UAR	Ağırlıksız Ortalama Recall / Unweighted Average Recall
CE-Loss	Çapraz Entropi Kaybı / Cross Entropy Loss
E2E	Uçtan Uca / End to End
HuBERT	Hidden Unit BERT
ECAPA-TDNN	Vurgulanmış Kanal Dikkati, Yayılım ve Birleştirme Zaman Gecikmeli Sinir Ağı / Emphasized Channel Attention, Propagation, and Aggregation Time Delay Neural Network
SOTA	Alanındaki En İyi Yöntem / State of the Art
CV	Çapraz Doğrulama / Cross Validation
Wav2Vec 2.0	Waveform to Vector 2.0

ITS	Intelligent Transportation Systems
SAGIN	Space-Air-Ground Integrated Network
5G	Beşinci Nesil / Fifth Generation
DNN	Derin Sinir Ağı / Deep Neural Network
TESS	Toronto Emotional Speech Set
ResNet50	Residual Network 50
AUC	Eğri Altındaki Alan / Area Under the Curve
ROC	Alıcı İşletim Karakteristiği Eğrisi / Receiver Operating Characteristic
DS-LSTM	Çift-Dizili LSTM / Dual-Sequence LSTM
SFS	Stokastik Fraktal Arama / Stochastic Fractal Search
WOA	Balina Optimizasyon Algoritması / Whale Optimization Algorithm
nEMO	Dataset of Emotional Speech in Polish
RBFN	Radyal Tabanlı Fonksiyon Ağı / Radial Basis Function Network
STFT	Kısa Süreli Fourier Dönüşümü / Short Time Fourier Transform
TGFE	Zamansal Küresel Özellik Çıkarıcı / Temporal Global Feature Extractor
MELD	Multimodal EmotionLines Dataset
MOSI	Multimodal Opinion Sentiment Intensity Corpus
Q	Sorgu / Query
K	Anahtar / Key
V	Değer / Value
DSA	Directional Self-Attention
ASR	Otomatik Konuşma Tanıma / Automatic Speech Recognition
MSER	Çok Modlu Konuşma Duygu Tanıma / Multimodal Speech Emotion Recognition
MSA	Multi-Head Self-Attention
FFN	Fully Connected Feed-Forward Network
LSSED	Large-Scale Speech Emotion Dataset
CCAB	Cascaded Cross-Attention Block
SSL	Yarı Denetimli Öğrenme / Semi-Supervised Learning
MSP-IMPROV	Multimodal Signal Processing-Improvised
MER	Çok Modlu Duygu Tanıma / Multimodal Emotion Recognition
EER	Eşit Hata Oranı / Equal Error Rate

SLURP	Spoken Language Understanding Resource Package
CCC	Uyum Korelasyonu Katsayısı / Concordance Correlation Coefficient
V-FT	Vanilla Fine-Tuning
TAPT	Task Adaptive Pretraining
P-TAPT	Pseudo-Label Task Adaptive Pretraining
MMS	Geniş Ölçekli Çok Dilli Konuşma / Massively Multilingual Speech
LLM	Büyük Dil Modelleri / Large Language Model
MoE	Mixture Of Experts
HF	İnsan Geri Bildirimi / Human Feedback
SMO	Sequential Minimal Optimization
XLSX	Microsoft Excel'in 2007 ve sonrası sürümlerinde kullanılan dosya formatı
CSV	Düz metin formatında bir dosya türü
TDK	Türk Dil Kurumu
JSON	JavaScript Nesne Gösterimi / JavaScript Object Notation
BAUM-1	BAhçeşehir University Multimodal Database-1
TANH	Hiperbolik Tanjant / Hyperbolic Tangent
RELU	Rectified Linear Unit
KB	Kilobayt / Kilobyte
CPU	Merkezi İşlem Birimi / Central Processing Unit
h	Saat / Hour
min	Dakika / Minute
SGD	Stokastik (Rastgele) Gradyan İnişi / Stochastic Gradient Descent
ZIP	Veri sıkıştırmak ve birden fazla dosyayı tek bir arşivde toplamak için kullanılan bir dosya formatı
JDK	Java Geliştirme Kiti / Java Development Kit
HNR	Harmonik Gürültü Oranı / Harmonic Noise Ratio
SIFT	Scale Invariant Fourier Transform Magnitudes
FFT	Hızlı Fourier Dönüşümü / Fast Fourier Transform
ELECTRA	Efficiently Learning an Encoder that Classifies Token Replacements Accurately

TABLOLAR DİZİNİ

Tablo No	Tablo Adı	Sayfa No
Tablo 1	Kuvvetlendirici / Zayıflatıcı ifadeler ve sınıf etiketleri	58
Tablo 2	Koşullu pozitif ve koşullu negatif sınıflar için örnek cümleler	60
Tablo 3	Deyimleşmiş duygu ifadeleri	61
Tablo 4	Veri kümesinden bir kesit	63
Tablo 5	"Biçimsel Sonuç" sınıfının eğitim ve test veri kümelerindeki dağılımı	65
Tablo 6	"Anlamsal Sonuç" sınıfının eğitim ve test veri kümelerindeki dağılımı	65
Tablo 7	Temel duygu sınıflarının eğitim veri kümesindeki dağılımları	65
Tablo 8	Temel duygu sınıflarının test veri kümesindeki dağılımları	66
Tablo 9	Temel duygu sınıflarının tüm veri kümesindeki dağılımları	66
Tablo 10	Veri kümesindeki cümlelerin kelime sayısı dağılımları	67
Tablo 11	Duygu-Türk ses veri kümesi	68
Tablo 12	Karakter düzeyinde UniGram yönteminde karakterlerin vektörel değerleri	73
Tablo 13	Harflerin kullanım sıklığı analizi	74
Tablo 14	Kural tabanlı yaklaşım vektöründeki öz nitelikler	77
Tablo 15	Örnek cümle	82
Tablo 16	Unigram ve kural tabanlı vektör	83
Tablo 17	Kelime vektörünün oluşumu	86
Tablo 18	Cümle vektörü	86
Tablo 19	Yazılı metinler için LSTM modelin hiperparametreleri ve kullanılan optimum değerler	88
Tablo 20	Sınıf etiketleri ve değerleri	91
Tablo 21	Ses sınıf etiketleri ve değerleri	97

Tablo 22	Ses öz nitelikleri	98
Tablo 23	Sözlü metinler için LSTM modelin hiperparametreleri ve kullanılan optimum değerler	106
Tablo 24	Biçim ve Anlam modele ait sonuçlar	108
Tablo 25	Anlam model sınıflarına ait sonuçlar	109
Tablo 26	Temel duygu modellerine ait sonuçlar	110
Tablo 27	Özel bir eğitimden geçirilmeyen BERT sonuçları	111
Tablo 28	Duygu-Türk ve diğer modellerin performans sonuçları	111
Tablo 29	Duygu-Türk ve diğer modellerin performans sonuçları-1	111
Tablo 30	Duygu-Türk ve diğer modellerin performans sonuçları-2	112
Tablo 31	Ses duygu modellerine ait sonuçlar	113

ŞEKİLLER DİZİNİ

Şekil No	Şekil Adı	Sayfa No
Şekil 1	Yazılı metinler için duygu analizi yaklaşımları	5
Şekil 2	Topluluk öğrenmesi	22
Şekil 3	Psikolog Robert Plutchik tarafından geliştirilen duygu teorisine göre oluşturulmuş duygu çarkı modeli	50
Şekil 4	Yazılı metinler için veri kümesinin oluşumu ve etiketleme işleminde dikkat edilen özellikler	53
Şekil 5	Türk Dil Kurumu Güncel Türkçe Sözlük'te "sevinç" kelimesinin gösterimi	55
Şekil 6	https://deyimlerimiz.com/ web sayfasında "etekleri zil çalmak" deyiminin gösterimi	56
Şekil 7	Yazılı metinler için geliştirilen yönteme ait iş akış şeması	71
Şekil 8	Geliştirilen uygulamada yer alan cümle vektörü dosyasından bir kesit	87
Şekil 9	LSTM modülü	89
Şekil 10	Duygu yoğunluğu seviyelerinin Plutchik'in duygu çarkında gösterimi	93
Şekil 11	Sözlü metinler için geliştirilen yöntemin iş akış şeması	96
Şekil 12	Geliştirilen uygulamada ses öz niteliklerinin görüldüğü ses vektör dosyasından bir kesit	105
Şekil 13	Kullanıcının girdiği cümlelerin vektöre dönüştürülmesi	114
Şekil 14	Kullanıcının girdiği cümlelerin vektör dosyasından bir kesit	114
Şekil 15	Biçim model için örnek cümleler ve çıktı dosyası	115
Şekil 16	Anlam model için örnek cümleler ve çıktı dosyası	115
Şekil 17	Duygu model için örnek cümle ve çıktı dosyası	116
Şekil 18	Duygu model için örnek cümlenin duygu çarkındaki görüntüsü	117
Şekil 19	Hibrit yaklaşım için örnek cümle ve ekran görüntüsü-1	118
Şekil 20	Hibrit yaklaşım için örnek cümle ve ekran görüntüsü-2	118

Şekil 21	Hibrit yaklaşım için örnek cümle ve ekran görüntüsü-3	119
Şekil 22	Hibrit yaklaşım için örnek cümle ve çıktı dosyası	119
Şekil 23	Hibrit yaklaşım için örnek cümle ve duygu çarkındaki görüntüsü	120
Şekil 24	Duygu-Türk uygulaması akış şeması	I

BİRİNCİ BÖLÜM
GİRİŞ

Duygu analizi, bireylerin düşüncelerini, hislerini ve tutumlarını anlamak için etkili bir yöntem olup, özellikle sosyal medya, müşteri geri bildirimleri, halkla ilişkiler ve pazarlama gibi birçok alanda kritik bir rol oynamaktadır. Bu alanlarda, duygu analizi kullanılarak bireylerin duygusal tepkileri incelenebilmekte, böylece daha iyi stratejiler geliştirilebilmektedir.

Doğal dil işleme (NLP) alanındaki hızlı gelişmeler ve sosyal medya platformlarında kullanıcılar tarafından oluşturulan içeriğin hacminin artması, özellikle Türkçe gibi morfolojik açıdan zengin ve kaynakları sınırlı diller için duygu analizinin önemini daha da artırmıştır. Duygu analizi, öznel bilgilerin çıkarılmasını kolaylaştırmakla kalmaz, aynı zamanda pazarlama, kamu politikası ve sağlık gibi çeşitli alanlarda bilinçli karar vermeyi de desteklemektedir (Wankhade vd., 2022).

Bu uygulamalara ek olarak, duygu analizi, yanlış bilgi ile mücadelede ve yanıltıcı içeriğin yayılmasının önlenmesinde kritik bir rol oynamaktadır. Bu, günümüzün en acil sorunlarından biridir (Alonso vd., 2021). Duygu analizi teknikleri, çevrimiçi içeriğin duygusal tonunu değerlendirmek için kullanılabilir, böylece içeriğin güvenilirliğini değerlendirmek ve güvenilir bilgiler ile yanıltıcı bilgileri ayırt etmek mümkün hale gelir. Bu tür analizler, içerik denetim sistemlerini geliştirebilir, dijital okuryazarlığı artırabilir ve içeriğin belirli kitleler için uygunluğunun belirlenmesine yardımcı olabilir. Örneğin, kitap incelemelerinde veya özetlerinde aktarılan duyguları analiz etmek, materyalin çocuklar için uygun olup olmadığını değerlendirmek için yardımcı olabilir.

Duygu analizinin önemi giderek artmasına rağmen, mevcut araştırmalar büyük ölçüde İngilizce gibi kaynakları bol dillere odaklanmıştır (Aydın ve Güngör, 2021), Türkçeyse nispeten daha az araştırılmıştır (Balli vd., 2022). Bugüne kadar Türkçe duygu analizi üzerine yapılan çalışmalar, temel olarak iki metodolojik paradigma benimsemiştir. Bunlar, sözlük tabanlı yaklaşımlar ve dönüştürücü tabanlı (transformer-based) modellerdir.

Erken dönem sözlük tabanlı yöntemler (Demirtas ve Pechenizkiy, 2013; Vural vd., 2013) bu alana temel kaynaklar sağlamıştır. Ancak genellikle sınırlı sözcük kapsamı ve Türkçenin eklemeli (aglutinatif) yapısının getirdiği anlamsal değişkenliğin yetersiz işlenmesi sorunları ile karşı karşıya kalmıştır. Öte yandan, BERT gibi dönüştürücü modeller (transformer models), bağlamsal bağımlılıkları modelleme yetenekleri nedeniyle son zamanlarda öne çıkmıştır. Bu modeller, yüksek kaynak gerektiren ortamlarda güçlü performans göstermiş olsa da, Türkçe duygu analizinde kullanımları, azalan yorumlanabilirlik, uzun veya karmaşık cümlelerde bağlam kaybı ve büyük ölçekli etiketli veri kümelerine ve hesaplama kaynaklarına yüksek bağımlılık gibi çeşitli sınırlamalarla kısıtlı kalmaktadır (Alawi ve Bozkurt, 2024).

Ayrıca, Türkçe duygu analizi literatürünün derinlemesine incelenmesi sonucunda, kullanılan yöntemden bağımsız olarak, çalışmaların çoğunun genellikle sadece iki (olumlu/olumsuz) veya üç (olumlu/olumsuz/nötr) kategoriyi kullanan basitleştirilmiş duygu polaritesi sınıflandırmasına dayandığını ortaya koymaktadır. Duyguların önemli bir boyutu olan duygusal yoğunluk büyük ölçüde göz ardı edilmiştir (Aslan, 2023; Balli vd., 2022; Polat ve Ağca, 2022; H. Shehu vd., 2021; Uyaroğlu Akdeniz ve Cebeci, 2021). Ayrıca, deyimler, atasözleri, bileşik fiiller, kalıplaşmış ifadeler ve morfo-semantik ekler gibi Türkçeye özgü temel dil bilimsel özellikler çok az ilgi görmüş ve bu da mevcut duygu modellerinin doğruluğunu ve kültürel uygunluğunu sınırlamıştır.

Az sayıda çalışma üçten fazla duygu kategorisi önermiş olsa da (Alkan vd., 2023; Guven, 2021), bu çalışmalar genellikle en fazla beş sınıf içermekte ve çoğu zaman net bir teorik temele dayanmadan seçildiği görülmektedir. Bildiğimiz kadarıyla, birden fazla birincil duygunun bir arada ortaya çıkmasından kaynaklanan bileşik veya ikincil duyguları tanımlamaya yönelik hiçbir girişimde bulunulmamıştır. Bu durum, insan duygularının tüm çeşitliliğini modellemede kritik bir boşluk oluşturmaktadır.

Ayrıca, kullanılan yöntemden bağımsız olarak, yazılı metinler üzerinde gerçekleştirilen duygu analizi çalışmaları, dilin yapısal ve anlamsal özelliklerini değerlendirerek bir noktaya gelmiş olsa da, yalnızca metin temelli yaklaşımlar insan

duygularının bütünsel ifadesini yakalamakta bazı durumlarda yetersiz kalabilmektedir. Bu tür durumlarda ses verilerinin de entegre edilmesine ihtiyaç duyulmaktadır. Bildiğimiz kadarıyla, Türkçe yazılı metinler için geliştirilen duygu analizi modellerine ses verilerinin de entegre edildiği yeni nesil hibrit yaklaşımların mevcut literatürde oldukça sınırlı olduğu görülmektedir.

Bu sınırlamaları gidermek için ilgili tez çalışmasında, Plutchik'in Duygu Çarkı kuramını (Plutchik, 1982) temel alan, Türkçe yazılı ve sözlü verilerden duygu tespiti yapabilen bütüncül bir yapay zeka sistemi olan Duygu-Türk modeli geliştirilmiştir. Duygu-Türk modeli, yazılı metinler için geliştirilen ve eğitilen LSTM tabanlı model ile sözlü metinler için geliştirilen ve eğitilen başka bir LSTM modeli birleştiren hibrit bir yöntemdir.

Duygu analizi alanındaki mevcut modellerin üzerinde durmadığı ancak Türk dili için duygu tespitinde önemli yer tutan kural ve mekanizmalar Duygu-Türk modeline entegre edilmiştir. Bunlar arasında, monoton olmayan mantık yaklaşımı, koşullu pozitif ve koşullu negatif duygu durumlarının tespiti için modele entegre edilmiştir. Ayrıca, morfo-semantik ekler, bileşik fiiller, deyimsel ifadeler ve bağlama duyarlı duygusal ifadeler de dahil olmak üzere Türkçenin temel dil bilimsel özellikleri de entegre edilmiştir. Bu sayede hem dil bilimsel hem de bağlama duyarlı bir yaklaşım gerçekleştirilmiştir. Duygu-Türk, mevcut modellerin eksiklerini ve sınırlamalarını gidererek, Türkçe duygu analizi için daha esnek, doğru ve kaynak verimli bir çözüm sunmayı amaçlamaktadır. Böylelikle, önerilen metodoloji sadece duygu analizi sistemlerinin temsil kapasitesini güçlendirmekle kalmamakta, aynı zamanda gerçek dünyadaki, düşük kaynaklı NLP bağlamlarında daha geniş bir uygulanabilirlik sağlamaktadır.

Bunun yanında çalışmada, metin tabanlı duygu analizine, ses sinyallerinden elde edilen akustik ve prosodik özellikler entegre edilerek, duygusal durumların çok boyutlu bir biçimde tanımlanmasına olanak tanınmaktadır. Bu sayede, hem dilsel hem de ses temelli duygusal yaklaşımları bir araya getiren bütüncül bir duygu analizi yaklaşımı ortaya konmuştur.

Duygu-Türk modeli, yazılı metinleri cümle düzeyinde analiz ederek üç farklı sınıflandırma yapabilmektedir. İlk olarak biçim bakımından "pozitif, negatif" sınıflandırma yapmaktadır. İkinci olarak monoton olmayan mantık yaklaşımını kullanarak anlam bakımından "pozitif, negatif, nötr, koşullu pozitif ve koşullu negatif" sınıflandırma yapmaktadır. Üçüncü olarak ise Plutchik'in Duygu Çarkı'ndaki sekiz temel duyguya (sevinç, güven, korku, şaşkınlık, üzüntü, tiksinme, öfke ve beklenti) göre sınıflandırma yapmakta ve her duyguyu 0 ile 1.8 arasında değişen on farklı yoğunluk düzeyinde gösterebilmektedir. Bunun yanı sıra, Duygu-Türk modeli, temel duyguların birleşiminden oluşan ikincil duyguları da (aşk, teslimiyet, haşmet, kınama, pişmanlık, küçümseme, agresiflik, optimizm) tespit etmektedir. Bu modelin eğitimi için, Türkçe diline özgü duygu ifade eden kelimeleri, atasözlerini, deyimleri, birleşik fiilleri, kalıp sözleri, duygusal fonksiyon kazandıran ekleri, monoton olmayan mantık yaklaşımını, duygu ifade eden noktalama işaretlerini ve duyguyu kuvvetlendiren ve zayıflatan ifadeleri dikkate alan 136.000 cümlelik etiketlenmiş kapsamlı bir veri kümesi oluşturulmuştur.

Duygu-Türk modeli, sözlü metinlerde ise konuşma kayıtlarından elde edilen ses sinyalleri üzerinden çeşitli kepstral, prozodik, spektral, zamansal ve özetleyici istatistiksel özellikleri çıkarıp analiz ederek üç farklı sınıflandırma yapabilmektedir. İlk olarak anlam bakımından "pozitif, negatif ve nötr" olarak sınıflandırma yapmaktadır. İkinci olarak "sevinç, korku, şaşkınlık, üzüntü, tiksinme, öfke ve nötr" duygulara göre sınıflandırma yapmaktadır. Üçüncü olarak ise her duyguyu duygu yoğunluğuna göre "az (sakin) ve çok (şiddetli)" olarak iki farklı yoğunluk düzeyinde sınıflandırmaktadır.

Son aşamada, yazılı ve sözlü metinler için geliştirilmiş LSTM derin öğrenme tabanlı yapay zeka modellerinden elde edilen sonuçları birleştiren ve nihai duyguyu daha kapsamlı bir biçimde ele alabilen Duygu-Türk hibrit yöntemi geliştirilmiştir. Bu yöntem hem metin hem de ses tabanlı analizleri bir araya getirerek daha geniş bir duygu analizi süreci sunmakta ve tespit edilen duyguyu ise Plutchik'in Duygu Çarkı üzerinde konumlandırarak görselleştirebilmektedir.

İKİNCİ BÖLÜM
ÖNCEKİ ÇALIŞMALAR

Önceki çalışmalar, "yazılı metinler için önceki çalışmalar" ve "sözlü metinler için önceki çalışmalar" şeklinde iki başlık altında incelenmektedir.

2.1. Yazılı Metinler için Önceki Çalışmalar

Yazılı metinler üzerinde yapılan duygu analizi çalışmaları incelendiğinde üç farklı yaklaşımın izlendiği görülmektedir. Bu yaklaşımların, sözlük tabanlı yaklaşımlar (lexicon based approaches), makine öğrenmesi yaklaşımları (machine learning approaches) ve hibrit yaklaşımlar (hybrid approach) olduğu görülmektedir. Bu yaklaşımlar, Şekil 1'de gösterilmektedir.

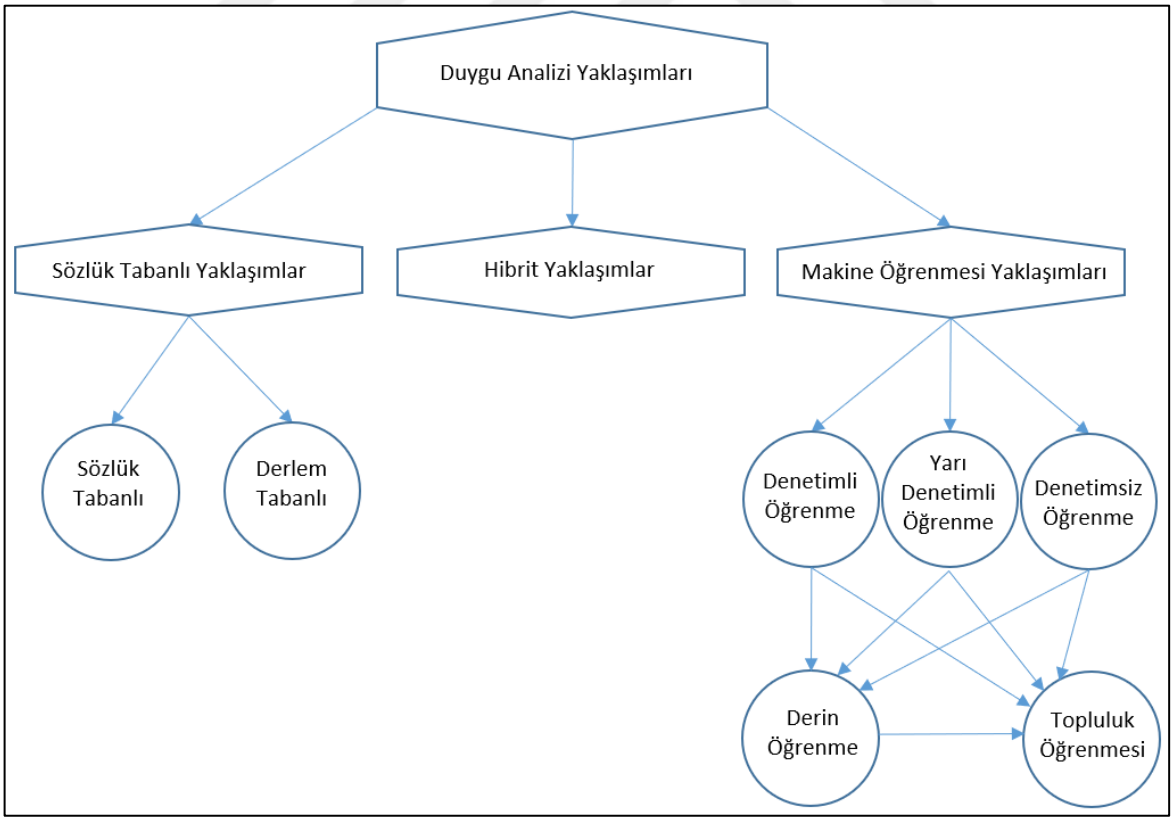

Şekil 1. Yazılı metinler için duygu analizi yaklaşımları.

2.1.1. Sözlük Tabanlı Yaklaşımlar

Sözlük tabanlı yaklaşımlar, sözlük tabanlı yaklaşımlar (dictionary based approaches) ve derlem tabanlı yaklaşımlar (corpus based approaches) olmak üzere kendi içinde iki kategoriye ayrılmaktadırlar. Sözlük tabanlı yaklaşımlarda, duygu ifade eden kelime veya kelime öbeklerinden oluşan sözlükler kullanılmaktadır. Bu sözlüklerin, bazı çalışmalarda tamamen manuel oluşturulduğu, bazı çalışmalarda daha önceden hazırlanmış ve kullanıma sunulmuş sözlüklerden yararlanıldığı, bazı çalışmalarda ise önceden hazırlanmış ve kullanıma sunulmuş sözlüklerin birleştirilip genişletildiği görülmüştür. Bu sözlüklerde yer alan terimlere ilgili duygu oranlarını ifade eden puanların verilmiş olduğu görülmektedir. Çalışmalarda, sözlüklerde yer alan kelime veya kelime öbeklerine verilen duygu puanlarının direkt olarak kullanıldığı; bazı çalışmalarda ise aranılan terimin eş anlamlı, zıt anlamlı veya yakın anlamlı terimlerinden yararlanılarak da duygu puanlarının kullanıldığı görülmektedir. Sözlük kullanımının bir dezavantajı, sözlükteki terimlerin bağlamdan bağımsız olarak değerlendirilmesi ve bu yüzden performans kaybına sebep olmasıdır (Sağlam, 2019). Derlem tabanlı yaklaşımda ise kelimelerin duygu puanlarının veya duygu sınıflarının bulundukları derleme bağlı istatistiksel olarak belirlendiği görülmektedir. Sözlük tabanlı yaklaşım izleyen çalışmalara bazı örnekler aşağıda verilmektedir.

Öztürk ve Ayvaz (Öztürk ve Ayvaz, 2018) çalışmalarında, Suriye'deki savaş ve mülteci krizine ilişkin Türkçe ve İngilizce tweetlerden oluşan veri kümesi ele alınarak hem Türkçe hem İngilizce dilinde sözlük tabanlı bir duygu analizi çalışması yapmışlardır. İlgili çalışmada İngilizce için mevcut olan RSentiment sözlük kullanılmıştır. RSentiment paketi, İngilizce cümle düzeyinde duygu analiz edilmesine yardımcı olan ve duygu puanı sağlayan kapsamlı bir duygu sözlüğü içermektedir. Türkçe için ise 5405 kelimeden oluşan geniş bir duygu sözlüğü geliştirilmiştir. Bu kelimeler duygu değerlerine göre -5'ten +5'e kadar puanlanmıştır: -5 çok olumsuz, +5 ise çok olumlu anlamına gelmektedir. Objektif bir puan elde etmek için sözlükte yer alan terimler, ana dili Türkçe olan 3 farklı kişi tarafından manuel olarak puanlanmıştır. Sözlükteki her bir terim, diğer puanlayıcıların verdiği terimlerin puanı bilinmeden bireyler tarafından ayrı ayrı puanlanmıştır. Nihai duygu puanlarının güvenilirliğini ve doğruluğunu denetlemek için, daha sonra değerlendiriciler tarafından verilen sözlükteki terimlerin duygu puanları, manuel olarak incelenmiş olup

değerlendiricilerin duygu puanlarının sözlükteki terimlerin çoğunluğu için tutarlı olduğu gözlemlenmiştir. Ardından puanlayıcılar tarafından farklı puanlanan terimler üzerinde fikir birliğine varılması için grup puanlarının ortalamaları hesaplanarak sözlükteki her terime ilgili puan atanmıştır.

Karamollaoğlu ve ark. (Karamollaoğlu vd., 2018) çalışmalarında sözlük tabanlı bir yaklaşım izlemişlerdir. Twitter verilerini alıp klasik NLP yöntemleri ile veri temizleme yapmışlardır. Zemberek uygulamasını kullanarak tespit ettikleri kelime köklerini İngilizceye çevirmişlerdir. İngilizce olan SentiWordNet duygu sözlüğündeki kelime ağırlıklarından yararlanılarak cümleler, pozitif, negatif, nötr olarak sınıflandırılmıştır. Java programlama dilinde geliştirilen bu çalışmanın %80 doğruluk ile başarı elde ettiği görülmüştür.

Demir ve ark. (Demir vd., 2019) yaptıkları çalışmada, Afinn, Bing ve NRC olmak üzere üç farklı sözlük kullanmışlardır. Bu sözlüklerin tamamı çalışma kapsamında Türkçeye çevrilmiştir. Afinn Sözlüğü, – 5 (negatif) ve +5 (pozitif) arasında bir tamsayı ile ve elle derecelendirilen İngilizce terimler listesidir. Bing, kelimeleri ikili bir biçimde pozitif ve negatif kategoriler olarak sınıflandırır. NRC ise kelimeleri pozitif, negatif, öfke, beklenti, tiksinti, korku, sevinç, üzüntü, şaşkınlık ve güven kategorilerine sınıflandırır. Türkçeye çevrilen bu sözlükler, SentiTurkNet sözlüğü ile birleştirilmiştir. Bu sözlükler, bir araya getirilip değerlendirilerek duygu analizindeki kutupsallıkların belirlenmesi hedeflenmiştir. Geliştirilen sistemin görevi, kendisine sunulan metni oluşturan kelimeleri analiz ederek, o metnin içerdiği en baskın duyguya göre veya polariteye göre sınıflandırma gerçekleştirmektir. Geliştirilen uygulamada kullandıkları sözlük; sıfatlar, isimler, fiiller, zarflar, ön ekler, son ekler türünde kelimeler içermektedir. Kullanılan birinci sözlük 5.000 kelime, ikinci ve üçüncü sözlük yaklaşık 25.000 kelime içermektedir. Geliştirilen iki yöntemle üç farklı veri kümesi üzerinde deneyler yapılmıştır. Birinci yöntemde, "öfke, nefret, korku, mutluluk, üzüntü, sürpriz" duygu türüne göre sınıflandırma yapılmıştır. Birinci yöntem bu veri kümelerinde sırasıyla %77,14, %72,78 ve %74,17 doğruluk oranına ulaşmıştır. İkinci yöntemde "olumlu, olumsuz, zayıf, güçlü" duygu sınıflarına göre sınıflandırma yapılmıştır. İkinci yöntem ise aynı veri kümeleri üzerinde sırasıyla %82,85, %74,92 ve %77,50 doğruluk oranına erişmiştir. Yapılan deneysel çalışmaların sonuçları incelendiğinde sistemin hatalı karar verdiği cümlelerde hatalı yazılan kelimeler, kinayeli

yorumlar, art niyetli yazılmış yorumlar, bazı deyimlerin ve kelimelerin birden fazla anlamının olması, karşılaştırma içeren cümlelerin bir taraf için olumlu duygu taşırken diğer taraf için olumsuz duygu taşıması gibi durumların hatalı tespit işleminde etkin olduğu gözlemlenmiştir.

Yurtalan ve ark. (Yurtalan vd., 2019) yaptıkları çalışmada, bir cümlenin kutuplaşmasını etkileyen özel Türkçe kelimeler ve dilsel yapılar, bir Türk dil bilimcinin yardımıyla belirlenmekte ve bu dile uygun sözlük tabanlı kutup belirleme ve hesaplama yaklaşımı tanıtılmaktadır. Önerilen metodoloji, Twitter'dan toplanan farklı veri kümeleri kullanılarak test edilmiş ve test sonuçları, önerilen sistemin Türkçe için daha önce geliştirilen kelime tabanlı duygu analizi sistemlerinden daha iyi doğruluk elde ettiğini göstermiştir. Yazarlar, özellikle kelime gruplarının analizinin sistemin genel performansını önemli ölçüde artırdığı sonucuna varmıştır. Bir cümlenin kutuplaşmasını etkileyen özel Türkçe kelimeler ve dilsel yapılar, bir Türk dil bilimcinin yardımıyla belirlenmekte ve bu dile uygun sözlük tabanlı kutup belirleme ve hesaplama yaklaşımı getirilmektedir. Bu çalışmada, diğer sözlük tabanlı yaklaşımlardan farklı olarak deyim/atasözü çözümleyicisi kullanılmış olup bigram ve trigramlar ile kelime grupları analiz edilmiştir.

Yıldırım ve ark. (S. Yıldırım vd., 2019) yaptıkları çalışmada Twitter üzerinden belli etiketler ile toplanan Türkçe veriler üzerinde duygu analizi çalışması yapmışlardır. Duygu analiz yöntemi olarak varlık-görüş seviyesi ve cümle seviyesi kullanılmıştır. Bu çalışmada, var olan kütüphanelerden bazıları incelenmiş olup bunları genişleten kapsamlı bir kütüphane oluşturulmuştur. Daha önce yapılmış çalışmalara ek olarak kütüphaneye basit emoji karakterler ve puanlama altyapısı eklenmiştir. Ayrıca duygu kütüphanesine duygu yönelim gruplamaları ve duygu yoğunluğu parametreleri eklenmiştir. Böylelikle, cümle bazında seviyede yapılan analiz çalışmalarında oluşan anlam kayıplarından çıkan hatalar en aza indirilmiştir. Ek olarak, duygu kütüphanesine eklenen emojiler de duygu analizini destekleyecek şekilde puanlandırılmıştır. Böylelikle emojilerin duygu etkileri de kelimeler gibi dikkate alınmıştır. Ayrıca Türkçede yer alan kelime grupları ve ikilemeler de kapsama dâhil edilmiştir ve duygu yoğunluk değeri olarak daha büyük puanlar verilerek etkime oranı arttırılmıştır. Türkçe paylaşımlarda yaşanan sorunları çözmek için kelimelerden Türkçe klavyede yer alan ve İngilizce klavyede yer almayan harflerin yerine neler kullanılabileceği

belirlenerek bu kütüphane zenginleştirilmiştir. Bu sayede Twitter kullanıcılarının Türkçe metinleri İngilizce alfabe kullanarak yazmaları sonrasında oluşan paylaşımları da analiz edebilme kabiliyeti kazandırılmıştır. Ayrıca büyük, küçük harf karmaşasından oluşabilecek sorunlar içinde çözümler üretilmiştir. Bu çalışmada iki deney yapılmıştır. Deneylerden ilkinde, kullanıcıların paylaşımlarının hava durumuna göre değişen duygularını ölçme amacıyla analiz çalışmaları yapılmıştır. Bu çalışmalar sonrasında paylaşımlardaki duygu düzeyinin hava durumuna göre değişiklik gösterdiği sonucu ortaya çıkmıştır. Kış aylarında olumsuz, yaz aylarında ise pozitif paylaşım oranlarının arttığı gözlemlenmiştir. İkinci deneyde ise Türkçe paylaşım yapan Twitter kullanıcılarının bozuk dil kullanma, genelde olumsuz durumları daha çok ifade etme alışkanlıklarını ölçmek adına Survivor etiketi ile yapılan paylaşımlar incelenmiştir. Survivor izleyen kitlenin genel olarak olumsuz içerikli paylaşımlar yaptığı sonucu çıkartılmıştır.

Alkan ve ark. (Alkan vd., 2023) tarafından yapılan çalışmada, R yazılımında alana özel duygu sözlüğü oluşturularak sözlük tabanlı duygu analizinin Türkçe metinler üzerinde uygulanmasına yönelik kapsamlı bir yöntem önerilmiştir.

2.1.2. Makine Öğrenmesi Yaklaşımları

Makine öğrenmesi, bir sistem veya algoritmanın, verileri kullanarak deneyim kazanma ve bu deneyime dayalı olarak belirli bir görevi veya problemi çözme yeteneğini geliştirmek için kullanılan bir yapay zeka alt dalıdır. Support Vector Machines (SVM), Linear Support Vector Machines (Linear SVM), Decision Tree (DT), Random Forest (RF), Random Forest ile Support Vector Machines birlikte (RSVM), K-Nearest Neighbors (KNN), Naive Bayes (NB), Multinomial Naive Bayes (MNB), Logistic Regression (LR), Linear Regression (Linear R), Maximum Entropy (ME), Linear Discriminant Analysis (LDA) gibi algoritmalar, literatürde en çok kullanılan makine öğrenmesi algoritmalarındandır.

Makine öğrenmesi yaklaşımları, denetimli, yarı denetimli ve denetimsiz olmak üzere kendi içinde üç kategoriye ayrılmaktadır.

Denetimli Öğrenme

Bir modelin etiketli verilere dayalı tahminler yapmak üzere eğitildiği bir makine öğrenmesi yaklaşımıdır. Denetimli öğrenmede, model çok sayıda örnek içerir ve her örneğin hem girdi verileri hem de girdi verilerine karşılık gelen bir etiketi vardır. Denetimli öğrenme algoritmaları, giriş verileri ve hedef çıktılar arasındaki ilişkiyi öğrenerek model kurmak için kullanılır.

Shehu ve Tokat (Shehu ve Tokat, 2020) yaptıkları çalışmada, SVM'lerin negatif ve nötr verileri sınıflandırmada; RF algoritmasının ise pozitif verileri sınıflandırmada daha iyi performans gösterdiğini deneysel sonuçlar ile açıklamışlardır. Buradan yola çıkarak RF ve SVM'lerin hiyerarşik birleşiminden oluşan hibrit bir yaklaşım geliştirmişlerdir. Son olarak geliştirilen yaklaşım, iki farklı veri kümesi üzerinde test edilmiştir. Geliştirilen hibrit yaklaşımın sırasıyla birinci ve ikinci veri kümesinde %86,4 ve %82,8'e varan doğruluk elde ettiği görülmüştür.

Yarı Denetimli Öğrenme

Etiketlenmemiş veri varsa denetimli öğrenme de denetimsiz öğrenme de yetersiz kalabilir. Bu durumda en ideal yöntem az sayıdaki etiketlenmiş veriden hareketle etiketlenmemiş veriler hakkında bilgi sahibi olmaya çalışmak, onları sınıflandırmaktır. Bu yönteme de yarı denetimli öğrenme denir. Yarı denetimli öğrenme yöntemi ile ön plana çıkan çalışmalar aşağıda yer almaktadır.

Bilgin ve Şentürk (Bilgin ve Şentürk, 2019) yaptıkları çalışmada Türkçe ve İngilizce tweetler üzerinde duygusal sınıflandırma çalışması gerçekleştirmişlerdir. Doküman vektörleri (Doc2Vec) kullanılarak yapılan çalışmada hem DBOW ve DM gibi iki farklı doküman vektörü yönteminin çalışması, hem de yarı denetimli ve denetimli öğrenmenin etkileri, SVM kullanılarak araştırılmıştır. Hem Türkçe hem de İngilizce dilleri için hem etiketli hem de etiketsiz veri kümelerinin oluşturulması ile işe başlanmıştır. Elde edilen veri kümeleri üzerinde çeşitli ön işlemler gerçekleştirildikten sonra veriler eğitim için hazır hale

getirilmiştir. Eğitim aşamasında elimizdeki veriler yarı denetimli ve denetimli öğrenme kullanılarak Doc2Vec algoritmasının iki farklı yöntemi DBOW ve DM üzerinde çalıştırılarak bir model oluşturulmuştur. Oluşturulan modeller kullanılarak test aşamasına geçilmiştir. Gerçekleştirilen çalışma sonucunda yarı denetimli öğrenme yöntemi hem Türkçe hem de İngilizce veri kümesinde denetimli öğrenmeye göre daha başarılı sonuçlar elde etmiştir.

Rumelli ve ark. (Rumelli vd., 2019)[1] yaptığı çalışmada, NB, RF, SVM ve KNN algoritmaları olmak üzere dört farklı makine öğrenmesi yöntemi kullanmışlardır. Çalışmada, önerilen modelin, yeni Türkçe metinlerin duygu açıklamalarını hiçbir insan müdahalesi olmadan KNN algoritması ile %73,8'lik bir doğruluk başarı oranıyla gerçekleştirebildiği gösterilmiştir.

Şahinaslan ve ark. (Şahinaslan vd., 2022) çalışmalarında, NB sınıflandırma algoritması kullanarak sosyal medya verileri üzerinden dünya dillerinde yapılan yorum ve paylaşımların anlaşılmasına katkıda bulunmayı amaçlamışlardır. Dünyadaki farklı dil ve lehçelerde yapılan yorumlar üzerinden çok dilli duygu analiz çalışması sınırlıdır. Bu çalışmada, Türkçe, İngilizce, Almanca, Fransızca, Arapça, Rusça ve Korece gibi farklı dünya dillerinden YouTube yorum verileri kullanılmıştır. PHP ile elde edilen bu ham veriler üzerinden anlamsız veriler temizlenerek belirli bir kalitede veri kümesi elde edilmiştir. Bu yorum verilerini İngilizceye çevirmek için Google çeviri aracı API'si kullanılmıştır. Duygular, PHP Niiknow kütüphanesi üzerinden NB algoritması kullanılarak pozitif, negatif ve nötr olarak sınıflandırılmıştır. WEKA uygulaması ile yapılan veri analizinde doğru sınıflandırma oranı %65,56 olarak bulunmuştur. Bu çalışma, 15.082 veri kümesi ve Google çeviri aracı tarafından desteklenen 108 dil sayısı ile sınırlıdır. Çok dilli bir çalışma olduğundan doğruluk oranı başarılı bulunmuştur.

Uyaroğlu Akdeniz ve Cebeci (Uyaroğlu Akdeniz ve Cebeci, 2021) çalışmalarında, Sakarya ili özelini kapsayarak; Twitter kullanıcılarının Sakarya Büyükşehir, Adapazarı, Serdivan, Erenler ve Hendek belediyeleri hakkında paylaşımlarını incelemişler ve

[1] Rumelli ve ark. (Rumelli vd., 2019) tarafından yapılan çalışma hakkında detaylı bilgiler, ilerideki bölümlerde yer almaktadır.

vatandaşın belediyelere karşı tutumlarını analiz etmişlerdir. Belediye hesaplarına atılmış tweet metinleri toplanmış ve elde edilen bu veriler öncelikle makine öğrenmesi yöntemleriyle önceden belirlenmiş gruplara (Fen İşleri, Kültür İşleri, Sosyal Hizmetler, Spor Hizmetleri ve Çevre Hizmetleri) atanmıştır. Bu aşamada, NB, DT, GB[2] ve RF olmak üzere dört farklı makine öğrenmesi algoritması kullanılmış ve başarıları ölçülmüştür. En başarılı algoritma yaklaşık %92 doğruluk oranı ile NB olduğu için makine öğrenmesi yöntemi olarak NB seçilerek gruplandırma tamamlanmıştır. Daha sonra makine öğrenmesi ve derin öğrenme yaklaşımlarından biri olan Turkish Bert[3] yöntemi ile duygu analizi gerçekleştirilmiştir. Vatandaşların belediyelere karşı olan tutumu ortaya çıkmış, olumlu ve olumsuz yanıyla değerlendirmeye tabi tutulmuştur.

Sağbaş (Sağbaş, 2023) yaptığı çalışmada, farklı öz nitelik seçim yöntemlerinin performansını test ederken dokuz veri kümesi için MNB sınıflandırıcısını kullanarak ortalama %94,34 doğruluk oranlarına ulaştığını göstermiştir.

Denetimsiz Öğrenme

Bu model, denetlenmeye gerek olmayan bir makine öğrenme tekniğidir. Denetimsiz öğrenmede sisteme herhangi bir şey öğretilmez; model, verilerden kendi öğrenir. Denetimsiz makine öğrenimi, verilerdeki bilinmeyen her türlü örüntüyü bulur. Literatür incelendiğinde, Türkçe duygu analizinde denetimsiz makine öğrenme yaklaşımları kullanılarak yapılan çalışmaların sayısı oldukça azdır. Denetimsiz öğrenme algoritmaları kullanılarak gerçekleştirilen güncel bir çalışmaya bu bölümde yer verilmektedir.

Desai (Desai, 2018) çalışmasında, Fuzzy C-Means (FCM) ve Possibilistic Fuzzy C-Means (PFCM) algoritmalarını ayrı ayrı SVM ile birlikte uygulayarak film tweetlerinde duygu analizi çalışması gerçekleştirmiştir. Çalışmada kullanılan denetimli makine öğrenmesi algoritmaları, SVM ve NB; denetimsiz makine öğrenmesi algoritmaları ise FCM ve PFCM'dir. Öz nitelik seçme metotlarından, emoticons, synonyms ve 3-gram

[2] Gradient Boosting (GB), topluluk öğrenmesi (ensemble learning) yöntemi olduğundan ilgili bölümde de değinilmektedir.
[3] BERT yöntemi, derin öğrenme (deep learning) yöntemi olduğundan ilgili bölümde de değinilmektedir.

kullanılmıştır. Çalışma sonucunda, SVM + PFCM'nin %91,67 doğruluk oranı ile SVM + FCM'den daha başarılı sonuç elde ettiği görülmüştür.

Derin Öğrenme

Bir veya daha fazla gizli katman içeren yapay sinir ağlarını kullanarak karmaşık problemleri çözmek ve veri analizi yapmak için kullanılan bir makine öğrenme alt dalıdır. Derin öğrenme algoritmaları yapay sinir ağlarının (YSA) yapısal olarak daha karmaşık hali olarak düşünülebilir. Derin öğrenmenin tek katmanlı yapay sinir ağlarından farkı, lineer olmayan problemlerin çözülmesine olanak tanımasıdır. Convolutional Neural Networks (CNN), Recurrent Neural Networks (RNN), Bidirectional Recurrent Neural Networks (Bi-RNN), Long Short-Term Memory (LSTM), Bidirectional Long Short Term Memory (Bi-LSTM), Gated Recurrent Unit (GRU), Bidirectional Gated Recurrent Unit (Bi-GRU), Neural Network Architecture (NN), Multi Layer Perceptron (MLP), Hierarchical Attention Network (HAN) ve Bidirectional Encoder Representations from Transformers (BERT) gibi doğal dil işleme modelleri, literatürde en çok görülen derin öğrenme modellerindendir.

Derin öğrenme yöntemleri, denetimli, yarı denetimli ve denetimsiz öğrenme problemlerini çözmek için kullanılabilir. Her biri belirli uygulamalarda ve veri türlerinde etkili olabilir. Derin öğrenme, bu üç öğrenme türünü ele almak için çok sayıda model ve algoritma sunar. Herhangi bir derin öğrenme modeli, veri türüne ve problemin karmaşıklığına bağlı olarak tercih edilebilir. Ayrıca, transfer öğrenme gibi teknikler de denetimli, yarı denetimli ve denetimsiz öğrenmeyi birleştirmek için kullanılabilir. Derin öğrenme yöntemleri kullanılarak gerçekleştirilen güncel çalışmalara bu bölümde yer verilmektedir.

Salur ve Aydın (Salur ve Aydın, 2018) çalışmalarında, Twitter mesajları üzerinde ikili sınıflandırma (olumlu, olumsuz) işlemini, makine öğrenmesi algoritmaları (KNN, LDA, DT, SVM, LR) ve derin öğrenme algoritması olan CNN ile gerçekleştirmişler ve paket boyutunun (batch size) sınıflandırmaya etkisini incelemişlerdir. Çalışma neticesinde, derin

öğrenme algoritması, diğer beş makine öğrenmesi algoritmalarına kıyasla yaklaşık %10 daha yüksek başarı oranıyla veri kümesini sınıflandırmıştır.

Ciftci ve Apaydin (Ciftci ve Apaydin, 2018) çalışmalarında, Türkçede duygu analizi için derin öğrenme yöntemlerinin kullanılmasını önermişlerdir. Duygu analizi çalışmalarında genellikle kelimelerin cümle içindeki sırasını dikkate almayan kelime torbası (BoW) yaklaşımları, LR veya NB gibi geleneksel makine öğrenmesi yöntemleri ile kullanıldıklarında uygulanabilirliklerinin sınırlı olduğunu belirtmişlerdir. Bu çalışmada, geleneksel makine öğrenimi yaklaşımları, Türk alışveriş ve film sitelerinden taranan bir veri kümesi üzerinde, RNN tabanlı bir yaklaşım olan LSTM modeli ile karşılaştırılmıştır. Python programlama dili kullanılan çalışmada, veriler önce kelime vektörlerine çevrilmiştir, ardından LSTM modele verilmiştir. LSTM model %83,3 doğruluk oranında başarı elde etmiştir. Sonuçlar, kelime vektörü girdileriyle çalışan RNN tabanlı yaklaşımların sınıflandırma doğruluğunu arttırdığını göstermektedir.

Yusufoğlu ve ark. (Yusufoğlu vd., 2021) çalışmalarında, duygu analizi kullanarak LSTM modeli üzerinde EUR/USD değerlerini tahmin edebilen derin öğrenmeye dayalı bir model geliştirmeyi amaçlamışlardır. Bu amaç doğrultusunda çalışmada veri kümelerinin belirlenmesi ve modelin eğitimi/testi olmak üzere iki farklı uygulama gerçekleştirilmiştir. Çalışmada gerçekleştirilen ilk uygulama veri kümesinin oluşturulmasını içermektedir. Veri kümesinin oluşturulmasında ilk adım olarak Twitter üzerindeki "#eurusd" konu etiketli veya "eurusd" kelimesini barındıran filtrelenmiş İngilizce tweet mesajları içeriklerine göre duygu analizi yöntemiyle sınıflandırılmıştır. Bu maksatla her bir tweetin olumlu, olumsuz veya tarafsız (nötr) olup olmadığı belirlenmiş ve günlük olarak bu tweetlerin duygu oranlarının ortalamaları hesaplanmıştır. Veri kümesinin oluşturulmasındaki ikinci adım finance.yahoo.com sitesinden günlük olarak EUR/USD değerlerinin elde edilmesi aşamasıdır. Son aşama ise elde edilen verilerin zaman serisine dayalı olarak "csv" formatında birleştirilmesidir. Veri kümesi belirlendikten sonra LSTM tahmin modelinin eğitimi ve testi aşamasına geçilmiştir. LSTM, uzun vadeli bağımlılıkları öğrenebilen bir derin öğrenme algoritmasıdır. Bu aşamada en yüksek başarı oranına sahip LSTM tahmin modelini belirlemek maksadıyla eğitim adımlarının ve LSTM sinir ağı katman yapısının değiştirilmesi suretiyle farklı deneyler yapılmıştır. Yapılan bu deneyler sonucunda %94,48

başarı oranına sahip en iyi LSTM modeli belirlenmiştir. Araştırmanın sonuçları yapay zeka algoritmaları ile duygu analizi açısından önemli bilgiler içermesinin yanı sıra, gelecekte farklı sektörlerde uygulanması açısından değer taşıdığı görülmektedir.

Uca ve ark. (Uca vd., 2022) çalışmalarında, sağlık alanında var olan verilerin duygu analizi ile sınıflandırmasını yapmışlardır. Bu çalışmada, duygu analizinin gerçekleştirimi için LSTM derin öğrenme modeli kullanılmıştır. LSTM uzun metinlerin işlenmesinde çok başarılı olmuştur. Model eğitimi sonucunda %94 başarı elde edilmiştir. Elde edilen bu sonuç, diğer iyi bilinen sınıflandırıcılarla karşılaştırıldığında etkinliği ikna edici şekilde kanıtlanmaktadır.

Colón-Ruiz ve Segura-Bedmar (Colón-Ruiz ve Segura-Bedmar, 2020) çalışmalarında, CNN ve RNN tabanlı LSTM gibi çeşitli derin öğrenme mimarilerinin karşılaştırmasını sunmuşlardır. Bu modellerin çeşitli kombinasyonlarını denemişler ve ayrıca önceden eğitilmiş farklı kelime gömme (word embedding) modellerinin etkisini de incelemişlerdir. Transformatörler, birçok NLP görevi için en son teknolojiye sahip sonuçlar elde ederek bu alanda devrim yarattığından, ilaç incelemelerinin duygu analizi için Bi-LSTM ile BERT modelini de araştırmışlardır. Deney sonuçları, BERT kullanımının çok yüksek bir eğitim süresiyle en iyi sonuçları verdiğini göstermektedir. BERT, en doğru kelime yerleştirmeyi sağlamak için kelimenin bulunduğu yerdeki bağlamı dikkate alarak vektör üretmektedir. Öte yandan CNN'nin daha az eğitim süresi gerektirerek kabul edilebilir sonuçlar elde ettiği görülmüştür. Sonuç olarak, BERT ile LSTM'nin bir arada kullanıldığı model, en iyi performansı sağlamıştır.

Demirci ve ark. (Demirci vd., 2019) çalışmalarında veri kümesini klasik NLP yöntemlerini kullanarak ön işleme tabi tutmuşlardır. Ardından modellerin uygulanması için veri kümesini vektörleştirmek ve hazırlamak amacıyla üç farklı veri öz nitelik seçme yöntemi olan BoW, TF-IDF, Word2Vec kullanmışlardır. Daha sonra makine öğrenmesi ve derin öğrenme yöntemlerini uygulayıp sonuçlara bakarak karşılaştırmışlardır. LR, SVM, RF ve NN modelleri 3 farklı kelime gömme yöntemi ile (BoW, TF-IDF, Word2Vec) denenmiştir. Bu karşılaştırmada derin öğrenmenin doğruluğunun geleneksel makine

öğrenmesi algoritmalarından daha yüksek olduğu gözlemlenmiştir. En başarılı yöntem, 16 batch boyutlu, 50 epoch değeri ile gerçekleştirilen NN derin öğrenme modelinin %81,86 doğruluk oranına ulaştığı görülmüştür.

Toçoğlu ve ark. (Toçoğlu vd., 2019) yaptıkları çalışmada, Türkçe metinlerden duygu çıkarımı alanında kullanılan ve bir anket çalışması sonucu oluşturulan TREMO veri kümesi üzerinde farklı makine öğrenmesi algoritmalarının sınıflandırma sonuçlarını karşılaştırmışlardır. Duygu analizi bir metin sınıflandırma problemi olarak ele alınmış ve MLP, SVM, RF ve KNN algoritmaları olmak üzere dört yaklaşım incelenmiştir. İncelenen duygu kategorileri olarak veri kümesinin sağladığı, mutluluk, korku, öfke, üzüntü, tiksinme ve şaşırma kategorileri kullanılmıştır. Veri ön işleme bölümünde, veri kümesini oluşturan kelimelerin kökleri ilk beş karakter (F5) yöntemi kullanılarak tespit edilmiştir. Kelimeler kök haline getirildikten sonra Vektör Uzay Modeli ile veri kümesi modellenmiş ve her duygu için en önemli ilk 500 kelime Karşılıklı Bilgi (Mutual Information, MI) yöntemi ile tespit edilmiştir. Sınıflandırma sonuçlarının karşılaştırılmasında doğruluk metriği esas alınmıştır. Deneysel çalışma sonuçlarına göre, YSA algoritması olan MLP en iyi sonucu vermiştir. SVM, RF ve KNN algoritmaları ise sırasıyla azalan başarım göstermişlerdir.

Tuzcu (Tuzcu, 2020) yaptığı çalışmada, çevrim içi bir kitap satış sitesinin kullanıcı yorumları üzerinde duygu analizi için öncelikle Python programlama dili kullanarak MLP algoritmasını uygulamıştır. MLP, yapay sinir ağlarının bir türüdür ve makine öğrenmesi ile derin öğrenme modellerinin temelini oluşturan bir yapıdır. MLP, birden çok gizli katmanı içeren bir yapay sinir ağı modelini ifade eder. Her katmandaki nöronlar, önceki katmandaki nöronlarla bağlantılıdır ve bu bağlantılar üzerinden veriyi işler. Tuzcu çalışmasında, daha sonra bir veri bilimi yazılımı olan RapidMiner kullanarak, aynı veri kümesi üzerinde NB, SVM ve LR algoritmalarını uygulamıştır. Algoritmaların yorumları sınıflandırma başarıları karşılaştırılmış ve MLP, bu veri kümesinde en iyi sonuçları gösteren algoritma olmuştur. Ayrıca, sinir ağını optimize etmek için ise Stokastik Gradyan İniş (Stochastic Gradient Descent) optimizasyon algoritması kullanılmıştır.

Shehu ve ark. (Shehu vd., 2021) yaptıkları çalışmada, geleneksel makine öğrenme algoritmaları ile derin öğrenme algoritmalarını karşılaştırmışlardır. Öncelikle eğitim verilerinin boyutunu artırmak için Shift, Shuffle ve Hybrid olmak üzere üç veri büyütme tekniği kullanmışlardır. Daha sonra duygu analizi için kelime kökleri tespit edilmiş, Türkçe twitter verilerini sınıflandırmak amacıyla RNN, CNN ve HAN olmak üzere üç temel derin öğrenme modeli kullanmışlardır. Bu derin öğrenme modellerinin performansı mevcut geleneksel makine öğrenimi modelleriyle (RSVM, RF, ME, SVM ve DT) karşılaştırılmıştır. HAN derin öğrenme modeli, belirli bir bağlamı dikkate alarak cümledeki en önemli kelimeleri bulan bir dikkat mekanizması içerdiğinden bu araştırmada kullanılmak üzere seçilmiştir. Geleneksel makine öğrenimi modellerinin performansı, kelime kökleri tespit edilmiş verilerden olumsuz yönde etkilenmiş, ancak veri artırma tekniklerinin kullanılmasıyla derin öğrenme modellerinin performansı büyük ölçüde iyileştirilmiştir. Sonuç analizine dayanarak, geleneksel makine öğrenimi modellerinin hem eğitim zamanı hem de çalışma zamanı karmaşıklıkları açısından derin öğrenme modellerinden daha iyi performans gösterdiği sonucuna varılmıştır. Bunun yanında derin öğrenme modelleri, başarı ortalaması açısından da geleneksel makine öğrenimi modellerinden daha iyi performans göstermektedir. Ayrıca, bu çalışmadaki deneysel sonuçlar, veri büyütme tekniğinin köklü Türkçe metin verileri üzerinde uygulanmasının, derin öğrenme modeliyle elde edilen performansta önemli bir artışa yol açabileceği fikrini vermiştir.

Acikalin ve ark. (Acikalin vd., 2020) çalışmalarında, duygu analizinin, oldukça popüler bir araştırma alanı olmakla birlikte, araştırmaların büyük bir kısmının İngilizce üzerine yapılmış olup, Türkçe üzerine yapılan çalışmaların kısıtlı sayıda olduğunu belirtmişlerdir. Türkçe için diğer dillere nazaran daha kısıtlı olan doğal dil işleme kaynakları da bu konuda yapılan araştırmalar için büyük bir engel teşkil etmektedir. Bu kısıtlamaları aşmak için, bu çalışmada iki türlü yaklaşım önerilmiştir: Bunlardan birincisi, BERT'in çok dilli modelinin Türkçe duygu analizi için uyarlanması, ikincisi ise Türkçe metinlerin önce İngilizceye otomatik tercümesi yapılıp BERT'in ana modelinin kullanılmasıdır. Gerçekleştirilen bu çalışmada, Türkçe duygu analizi için BERT bazlı üç farklı model geliştirilmiştir. Bu modeller, çok dilli modelin Türkçe metinler ile eğitilmesi ve Türkçe metinlerin önce otomatik tercüme ile İngilizceye çevrilip BERT'in temel ve büyük modellerinin eğitilmesi ile oluşturulmuştur. Film ve otel yorumlarından oluşan, pozitif ve

negatif olmak üzere 2 etikete sahip Türkçe veri kümeleri üzerinde yapılan deneylerde BERT modelleri, yüksek başarım elde etmiştir. Çalışma sonunda, FastText ile BERT modelleri karşılaştırılmıştır. Otel ve film yorumlarını içeren iki farklı veri kümesinde gerçekleştirilen deneylerde elde edilen sonuçlar şu şekilde özetlenmiştir: BERT modeli FastText'e göre farklı temalardaki metinlerin duygusunu analiz etmede daha başarılıdır. Yeterli miktarda eğitim verisi olduğunda, çok dilli BERT modeli yerine, otomatik tercüme ile metinlerin İngilizceye çevrilip sadece İngilizce için geliştirilmiş olan BERT modellerini kullanmak daha iyi sonuç vermektedir. BERT modelleri film veri kümesinde var olan çalışmalardan daha yüksek başarım elde etmiştir. Çalışma sonucunda, gelecekte BERT'in çok dilli versiyonu yerine sadece Türkçe için bir model geliştirilip duygu analizi için kullanılmasının daha yararlı olacağı belirtilmiştir.

Punith ve Raketla (Punith ve Raketla, 2021) çalışmalarında, ELMo kelime gömme (word embedding) içeren sinir ağı tabanlı modeller oluşturmuşlar ve BERT, XLNET ve BERT modelinin diğer varyantları gibi çeşitli transformers tabanlı sınıflandırmalarla karşılaştırmışlardır. BERT, diğer dil modellerinden farklı olarak, metin içeriğini her iki yönde de anlayabilen bir modeldir. BERT, bir kelimenin anlamını ve bağlamını hem önceki hem de sonraki kelimeleri göz önünde bulundurarak belirleyebilir. XLNET ise her bir kelimenin herhangi bir diğer kelimeye bağımsız olarak dikkate alındığı ve tahmin edildiği kendi kendine dikkat (self-attention) mekanizmasını kullanır. XLNET, önceki transformer modellerinden farklı bir öğrenme paradigması kullanır ve "Transformer-XL" ve "ELMo" gibi diğer NLP modellerinin özelliklerini bir araya getirerek daha iyi performans sağlar. Bu çalışmanın ilaç incelemelerinden oluşan veri kümesi kullanılarak çeşitli önceden eğitilmiş kelime yerleştirme modellerinin, transformatörler ve derin sinir ağı mimarileriyle birlikte karşılaştırıldığı bir çalışma olduğu görülmektedir. Önerilen araştırma çalışması, çoklu derin öğrenmeye dayalı sınıflandırma sistemlerine örnek teşkil etmektedir. Çalışma sonucunda, ConvBERT modelinin %94,3 doğruluk oranı ile en başarılı model olduğu görülmüştür.

Guven (Guven, 2021) yaptığı çalışmada, İngilizce dilinde BERT modeli gibi dil modelleri yaygın olarak kullanılırken, duygu analizi konusunda Türkçe için çok az çalışma bulunduğunu belirtmiştir. Bu çalışmada BERT modelleri ve makine öğrenmesi yöntemleri kullanılarak Türkçe tweetler üzerinde duygu analizi yapılmıştır. Ayrıca eğitilen BERT

modelleri ile makine öğrenme yöntemleri karşılaştırılmıştır. Makine öğrenmesi yöntemlerinden RF, NB ve LR kullanılmış olup bunlar arasında LR %98,4 ile en başarılı yöntem olmuştur. BERT modellerinden ise BERT-Turkish (Bert-T), BERT-Multilingual (Bert-M), DistilBERT-Turkish (Dbert-T) kullanılmış olup bunlar arasında Bert-T %98,75 ile en başarılı yöntem olmuştur. Sonuçlar, genel olarak incelendiğinde ise BERT modelleri %98,75 doğruluk elde ederek makine öğrenimi yöntemlerinin başarısını geride bırakmıştır. BERT modelinin duygu analizi üzerindeki olumlu etkisi gösterilmiştir.

Gündüz (Gündüz, 2023) tarafından yapılan çalışmada, Türkçe film sitesi beyazperde.com'dan derlenen film yorumları üzerinde duygu analizi yapılmıştır. Önerilen yöntem ön eğitimli BERTurk modelini temel almıştır. Yapılan ilk deneyde BERTurk modelinin sondan bir önceki dönüştürücü katmanından derin temsiller çıkarılmış ve bu temsiller SVM modeline girdi olarak verilmiştir. İkinci deneyde BERTurk üzerinde ince ayarlama yapılarak sınıflandırma gerçekleştirilirken, son deneyde ince ayarlı BERTurk modelinden ilk deneyde olduğu gibi derin temsiller çıkarılmış ve SVM ile sınıflandırma yapılmıştır. Yapılan deneylerde en yüksek doğruluk oranına %98,4 ile ince ayarlı BERTurk temsilleriyle ulaşılmıştır. İnce ayar işlemi sonunda elde edilen temsiller doğruluk oranında yaklaşık %10'luk artışa neden olurken, sınıflandırmada direkt olarak BERTurk yerine BERTurk'ten elde edilen temsiller ile SVM'nin birleşiminin kullanılması yaklaşık %5'lik doğruluk artışıyla sonuçlanmıştır.

Savci ve Das (Savci ve Das, 2023) çalışmalarında Türkçe, İngilizce ve Arapça için e-ticaret verilerini içeren yeni veri kümeleri oluşturmuş ve ilk kez üç farklı dildeki metinlerden karşılaştırmalı duygu analizi yapmışlardır. Ayrıca bu çalışma ile hem Türkçe, Arapça ve İngilizce için önceden eğitilmiş dil modellerinin hem de derin öğrenme ve makine öğrenmesi modellerinin performansları karşılaştırılarak oldukça kapsamlı bir çalışma, araştırmacılara sunulmuştur. Bu çalışma ile popüler derin öğrenme, makine öğrenmesi yaklaşımları ve önceden eğitilmiş dil modellerinin farklı dillerde yazılmış, düzensiz, farklı kelime türleri ve yazım yanlışları içeren metinler üzerindeki performansları karşılaştırılarak bu yaklaşımların başarıya katkısı incelenmiştir. Üç farklı yöntem uygulanmıştır. Birinci yöntem olarak, makine öğrenmesi yaklaşımlarından MNB, SVM ve RF algoritmaları uygulanmıştır. İkinci yöntem olarak, derin öğrenme yaklaşımlarından RNN, CNN ve LSTM

uygulanmıştır. Üçüncü yöntem olarak ise önceden eğitilmiş dil modellerinden olan Bert-base-multilingual-cased, Convbert-base-turkish-cased, Distilbert-base-turkish-cased modelleri uygulanmıştır. Savci ve Das'ın çalışmalarında, Türkçe için önceden eğitilmiş dil modelleri hakkında aşağıdaki bilgiler verilmiştir:

Bert-base-multilingual-cased: Bu model, maskeli dil modelleme kullanan, 104 dilde Vikipedi ile önceden eğitilmiş bir transformatör modelidir ve büyük/küçük harfe duyarlıdır. Modelde, kelimelerin %15'i rastgele girdi olarak maskelenmekte ve maskelenen cümlenin tamamı model üzerinde çalıştırılarak maskelenen kelimeler tahmin edilmektedir. Ayrıca bu model, iki cümlenin birbirini takip edip etmediğini tahmin edebilmektedir (Savci ve Das, 2023).

Convbert-base-Turkish-cased: Bu dil modeli aynı zamanda mC4 derleminin Türkçe kısmında bir ConvBERT modelini de eğitmiştir. Bu modelde tüm eğitim süresi boyunca 512 dizi uzunluğu kullanılmaktadır (Savci ve Das, 2023).

Distilbert-base-Turkish-cased: Bu dil modeli, BERTurk'ün eğitimlerinde kullanılan orijinal eğitim verilerinin 7 GB'ının üzerinde Türkçe için tasarlanmış bir BERT modelidir (Savci ve Das, 2023).

Yukarıda belirtilen bilgiler ışığında Savci ve Das, diğer çalışmalardan farklı olarak verilerden olumlu, olumsuz ve nötr duygu sınıflarını çıkarmak için önceden eğitilmiş farklı dil modellerini de kullanmışlar ve bu modellerin duygu analizindeki doğruluk performansına katkılarını araştırmışlardır. Deneysel sonuçlar, önceden eğitilmiş dil modellerinin üç sınıf duygu analizinde iyi performans sonuçları elde ettiğini göstermiştir. Arapçada bert-base-multilingual-cased model %95,1; İngilizcede distilroberta bazlı model %91,4; Türkçede ise convbert-base-turkish-cased model %88,4 ile ön eğitimli modeller arasında en yüksek doğruluğa ulaşmıştır. Türkçe için diğer yaklaşımlara bakıldığında SVM %91, RNN ise %87,1 doğruluk oranına ulaştığı ve Türkçe için en yüksek başarı performansını SVM'nin gösterdiği görülmektedir.

Bozuyla (Bozuyla, 2023) yaptığı çalışmada, tıbbi alanda yapılan Türkçe araştırmaların sınırlı olduğunu ve özellikle ilaç incelemeleri alanında duygu analizi ile ilgili bir çalışma bulunmadığını belirtmiştir. Bu çalışmada, bir Türkçe ilaç inceleme veri kümesi oluşturulmuştur. Geleneksel makine öğrenimi algoritmaları için ön işleme aşamasında, klasik NLP yöntemleri, BoW, TF-IDF ve Zemberek uygulaması kullanılmıştır. Ardından, NB, MNB, LR, SVM, KNN, J48, RF makine öğrenme algoritmaları uygulanmıştır. Derin öğrenme algoritmaları için ön işleme ve öz nitelik seçme aşamasında ise Word2Vec kelime gömme algoritması kullanılmıştır. Ardından, LSTM, Bi-LSTM, RNN, Bi-RNN, GRU, Bi-GRU, CNN derin öğrenme algoritmaları uygulanmıştır. Transformers modelleri için ön işleme aşamasında tokenization, padding ve mask creation kullanılmıştır. Ardından, BERT, RoBERTa, DistilBERT, BERTurk transformers modelleri uygulanmıştır. Sonuçlar, Türkçeye özel olan BERTurk transformers modelinin %95,1 ağırlıklı F1 puanı ile en iyi performansa ulaştığını göstermiştir.

Topluluk Öğrenmesi

Topluluk öğrenme yöntemleri hem makine öğrenmesi hem de derin öğrenme alanlarında kullanılabilen bir tekniktir. Bu yöntemler, birçok temel modeli bir araya getirerek daha güçlü ve daha istikrarlı bir tahmin veya sınıflandırma sonucu elde etmeyi amaçlar. Adaptive Boosting (AdaBoost), Gradient Boosting (GB), Bagging, Random Subspace gibi algoritmalar topluluk öğrenmesi algoritmalarındandır. Topluluk öğrenmesi algoritmaları kullanılarak gerçekleştirilen güncel çalışmalara aşağıdaki bölümde yer verilmektedir.

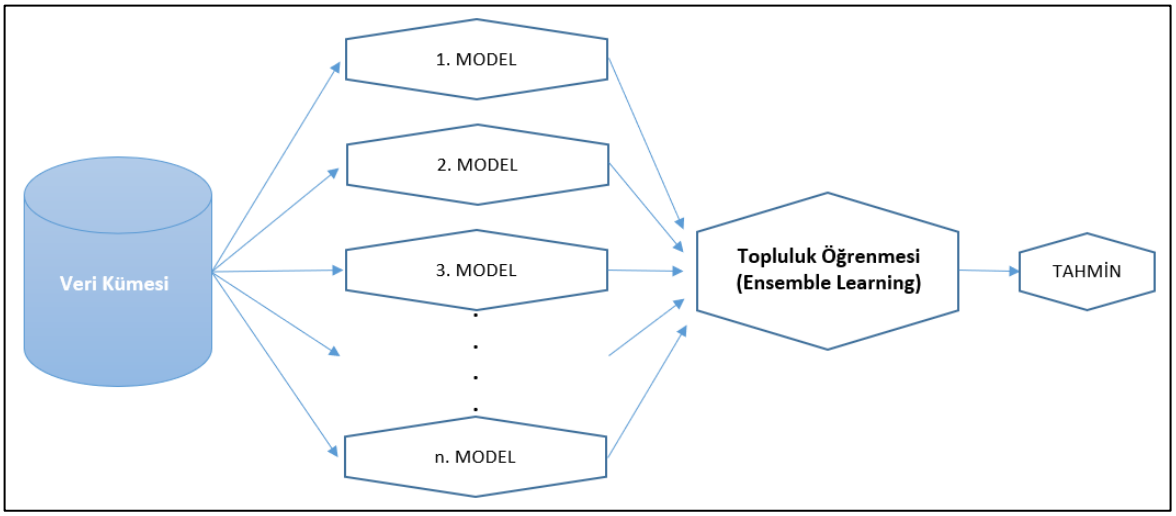

Şekil 2. Topluluk öğrenmesi.

Onan (Onan, 2021) yaptığı çalışmada, kısa metin mesajları için uygun terim temsil şemasının belirlenmesinin çok önemli bir görev olduğunu belirtmiştir. Vektör uzayı modelinde terim ağırlıklandırma şemaları, metin belgelerini temsil eden önemli şemalardır. Bu çalışmada, denetimli ve denetimsiz dokuz terim ağırlıklandırma şemasıyla Türkçede duygu analizi üzerine kapsamlı bir analiz sunulmuştur. Bunlar; Term frequency (TF), Term frequency-inverse document frequency (TF-IDF), Odds ratio (OR), Relevance frequency (RF), Balanced distributional concentration (BDC), Inverse question frequency (IQF), Short text weighting (SW), Inverse gravity moment (IGM), Regularized entropy (RE) şemalarıdır. Dört denetimli öğrenme algoritması (NB, SVM, KNN ve LR) ve üç topluluk öğrenme yöntemi (AdaBoost, Bagging ve Random Subspace), terim ağırlıklandırma şemalarının tahmin verimliliğini araştırmak için kullanılmıştır. Deneysel sonuçlar, denetimli terim ağırlıklandırma modellerinin, denetimsiz terim ağırlıklandırma modellerinden daha iyi performans gösterdiğini kanıtlamıştır. Regularized entropy (RE) terim ağırlıklandırması ile Random Subspace (SVM) kombinasyonu, karşılaştırılan tüm konfigürasyonlar arasında %89,76 doğruluk oranı ile en iyi tahmin sonucunu üretmiştir.

Aydın ve Güngör (Aydın ve Güngör, 2021) çalışmalarında, Türkçede iki sınıflı (pozitif, negatif) duygu sınıflandırma problemi için bir çerçeve geliştirmişlerdir. Dokümanlar öncelikle dile özel kapsamlı ön işleme işlemlerine tabi tutulmuş, daha sonra normalize edilmiş metinlerden özellikler çıkarılmıştır. Üç ana yaklaşımı takip eden yöntemler önerilmiştir. Birinci yaklaşım olan denetimsiz/yarı denetimli yaklaşımda, bir dizi

zıt anlamlı kelime kullanılarak kelimelerin kutupsallık puanı belirlenmiş ve ardından bir belgenin duygusu, içerdiği kelimelerin puanlarının toplamı olarak elde edilmiştir. İkinci yaklaşım olan denetimli yaklaşımda, yeni ölçümler de dahil olmak üzere çeşitli özellik ağırlıklandırma ölçümleri kullanılmış ve denetimli sınıflandırıcılardan oluşan bir topluluk oluşturulmuştur. Denetimli yöntemler klasik öğrenme algoritmaları (J-48, SVM, KNN, NB) ve derin öğrenme modelleri (CNN, LSTM) olmak üzere iki grupta analiz edilmiştir. Son olarak üçüncü yaklaşımda ise denetimsiz ve denetimli yaklaşımlar birleştirilmiştir. Bu sayede hem etiketli verileri hem de etiketsiz verileri kullanan bir topluluk modeli oluşturulmuştur. Sonuçları birleştiren veya birbiriyle etkileşimde bulunan algoritmaların daha iyi bir sonuç elde etmek için birlikte çalıştırılabileceği görülmüştür.

2.1.3. Hibrit Yaklaşımlar

Hibrit yaklaşımlar ise hem sözlük tabanlı yaklaşımların hem makine öğrenmesi yaklaşımlarının hem de derin öğrenme yöntemlerinin bir arada kullanıldığı çalışmalarda görülmektedir. Hibrit yaklaşım izleyen bazı duygu analizi çalışmalarına aşağıda yer verilmektedir.

Rumelli ve ark. (Rumelli vd., 2019) çalışmalarında, Türkçe metinler için bir duygu analizi modeli geliştirmişlerdir. Bu model geliştirilirken sözlük tabanlı yöntemler ve makine öğrenmesi algoritmaları bir arada kullanılmıştır. Duygu analizi yöntemi olarak, bir cümledeki her kelimenin kökü sözlükten puan alır ve ilgili cümlenin son polarite puanı, toplamsal puana dayalı modeller kullanılarak hesaplanır. Makine öğrenimi modelleri, metinlerin kutupsallık puanlarına dayalı özellikleri kullanarak doğru duygu açıklamaları gerçekleştirecek şekilde eğitilir. Çalışmada NB, RF, SVM ve KNN algoritmaları olmak üzere dört farklı makine öğrenmesi yöntemi kullanılmıştır. Çalışmada, önerilen modelin, yeni Türkçe metinlerin duygu açıklamalarını hiçbir insan müdahalesi olmadan %73'e varan bir başarı oranıyla gerçekleştirebildiği gösterilmiştir. Çalışmada en başarılı yöntem %73,8 başarı oranı ile KNN algoritması olmuştur.

Erşahin ve ark. (Erşahin vd., 2019) çalışmalarında, Türkçe duygu analizi için sözlük tabanlı ve makine öğrenimi tabanlı yaklaşımları birleştiren hibrit bir metodoloji sunmuşlardır. Sözlük tabanlı tarafta, eş anlamlılar sözlüğüyle genişletilmiş bir duygu sözlüğü kullanmışlardır. İlk kapsamlı Türkçe sözlük SentiTurkNet (STN), otomatik eşanlamlı sözlüğü (ASDICT) kullanılarak genişletilmiştir. Bunun yanı sıra, sınıflandırma problemi için makine öğrenmesi tarafında, NB, SVM ve bir DT algoritma türü olan J48 yöntemleri kullanılmıştır. Hibrit metodolojileri, özellik oluşturma algoritmasına göre yeni bir sözlük tabanlı değer üreterek bu iki yaklaşımı birleştirir ve bunu özelliklerden biri olarak makine öğrenimi sınıflandırıcılarını besler. Türkçenin morfolojik yapısından kaynaklanan dilsel zorluklara rağmen deneysel sonuçlar, hibrit yaklaşımın, doğruluğu ortalama %7 oranında artırdığını göstermiştir.

Karagoz ve ark. (Karagoz vd., 2019) çalışmalarında, Türkçe metinlerde hedef tabanlı duygu analizi problemine yönelik bir çerçeve sunmuşlardır. İlk aşamada, konunun hedeflerine karşılık gelen kelimelerin tespiti olan hedef çıkarma işlemini gerçekleştirmişlerdir. İkinci aşamada, tespit edilen hedefleri, duygu sözlüğü kullanarak hedef-duygu eşleştirmesi yapmışlardır. Son aşamada ise hem LSTM hem de Conditional Random Fields (CRF) kullanılarak duygu çıkarımında bulunmuşlardır. LSTM için Python Keras kütüphanesinden, CRF için ise MALLET (Machine Learning for LanguagE Toolkit) aracından yararlanmışlardır. Bu açıdan düşünüldüğünde sözlük tabanlı yaklaşımın, makine öğrenmesi ve derin öğrenme yaklaşımları birlikte kullanılarak hibrit bir yol izlendiği görülmektedir.

Polat ve Ağca (Polat ve Ağca, 2022) çalışmalarında, TripAdvisor kullanıcılarının Türkçe ve İngilizce yorumlarındaki duygusal eğilimlerin ortaya çıkarılması ve sınıflandırılması amacıyla, sözlük tabanlı duygu analizi yöntemleri ile makine öğrenmesi algoritmalarını kullanan duygu analizi yöntemlerini karşılaştırmışlardır. Amaç kapsamında makine öğrenme yöntemlerinden DT, RF gibi sınıflandırma algoritmaları kullanılmıştır. Nicel araştırma özelliği gösteren bu çalışma kapsamında veriler, TripAdvisor turizm portalından web kazıma tekniği ile elde edilmiştir. Amaçsal örnekleme yönteminin benimsendiği bu çalışmada verilerin analiz edilmesi sürecinde duygu analizi yöntemi kullanılmıştır. Veri analiz sürecinde açık kaynak kodlu KNIME veri madenciliği

programından yararlanılmıştır. Araştırma neticesinde, makine öğrenme algoritmalarının sözlük tabanlı analize göre daha etkin sınıflandırma gerçekleştirdiği görülmüştür. Ayrıca makine öğrenme algoritmaları, sınıflandırma aşamasında Türkçe dilindeki yorumlarda daha başarılı sonuçlar üretmiştir.

Tohma ve ark. (Tohma vd., 2023) çalışmalarında, Türkçe soru cevap sistemleri için duygusal performansı artırmak amacıyla makine öğrenmesi algoritmaları kullanılarak yeni bir hibrit duygu analizi modeli önermişlerdir. Bu bağlamda ilk olarak Türkçe soru-cevap-duygu veri kümesine metin ön işleme adımları uygulanmıştır. Daha sonra önceden işlenmiş soru cevap metinlerini, önceden eğitilmiş Türkçe BERT modeli ve iki farklı kelime temsil yöntemi olan TF-IDF ve Word2Vec kullanarak metinler, vektör formuna dönüştürülmüştür. Ek olarak, kelimelerin pozitif ve negatif puanlarını içeren önceden belirlenmiş polarite vektörleri, soru-cevap metin vektörüne dahil edilmiştir. Son olarak, vektörleştirilmiş ve genişletilmiş soru-cevap metin vektörleri, eğitim ve test verilerine ayrılmış, makine öğrenimi algoritmalarıyla eğitilip test edilmiştir. Daha önce Türkçe soru cevap sistemlerinde kullanılmayan bu yöntemi kullanarak duygu analizinde %91,05'e varan doğruluk değerine ulaşılmıştır. Bu modelin duygu analizindeki başarı oranını arttırmak için kelime vektörlerine polarite skoru değerleri ekleyen hibrit bir sistem oluşturulmuştur. Sonuç olarak bu çalışma, Türkçedeki insan-robot etkileşimlerinin daha gerçekçi ve duyarlı hale getirilmesine katkı sağlamıştır.

2.2. Sözlü Metinler için Önceki Çalışmalar

Literatür kapsamında incelenen çalışmalarda Konuşma Duygu Tanıma (SER) alanında geleneksel makine öğrenmesi yaklaşımları, derin öğrenme yöntemleri, dikkat mekanizmaları ve topluluk öğrenmesi başlıkları altında yer alan birçok farklı mimariye sahip yöntemin kullanıldığı görülmüştür. Bu yöntemlerin kullanıldıkları çalışmalar, bu bölümde değerlendirilmiştir.

2.2.1. Geleneksel Makine Öğrenmesi Yaklaşımları

Geleneksel makine öğrenmesi yaklaşımları, veriden anlamlı çıkarımlar elde etmek için istatistiksel modeller ve öğrenme algoritmalarını temel almaktadırlar. Bu yaklaşımlar genel olarak iki ana grupta incelenmekktedir. Bunlar, istatistiksel ve bayesçi yöntemler ile öğrenme tabanlı yöntemlerdir. İstatistiksel ve Bayesçi yöntemler, olasılıksal modeller üzerinden veri dağılımlarını ve parametre ilişkilerini açıklayarak çıkarım yapmayı amaçlamaktadır. Öğrenme tabanlı yöntemler ise örneklerden genelleme yapabilen, deneyim yoluyla performansını artıran algoritmalara dayanmaktadır. Bu iki yaklaşım birlikte değerlendirildiğinde, makine öğrenmesinin teorik temellerini ve modern derin öğrenme tekniklerinin zeminini oluşturmaktadırlar.

İstatistiksel ve Bayesçi Yöntemler

Naive Bayes (NB), Linear Discriminant Analysis (LDA), Fuzzy C-Means (FCM), Gaussian Mixture Model (GMM) gibi algoritmalar, literatürde en çok kullanılan istatistiksel ve bayesçi yöntemlerdendir. Belirtilen yöntemlerin kullanıldığı bazı çalışmalar aşağıda değerlendirilmektedir.

Koduru ve ark. (Koduru vd., 2020) çalışmalarında, SER sistemlerinde tanıma oranını artırmak için kullanılan farklı özellik çıkarma algoritmalarını incelemişlerdir. Çalışmada, RAVDESS veri kümesindeki ses örnekleri üzerinde özellik çıkarma, özellik seçimi ve sınıflandırıcı aşamaları gerçekleştirilmiştir. İlk olarak, konuşma sinyalleri üzerindeki gürültü Butterworth ve Chebyshev filtreleriyle temizlenmiş, ardından MFCC, DWT, pitch, energy ve ZCR gibi akustik özellikler çıkarılmıştır. Özellik seçiminde, GFA kullanılarak gereksiz bilgiler elenmiş ve bu özellikler DT, SVM ve LDA gibi sınıflandırıcılarla işlenmiştir. Sonuçlara göre, en yüksek doğruluk oranı %85 ile DT kullanılarak elde edilmiştir. Çalışma, önerilen özellik çıkarma ve seçim algoritmalarının duygu tanıma doğruluğunu artırdığını ve işlem süresini optimize ettiğini ortaya koymaktadır.

Kumar ve ark. (Kumar vd., 2023)[4] çalışmalarında, SER için önerdikleri modeli, GMM ve SVM ile karşılaştırmışlar ve hata oranını %19,79'a kadar düşürüp işlem süresini azaltmışlardır. GMM bu çalışmada karşılaştırma için kullanılmıştır.

Öğrenme Tabanlı Yöntemler

K-Nearest Neighbors (KNN), Support Vector Machines (SVM), Decision Tree (DT), Random Forest (RF), Multiple Random Forest (MRF), Two-Layer Fuzzy Multiple Random Forest (TLFMRF) gibi algoritmalar, literatürde en çok kullanılan öğrenme tabanlı yöntemlerdendir. Belirtilen yöntemlerin kullanıldığı bazı çalışmalar aşağıda değerlendirilmektedir.

Ancilin ve Milton (Ancilin ve Milton, 2021) çalışmalarında, SER için MFMC kullanımını araştırmışlardır. Çalışma, EMO-DB, RAVDESS, SAVEE, EMOVO, eNTERFACE ve URDU gibi altı farklı veri kümesinde MFMC'nin performansını değerlendirmiştir. EMO-DB veri kümesinde MFMC'nin doğruluk oranı %81,50 ile en yüksek sonucu elde etmiştir. Sonuçlar, MFMC'nin geleneksel MFCC, LFPC ve LPCC gibi özelliklerden daha iyi duygu tanıma doğruluğu sağladığını göstermektedir.

Tepecik ve Demir çalışmalarında (Tepecik ve Demir, 2024), Türkçe ses kayıtlarıyla duygu analizi gerçekleştirmek amacıyla bir çalışma sunmuşlardır. Çalışmada Common Voice (Mozilla, 2021) platformunda yer alan Türkçe ses kayıtlarından oluşturulan veri kümesi kullanılmıştır. Çalışmada, Türkçe ses verilerinin doğrudan ses tabanlı analizi yerine metin formatına dönüştürülerek duygu etiketleme işlemi yapıldığı belirtilmektedir. BERT modeli kullanılarak veri kümesi negatif, pozitif ve nötr olmak üzere üç duygu sınıfına ayrılmıştır. Daha sonra, literatürde yaygın olarak kullanılan NB, SVM, RF, DT ve KNN gibi beş farklı makine öğrenimi algoritması ile analizler gerçekleştirilmiştir. Python programlama dili ve RapidMiner kullanılarak yapılan deneyler sonucunda, Python ortamında NB ve SVM %67 doğruluk oranı ile en iyi performansı gösterirken, RapidMiner'da ise NB algoritması

[4] Kumar ve ark. (Kumar vd., 2023) tarafından yapılan çalışma hakkında detaylı bilgiler, ilerideki bölümlerde yer almaktadır.

%60,61 doğruluk oranıyla en iyi sonucu vermiştir. Çalışma, Türkçe duygu analizi alanına yeni bir veri kümesi kazandırmış olmakla birlikte doğrudan ses verisi özellikleri kullanılmadığından SER çalışmaları için değil daha çok metinden duygu analizi çalışmaları için katkı sunduğu görülmektedir.

Chen, Su ve ark. (Chen vd., 2020) SER için TLFMRF yöntemi önermişlerdir. SER sırasında genellikle bazı problemlerle karşılaşılmaktadır. Bunlardan biri, özellik çıkarımının kişiselleştirilmiş özelliklere dayanmasıdır. Diğeri ise, duygu tanımanın farklı insan grupları arasındaki farklılıkları dikkate almamasıdır. Önerilen yöntemde, kişiselleştirilmiş ve kişiselleştirilmemiş özellikler SER için birleştirilmiştir. Yüksek boyutlu duygusal özellikler, FCM kümeleme algoritması kullanılarak farklı alt sınıflara ayrılmış ve farklı duygusal durumları tanımak için çoklu RF uygulanmıştır. Sonuç olarak, bir TLFMRF modeli oluşturulmuştur. Ayrıca, tanınması zor olan bazı duygular için ayrı bir sınıflandırma yapılmıştır. Sonuçlar, TLFMRF'nin duyguları kararlı bir şekilde tanımlayabildiğini göstermiştir. Önerinin etkinliğini göstermek için CASIA ve EMO-DB veri kümelerinde deneyler gerçekleştirilmiştir. Deneysel sonuçlar, önerilen yöntemin BPNN'ye göre %1,39 ila %7,64; RF algoritmasına göre ise %4,06 ila %4,30 daha yüksek duygu tanıma doğrulukları elde ettiğini ortaya koymuştur.

2.2.2. Derin Öğrenme Yöntemleri

Derin öğrenme yöntemleri, çok katmanlı yapay sinir ağları kullanarak veriden soyut ve yüksek seviyeli temsiller elde etmeyi amaçlayan gelişmiş makine öğrenmesi teknikleridir. Bu yöntemler temel olarak üç ana başlık altında incelenmektedir. Bunlar, çok katmanlı algılayıcılar (MLP), evrişimli sinir ağları (CNN) ve özyinelemeli sinir ağlarıdır (RNN). Çok katmanlı algılayıcılar, doğrusal olmayan ilişkileri modelleme gücü sayesinde derin öğrenmenin temelini oluşturmaktadır. Evrişimli sinir ağları, özellikle görsel ve mekânsal verilerin işlenmesinde öne çıkarak öznitelik çıkarımı konusunda yüksek başarı sağlamaktadır. Özyinelemeli sinir ağları ise zaman serileri ve dil gibi ardışık verilerdeki bağımlılıkları yakalama kabiliyetiyle sıralı veri analizi için etkin bir çözüm sunmaktadır. Bu yöntemler birlikte değerlendirildiğinde, derin öğrenmenin hem yapısal çeşitliliğini hem de çok yönlü uygulama potansiyelini temsil etmektedirler.

Çok Katmanlı Algılayıcılar

Multi-Layer Perceptrons (MLP), Backpropagation Neural Network (BPNN) gibi algoritmalar, literatürde en çok kullanılan çok katmanlı algılayıcılardandır. Belirtilen algılayıcıların kullanıldığı bazı çalışmalar aşağıda değerlendirilmektedir.

Kumar ve ark. (Kumar vd., 2023) çalışmalarında, SER için MLP tabanlı bir model önererek akıllı asistan sistemlerinde duygu tespitini hedeflemişlerdir. Model, sesli mesajlar üzerinden endişe, sürpriz, nötr, üzüntü, mutluluk, nefret ve sevgi olmak üzere yedi farklı duyguyu tanımlayabilmektedir. Özellik çıkarımı için MFCC kullanılmış, sınıflandırma aşamasında ise MLP yöntemi uygulanmıştır. RAVDESS, TIMIT ve EMO-DB veri kümeleriyle test edilen model, doğruluk oranı açısından sırasıyla %81,02; %84,23 ve %86,71 başarım elde etmiştir. Önerilen model, GMM ve SVM ile karşılaştırıldığında hata oranını %19,79'a kadar düşürmüş ve işlem süresini azaltmıştır. Ayrıca model, duygu tespiti sonrası kullanıcıya LED ışıkları ve sesli uyarılar ile geri bildirim sağlayarak özellikle sağlık hizmetleri ve uzaktan izleme sistemlerinde pratik bir çözüm sunmaktadır.

Chen, Su ve ark. (Chen vd., 2020)[5] SER için önerdikleri TLFMRF yöntemini, BPNN ile karşılaştırmışlar ve önerilen yöntemin BPNN'ye göre %1,39 ila %7,64 daha yüksek tanıma doğrulukları elde ettiğini ortaya koymuşlardır. BPNN bu çalışmada karşılaştırma için kullanılmıştır.

Evrişimli Sinir Ağları (CNN Tabanlı Yöntemler)

Derin öğrenme yöntemlerinin en yaygın olarak kullanılanlarından birisi olan CNN'nin ilk olarak önerilmesi, Kim'in (Kim, 2014) 2014 yılında tek katmanlı bir CNN mimarisi tanımlamasıyla gerçekleşmiştir. Convolutional Neural Network (CNN), 1D Convolutional Neural Network (1D-CNN), 2D Convolutional Neural Network (2D-CNN),

[5] Chen, Su ve ark. (Chen vd., 2020) tarafından yapılan çalışma hakkında detaylı bilgiler, yukarıdaki bölümlerde yer almaktadır.

3D Convolutional Neural Network (3D-CNN), Temporal Convolutional Neural Networks (TCNN), Fully Convolutional Neural Network (FCNN), Emphasized Channel Attention, Propagation, and Aggregation Time Delay Neural Network (ECAPA-TDNN), AlexNet, VGG-16, ResNet50, ResNet101, Xception gibi algoritmalar, literatürde en çok kullanılan CNN tabanlı yöntemlerdendir. Belirtilen yöntemlerin kullanıldığı bazı çalışmalar aşağıda değerlendirilmektedir.

Issa ve ark. (Issa vd., 2020) çalışmalarında, MFCC, chromagram, mel-spectrogram, tonnetz ve spectral contrast özelliklerini ses dosyalarından çıkaran ve bunları duygu tanımlama için 1D-CNN'e girdi olarak kullanan yeni bir mimari tanıtmışlardır. Bu işlemde RAVDESS, EMO-DB ve IEMOCAP veri kümelerinden aldıkları örnekleri kullanmışlardır. Geliştirdikleri modelin sınıflandırma doğruluğunu artırmak için artımlı bir yöntem uygulamışlardır. Önerdikleri tüm modelleri, önceki bazı yaklaşımların aksine, görsel temsillere dönüştürme ihtiyacı olmaksızın doğrudan ham ses verileriyle çalıştırmışlardır. Deneysel sonuçlara dayanarak, önerdikleri en iyi model, RAVDESS ve IEMOCAP veri kümeleri için mevcut yaklaşımları geride bırakarak yeni bir "state-of-the-art" (en iyi mevcut yöntem) düzeyi belirlemiştir. EMO-DB veri kümesi için ise yalnızca bir önceki çalışmadan daha düşük performans göstermiş, ancak genellik, basitlik ve uygulanabilirlik açısından bu çalışmayla olumlu şekilde kıyaslanmıştır. Önerilen yaklaşım, RAVDESS veri kümesi için 8 sınıfta %71,61; 535 örnek ve 7 sınıfta EMO-DB için %86,1; 520 örnek ve 7 sınıfta EMO-DB için %95,71 ve IEMOCAP veri kümesi için konuşmacıdan bağımsız ses sınıflandırma görevinde 4 sınıfta %64,3 doğruluk oranı elde etmiştir. Çalışmada, MFCC, chromagram, mel-spectrogram, tonnetz ve spectral contrast özellikleri birleştirilmiştir. Bu özellikler birleştirilerek, sinyalin daha kapsamlı bir temsili elde edilmiş ve bu sayede RAVDESS, EMO-DB ve IEMOCAP veri kümelerinde sınıflandırma performansı önemli ölçüde artmıştır. Özellikle farklı özelliklerin bir arada kullanılması, modelin duygusal durumları ayırt etme yeteneğini güçlendirdiği görülmüştür. Çalışma, basitlik, genellik ve uygulanabilirlik açısından SER için önemli bir katkı sunmaktadır.

Anvarjon ve ark. (Anvarjon vd., 2020) çalışmalarında, SER için hafif ve düşük hesaplama maliyetine sahip bir derin öğrenme modeli Deep-Net önererek, spektrum tabanlı özelliklerin etkisini incelemişlerdir. Çalışmada, konuşma sinyallerinden derin frekans

özellikleri çıkarmak için özel dikdörtgen filtreler ve modifiye edilmiş havuzlama (pooling) stratejisi kullanan bir CNN tabanlı model geliştirilmiştir. Önerilen model, IEMOCAP ve EMO-DB veri kümeleri üzerinde test edilmiş ve sırasıyla %77,01 ve %92,02 doğruluk oranlarına ulaşmıştır. Çalışma, hafif CNN yapısının geleneksel CNN ve RNN tabanlı modellere kıyasla daha düşük hesaplama maliyetiyle rekabetçi performans sunduğunu göstermiştir. Ayrıca, önerilen modelin gerçek zamanlı uygulamalara uygun olduğu ve SER sistemlerinin doğruluğunu artırabileceği sonucuna varılmıştır.

Mustaqeem ve Kwon (Mustaqeem ve Kwon, 2021) çalışmalarında, konuşmanın insanlar arası iletişimde ve insan-bilgisayar etkileşiminde (HCI) önemli bir araç olduğunu vurgulamışlardır ancak mevcut SER sistemlerinin gerçek zamanlı işlem kapasitesinde eksiklikler yaşandığını belirtmişlerdir. Bu sorunu çözmek için, bir boyutlu genişletilmiş CNN tabanlı (One-dimensional Dilated Convolutional Neural Network, 1D-DCNN), uçtan uca bir gerçek zamanlı SER modeli önermişlerdir. Model, MLT (Multi Learning Trick) ile çalışarak mekansal öne çıkan duygusal özellikleri çıkarırken, uzun vadeli bağlamsal bağımlılıkları öğrenir. Rezidüel bloklar ve sıralama öğrenme modülleri aracılığıyla duygusal işaretlerin ve ardışık bağlamların öğrenilmesi sağlanmış, özelliklerin birleştirilmesi için bir füzyon katmanı kullanılmıştır. IEMOCAP ve EMO-DB veri kümelerinde sırasıyla %73 ve %90 doğruluk oranı elde eden model, gerçek zamanlı SER sistemleri için hafif ve etkili bir çözüm sunmuş, özgün konuşma sinyallerini işleyebilme yeteneğiyle dikkat çekmiştir.

Alluhaidan ve ark. (Alluhaidan vd., 2023) çalışmalarında, SER için hibrit özelliklerin (MFCC ve zaman alanı özellikleri) birleştirilmesiyle geliştirilmiş bir CNN tabanlı model önermişlerdir. Geleneksel SER sistemlerinin yalnızca spektral veya zamansal özelliklere odaklanmasının sınırlamalarını vurgulayan çalışma, MFCC'ler ile zaman alanı özelliklerinin birleştirilmesiyle (MFCCT) daha sağlam bir duygu tanıma modeli elde etmeyi hedeflemektedir. Önerilen yöntem, EMO-DB, SAVEE ve RAVDESS veri kümeleri üzerinde test edilmiş ve sırasıyla %97, %93 ve %92 ağırlıklı doğruluk oranlarına ulaşmıştır. Modelin başarısı, hafif ve verimli bir 1D-CNN kullanılarak hesaplama yükünü azaltmasıyla açıklanmaktadır. Çalışmada, MFCC'lerin spektral özellikleri, zaman alanı özellikleri ile birleştirilerek duygu tanıma performansının artırıldığı ve geleneksel makine öğrenimi yöntemlerinden (SVM, RF, KNN) daha iyi sonuçlar elde edildiği gösterilmiştir. Sonuçlar,

SER sistemlerinde hibrit özellik kullanımının duygu tanıma doğruluğunu artırmada etkili olduğunu ve insan-bilgisayar etkileşimi, çağrı merkezi analitiği, sürücü destek sistemleri ve sağlık uygulamaları gibi alanlarda uygulanabilirlik sunduğunu göstermektedir.

Bhangale ve Kothandaraman (Bhangale ve Kothandaraman, 2023) çalışmalarında, SER için birden fazla akustik özelliği kullanarak derin CNN (One-dimensional Deep Convolutional Neural Network, 1-D DCNN) tabanlı bir yöntem önermişlerdir. Geleneksel SER sistemlerinin karmaşıklık, gürültü ve düşük ayırt edicilik gibi zorluklarla karşı karşıya olduğunu belirten çalışma, MFCC, LPCC, WPT, ZCR, spectral centroid, spectral roll-off, spectral kurtosis, RMS Energy, pitch, jitter, shimmer ve formants gibi bir dizi akustik özelliği kullanarak ayırt ediciliği artırmayı hedeflemektedir. Önerilen sistem, hafif ve kompakt 1-D DCNN kullanarak hesaplama karmaşıklığını azaltmakta ve konuşma sinyalindeki uzun vadeli bağımlılıkları temsil etmektedir. Model, EMO-DB ve RAVDESS üzerinde test edilmiş ve sırasıyla %93,31 ve %94,18 genel doğruluk oranlarına ulaşmıştır. Bu sonuçlar, önerilen MFCC ve 1-D DCNN modelinin geleneksel SER tekniklerinden daha yüksek doğruluk sağladığını göstermektedir. Makale, insan-bilgisayar etkileşimi, çağrı merkezi analizleri, sürücü destek sistemleri ve çevrimiçi eğitim platformları gibi birçok uygulama alanında SER sistemlerinin iyileştirilmesine katkı sağlamayı amaçlamaktadır.

Liu ve ark. (Liu vd., 2024) çalışmalarında, SER için çok ölçekli ve çok kanallı özellik çıkarımı sağlayan bir 1D-CNN tabanlı model (Multichannel Feature Extraction and 1D-CNN, MCDNet) önermişlerdir. Çalışmada, konuşma sinyallerinden hem yerel hem de küresel özellikleri yakalamak için çok ölçekli ve çok kanallı bir özellik çıkarma yapısı kullanılmıştır. MFCC ve ZCR özellikleri çıkarılarak modelin eğitiminde kullanılmıştır. Modelin genelleme yeteneğini artırmak için beyaz gürültü ekleme, perde kaydırma ve zaman esnetme gibi veri artırma teknikleri uygulanmıştır. Önerilen MCDNet modeli, CREMA-D, RAVDESS ve EMO-DB veri kümeleri üzerinde test edilmiş ve sırasıyla %92,97; %95,83 ve %96,25 ortalama doğruluk oranları elde edilmiştir. Çalışma, çok ölçekli özellik çıkarımı ve derin öğrenme tabanlı sınıflandırmanın birleşimi ile SER alanında mevcut yöntemlerden daha iyi performans sunduğunu göstermektedir.

Alhussein ve ark. (Alhussein vd., 2025) çalışmalarında, konuşma tabanlı duygu iklimi (Emotion Climate, EC) tanıma için AffECt adlı yeni bir model önermişlerdir. Bu model, konuşmalardaki duygu dinamiklerini analiz ederek, bireyler arasındaki duygusal ortamı belirlemeyi hedeflemektedir. Çalışmada, MFCC'ler, konuşma sinyallerini daha iyi temsil eden akustik öznitelikler oluşturmak için kullanılır. AffECt framework'ü, her 5 saniyelik konuşma segmentini MFCC dönüşümüne tabi tutarak, elde edilen verileri TCNN ile işlemektedir. Önerilen model, TCNN kullanarak konuşma sinyallerinden derin öznitelikler çıkarmakta ve duygu dinamikleri (Affect Dynamics, AD) ile birleştirerek EC sınıflandırmasını gerçekleştirmektedir. Model, K-EmoCon, IEMOCAP ve SEWA veri kümelerinde test edilerek, arousal (uyarılma) ve valence (duygu değeri) sınıflandırmalarında sırasıyla %83,3 ve %80,2 doğruluk oranlarına ulaşmıştır. AffECt'in başarısı, duygusal dinamiklerin derin öğrenme modellerine entegrasyonu ile ilişkilendirilmiş ve modelin farklı dillerde ve kültürlerde başarılı sonuçlar verdiği görülmüştür. Çalışma, psikolojik değerlendirmeler, grup terapisi, müzakereler ve duygu farkındalığına sahip mobil uygulamalar gibi alanlarda uygulanabilirliği artırarak, konuşma tabanlı duygu analizi araştırmalarına önemli bir katkı sağlamaktadır.

Ye ve ark. (Ye vd., 2023) çalışmalarında, SER için yeni bir zamansal duygu modelleme yaklaşımı olan CNN tabanlı TIM-Net modelini önermişlerdir. Modelin temel bileşenleri arasında Dilated Causal Convolution (DC Conv) tabanlı zamansal farkındalık blokları (Temporal-Aware Blocks, TABs), çift yönlü (bi-directional) yapı ve dinamik ölçekli füzyon mekanizması bulunmaktadır. Model, dilated nedensel evrişim (DC Conv) tabanlı zamansal farkındalık blokları ile duygusal özellikleri çıkarır, çift yönlü mimarisiyle zamansal bağımlılıkları modeller ve dinamik birleştirme modülüyle farklı zaman ölçeklerinden gelen bilgileri optimize eder. TIM-Net, konuşma sinyallerindeki çok ölçekli bağlamsal duygu temsillerini öğrenmek için geliştirilmiş olup, geçmiş ve gelecekten gelen tamamlayıcı bilgileri entegre ederek uzun menzilli zamansal bağımlılıkları yakalamaktadır. Altı farklı veri kümesi üzerinde yapılan deneyler, TIM-Net'in, mevcut yöntemlere kıyasla ağırlıklı ortalama Recall (WAR) ve ağırlıksız ortalama Recall (UAR) değerlerinde %2,34 ve %2,61 oranında iyileşme sağladığını göstermektedir. Ayrıca çapraz-korpus analizleri ve ablasyon çalışmaları, modelin genel performansını ve genelleme yeteneğini desteklemektedir.

Aftab ve ark. (Aftab vd., 2022) çalışmalarında, düşük donanım kaynaklarına sahip sistemlerde konuşma sinyalinden doğrudan duygu tespiti için hafif ve verimli bir FCNN modeli önermişlerdir. Mevcut SER modellerinin yüksek hesaplama ve depolama gereksinimleri nedeniyle gömülü sistemlerde uygulanmasının zor olduğu belirtilmiş ve bu sorunu çözmek için optimize edilmiş bir model geliştirilmiştir. Önerilen model, üç ana bileşenden oluşmaktadır: giriş aşaması, özellik çıkarma katmanları (gövde) ve sınıflandırıcı katman (baş). Gövde bölümü iki alt bileşene ayrılmıştır: paralel 2D evrişimli filtreler ve yerel özellik öğrenme blokları (LFLBs). İlk aşamada, ses sinyalleri normalleştirilerek MFCC özellikleri çıkarılır ve üç paralel evrişimli ağ ile spektral ve zamansal bilgileri dengeli bir şekilde öğrenmek için işlenir. Daha sonra, bu çıkarılan düşük seviyeli özellikler, daha derin ağ katmanlarında yüksek seviyeli temsiller oluşturmak için birleştirilir. Modelin nihai aşamasında, bir dropout katmanı ve softmax sınıflandırıcı kullanılarak düşük hesaplama maliyeti ile duygu sınıflandırması gerçekleştirilir. Özetle önerilen FCNN modeli, farklı filtre boyutlarına sahip üç paralel yol kullanarak çeşitli özellik haritalarını çıkarmakta ve böylece derin evrişim bloklarının yüksek seviyeli özellikleri ayırt edilebilir bir şekilde öğrenmesini sağlamaktadır. Model, giriş konuşma segmentinden çıkarılan bu özellikleri kullanarak duyguları sınıflandırmaktadır. Yapılan deneyler, modelin IEMOCAP ve EMO-DB veri kümelerinde daha küçük boyutuna rağmen, mevcut en iyi modellerden daha yüksek performans gösterdiğini ortaya koymuştur. Özellikle, EMO-DB üzerinde %94,15 ağırlıksız ortalama Recall (UAR); %94,21 ağırlıklı doğruluk (WA) ve %94,16 F1 Skor ile tüm yöntemleri geride bırakmıştır. Bu çalışma, sınırlı donanım kaynaklarına sahip sistemlerde etkili SER uygulamaları için önemli bir adım sunmaktadır.

Morais ve ark. (Morais vd., 2022) çalışmalarında, SER için kendinden denetimli (self-supervised) öğrenme tabanlı özelliklerin etkinliğini incelemişlerdir. Bu çalışmada, Upstream + Downstream mimarisine dayalı modüler bir Uçtan Uca (End to End, E2E) SER sistemi önerilmektedir. Upstream modeli, konuşma verisinden görevden bağımsız (task-independent) özellikler çıkaran, kendinden denetimli öğrenme ile eğitilmiş bir ön işleme modelidir. Downstream modeli ise, bu özellikleri kullanarak duygusal kategorileri tahmin eden görev bağımlı (task-dependent) bir sınıflandırıcı olarak çalışmaktadır. Bu çalışmada, Upstream model olarak Wav2Vec 2.0 ve Hidden Unit BERT (HuBERT) kullanılmış,

Downstream model olarak ise Ortalama Havuzlama (Mean Average Pooling) + Doğrusal Sınıflandırıcı ve ECAPA-TDNN tabanlı modeller tercih edilmiştir. IEMOCAP veri kümesi üzerinde yapılan deneyler, dikkatlice seçilen Upstream ve Downstream model kombinasyonlarının SER performansını önemli ölçüde artırabileceğini göstermektedir. Özetle bu makalede, kendinden denetimli öğrenme (self-supervised learning) tabanlı özellik çıkarma tekniklerinin SER üzerindeki etkisi incelenmiştir. IEMOCAP veri kümesi üzerinde yapılan deneyler, önerilen modelin, özellikle Wav2Vec 2.0 ve HuBERT tabanlı özelliklerin etkili bir şekilde işlenmesiyle %77,76 ağırlıksız doğruluk ve %77,36 ağırlıklı doğruluk başarı oranlarına ulaştığını göstermektedir. Elde edilen bu sonuçlar, kendinden denetimli akustik özelliklerin, sadece konuşma verisine dayalı sistemlerde çok modlu (multimodal) yöntemlere yakın veya daha iyi performans sergileyebileceğini göstermektedir. Bu çalışma, büyük miktarda etiketlenmemiş konuşma verisinden öğrenilen özelliklerin SER alanında güçlü bir potansiyele sahip olduğunu ortaya koymaktadır.

Tan ve ark. (Tan vd., 2021) çalışmalarında, otonom araçların yeni nesil Akıllı Ulaşım Sistemlerinde (Intelligent Transportation Systems, ITS) SER teknolojisinin kullanımını artırmayı amaçlamışlardır. Mevcut araç içi SER sistemleri, iletişim ağı kapasitesinin yetersizliği ve düşük duygu tanıma doğruluğu gibi iki temel sorundan muzdariptir. Bu sorunları çözmek için, 5G destekli bir Uzay-Hava-Yer Entegre Ağı (Space-Air-Ground Integrated Network, SAGIN) tabanlı çok modlu bir duygu tanıma modeli önermişlerdir. AlexNet modeli, bu çalışmada otonom araçlarda SER için kullanılmıştır. Çalışmada, araç içi konuşma verileri spektrogramlara dönüştürülerek AlexNet modeline giriş olarak verilmiş ve araç konuşma akustik modelinin yüksek seviyeli özellikleri çıkarılmıştır. Aynı zamanda, konuşma verileri metne dönüştürülerek BERT modeline giriş olarak verilmiş ve metin modelinin yüksek seviyeli özellikleri elde edilmiştir. Son olarak, bu iki özellik kümesi birleştirilerek bir softmax sınıflandırıcıya gönderilmiş ve duygu sınıflandırması gerçekleştirilmiştir. Deneysel sonuçlar, AlexNet ve BERT tabanlı çok modlu yaklaşımın, yalnızca ses veya metin bazlı modellerden daha yüksek doğruluk sağladığını göstermektedir IEMOCAP veri kümesi üzerinde yapılan deneyler, bu çözümün %74 ağırlıklı doğruluk ve %65,4 ağırlıksız doğruluk sağladığını göstermektedir. Çalışma, SER teknolojisinin otonom araçlarda güvenlik, kullanıcı deneyimi ve iletişim performansını önemli ölçüde artırabileceğini ortaya koymaktadır.

Aggarwal ve ark. (Aggarwal vd., 2022) çalışmalarında, SER için iki farklı özellik çıkarma yöntemi kullanılarak kapsamlı bir analiz yapmışlardır. İlk yöntemde, süper yakınsama (superconvergence) yaklaşımı kullanılarak konuşma verisinden iki farklı özellik kümesi çıkarılmıştır. Birinci yöntemde, özellik kümesi (MFCC, Log-Mel Spectrogram, chromagram, spectral centroid, spectral roll-off), PCA uygulanarak elde edilmiş ve ardından yoğun (dense) ve dropout katmanlarına sahip Derin Sinir Ağı (DNN) ile işlenmiştir. İkinci yöntemde ise, ses dosyalarından Mel-spectrogram görüntüleri çıkarılmış ve bu görüntüler önceden eğitilmiş VGG-16 modeli ile sınıflandırılmıştır. Çalışmada, her iki yöntem RAVDESS veri kümesi üzerinde test edilerek detaylı bir karşılaştırmalı analiz yapılmıştır. Sonuçlar, görsel tabanlı özelliklerin (Mel-spectrogram görüntüleri) DNN üzerinde elde edilen sayısal özelliklere kıyasla daha iyi performans sergilediğini göstermiştir. Bu çalışmada iki farklı özellik çıkarma yaklaşımı kullanılarak SER sistemi geliştirilmiştir. Birinci yaklaşımda, DNN modeli kullanılarak RAVDESS ve TESS veri kümeleri üzerinde eğitim gerçekleştirilmiş ve doğruluk oranları sırasıyla %73,95 ve %99,99 olarak elde edilmiştir. İkinci yaklaşımda ise VGG-16 transfer öğrenme modeli kullanılmış ve RAVDESS için %81,94; TESS için %97,15 doğruluk oranlarına ulaşılmıştır. Bu sonuçlar, VGG-16 modelinin yerleşik özellik çıkarma mekanizması sayesinde DNN modeline göre daha üstün performans gösterdiğini ortaya koymaktadır.

Karasulu ve ark. (Karasulu vd., 2024) çalışmalarında, Arnavutça konuşma verileri üzerinde derin öğrenme tabanlı duygu durumu analizi gerçekleştirmeyi amaçlamışlardır. Literatürde Arnavutça konuşma verileri üzerine yapılan çalışmaların sınırlı olduğu belirtilerek, bu boşluğu doldurmak için dört farklı duygu sınıfını (öfkeli, mutlu, üzgün, şaşkın) içeren özgün bir veri kümesi oluşturulmuştur. Veri kümesi, dokuz farklı ana dili Arnavutça olan bireyden elde edilmiş ve duygu sınıflandırma için Mel spektrogram tabanlı özellik çıkarımı kullanılmıştır. Model eğitimi için ResNet50, Xception ve CNN modelleri uygulanmıştır. Modelin her bir sınıfı için ROC eğrisi çizdirilmiş ve AUC değerleri hesaplanmıştır. Duygu tanıma doğruluk oranları, ROC altında kalan alan AUC değerleri ile değerlendirilmiştir. Sonuçlar, mutlu (area: 1,0), üzgün (sad: 1,0), şaşkın (area: 0,93) ve öfkeli (area: 0,76) duygu sınıfları için elde edilen yüksek başarımlarla modelin etkinliğini göstermektedir. Bu çalışma, Arnavutça konuşma verileri için duygu analizi alanına katkı

sunmakta ve düşük kaynaklı diller için duygu sınıflandırma çalışmalarına bir referans oluşturmaktadır.

Özyinelemeli Sinir Ağları (RNN Tabanlı Yöntemler)

RNN, dahili belleğe sahip bir tür sinir ağıdır. Bir önceki adımın çıktısı, giriş olarak mevcut adıma gönderilmektedir. RNN'lerdeki tüm girdiler birbiriyle ilişkilidir ve bazı bilgileri hatırlayan gizli katmanlara sahiptirler. Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM), Bidirectional Long Short-Term Memory (BiLSTM), Directional Gated Recurrent Unit (GRU), Bidirectional Gated Recurrent Unit (BiGRU) gibi algoritmalar, literatürde en çok kullanılan RNN tabanlı yöntemlerdendir. Belirtilen yöntemlerin kullanıldığı bazı çalışmalar aşağıda değerlendirilmektedir.

Wang ve ark. (Wang vd., 2020) çalışmalarında, SER için Çift-Dizili LSTM (Dual-Sequence LSTM, DS-LSTM) mimarisini önererek, ses sinyallerinden elde edilen MFCC ve mel-spectrogram özelliklerini birlikte işlemenin duygu tanıma performansını artırabileceğini göstermişlerdir. Model, standart LSTM ile MFCC özelliklerini işlerken, DS-LSTM ile iki farklı zaman-frekans çözünürlüğüne sahip mel-spectrogramları aynı anda analiz edebilmektedir. Önerilen model, IEMOCAP veri kümesi üzerinde test edilmiş ve ortalama ağırlıklı doğrulukta %72,7 ve ağırlıksız doğrulukta %73,3 oranına ulaşarak, önceki tek modlu SER modellerine kıyasla %6'lık bir iyileşme sağlamıştır. Ayrıca, modelin performansı çok modlu SER modellerine yakın sonuçlar vermiştir. Çalışma, MFCC ve mel-spectrogram özelliklerinin çift seviyeli işlenmesiyle SER alanında önemli bir gelişme sağladığını ve özellikle tek modlu SER modellerinin tam potansiyelinin henüz keşfedilmediğini öne sürmektedir.

Abdelhamid ve ark. (Abdelhamid vd., 2022) çalışmalarında, SER için veri artırma ve hiperparametre optimizasyonu içeren yeni bir derin öğrenme modeli önermişlerdir. Mevcut derin öğrenme modellerinin büyük veri kümelerine ihtiyaç duyması nedeniyle, yazarlar gürültü ekleme tabanlı veri artırma algoritması geliştirerek eğitim verisini genişletmiştir. Ayrıca, önerilen modelde hiperparametreler stokastik fraktal arama (SFS) destekli balina

optimizasyon algoritması (Whale Optimization Algorithm, WOA) ile optimize edilerek daha yüksek doğruluk oranları elde edilmiştir. Önerilen derin öğrenme modeli, dört yerel özellik öğrenme bloğundan oluşan bir CNN katmanı ve uzun vadeli bağıntıları öğrenmek için LSTM katmanı içermektedir. Giriş olarak Log-Mel Spectrogramları kullanılmış ve modelin öğrenme oranı ile etiket yumuşatma (label smoothing) parametresi optimize edilmiştir. Modelin performansı IEMOCAP, EMO-DB, RAVDESS ve SAVEE veri kümeleri üzerinde test edilmiş olup, sırasıyla %98,13; %99,76; %99,47 ve %99,50 doğruluk oranlarına ulaşılmıştır. Elde edilen sonuçlar, önerilen yöntemin geleneksel yaklaşımlara kıyasla üstün performans gösterdiğini ve stabil bir model sunduğunu göstermektedir.

Donuk ve Hanbay (Donuk ve Hanbay, 2022) çalışmalarında, SER için LSTM tabanlı bir model önererek akustik özelliklerin etkisini incelemişlerdir. Çalışmada, konuşma sinyallerinden MFCC, ZCR ve RMS Energy özellikleri çıkarılarak LSTM modeli ile duygu sınıflandırması yapılmıştır. Model, ön işleme, özellik çıkarma, özellik birleştirme, LSTM katmanı ve sınıflandırma olmak üzere dört aşamadan oluşmaktadır. RAVDESS ve TESS veri kümeleri üzerinde test edilen model, eğitimde %99,87; doğrulamada %85,14 ve test aşamasında %88,92 doğruluk oranına ulaşmıştır. Sonuçlar, önerilen LSTM tabanlı modelin, önceki çalışmalarla karşılaştırıldığında rekabetçi bir performans sunduğunu ve SER için akustik özelliklerin önemli bir rol oynadığını göstermektedir. Çalışma, duygu tanıma için LSTM tabanlı derin öğrenme modellerinin etkinliğini ortaya koyarak literatüre katkı sağlamaktadır.

Parlak (Parlak, 2024) çalışmasında, SER uygulamalarında hiperparametre optimizasyonunun etkisini inceleyerek, derin öğrenme modellerinin performansını artırmayı amaçlamıştır. Çalışmada, nEMO duygu konuşma veri kümesi kullanılarak CNN, LSTM ve DNN modelleri eğitilmiş ve farklı hiper parametre optimizasyon yöntemleri karşılaştırılmıştır. Rassal Arama, Bayesçi Optimizasyon ve Hiperkomite Arama metotları KerasTuner kullanılarak test edilmiş ve performansları ölçülmüştür. Sonuçlar, Bayesçi Optimizasyon yönteminin en iyi sonuçları verdiğini, özellikle LSTM modelinde %64,53 doğruluk oranına ulaşıldığını göstermektedir. Rassal Arama'nın düşük maliyetli ve hızlı olmasına rağmen Bayesçi Optimizasyona oldukça yakın sonuçlar ürettiği, Hiperkomite yönteminin ise daha fazla bellek ve zaman tüketmesine rağmen beklenen üstün performansı

gösteremediği belirtilmiştir. Çalışma, hiper parametre optimizasyonunun SER performansını artırmada kritik bir rol oynadığını ve derin öğrenme modellerinde otomatik optimizasyonun gelecekte daha yaygın kullanılacağını ortaya koymaktadır.

Mustaqeem, Sajjad ve Kwon (Mustaqeem vd., 2020) çalışmalarında SER için yeni bir yaklaşım sunmuşlardır. Önerilen yöntemde, ses sinyallerindeki benzer segmentlerin belirlenmesi için K-Means Clustering algoritması uygulanmıştır. Bu algoritma, sinyali benzer özelliklere sahip segmentlere ayırarak veri kümesinde anlamlı kümeler oluşturur. Kümelerden elde edilen segmentler, küme içi benzerlik ölçümleri için RBFN kullanılarak değerlendirilmiş ve en bilgilendirici segmentler seçilmiştir. Seçilen anahtar segmentler, STFT algoritması uygulanarak spektrogramlara dönüştürülmüş ve ardından ayırt edici özelliklerin çıkarılması için bir CNN modeli kullanılmıştır. Tanıma doğruluğunu artırmak için CNN'den çıkarılan özellikler normalize edilerek, duyguların nihai durumunu tanımak amacıyla BiLSTM modeline verilmiştir. Önerilen yöntem, işlem karmaşıklığını azaltmak için tüm ifadeler yerine yalnızca anahtar segmentleri işlerken, CNN özelliklerini normalleştirerek uzamsal-zamansal bilgilerin etkili bir şekilde tanınmasını sağlamaktadır. Sistem, IEMOCAP, EMO-DB ve RAVDESS veri kümeleri üzerinde değerlendirilmiş ve sırasıyla %72,25; %85,57 ve %77,02 doğruluk oranlarıyla mevcut SER yöntemlerinden daha iyi performans sergilediği görülmüştür.

Shixin ve ark. (Shixin vd., 2024) çalışmalarında SER için otomatik kodlayıcı (autoencoder) tabanlı çok modlu özellik füzyonu yöntemini önermişlerdir. Çalışmada, konuşma sinyalleri ve metin içeriklerinden yüksek seviyeli duygu özellikleri çıkarmak için Temporal Global Feature Extractor (TGFE) ve BiLSTM ağı kullanılmıştır. Bu özellikler daha sonra bir otomatik kodlayıcı aracılığıyla birleştirilerek konuşmanın duygu bilgisini daha etkili bir şekilde temsil eden ortak bir özellik uzayı oluşturulmuştur. Model, IEMOCAP, MELD ve MOSI veri kümeleri üzerinde test edilmiş olup, elde edilen sonuçlar, çok modlu özellik füzyonunun (audio ve text) duygu sınıflandırma başarısını artırdığını göstermektedir. Önerilen model, IEMOCAP veri kümesinde %74,8 ağırlıklı doğruluk, MELD ve MOSI veri kümesinde sırayla %63,64; %79,85 doğruluk oranı elde etmiştir. Özellikle IEMOCAP ve MELD veri kümelerinde önceki yöntemlerden daha iyi performans sergileyen model, MOSI veri kümesinde de rekabetçi sonuçlar elde etmiştir. Bu çalışma,

konuşma ve metin bilgilerini birleştirerek duygu tanıma doğruluğunu artırmaya yönelik etkili bir yöntem sunmaktadır.

Mustaqeem ve Kwon (Mustaqeem ve Kwon, 2021)[6] çalışmalarında BiGRU'lardan oluşan sıralama öğrenme (Seq_L) modülü kullanmışlardır.

2.2.3. Dikkat Mekanizmaları

Dikkat mekanizmaları, modelin her bir girdiye farklı düzeyde önem atamasını sağlayarak bilgi akışını optimize etmektedir. Kendi Kendine Dikkat Mekanizması (Self-Attention Mechanism), Eş-Dikkat Mekanizması (Co-Attention Mechanism), Çapraz Dikkat Mekanizması (Cross-Attention Mechanism) gibi mekanizmalar, literatürde en çok kullanılan dikkat mekanizmalarındandır. Bu mekanizmaların birleşimiyle oluşturulan Transformer modelleri ise doğal dil işleme ve konuşma analizi gibi birçok alanda son yıllarda önemli başarılar elde etmiştir. Belirtilen mekanizmaların kullanıldığı bazı çalışmalar aşağıda ayrı başlıklar altında değerlendirilmektedir.

Kendi Kendine Dikkat Mekanizması

Kendi Kendine Dikkat Mekanizması (Self-Attention Mechanism), bir dizideki her öğenin diğer öğelerle ilişkisini belirleyerek bağlamsal bilgiyi yakalayan bir dikkat mekanizmasıdır. Bu mekanizma, uzun menzilli bağımlılıkları modelleyerek her bir giriş öğesinin tüm diğer öğelerle etkileşimini tek bir adımda dikkate almasını sağlamaktadır (Vaswani vd., 2017).

Li, Liu ve ark. (Li vd., 2021) çalışmalarında, SER için BiLSTM ve yönlendirilmiş kendine dikkat (Directional Self-Attention, DSA) mekanizmasını birleştiren yeni bir model olan BiLSTM-DSA'yı önermişlerdir. Bu model, konuşma sinyallerindeki zaman içindeki bağıntıları analiz ederek duygu sınıflandırma performansını artırmayı amaçlamaktadır.

[6] Mustaqeem ve Kwon (Mustaqeem ve Kwon, 2021) tarafından yapılan çalışma hakkında detaylı bilgiler, önceki bölümlerde yer almaktadır.

Çalışmada, BiLSTM ile konuşma sinyallerinin ileri ve geri yönde işlenmesi sağlanmış ve DSA mekanizması ile çerçeve düzeyindeki bağıntılar otomatik olarak belirlenmiştir. Bu sayede, duygusal olarak daha anlamlı ses çerçevelerine ağırlık verilerek sınıflandırma performansı artırılmıştır. Önerilen model, IEMOCAP ve EMO-DB veri kümeleri üzerinde test edilmiş ve sırayla %61,2 ve %85,95 ağırlıklı doğruluk oranları elde edilmiştir. Önerilen model, geleneksel LSTM, CNN ve BiLSTM modellerine kıyasla daha yüksek doğruluk oranlarına ulaşmıştır. Özellikle mutluluk ve öfke duygularının tanınmasında önemli başarı elde edilmiştir. Sonuçlar, BiLSTM-DSA modelinin duygu tanıma için güçlü bir yöntem sunduğunu ve insan-bilgisayar etkileşimi, akıllı asistanlar ve duygu analizi uygulamalarında kullanılabileceğini göstermektedir.

Eş-Dikkat Mekanizması

Eş-Dikkat Mekanizması (Co-Attention Mechanism), iki farklı veri kaynağı arasındaki ilişkileri modellemek için kullanılan bir dikkat mekanizmasıdır. Kendi kendine dikkat mekanizması, tek bir veri dizisi içindeki bağıntıları öğrenirken, eş-dikkat mekanizması farklı iki veri dizisini eşzamanlı olarak dikkate alır ve her birinin diğerine nasıl bağlı olduğunu belirler (Lu vd., 2016).

Zou ve ark. (Zou vd., 2022) çalışmalarında, SER için çok seviyeli akustik bilgileri entegre eden ve eş-dikkat (co-attention) modülü ile özellikleri birleştiren uçtan uca bir model önermişlerdir. Model, MFCC, spectrogram ve wav2vec 2.0 tabanlı yüksek seviyeli akustik bilgileri çıkararak CNN, BiLSTM ve transformer tabanlı bir ağ kullanmaktadır. Bu çoklu özellikler, eş-dikkat mekanizması ile birleştirilerek duygu tanıma performansı artırılmaktadır. IEMOCAP veri kümesi üzerinde yapılan deneyler, modelin leave-one-speaker-out ve leave-one-session-out çapraz doğrulama stratejileriyle rekabetçi bir performans sergilediğini göstermektedir. Önerilen model, leave-one-session-out çapraz doğrulama stratejisinde %69,80 ağırlıklı doğruluk ve %71,05 ağırlıksız doğruluk değerleriyle en iyi performansı elde etmiştir. Leave-one-speaker-out stratejisinde ise, %72,70 ağırlıksız doğruluk ile en yüksek sonucu almış ve %71,64 ağırlıklı doğruluk değeriyle diğer modellere kıyasla rekabetçi bir sonuç göstermiştir. Özetle, bu modelin hem çok seviyeli akustik özellikleri birleştirme stratejisi hem de co-attention mekanizmasıyla

geleneksel yöntemlerden daha iyi sonuçlar verdiği söylenebilir. Yapılan ablation çalışmasına göre, tek başına en iyi performansı wav2vec 2.0 sağlamış olup, MFCC ve spectrogram gibi geleneksel akustik özelliklerin eklenmesiyle modelin doğruluğu artmıştır.

Li, Bell ve ark. (Y. Li vd., 2022) çalışmalarında, SER için ASR çıktılarının birleştirilmesini önererek, çok modlu bir eğitim yöntemi sunmaktadır. Geleneksel SER yaklaşımlarının hem akustik hem de dilbilimsel özellikleri birleştirmesi gerektiği belirtilmiş, ancak duygu anotasyonlu veri kümelerinin kısıtlılığı ve duygusal konuşmaların ASR sistemleri üzerindeki olumsuz etkileri nedeniyle güvenilir dil bilimsel özelliklerin elde edilmesinin zor olduğu vurgulanmıştır. Bu çalışmada, ASR çıktılarının SER modeline entegre edilmesi ve ortak eğitim (joint training) ile sistem performansının artırılması hedeflenmiştir. IEMOCAP veri kümesi üzerinde yapılan deneylerde, wav2vec 2.0 modelinden elde edilen ASR gizli katman (hidden layer) çıktıları ve metin çıktıları kullanılarak, çok düzeyli eş-dikkat mekanizması (hierarchical co-attention fusion) ile en iyi sonuçların elde edildiği gösterilmiştir. Önerilen model, %63,4 ağırlıklı doğruluk oranına ulaşarak, transkriptlerin doğrudan kullanıldığı modellerle karşılaştırılabilir performans elde etmiştir. Çalışma, ASR ve SER modellerinin birlikte eğitilmesinin SER performansını iyileştirebileceğini ve gelecekteki çalışmalar için önemli bir yönelim sağlayabileceğini göstermektedir.

Çapraz Dikkat Mekanizması

Çapraz Dikkat Mekanizması (Cross-Attention Mechanism), iki farklı veri dizisi arasında bağlamsal ilişki kurarak bir veri kaynağının diğerine göre dikkat ağırlıklarını öğrenmesini sağlar. Bu yöntem, özellikle çok modelli (multimodal) sistemlerde, örneğin metin ve görsel verilerin bütünleşik analizinde kullanılır. Bu mekanizma, bilgi akışını bir kaynaktan diğerine yönlendiren tek yönlü bir dikkat mekanizmasıdır. Bu yönüyle, çift yönlü dikkat sağlayan eş-dikkat mekanizmasından farklıdır (Vaswani vd., 2017).

Khan ve ark. (Khan vd., 2024) çalışmalarında, SER için çok modlu bir model olan Multimodal Speech Emotion Recognition (MSER) modelini tanıtarak, cross-attention mekanizması ve derin füzyon (deep fusion) tekniğini kullanmışlardır. Önerilen model,

konuşma sinyalleri ve metin verilerini birleştirerek duyguları daha hassas bir şekilde sınıflandırmayı hedeflemektedir. Modelin ses ve metin girdilerini ayrı ayrı işleyerek özellik çıkarımı yaptığı, ardından çapraz dikkat mekanizmasıyla etkileşimlerini güçlendirdiği belirtilmektedir. Derin füzyon tekniği sayesinde farklı katmanlardan gelen bilgilerin etkili bir şekilde birleştirilmesi sağlanmaktadır. IEMOCAP ve MELD veri kümeleri üzerinde test edilen model, önceki yöntemlere kıyasla %4,5 oranında daha yüksek duygu tanıma doğruluğu sağlamıştır. Modelin başarısı, çapraz dikkat mekanizmasının ses ve metin arasındaki bağlantıyı güçlendirmesi ve derin füzyon stratejisinin daha zengin duygu temsilleri üretmesiyle ilişkilendirilmiştir.

Transformer Modelleri

Transformer modelleri ise dikkat mekanizmalarını çok katmanlı yapılar içinde birleştirerek paralel işlemeyi mümkün kılmakta ve uzun bağımlılık ilişkilerini etkin bir biçimde öğrenmektedir. Wav2Vec 2.0, Hidden-Unit BERT (HuBERT), Whisper, Massively Multilingual Speech (MMS) gibi modeller, literatürde en çok kullanılan transformer modellerdir. Belirtilen modellerin kullanıldığı bazı çalışmalar aşağıda değerlendirilmektedir.

Chen, Xing, Xu ve ark. (Chen vd., 2022) çalışmalarında, SER için anahtar-seyrek (Key-Sparse) Transformer (KS-Transformer) tabanlı çok modlu bir model önererek, duygu ile ilişkili bilgilerin daha etkili bir şekilde yakalanmasını amaçlamaktadır. Geleneksel Transformer modellerinin, tüm giriş verilerini eşit şekilde dikkate aldığını ve bu durumun duygu tanıma sistemlerinde gürültüye neden olduğunu belirten çalışma, KS-Transformer ile yalnızca duygu ile ilgili önemli bilgilere odaklanarak performans artışı sağlamayı hedeflemektedir. Önerilen model, IEMOCAP ve LSSED veri kümeleri üzerinde test edilmiş ve sırayla %74,3; %65,0 ağırlıklı doğruluk oranı elde etmiştir. Sonuçlara göre önerilen model önceki Transformer tabanlı modellerden daha yüksek doğruluk oranlarına ulaşmıştır. Modelin başarısı, modeller arası çapraz dikkat (Cascaded Cross-Attention Block, CCAB) mekanizması ile artırılmış ve farklı modaliteler (ses ve metin) arasındaki etkileşimin güçlendirilmesi sağlanmıştır. Deney sonuçları, KS-Transformer'ın gereksiz bilgileri filtreleyerek daha odaklı bir duygu analizi gerçekleştirdiğini ve çok modlu SER sistemlerinde yeni bir standart oluşturabileceğini göstermektedir. Çalışma, insan-bilgisayar

etkileşimi, otomatik duygu analizi ve sağlık teknolojileri gibi alanlarda potansiyel uygulamalara sahip olduğunu vurgulamaktadır.

Chen, Xing, Chen ve ark. (Chen vd., 2024) çalışmalarında, SER için Vesper adlı kompakt ve etkili bir önceden eğitilmiş model (pretrained model) önermişlerdir. Büyük ölçekli önceden eğitilmiş modeller, geniş veri kümelerinde genel amaçlı öğrenme için geliştirilmiş olsa da belirli görevler için optimize edilmediklerinde etkili olmayabilirler. Bu çalışmada, WavLM tabanlı bir model olan Vesper, duygu tanımaya özgü hale getirilerek geliştirilmektedir. Model, duygu odaklı maskeleme stratejisi kullanarak, konuşma sinyallerindeki duygu açısından önemli bölgeleri belirleyerek maskeleme yapmaktadır. Ayrıca, hiyerarşik ve çapraz katmanlı kendiliğinden denetimli öğrenme (self-supervision) mekanizmaları sayesinde hem akustik hem de anlamsal özellikleri daha etkili şekilde yakalamaktadır. IEMOCAP, MELD ve CREMA-D veri kümeleri üzerinde yapılan testlerde sırayla %70,7; %54,2; %77,2 ağırlıklı doğruluk sonuçları elde edilmiştir. Bu çalışma, duygu tanıma için hafif ve etkili önceden eğitilmiş modellerin geliştirilmesine yönelik yeni bir yaklaşım sunmaktadır.

Agarla ve ark. (Agarla vd., 2024) çalışmalarında, çapraz dilli SER (cross-lingual SER) için yarı gözetimli öğrenme (semi-supervised learning, SSL) yaklaşımı önermişlerdir. Geleneksel SER modelleri, eğitim ve test verileri aynı dilde olduğunda yüksek performans göstermektedir ancak farklı dillerde uygulandığında model başarımı dağılım farkları (domain shift) nedeniyle düşmektedir. Bu sorunu çözmek için transformer tabanlı bir model geliştirilmiş ve yalnızca birkaç etiketli örnek içeren yeni bir dile uyarlanması için sahte etiketleme (pseudo-labeling) stratejisi kullanılmıştır. Sert (hard) ve yumuşak (soft) sahte etiketleme yöntemleri karşılaştırılmış, özellikle sert sahte etiketlerin daha iyi sonuç verdiği belirlenmiştir. Model, beş farklı dilden oluşan bir veri kümesi üzerinde değerlendirilmiş ve geleneksel yöntemlere göre ortalama %40 ağırlıksız doğruluk artışı sağladığı gösterilmiştir. Bu yöntem, kullanıcıların etkileşimde olduğu cihazlarda (örneğin akıllı aynalar, telefonlar, saatler) duygu tanımanın daha düşük maliyetle ve daha geniş dil kapsamıyla gerçekleştirilmesini sağlamayı hedeflemektedir. Son olarak, etiketli ve sahte etiketli verilerin dengelenmesi ile modelin genelleme yeteneğinin artırılabileceği gösterilmiştir. Bu çalışmada, çapraz dil (cross-lingual), bir SER modelinin eğitildiği dilden farklı bir dilde test

edilmesi veya uygulanması anlamına gelmektedir. Geleneksel SER modelleri, eğitim ve test verileri aynı dilde olduğunda yüksek performans gösterirken, farklı diller arasında duygu tanıma yapılmaya çalışıldığında "dağılım farkı" (domain shift) nedeniyle başarım düşebilir. Çalışmada, farklı dillerden etiketli ve etiketsiz verileri kullanarak bir modelin yeni bir dile uyum sağlaması için yarı gözetimli öğrenme (semi-supervised learning, SSL) ve sahte etiketleme (pseudo-labeling) yöntemleri uygulanmıştır. Bu sayede, çok az etiketli örnekle bile modelin çapraz dil senaryolarında duygu tanıma başarımının artması hedeflenmiştir.

Ahn ve ark. (Ahn vd., 2025) çalışmalarında, çapraz-korpus SER (cross-corpus SER) alanındaki performans sınırlamalarını aşmak için çok görevli bir Transformer modeli önermişlerdir. Çalışmada, ana görev olarak SER kullanılırken, yan görevler olarak karşıt öğrenme (contrastive learning) ve bilgi maksimizasyonu (information maximization) uygulanmıştır. Model, duygusal etiket içermeyen hedef verilerden daha iyi temsil öğrenmek amacıyla tasarlanmıştır. Transformer tabanlı bu yaklaşım, IEMOCAP, MSP-IMPROV ve EMO-DB veri kümeleri üzerinde test edilerek çapraz-korpus ortamında önceki çalışmalara kıyasla daha yüksek doğruluk oranları elde etmiştir. Ayrıca, ses ve metin modalitelerini ayrı ayrı işleyerek karar düzeyinde füzyon (decision-level fusion) ile çok modlu duygu tanıma (MER) gerçekleştirilmiştir. Sonuçlar, önerilen çok görevli Transformer modelinin çapraz-korpus SER performansını artırdığını ve farklı veri kümeleri arasında daha iyi genelleme sağladığını göstermektedir.

Wang, Boumadane ve ark. (Wang vd., 2021) çalışmalarında, wav2vec 2.0 ve HuBERT gibi konuşma öz-denetimli (self-supervised) modellerin, ASR dışındaki görevlerdeki performanslarını incelemişlerdir. Araştırma, bu modellerin ince ayarlarının (fine-tuning) SER, konuşmacı doğrulama (speaker verification) ve konuşulan dil anlama (spoken language understanding) gibi görevlerde etkili olduğunu göstermişlerdir. Önerilen model yapılarıyla, IEMOCAP veri kümesinde konuşmacıya bağımlı senaryoda %79,58 ağırlıklı doğruluk ve konuşmacıya bağımsız senaryoda %73,01 ağırlıklı doğruluk oranı elde edilmiştir. Ayrıca, VoxCeleb1 veri kümesinde %2,36 eşit hata oranı (EER) ve SLURP veri kümesinde %89,38 doğruluk (intent sınıflandırması) ve %78,92 F1 Skoru (slot doldurma) elde edilmiştir. Sonuçlar, ince ayarlı wav2vec 2.0 ve HuBERT modellerinin, prosodik, ses

izi ve anlamsal temsiller öğrenmede güçlü olduklarını ve gerçek dünya uygulamalarında önemli potansiyele sahip olduklarını göstermektedir.

Wagner ve ark. (Wagner vd., 2023) çalışmalarında SER alanında transformer tabanlı mimarilerin etkinliğini kapsamlı bir şekilde incelemişlerdir. Özellikle wav2vec 2.0 ve HuBERT modelleri, MSP-Podcast veri kümesinde uyum (arousal), baskınlık (dominance) ve hoşnutluk (valence) boyutlarında ince ayar yapılarak değerlendirilmiş, ayrıca IEMOCAP ve MOSI veri kümelerinde çapraz veri kümesi genellemesi test edilmiştir. Çalışmanın öne çıkan bulgusu, açık dilsel bilgi kullanılmadan hoşnutluk tahmininde elde edilen 0.638'lik uyum korelasyon katsayısı (concordance correlation coefficient, CCC) ile literatürdeki en yüksek performansa ulaşılmasıdır. Transformer tabanlı modellerin, CNN tabanlı modellere kıyasla daha dayanıklı (robust), cinsiyet grupları arasında daha adil ve farklı veri kümelerinde daha iyi genelleme yeteneğine sahip olduğu ortaya konmuştur. Modelin başarısının, ince ayar sürecinde öğrenilen örtük dilsel bilgilere dayandığı belirlenmiştir. Bu çalışma, konuşma dilindeki dilbilimsel ve paralinguistik bilgi akışlarını entegre eden önceden eğitilmiş transformer tabanlı modellerin SER alanında yeni bir dönemin başlangıcını işaret ettiğini göstermektedir.

Chen ve Rudnicky (Chen ve Rudnicky, 2023) çalışmalarında, wav2vec 2.0 modelinin SER performansını artırmak için geliştirilen farklı ince ayar (fine-tuning) stratejilerini araştırmışlardır. Çalışmada üç temel yöntem karşılaştırılmıştır: Vanilla Fine-Tuning (V-FT), Task Adaptive Pretraining (TAPT) ve yeni geliştirilen Pseudo-label Task Adaptive Pretraining (P-TAPT). V-FT yöntemi, IEMOCAP veri kümesinde mevcut en iyi (state-of-the-art, SOTA) modellerden daha iyi sonuçlar elde etmiş, TAPT ise ince ayar performansını daha da artırmıştır. P-TAPT yöntemi, TAPT stratejisinin hedef görev odaklı hale getirilmiş bir versiyonudur ve özellikle veri yetersizliği durumlarında üstün performans sergilemiştir. IEMOCAP ve SAVEE veri kümeleri üzerinde yapılan deneylerde, P-TAPT yöntemiyle IEMOCAP'te %7,4'lük ağırlıksız doğruluk artışı sağlanmıştır. Ayrıca, çalışmada SER'deki alan kayması (domain shift) sorunu analiz edilmiş ve bu sorunun ince ayar stratejileriyle aşılabileceği gösterilmiştir. Ayrıca çalışmada, veri verimliliği (data efficiency) açısından farklı ince ayar yöntemlerinin performansı da incelenmiştir. Buna göre sonuçlar, P-TAPT'nin düşük veriyle daha verimli çalıştığını göstermektedir. Bu sonuçlar, wav2vec

2.0'ın SER alanında etkili bir temel model olduğunu ve geliştirilen stratejilerin çok modlu uygulamalara da genellenebileceğini ortaya koymaktadır.

Feng ve Narayanan (Feng ve Narayanan, 2024) çalışmalarında, SER süreçlerini iyileştirmek amacıyla temel modellerin transkripsiyon, duygu etiketleme ve veri artırma aşamalarında nasıl kullanılabileceğini araştırmıştır. Geleneksel SER sistemleri, etiketleme ve veri toplama süreçlerinde yüksek maliyet ve zaman gereksinimleri nedeniyle ölçeklenebilirlik açısından zorluklar yaşamaktadır. Bu çalışmada, Whisper ve MMS gibi ASR modelleri kullanılarak konuşmaların transkribe edilmesi, ardından LLaMa 2, Falcon ve Flan-T5 gibi büyük dil modelleri (LLM) ile duygu etiketlemesi yapılması önerilmektedir. Deneyler, ASR transkriptlerinin SER sistemlerinin doğruluğunu artırabileceğini, ancak duygu etiketlemenin dil modelleri ile tamamen otomatik hale getirilmesinin hâlâ zorlayıcı olduğunu göstermektedir. LLM'lerin tek başına düşük doğruluk sunduğu, ancak farklı LLM'lerin çıktılarının birleştirilmesi (Mixture of Experts, MoE) ve sınırlı insan geri bildirimiyle (Human Feedback, HF) desteklenmesi durumunda etiketleme kalitesinin önemli ölçüde arttığı gözlemlenmiştir. Çalışmanın bulguları, temel modellerin SER süreçlerinde veri artırma ve etiketleme görevlerinde önemli rol oynayabileceğini, ancak insan müdahalesinin tamamen ortadan kaldırılamayacağını göstermektedir. Gelecekte, çok modlu yaklaşımlarla (konuşma + metin) duygu anotasyonlarının iyileştirilmesi önerilmektedir. Bu çalışmada transkript, konuşma içeriğinin metin formatına dönüştürülmesi işlemidir. Konuşma tanıma sistemlerinde, ses dalgalarından elde edilen kelimeler ve cümleler yazıya dökülerek ASR sistemleri tarafından işlenir. Yukarıdaki makalede transkript, Whisper ve MMS gibi ASR modelleri kullanılarak konuşma verilerinin yazılı hale getirilmesi sürecini ifade etmektedir. Bu transkriptler, SER sistemlerinde hem akustik hem de metin tabanlı analizleri birleştirerek duygu tanıma başarısını artırmak amacıyla kullanılmaktadır.

2.2.4. Topluluk Öğrenmesi

Topluluk öğrenme yöntemleri hem makine öğrenmesi hem de derin öğrenme alanlarında kullanılabilen bir tekniktir. Bu yöntemler, birçok temel modeli bir araya getirerek daha güçlü ve daha istikrarlı bir tahmin veya sınıflandırma sonucu elde etmeyi amaçlar.

Zehra ve ark. (Zehra vd., 2021) çalışmalarında, robotlar ve insan–bilgisayar etkileşiminde konuşma tabanlı duygusal yanıtların doğru bir şekilde algılanması için çapraz veri kümesi ve çok dilli SER sistemi önermektedir. Geleneksel yaklaşımlar, genellikle tek bir veri kümesi üzerinde eğitilip test edildiği için çok dilli ortamlarda genellenemez. Bu çalışma, çoklu makine öğrenimi algoritmalarını (Sequential Minimal Optimization (SMO), RF, and J48) birleştiren "majority voting" (çoğunluk oyu) yöntemi ile bir topluluk öğrenme tekniği önererek bu sorunu çözmeyi hedeflemiştir. Çalışmada, Urduca, İngilizce, Almanca ve İtalyanca dillerinde dört farklı veri kümesi (SAVEE, URDU, EMO-DB, EMOVO) üzerinde deneyler yapılmıştır. Sonuçlar, topluluk öğrenme yaklaşımının geleneksel yöntemlere kıyasla hem aynı veri kümesi içinde hem de çapraz veri kümelerinde daha iyi performans sağladığını göstermiştir. Örneğin, topluluk yöntemi ile Urduca veri kümesinde %13, EMO-DB'de %8, EMOVO'da %11 ve SAVEE'de %5 doğruluk artışı elde edilmiştir. Çalışma, robotların çok dilli kullanıcılarla duygusal zeka ile daha etkili etkileşim kurmasını sağlayacak bir sistem sunmaktadır. Gelecekte, doğal ortamda kaydedilmiş konuşma verileri ve farklı topluluk teknikleriyle yapılan deneylerle doğruluğun daha da artırılması planlanmaktadır.

Ahmed ve ark. (Ahmed vd., 2023) çalışmalarında, SER için veri artırma teknikleriyle güçlendirilmiş bir 1D-CNN-LSTM-GRU topluluk modeli önermektedir. Model, konuşma sinyallerinden hem yerel hem de uzun vadeli bağlamsal özellikleri çıkarmak için CNN, LSTM ve GRU mimarilerinin birleşiminden oluşmaktadır. TESS, EMO-DB, RAVDESS, SAVEE ve CREMA-D gibi beş farklı veri kümesi üzerinde test edilen modelde, MFCC, log-mel spectrogram, ZCR, chromagram ve RMS Energy gibi özellikler kullanılmıştır. Veri artırma kapsamında beyaz gürültü ekleme, perde kaydırma ve zaman esnetme teknikleri uygulanmıştır. Topluluk modeli, bireysel modellerin ağırlıklı ortalamasını alarak çalışmakta ve bu sayede TESS veri kümesinde %99,46; EMO-DB'de %95,42; RAVDESS'te %95,62; SAVEE'de %93,22 ve CREMA-D'de %90,47 ağırlıklı ortalama doğruluk oranlarıyla önceki çalışmalara kıyasla üstün performans göstermektedir.

ÜÇÜNCÜ BÖLÜM
MATERYAL YÖNTEM

3.1. Plutchik'in Duygu Çarkı Modeli

Mevcut duygu analizi çalışmalarının çoğu (Aslan, 2023; Balli vd., 2022; Bozuyla, 2023; Polat ve Ağca, 2022; Savci ve Das, 2023; H. Shehu vd., 2021; Tepecik ve Demir, 2024a; Tohma vd., 2023; Uca vd., 2022; Uyaroğlu Akdeniz ve Cebeci, 2021) duyguları olumlu, olumsuz ve nötr olmak üzere iki veya üç kategoriye ayırarak değerlendirir. Ayrıca, üçten fazla duygu kategorisi kullanan çalışmalar nispeten sınırlıdır (Guven, 2021). Dahası, bu çalışmalarda genellikle duyguların seçimi için net kriterlerin bulunmaması dikkat çekicidir.

Bu çalışma, Plutchik'in Duygu Çarkı'nı Türkçeye uygulayan literatürdeki ilk çalışmadır. Duygu-Türk, bu modeli kullanarak birincil duyguların kümesini genişletir, duygu yoğunluğunu belirler ve duygu kombinasyonlarının oluşturduğu ikincil duyguları etiketler.

Plutchik (Plutchik, 1982) tarafından geliştirilen duygu teorisi, insanların yaşamları boyunca bir dizi temel duygu yaşadıklarını savunur. Bu birincil duyguları, duygu yoğunluğundaki değişiklikleri ve bunların kesişimlerinden oluşan ikincil duyguları temsil etmek için Duygu Çarkı modelini geliştirmiştir. Bu model Şekil 3'te sunulmuştur.

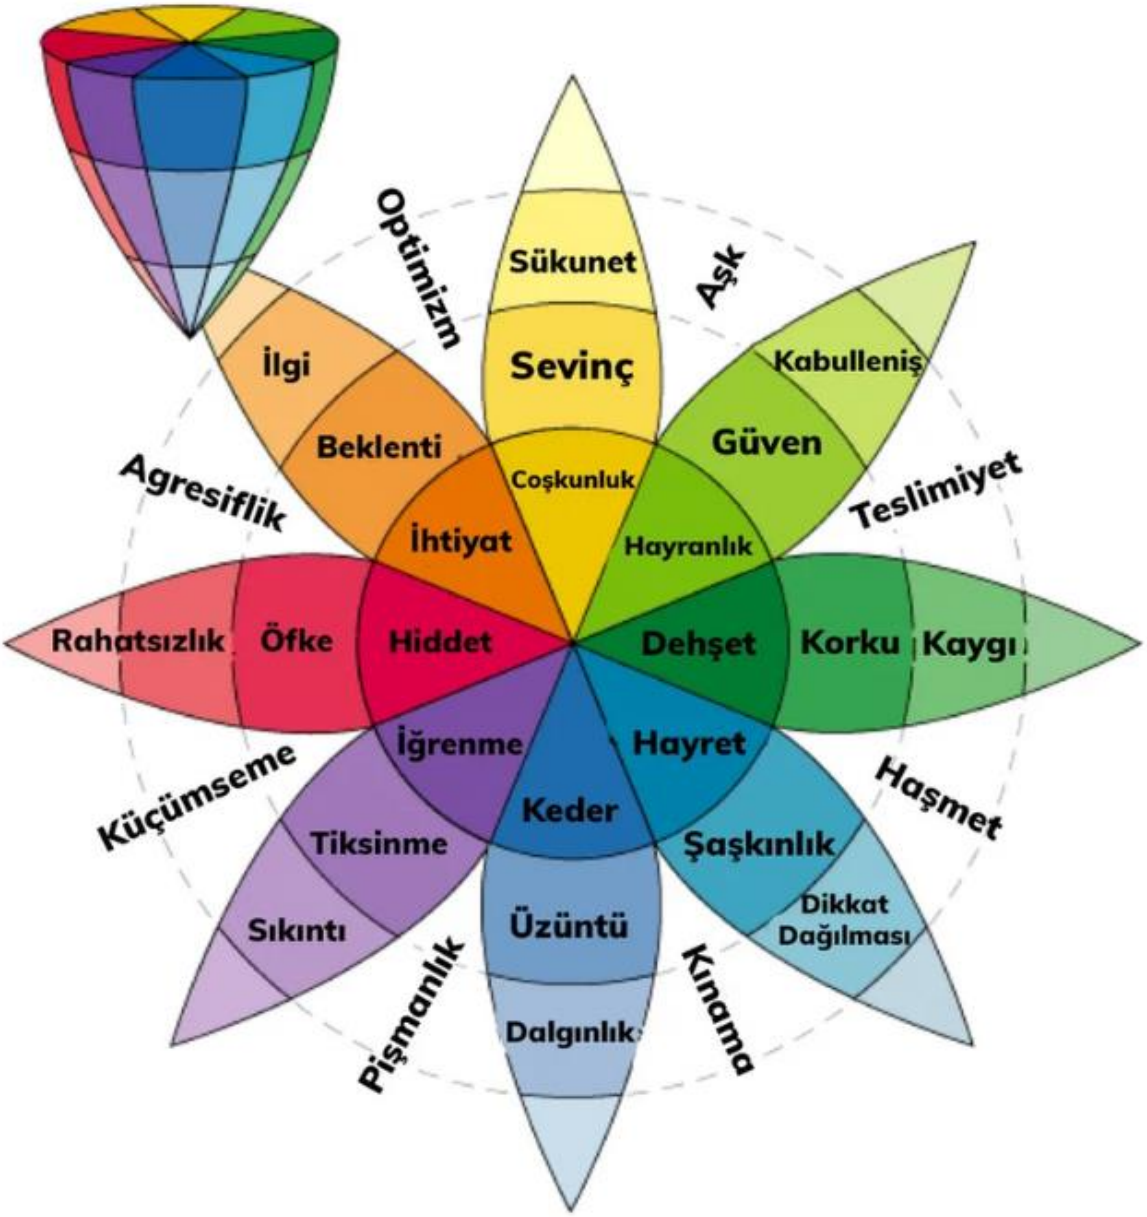

Şekil 3. Psikolog Robert Plutchik tarafından geliştirilen duygu teorisine göre oluşturulmuş duygu çarkı modeli (https://www.6seconds.org/2025/02/06/plutchik-wheel-emotions/, t.y.).

Plutchik (Plutchik, 1982) tarafından geliştirilen duygu teorisi, insanların yaşamları boyunca deneyimledikleri temel duyguların olduğunu savunur. Plutchik, bu duyguların evrimsel olarak geliştiğine ve her birinin belirli bir işlevi olduğunu öne sürmektedir. Plutchik'in duygu teorisi, sekiz temel duygu olarak kabul edilen duyguları ayrıntılı olarak açıklamaktadır:

- Sevinç: Başarı, mutluluk, sevgi, neşe gibi pozitif duyguları ifade eder.
- Güven: Güven, emniyet, huzur, rahatlık gibi pozitif duyguları ifade eder.
- Korku: Korku, endişe, kaygı, dehşet gibi negatif duyguları ifade eder.
- Şaşkınlık: Şaşkınlık, hayret, merak, şaşırtma gibi nötr duyguları ifade eder.
- Üzüntü: Kayıp, acı, yalnızlık, hüzün gibi negatif duyguları ifade eder.
- Tiksinme: Tiksinme, iğrenme, nefret, tiksinti gibi negatif duyguları ifade eder.
- Öfke: Öfke, sinir, hiddet, kızgınlık gibi negatif duyguları ifade eder.
- Beklenti: Beklenti, umut, arzu, hayal gibi nötr duyguları ifade eder.

Plutchik, bu temel duyguların birbirleriyle ilişkili olduğunu ve birbirlerini karşılıklı olarak güçlendirebildiklerini veya zayıflatabildiklerini de belirtir. Örneğin, öfke ve korku birbirini güçlendirebilirken, sevinç ve korku birbirini zayıflatabilir. Ayrıca Plutchik'in teorisine göre temel duygular birbirleriyle etkileşim içine girerek ikincil duyguları oluşturur (Plutchik, 1982). Bu ikincil duygular şu şekildedir:

- Sevinç + Güven = Aşk (Love)
- Güven + Korku = Teslimiyet (Submission)
- Korku + Şaşkınlık = Haşmet (Awe)
- Şaşkınlık + Üzüntü = Kınama (Disappointment)
- Üzüntü + Tiksinme = Pişmanlık (Remorse)
- Tiksinme + Öfke = Küçümseme (Contempt)
- Öfke + Beklenti = Agresiflik (Aggressiveness)
- Beklenti + Sevinç = Optimizm (Optimism)

Plutchik'in duygu teorisi, psikoloji, sosyoloji, antropoloji, sanat ve diğer alanlarda kullanılan birçok araştırmada ve uygulamada kullanılmaktadır. Ayrıca, Plutchik'in teorisi, duyguların işlevleri, çeşitleri ve nedenleri hakkında derinlemesine bir anlayış sağlar. Bu nedenle geliştirilen yöntemde, Plutchik'in duygu teorisinde yer alan temel duygular ve bu duyguların yoğunlukları ile ikincil duygular ele alınmaktadır.

Duygu-Türk, Plutchik'in Duygu Çarkı'nı kullanarak sekiz temel duyguyu, ikincil duyguları oluşturan kombinasyonları ve her biriyle ilişkili farklı yoğunluk düzeylerini temel almaktadır.

Buradan sonraki bölümlerde materyal ve yöntem, "yazılı metinler" ve "sözlü metinler" için ayrı başlıklar altında incelenmektedir.

3.2. Yazılı Metinler için Materyal

Yazılı Metinler için veri kümesi, ilk kaynak olarak Türk Dil Kurumu Sözlükleri'nde bulunan kelimeler için verilen örnek cümlelerden; ikinci kaynak olarak https://deyimlerimiz.com/ web sayfasında bulunan örnek cümlelerden; son olarak ise manuel olarak kurulan cümlelerden oluşturulmuştur.

Veri kümesi ilk olarak XLSX formatında bir dosya olarak oluşturulmuştur. Uygun görülen cümle, belirtilen dosyaya eklenmiştir. Ardından, eklenen cümle, Plutchik'in duygu çarkında yer alan temel ve ikincil duygular; kuvvetlendirici ve zayıflatıcı ifadeler; monoton olmayan mantık (Non-monotonic Logic) yaklaşımı; duygu ifade eden kelimeler, atasözleri, deyimler, birleşik fiiller veya kalıp sözler; duygu ifade eden noktalama işaretleri; duygusal fonksiyon kazandıran (Morfo-Semantik) ekler dikkate alınarak etiketlenmiştir. Belirtilen şekilde oluşturulmuş ve etiketlenmiş 136.000 adet cümleden oluşan veri kümesi elde edilmiştir. Ardından veri kümesi, CSV uzantılı formata dönüştürülmüştür. Veri kümesindeki satırların dengeli dağılım göstermesi için iki kez satırları rastgele karıştırma işlemi (data shuffling) uygulanmıştır. Veri kümesi geliştirilen yöntem için hazır hale getirilmiştir. Veri kümesinin oluşumu ve etiketleme işleminde dikkat edilen özellikler, Şekil 4'te gösterilmektedir.

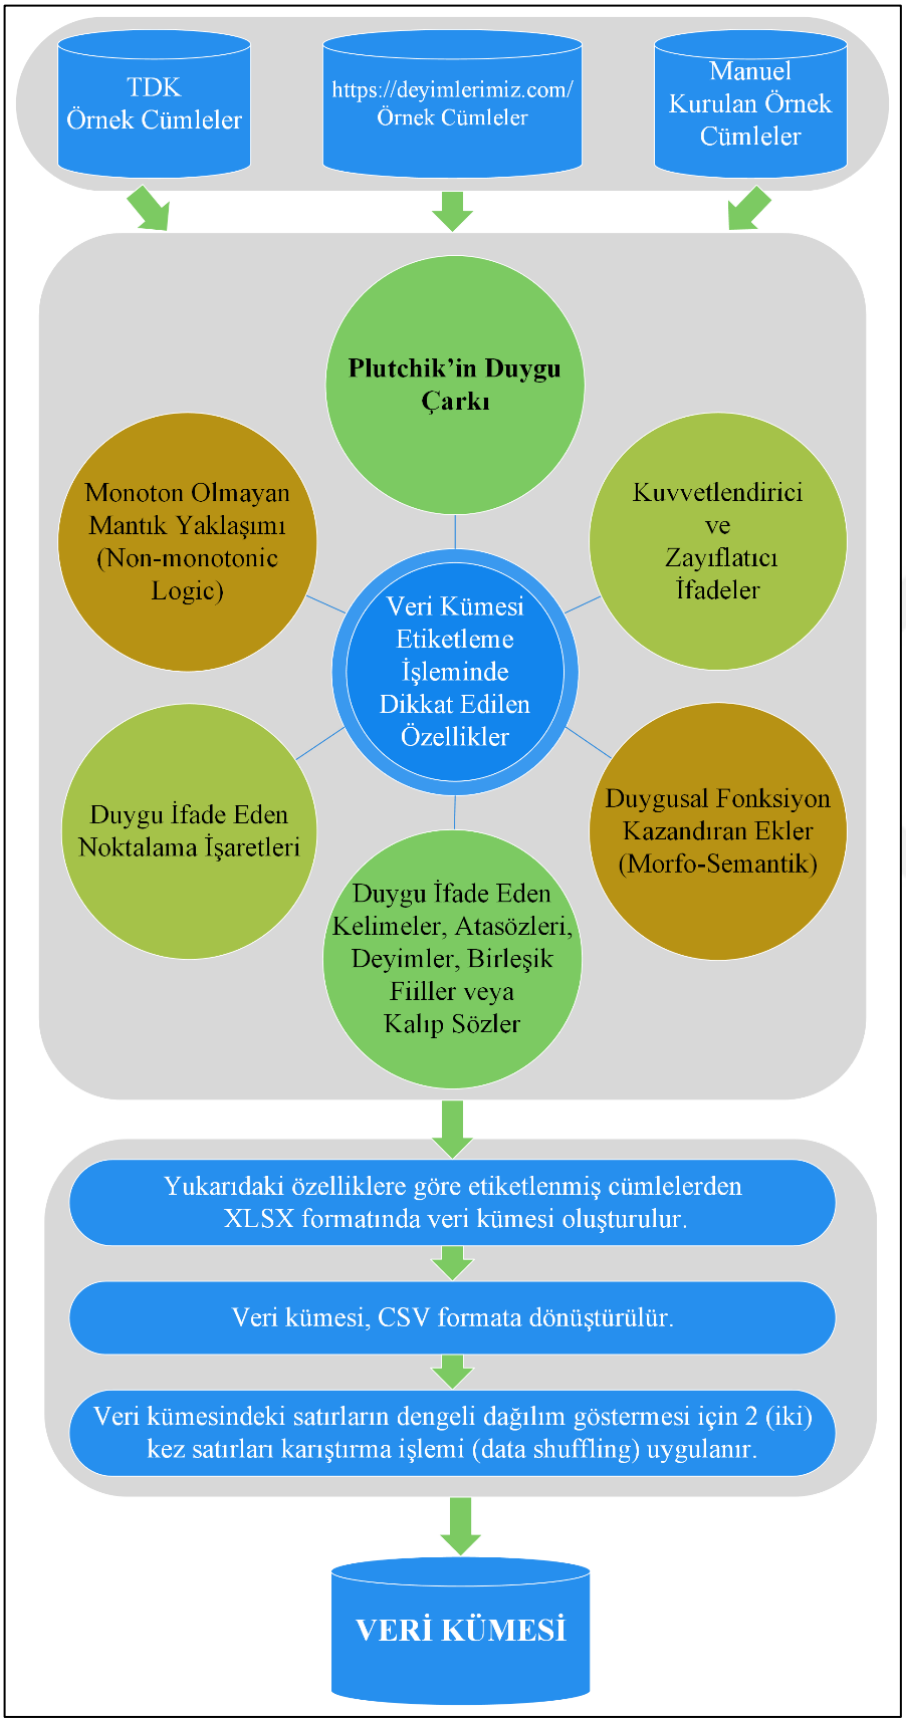

Şekil 4. Yazılı metinler için veri kümesinin oluşumu ve etiketleme işleminde dikkat edilen özellikler.

3.2.1. Metin Veri Kümesinin Oluşumu

Türk Dil Kurumu Örnek Cümleler

Duygusal ifadelerin yer aldığı örnek cümleler elde edilirken, öncelikle Türk Dil Kurumu Sözlükleri'nden Güncel Türkçe Sözlük'te yer alan kelimeler için verilen örnek cümleler değerlendirilmiştir. Türk Dil Kurumu sözlüklerinde yer alan cümle örnekleri, çeşitli edebî değeri olan eserlerden toplanmış, kullanımı doğru olan cümlelerden oluşmaktadır. Veri kümesinde yer alan örnek cümlelerin doğru, değerli ve anlamlı olması, geliştirilen yöntemin başarısını doğrudan etkileyeceği düşünüldüğünden Türk Dil Kurumu Sözlükleri, ilk veri kaynağı olarak tercih edilmiştir. https://www.kaggle.com/ web sayfasında NLP (Natural Language Processing) çalışmaları için paylaşılan güncel TDK sözlük, veri kaynağı olarak indirilmiştir. Bu kaynak, JSON dosya formatındadır. JSON formatındaki dosya, XLSX formatına dönüştürülmüştür. Bu sayede veri kümesi üzerinde daha kolay analiz yapılabilmesi sağlanmıştır. XLSX formatına dönüştürülen veri kaynağında 91.304 kelime, birleşik kelime ve deyim yer almaktadır. JSON formatından gelen ve excel dosyaya [List] şeklinde aktarılan "anlam" sütunu açıldığında ise yazılışları aynı, anlamları farklı olan kelimeler mükerrer olarak ilgili listeye eklenmektedir. Bu şekilde, anlam listesi açılarak aktarılan TDK sözlükte ise 121.458 kelime, birleşik kelime ve deyim yer almaktadır. Bu veri kaynağında örnek cümleler filtrelendiğinde, TDK sözlükte 34.360 örnek cümle yer aldığı görülmüştür. Yapılan incelemede, -az da olsa- bazı örnek cümlelerin, farklı kelimeler için ortak örnek cümle olarak kullanıldığı görülmüştür. TDK sözlükte yer alan ve duygu içeren örnek cümleler, veri kümesine eklenmiştir. Şekil 5'te Türk Dil Kurumu Güncel Türkçe Sözlük'te yer alan "sevinç" kelimesi ve bu kelime için verilen örnek cümle gösterilmektedir.

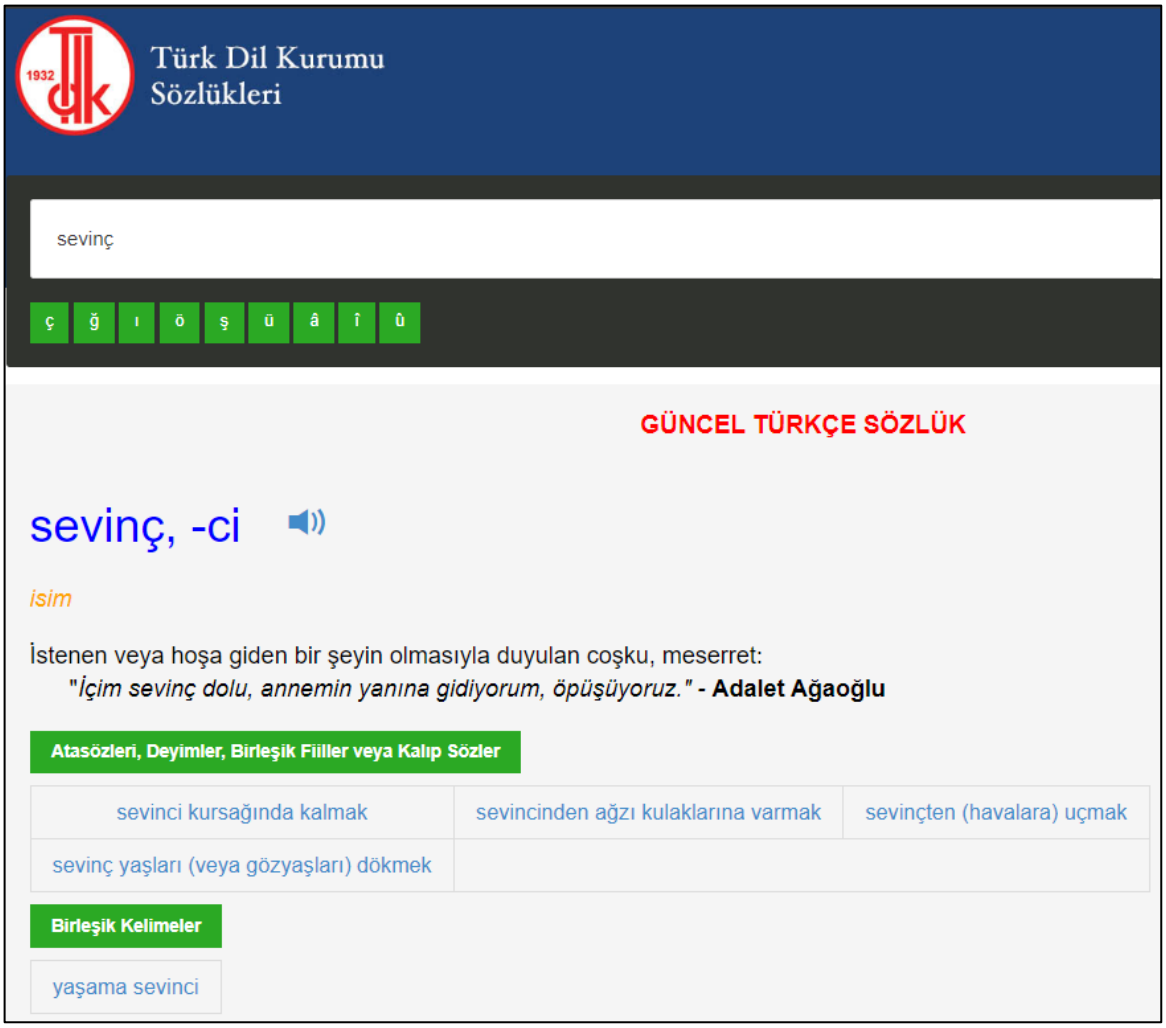

Şekil 5. Türk Dil Kurumu Güncel Türkçe Sözlük'te "sevinç" kelimesinin gösterimi (Türk Dil Kurumu, t.y.).

Web Sayfası (https://deyimlerimiz.com/) Örnek Cümleler

İkinci veri kaynağı olarak https://deyimlerimiz.com/ web sayfasında yer alan örnek cümleler değerlendirilmiştir. Belirtilen web sayfasında birçok deyim yer almaktadır. Bu deyimlere verilen örnek cümleler, günlük konuşma diline yakın, düzgün kurulmuş ve TDK'ya uyumlu cümlelerdir. Bu sebeple belirtilen web sayfasında duygu ifade eden deyimler için verilen örnek cümleler, veri kümesine eklenmiştir. Şekil 6'da https://deyimlerimiz.com/ web sayfasında, "sevinç" duygusu ifade eden "etekleri zil çalmak" deyiminin anlamı, açıklaması ve verilen örnek cümleler gösterilmektedir.



Şekil 6. https://deyimlerimiz.com/ web sayfasında "etekleri zil çalmak" deyiminin gösterimi.

Manuel Kurulan Örnek Cümleler

Veri kümesine son olarak manuel olarak kurulan cümleler eklenmiştir. Cümleler manuel olarak kurulurken; Plutchik'in duygu çarkında yer alan temel ve ikincil duygular; kuvvetlendirici ve zayıflatıcı ifadeler; monoton olmayan mantık (Non-monotonic Logic) yaklaşımı; duygu ifade eden kelimeler, atasözleri, deyimler, birleşik fiiller veya kalıp sözler; duygu ifade eden noktalama işaretleri; duygusal fonksiyon kazandıran (Morfo-Semantik) ekler dikkate alınmıştır.

Manuel etiketlemede tutarlılık ve güvenilirliği sağlamak için, dil bilim geçmişi olan ana dili Türkçe olan üç kişi anotatör (annotator, yorumcu) olarak görevlendirilmiştir. Bu kişiler, 16 duygu kategorisinin her biri için resmi tanımlar ve örnekler ile belirsizliği gidermeye yönelik kuralları içeren standart bir kılavuz belgesini takip etmişlerdir. Bu tanımlar ve karar kuralları, özellikle koşullu duygu ifadeleri, kuvvetlendirici ve zayıflatıcı ifadeler, noktalama işaretleri, morfo-semantik ekler vb. durumları içermekte olup ileriki bölümlerde ayrıntılı olarak açıklanmaktadır.

Anotatörler arasındaki uyumu göstermek için Fleiss Kappa metriği (Fleiss, 1971) kullanılmıştır. Bu metrik, anotatör sayısı ikiden fazla olduğunda daha güvenilir sonuçlar vermektedir (Sim ve Wright, 2005). Fleiss Kappa puanı 0,81 olarak hesaplanmıştır. Bu, anotatörler arasında önemli bir uyum olduğunu göstermektedir.

Manuel etiketlemeye ek olarak, otomatik bir etiketleme mekanizması da uygulanmıştır. Bu amaçla, çevrimiçi açık erişimli edebi kaynakları indirmek için bir web kazıyıcı (web scraper) tasarlanmıştır. Bu kaynaklar cümlelere ve ardından kelimelere bölünür, işlenir ve otomatik etiketleme için LSTM modeline aktarılabilmektedir.

3.2.2. Veri Kümesi Etiketleme İşleminde Dikkat Edilen Özellikler

Kuvvetlendirici ve Zayıflatıcı İfadeler

Önerilen yöntemde “çok, daha çok, çok fazla, çok daha fazla” gibi kuvvetlendirici ifadeler ile “az, çok az, biraz, daha az, çok daha az” gibi zayıflatıcı ifadeler dikkate alınmıştır. Veri kümesi etiketlenirken, duygulara ait sınıf etiketlerinin aldığı değerler, ilgili duygunun yoğunluğunu ifade edebilecek şekilde belirlenmiştir. Her duygunun duygu yoğunluğu seviyeleri; “0, 0.2, 0.4, 0.6, 0.8, 1, 1.2, 1.4, 1.6, 1.8” olarak belirlenmiştir. “0”, duygunun hiç olmaması, “1” ise duygunun var olmasıdır. Diğer değerler ise duygu yoğunluğunu seviyelerini kolay ifade etmek için tercih edilmiştir. Örneğin; “0.2” duygunun en hafif yoğunluğa sahip durumunu, “1.8” ise duygunun en yoğun durumunu ifade etmektedir.

Kuvvetlendirici ve zayıflatıcı ifadeler, duygu yoğunluğuna direkt etki ettikleri için manuel etiketleme adımında dikkat edilen unsurlardan biridir. Türkçe cümle yapıları incelenerek kuvvetlendirici ifadeler, "çok, daha, da, pek, fazla, en, derin, büyük, aşırı" olarak; zayıflatıcı ifadeler ise "az, biraz, küçük, minicik, azıcık" olarak belirlenmiştir. Bu ifadeler, veri kümesindeki örnek cümlelerde farklı kombinasyonlarda bir araya geldiklerinde duygu yoğunluklarını değiştirdiklerinden farklı sınıf etiketleri ile ifade edilmişlerdir. Bu ifadelerin örnek cümlelerde rastlanan kombinasyonları ve bu kombinasyonların duygu yoğunluk değişimini ifade eden sınıf etiketleri Tablo 1'de gösterilmektedir.

Tablo 1. Kuvvetlendirici / Zayıflatıcı ifadeler ve sınıf etiketleri.

Kuvvetlendirici ve Zayıflatıcı İfadelerin Kombinasyonları	**Sınıf Etiketleri**
Çok	1.2
Pek	1.2
Büyük	1.2
En	1.2
Daha Çok	1.4
Pek Çok	1.4
Çok Fazla	1.4
Pek Fazla	1.4
Çok Ama Çok	1.4
Çok Daha Fazla	1.6
Çok Çok Fazla	1.6
Daha da Çok	1.6
Aşırı	1.8
Haddinden fazla	1.8
Son derece	1.8
Derin	1.8
Az	0.8
Biraz	0.8
Küçük	0.8
Çok Az	0.6
Daha Az	0.6
Pek Az	0.6

Tablo 1 Devamı

Daha da Az	0.4
Çok Daha Az	0.4
Azıcık	0.2
Minicik	0.2

Monoton Olmayan Mantık Yaklaşımı (Non-monotonic Logic)

Reiter (Reiter, 1980), monoton olmayan mantığın (non-monotonic logic) ilk kez tanımlandığı ve ele alındığı önemli bir çalışma sunmuştur. Bu çalışma, monoton olmayan mantığın önemli bir bileşeni olan varsayılan akıl yürütme üzerine odaklanmıştır ve monoton olmayan mantığın temellerinin atıldığı çalışmalardan biridir. Reiter'in bu çalışması, yeni bilgiler ışığında çıkarımların değişebileceği durumları modelleyen bir mantık sisteminin teorik altyapısını oluşturmaktadır.

Literatüre bakıldığında genellikle duygu analizi yöntemlerinin monoton mantık yaklaşımı (Monotonic Logic) ile tasarlandığı ve genel olarak sadece "pozitif, negatif, nötr" olmak üzere standart sınıfların belirlendiği görülmüştür. Bu yaklaşım; koşula bağlanmış, henüz kesinleşmemiş duygusal durumları, sanki kesinleşmiş gibi yargıya vararak sınıflandırmaktadır. Bu nedenle koşula bağlı duyguları ve duygu durumu değişimlerini yansıtmaktan uzaktır (Boratav vd., 2011). Bu eksikliği gidermek amacıyla, geliştirilen yöntemde ise monoton olmayan mantık (non-monotonic logic) yaklaşımı takip edilerek "pozitif ve negatif" olarak yapılan sınıflandırmaların geçersiz hale gelebileceği ve değişebileceği "koşullu-pozitif" ve "koşullu negatif" durumları da ele alınmıştır. Geliştirilen yöntemde "anlamsal sonuç" sınıfları, "pozitif, negatif, nötr, koşullu pozitif, koşullu negatif" olmak üzere beş farklı etiketten oluşmaktadır. Bu yaklaşım, duygu analizi bakımından daha gerçekçi sonuçlar üretmektedir. Örneğin; "Beni dinlersen çok mutlu olurum" cümlesinde "mutlu olma" durumu, bir koşula bağlanmıştır. Bu cümleyi kuran kişi, henüz mutlu değildir ve bu kişinin mutlu olması, konuştuğu kişinin kendisini dinleyip dinlememe durumuna göre değişebilir. Bu sebeple, örnekteki cümleyi, "pozitif" olarak sınıflandırmak doğru değildir. "Mutlu olmak" pozitif bir duygu olduğundan ve bu duygu koşula bağlandığından "koşullu-

pozitif" olarak sınıflandırmak daha gerçekçi bir yaklaşım olacaktır. Tablo 2'de, "koşullu-pozitif" ve "koşullu negatif" sınıflar için farklı örnek cümleler gösterilmektedir.

Tablo 2. Koşullu pozitif ve koşullu negatif sınıflar için örnek cümleler.

Sıra No	Örnek Cümle	Anlamsal Sonuç	Açıklama
1	Söylediklerimi yaparsan ikimiz de mutlu oluruz.	kosullu-pozitif	"Mutlu olmak", söylenilenlerin yapılıp yapılmaması koşuluna bağlanmıştır. Henüz mutlu olan biri yoktur.
2	Yüksek not alırsan dünyalar benim olur.	kosullu-pozitif	"Dünyalar benim olur" ifadesi mutluluk belirten kalıp sözlerden biridir. Mutluluk, yüksek not alınıp alınmaması koşuluna bağlanmıştır. Henüz mutluluk yaşayan biri yoktur.
3	İşler tıkırında giderse, çok keyifli oluruz.	kosullu-pozitif	"Keyifli olmak", işlerin tıkırında gidip gitmemesi koşuluna bağlanmıştır. Henüz çok keyifli olan biri yoktur.
4	Müjdeyi versem, herkesin yüzü güler.	kosullu-pozitif	"Herkesin yüzünün gülmesi", müjdeyi verip vermeme koşuluna bağlanmıştır. Henüz yüzü gülen biri yoktur.
5	İşe geç kalırsak patron çok öfkelenir.	kosullu-negatif	"Patronun çok öfkelenmesi", işe geç kalıp kalmama koşuluna bağlanmıştır. Henüz öfkelenen biri yoktur.
6	Kendisine iki laf edilse, öfkeden gözleri yuvalarından fırlar.	kosullu-negatif	"Gözleri yuvalarından fırlamak" deyimi, bu cümlede -öfkelenmek- anlamında kullanılmıştır. Öfkelenme duygusu, kendisine iki laf edilip edilmemesi koşuluna bağlanmıştır. Henüz öfkelenen biri yoktur.
7	Yere tükürdüğünü görürsem buz gibi soğurum senden.	kosullu-negatif	"Buz gibi soğumak", deyimi bu cümlede -tiksinmeden ötürü nefret etmek- anlamında kullanılmıştır. Tiksinmeden ötürü nefret duygusu, yere tükürüldüğünün görülüp görülmemesi koşuluna bağlanmıştır. Henüz nefret eden biri yoktur.
8	Zamanında geri adım atmazsam pişmanlık duyarım.	kosullu-negatif	"Pişmanlık duymak" ifadesi, pişmanlık belirten bileşik fiillerden biridir. Pişmanlık duygusu, zamanında geri adım atılıp atılmaması koşuluna bağlanmıştır. Henüz pişmanlık duyan biri yoktur.

Duygu İfade Eden Noktalama İşaretleri

Cümlede yer alan "ünlem", "soru işareti" ve "yay ayraçlı ünlem" gibi duygu ifade eden noktalama işaretlerinin duygu analizi çalışmalarına katkı sağlayabileceği düşünüldüğünden ön işleme aşamasında bu işaretler kaldırılmadan tespit edilmiştir. Bu sebeple veri kümesine !, ?, (!) noktalama işaretlerini içeren örnek cümleler eklenmiştir.

- **Ünlem İşareti (“!”):** Sevinç, kıvanç, acı, korku, şaşma gibi duyguları anlatan cümle veya ibarelerin sonuna konur. Örneğin: “Hava ne kadar da sıcak!”, “Aşk olsun!”, “Ne kadar akıllı adamlar var!”, “Vah vah!” (Türk Dil Kurumu, 2019).
- **Yay Ayıraçlı Ünlem İşareti (“(!)”):** Alay, kinaye veya küçümseme anlamı kazandırılmak istenen sözden hemen sonra yay ayraç içinde ünlem işareti kullanılır. Örneğin: “İsteseymiş bir günde bitirirmiş (!) ama ne yazık ki vakti yokmuş (!)”, “Adam, akıllı (!) olduğunu söylüyor” (Türk Dil Kurumu, 2019)
- **Soru İşareti (“?”):** Bir soru sorulduğunda veya şüphe, merak veya endişe gibi duyguların ifade edildiği yerlerde kullanılabilir. Örneğin: “Neden bu kadar üzgünsün?”, “Bu nasıl gerçek olabilir?”, “Bu konuda ne düşünüyorsun?”.

Duygu İfade Eden Kelimeler, Atasözleri, Deyimler, Birleşik Fiiller veya Kalıp Sözler

Bilindiği üzere Türkçe, atasözlerin, deyimlerin, birleşik fiillerin veya kalıp sözlerin çokça yer aldığı bir dil yapısına sahiptir. Geliştirilen yöntem için duygu ifade eden cümlelerin yer aldığı bir veri kümesi oluşturulmuştur. Bu veri kümesi oluşturulurken, Türk Dil Kurumu Başkanlığı’na ait Güncel Türkçe Sözlük ve https://deyimlerimiz.com/ web sayfasında yer alan ve duygu ifade eden kelimeler, atasözleri, deyimler, birleşik fiiller ve kalıp sözlerden oluşmuş örnek cümleler veri kümesine eklenmiş ve bunun yanında manuel cümleler oluşturulmuştur. Manuel cümleler oluşturulurken -duygu ifade eden yapıların belirlenmesi sürecinde- Türk Dil Kurumu Başkanlığı’na ait sözlüklerin ve https://deyimlerimiz.com/ web sayfasının yanında farklı kaynaklardan da yararlanılmıştır. Şaş tarafından 2023 yılında “Türkiye Türkçesinde Deyimleşmiş Birleşik Duygu Fiilleri” üzerine yapılan bir çalışmada 707 adet deyimleşmiş duygu ifadeleri, temsil ettiği duygularla birlikte belirlenmiştir (Şaş, 2023). Belirtilen çalışma da dikkate alınarak duygu ifade eden yapılardan manuel olarak oluşturulan cümleler, veri kümesine eklenmiştir. Belirtilen çalışmada yer alan deyimleşmiş duygu ifadelerinden bir kesit, Tablo 3’te gösterilmektedir.

Tablo 3. Deyimleşmiş duygu ifadeleri.

Fiil	Sözlük Anlamı	Duygu Değeri	Duygu Adı

Tablo 3 Devamı

canı acı-	üzülmek, acı duymak	-	üzüntü
hâline acı-	merhamet etmek	-	üzüntü
içi acı-	üzülmek, merhamet etmek	-	üzüntü
yüreği acı-	üzülmek, merhamet etmek	-	üzüntü
gönülde şafak aç-	sevinmek, ümitlenmek	+	sevinç/ümit
gözünü aç-	rahatlamak	+	rahatlık
öfkenin önünü aç-	öfkelenmek	-	öfke
ciğeri açıl-	ferahlamak, iç sıkıntılardan kurtulmak	+	rahatlık
gönül kapısı açıl-	coşmak, ferahlamak, mutlu olmak	+	sevinç/rahatlık
gözü fal taşı gibi açıl-	hayret etmek, şaşırmak	+/-	hayret
ruhu açıl-	ferahlamak, rahatlamak	+	rahatlık
yüzü açıl-	neşelenmek	+	neşe
anası ağla-	üzülmek, sıkıntıya düşmek	-	üzüntü/sıkıntı
zar ağla-	çok üzülmek	-	üzüntü
(içi) kan ağla-	çok üzülmek	-	üzüntü
ağzının suyu ak-	imrenmek	+/-	arzu
gönlü ak-	hoşlanmak, sevmek, ilgi duymak	+	sevgi
yüreği ak-	hoşlanmak, sevmek, ilgi duymak	+	sevgi
derdini (kederini) içine akıt-	derdini veya kederini kimseye belli etmeden iç dünyasında yaşamak	-	üzüntü
hevesini al-	doyum noktasına ulaşmak, bıkmak	-	usanç

Duygusal Fonksiyon Kazandıran Ekler (Morfo-Semantik)

Türkçe dil yapısı detaylı incelendiğinde bazı eklerin, eklendikleri kelimelere duygusal fonksiyon kazandırdıkları görülmüştür. Bu konuda literatür araştırması yapılmış olup belirtilen konunun "Morfo-Semantik" adı altında incelendiği tespit edilmiştir. Bir çalışmada, "Morfo-Semantik; eklerin, eklendikleri kelimelere kazandırdığı anlam açısından inceleyen anlambilim dalıdır" ifadesi ile tanımlanmıştır (Akçataş ve Varol, 2021). Örneğin; "Çünkü zavallı kadıncağız…" ifadesinde **-cağız** ekinin, kadın sözcüğüne zavallılık ve acıma anlamları yüklediği görülmektedir (Akçataş ve Varol, 2021). Başka bir örnekte ise "Şimdi şuradan gurbetteki oğlum çıksa gelse." cümlesinde ise **-sa** ve **-se** eklerinin eklendiği fiillerdeki iş, oluş ve hareketin olması istenir (Bulak, 2011). Belirtilen ekin kullanımıyla birlikte "beklenti" duygusunun da verildiği görülmektedir.

Geliştirilen yöntemde, kural tabanlı yaklaşımdan elde edilecek vektörler aracılığıyla kelimelere duygusal fonksiyon kazandırdığı açıkça belirlenmiş eklerin de tespiti sağlanmaktadır. Bu sayede, tek başına herhangi bir duygu ifadesi içermeyen ancak aldığı ek sayesinde bir duygu ifadesi kazanan kelimeler de duygu analizi sürecinde değerlendirilmektedir.

3.2.3. Veri Kümesindeki Satırların Karıştırılması (Data Shuffling)

Veri kümesindeki satırların dengeli dağılım göstermesi için iki kez satırları rastgele karıştırma işlemi (data shuffling) uygulanmıştır. Veri kümesi, geliştirilen yöntem için hazır hale getirilmiştir. Tablo 4'te veri kümesinden bir kesit gösterilmektedir.

Tablo 4. Veri kümesinden bir kesit.

Sıra No	Örnek Cümle	Biçimsel Sonuç	Anlamsal Sonuç	Sevinç	Güven	Korku	Şaşkınlık	Üzüntü	Tiksinme	Öfke	Beklenti
1	Canım ciğerim evladımı çok seviyorum.	pozitif	pozitif	1.2	0	0	0	0	0	0	0
2	Ona her gün yeniden aşık oluyorum.	pozitif	pozitif	1	1	0	0	0	0	0	0
3	Dinginlikle dolu bir gün geçirmek ruhumu dinlendirdi.	pozitif	pozitif	0.2	0	0	0	0	0	0	0
4	Film bitinceye kadar hepimiz gülmekten çatladık.	pozitif	pozitif	1.8	0	0	0	0	0	0	0
5	Daha da fazla güzel olacak dünyamız.	pozitif	pozitif	1.6	0	0	0	0	0	0	1.6
6	Bize bu fırsatı verdiğiniz için size minnettarız.	pozitif	pozitif	0.8	0.8	0	0	0	0	0	0
7	Müdür çok öfkeli, gözüne görünmeyin!	negatif	negatif	0	0	0	0	0	0	1.2	0
8	Çocuğun tüm hevesini kırdılar, onu çok üzdüler.	pozitif	negatif	0	0	0	0	1.2	0	0	0
9	Güya, herkesin örnek aldığı biriymiş (!)	pozitif	negatif	0	0	0	0	0	1	1	0
10	Arabamı o halde görünce, başımdan aşağı kaynar sular döküldü.	pozitif	negatif	0	0	0	1	1	0	0	0
11	Sözüm ona, zeka küpüymüş (!) ama aslında pek de değilmiş.	negatif	negatif	0	0	0	0	0	1	1	0

Tablo 4 Devamı

12	İhanetinin intikamını almadan rahat etmeyeceğim.	negatif	negatif	0	0	0	0	0	0	1	0
13	Dün akşam sinemaya gittik.	pozitif	notr	0	0	0	0	0	0	0	0
14	Evlerinin etrafı meyve ağaçları ile doluydu.	pozitif	notr	0	0	0	0	0	0	0	0
15	Bir anda karşısına çıkan manzara karşısında çok fazla şaşırdı.	pozitif	notr	0	0	0	1.4	0	0	0	0
16	Onların evden çıkmasını dört gözle bekliyorum.	pozitif	notr	0	0	0	0	0	0	0	1.8
17	Montsuz dolaşmak yok.	negatif	notr	0	0	0	0	0	0	0	0
18	Her an müdür gelebilir, tetikte bekleyelim.	pozitif	notr	0	0	0	0	0	0	0	1.8
19	Yüksek not alırsan dünyalar benim olur.	pozitif	kosullu -pozitif	1.2	0	0	0	0	0	0	0
20	İşler tıkırında giderse, çok keyifli oluruz.	pozitif	kosullu -pozitif	1.2	0	0	0	0	0	0	0
21	Taksiyle gitseydim, daha da rahat olacaktı.	pozitif	kosullu -pozitif	1.4	0	0	0	0	0	0	0
22	Büyüklerine saygı gösterirsen, iyi olur.	pozitif	kosullu -pozitif	0.6	0	0	0	0	0	0	0
23	Müjdeyi versem, herkesin yüzü güler.	pozitif	kosullu -pozitif	1	0	0	0	0	0	0	0
24	Çatışmalar yaşanmasaydı bu sokaklar çok daha fazla tekin olurdu.	pozitif	kosullu -pozitif	0	1.6	0	0	0	0	0	0
25	İftira atılırsa kan beynine sıçrıyor.	pozitif	kosullu -negatif	0	0	0	0	0	0	1.8	0
26	Kendisine iki laf edilse, öfkeden gözleri yuvalarından fırlar.	pozitif	kosullu -negatif	0	0	0	0	0	0	1	0
27	Yere tükürdüğünü görürsem buz gibi soğurum senden.	pozitif	kosullu -negatif	0	0	0	0	0	1	0	0
28	Kızımın kılına zarar gelirse seni ellerimle gebertirim!	pozitif	kosullu -negatif	0	0	0	0	0	0	1	0
29	Çok fazla korkuya kapılmışsa kendini sürekli tehlike altında hissedebilir.	pozitif	kosullu -negatif	0	0	1.4	0	0	0	1	0
30	Zamanında geri adım atmazsam pişmanlık duyarım.	pozitif	kosullu -negatif	0	0	0	0	1	1	0	0

3.2.4. Veri Kümesindeki Sınıfların Dağılımları

Çalışma kapsamında, 136.000 cümleden oluşan veri kümesi oluşturulmuştur. Bu veri kümesinin 100.000 cümleden oluşan bölümü eğitim veri kümesi, geriye kalan 36.000 cümleden oluşan bölümü ise test veri kümesi olarak ayrılmıştır. Tablo 5'te "Biçimsel Sonuç" sınıfının eğitim ve test veri kümelerindeki dağılımı; Tablo 6'da "Anlamsal Sonuç" sınıfının eğitim ve test veri kümelerindeki dağılımı; Tablo 7'de temel duygu sınıflarının eğitim veri kümesindeki dağılımı; Tablo 8'de temel duygu sınıflarının test veri kümesindeki dağılımı; Tablo 9'da ise temel duygu sınıflarının tüm veri kümesindeki dağılımları gösterilmektedir.

Tablo 5. "Biçimsel Sonuç" sınıfının eğitim ve test veri kümelerindeki dağılımı.

Biçimsel Sonuç	Eğitim Veri Kümesi	Test Veri Kümesi	Tüm Veri Kümesi
Negatif	6.033	2.202	8.235
Pozitif	93.967	33.798	127.765
TOPLAM	100.000	36.000	136.000

Tablo 6. "Anlamsal Sonuç" sınıfının eğitim ve test veri kümelerindeki dağılımı.

Anlamsal Sonuç	Eğitim Veri Kümesi	Test Veri Kümesi	Tüm Veri Kümesi
Negatif	47.177	17.005	64.182
Pozitif	25.591	9.259	34.850
Nötr	13.336	4.781	18.117
Koşullu Pozitif	5.987	2.131	8.118
Koşullu Negatif	7.909	2.824	10.733
TOPLAM	100.000	36.000	136.000

Tablo 7. Temel duygu sınıflarının eğitim veri kümesindeki dağılımları.

Eğitim Veri Kümesi	Sevinç	Güven	Korku	Şaşkınlık	Üzüntü	Tiksinme	Öfke	Beklenti
0	85.531	89.748	85.558	86.267	86.793	84.983	76.499	85.811
0.2	481	1.114	1.155	1.264	783	1.130	1.623	1.004

Tablo 7 Devamı

0.4	253	725	1.152	1.017	614	801	1.179	832
0.6	469	643	1.244	1.366	1.204	903	1.472	890
0.8	1.019	1.227	2.053	1.869	946	2.016	2.173	1.616
1	6.615	2.413	2.439	3.394	4.572	5.079	8.606	5.813
1.2	1.940	926	1.443	1.443	1.592	1.585	2.603	1.271
1.4	1.412	1.029	1.348	1.158	1.500	1.438	1.983	1.058
1.6	480	839	1.021	1.004	551	677	1.341	750
1.8	1.800	1.336	2.587	1.218	1.445	1.388	2.521	955
TOPLAM	100.000	100.000	100.000	100.000	100.000	100.000	100.000	100.000

Tablo 8. Temel duygu sınıflarının test veri kümesindeki dağılımları.

Test Veri Kümesi	**Sevinç**	**Güven**	**Korku**	**Şaşkınlık**	**Üzüntü**	**Tiksinme**	**Öfke**	**Beklenti**
0	30.708	32.254	30.790	31.021	31.344	30.546	27.355	30.986
0.2	162	408	386	463	283	432	628	357
0.4	104	271	439	357	192	235	442	318
0.6	175	279	453	475	459	327	511	291
0.8	381	431	743	686	330	771	806	510
1	2.376	867	923	1.264	1.663	1.911	3.199	2.080
1.2	740	339	503	514	589	547	910	443
1.4	502	370	471	425	485	513	722	373
1.6	190	309	344	365	159	215	454	273
1.8	662	472	948	430	496	503	973	369
TOPLAM	36.000	36.000	36.000	36.000	36.000	36.000	36.000	36.000

Tablo 9. Temel duygu sınıflarının tüm veri kümesindeki dağılımları.

Tüm Veri Kümesi	**Sevinç**	**Güven**	**Korku**	**Şaşkınlık**	**Üzüntü**	**Tiksinme**	**Öfke**	**Beklenti**
0	116.239	122.002	116.348	117.288	118.137	115.529	103.854	116.797
0.2	643	1.522	1.541	1.727	1.066	1.562	2.251	1.361
0.4	357	996	1.591	1.374	806	1.036	1.621	1.150

Tablo 9 Devamı

0.6	644	922	1.697	1.841	1.663	1.230	1.983	1.181
0.8	1.400	1.658	2.796	2.555	1.276	2.787	2.979	2.126
1	8.991	3.280	3.362	4.658	6.235	6.990	11.805	7.893
1.2	2.680	1.265	1.946	1.957	2.181	2.132	3.513	1.714
1.4	1.914	1.399	1.819	1.583	1.985	1.951	2.705	1.431
1.6	670	1.148	1.365	1.369	710	892	1.795	1.023
1.8	2.462	1.808	3.535	1.648	1.941	1.891	3.494	1.324
TOPLAM	136.000	136.000	136.000	136.000	136.000	136.000	136.000	136.000

3.2.5. Veri Kümesindeki Cümlelerin Özellikleri

Çalışma kapsamında veri kümelerindeki cümleler, sahip oldukları kelime sayılarına göre analiz edilmiştir. Buna göre eğitim veri kümesinde en uzun cümle 18 kelimeden oluşmakta, test veri kümesinde en uzun cümle ise 17 kelimeden oluşmaktadır. Eğitim veri kümesindeki cümlelerin ortalama kelime uzunluğu 6,23419; test veri kümesindeki cümlelerin ortalama kelime uzunluğu 6,233861111; tüm veri kümesindeki cümlelerin ortalama kelime uzunluğu ise 6,234102941'dir. Veri kümesindeki cümlelerin kelime sayılarının dağılımları Tablo 10'da gösterilmektedir.

Tablo 10. Veri kümesindeki cümlelerin kelime sayısı dağılımları.

Kelime Sayısı	Eğitim Veri Kümesi Cümle Sayısı	Test Veri Kümesi Cümle Sayısı	Tüm Veri Kümesi Cümle Sayısı
1	70	24	94
2	1.450	544	1.994
3	5.539	1.984	7.523
4	12.574	4.639	17.213
5	18.916	6.880	25.796
6	20.621	7.242	27.863
7	16.512	5.835	22.347

Tablo 10 Devamı

8	11.067	3.940	15.007
9	6.403	2.389	8.792
10	3.731	1.390	5.121
11	1.874	666	2.540
12	807	298	1.105
13	290	115	405
14	109	35	144
15	22	12	34
16	9	5	14
17	3	2	5
18	3	-	3
TOPLAM	100.000	36.000	136.000

3.3. Sözlü Metinler için Materyal

Sözlü metinler için konuşma ses kayıtlarından oluşan veri kümeleri araştırılmıştır. Konuşma ses kayıtlarından duygu analizi çalışmaları için hazırlanmış üç farklı veri kümesinden yararlanılmıştır. Bu kapsamda yararlanılan veri kümelerinin dağılımı Tablo 11'de gösterilmektedir.

Tablo 11. Duygu-Türk ses veri kümesi.

Sıra No	Veri Kümesi	Örnek Sayısı
1	BAUM-1	274
2	RAVDESS	1.440
3	TESS	853
	TOPLAM	**2.567**

Duygu-Türk için oluşturulan ses veri kümesinde 2.567 adet ses kaydı bulunmaktadır. Bu kayıtlardan 274 adet ses kaydı BAUM-1 veri kümesinden, 1.440 adet ses kaydı

RAVDESS veri kümesinden, 853 adet ses kaydı ise TESS veri kümesinden alınmıştır. Adı geçen veri kümeleri aşağıdaki bölümde tanıtılmaktadır.

3.3.1. BAUM-1 Veri Kümesi

Bu çalışmada öncelikle, Önder ve ark. (Önder vd., 2013) sunduğu ve "BAUM-1" (BAhçeşehir University Multimodal Database-1) olarak isimlendirdikleri görsel işitsel Türkçe duygusal veri kümesi kullanılmıştır. Veri kümesinin oyunculuk gösterilerek oluşturulmuş kısmı olan "BAUM-1 a", "mutluluk, üzüntü, kızgınlık, tiksinme, sıkılma, ilgi (merak), korku, kafa karışıklığı, nötr ve şaşırma" olmak üzere 10 duygu içeren 278 video kayıttan oluşmaktadır. Veri kümesinin doğal (spontane) oluşturulmuş kayıtlardan oluşan kısmı olan "BAUM-1 s" ise "öfke, korku, iğrenme, mutluluk, üzüntü, sürpriz, can sıkıntısı, aşağılama, kafa karışıklığı, nötr, düşünme hali, konsantre olma durumu ve rahatsız olma" olmak üzere 13 duygusal ve zihinsel durum içeren 1222 video kayıttan oluşmaktadır. Belirtilen veri kümesinin Türkçe olması ve Plutchick'in Duygu Çarkında yer alan temel duyguları karşılayabilecek duygu sınıflarına ayrılmış olması sebebiyle tez çalışması kapsamında ilk olarak "BAUM-1" veri kümesi kullanılmıştır. Bu veri kümesinden 274 adet Türkçe konuşmadan oluşan ses kaydı Duygu-Türk ses veri kümesine dahil edilmiştir.

3.3.2. RAVDESS Veri Kümesi

RAVDESS (Ryerson Audio-Visual Database of Emotional Speech and Song) (Livingstone ve Russo, 2018), veri kümesi, Kuzey Amerika İngilizcesinde duygusal konuşma ve şarkı kayıtlarını içeren doğrulanmış birçok modlu veri kümesidir. Bu veri kümesi, 24 profesyonel aktör (12 erkek, 12 kadın) tarafından seslendirilmiş 7.356 kayıttan oluşmaktadır. Konuşma ifadeleri sakin, mutlu, üzgün, öfkeli, korkmuş, şaşırmış ve tiksinmiş duygularını içerirken; şarkılar sakin, mutlu, üzgün, öfkeli ve korkmuş duygularını kapsamaktadır. Tüm duygular iki farklı yoğunluk seviyesinde ifade edilmiştir. Kayıtlar üç formatta sunulmaktadır: yüz ve ses (audio-visual), yalnızca yüz (video-only) ve yalnızca ses (audio-only). Her kayıt, 247 Kuzey Amerikalı katılımcı tarafından duygusal geçerlilik, yoğunluk ve doğallık açısından değerlendirilmiş ve veri kümesi yüksek seviyede duygusal doğruluk ve test-tekrar güvenirliği göstermiştir.

RAVDESS, duygusal ses tanıma ve konuşma analizi alanında araştırmalar yapmak isteyen bilim insanları için serbestçe erişilebilir ve kullanılabilir bir kaynaktır. Bu veri kümesinden 12 kadın ve 12 erkek aktörün oluşturduğu 1.440 kayıt Duygu-Türk ses veri kümesine eklenmiştir.

3.3.3. TESS Veri Kümesi

TESS (Toronto Emotional Speech Set) (Pichora-Fuller ve Dupuis, 2020) veri kümesi, Northwestern University Auditory Test No. 6 (NU-6) temel alınarak oluşturulmuştur. Küme, "Say the word _____" taşıyıcı ifadesi içinde söylenen 200 hedef kelimeden oluşmaktadır. Bu kelimeler, 26 ve 64 yaşlarında iki oyuncu tarafından 7 farklı duyguyu (anger, disgust, fear, happiness, pleasant surprise, sadness, and neutral) ifade edecek şekilde seslendirilmiştir. Toplamda 2.800 ses örneği içeren veri kümesinde yer alan konuşmacılar Toronto bölgesinden seçilmiş olup, ana dilleri İngilizce olan, üniversite eğitimi almış ve müzikal geçmişi bulunan bireylerdir. Ayrıca, işitme testleri her iki konuşmacının da normal işitme aralıklarında olduğunu göstermiştir. TESS veri kümesi, konuşma tabanlı duygu analizi çalışmaları için dengeli bir veri kaynağı sağlamaktadır. TESS veri kümesinden 853 ses kaydı Duygu-Türk ses veri kümesine eklenmiştir.

3.4. Yazılı Metinler için Yöntem

Bu çalışmanın ilk bölümünde, Türkçe yazılı metinleri hem biçim hem de anlam bakımından inceleyebilen ve aynı zamanda Plutchik'in Duygu Çarkı'nı temel alarak sekiz temel duyguyu yoğunluklarına göre analiz edebilen ve temel duyguların etkileşiminden oluşan ikincil duyguları tespit edebilen bir yöntem geliştirilmesi amaçlanmaktadır. Bu amaç doğrultusunda, yazılı metinler için geliştirilen yönteme ait iş akış şeması, Şekil 7'de gösterilmektedir.

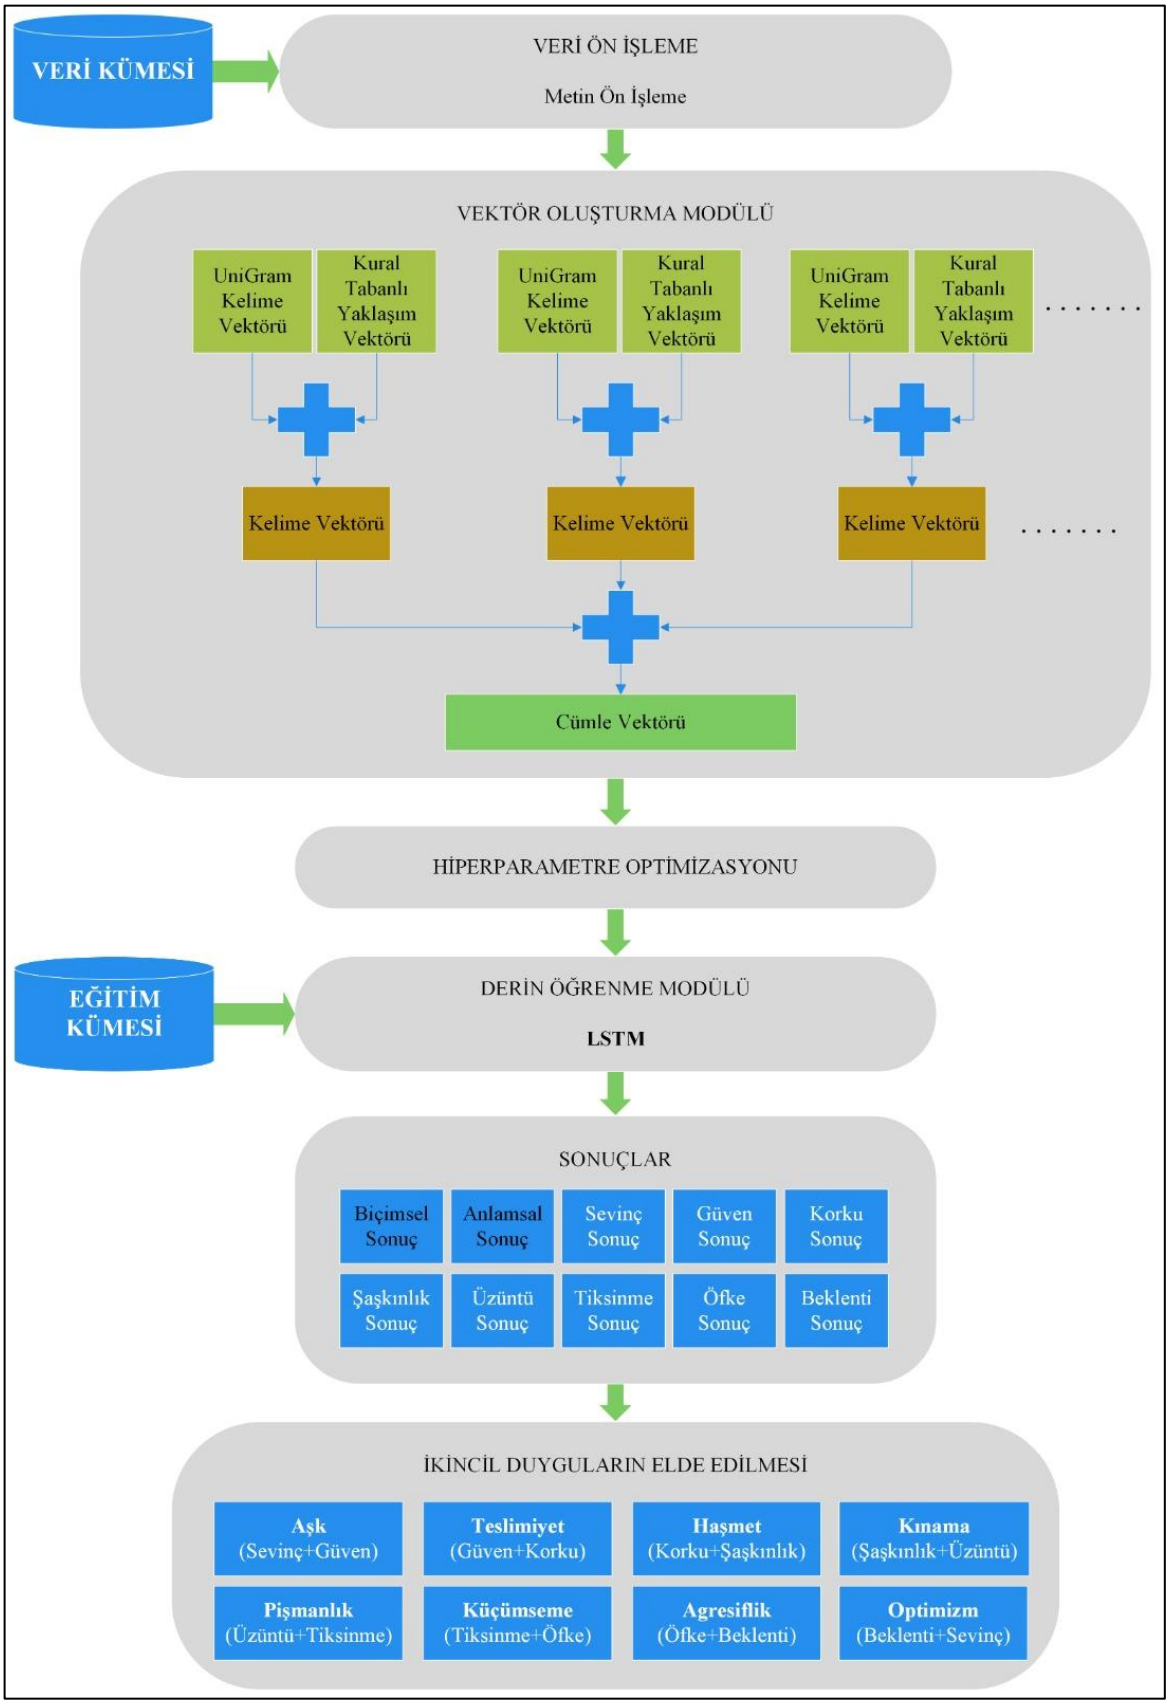

Şekil 7. Yazılı metinler için geliştirilen yönteme ait iş akış şeması.

İş akış şemasına göre ilk önce veri kümesi hazır hale getirilir. Veri kümesinin hazır hale getirilme süreci Şekil 3'te gösterilmektedir. Metinler, öncelikle veri ön işleme modülünde işlem görür. Ardından vektör oluşturma modülünde kelimeler, UniGram kelime vektörü ile kural tabanlı yaklaşım vektörünün birleşimiyle kelime vektörüne dönüştürülür. Kelime vektörleri birleşerek cümle vektörlerini meydana getirmektedirler. Hiperparametre optimizasyonu sonucunda elde edilen en başarılı parametrelerde eğitim kümeleri, ağırlıklandırılmış sınıflandırma yöntemi kullanan LSTM tabanlı bir derin öğrenme modeli ile eğitilmektedirler. Elde edilen modeller ile on farklı sonuç elde edilmektedir. Bu sonuçların etkileşiminden ise ikincil duyguların sonuçları kullanıcı arayüzünden tespit edilebilmektedir.

Şekil 7'deki iş akış şemasında yer alan adımlar, aşağıdaki bölümlerde detaylı bir şekilde açıklanmaktadır.

3.4.1. Veri Ön İşleme

Noktalama işaretlerinden "ünlem", "soru işareti" ve "yay ayraçlı ünlem" duygu ifade eden cümlelerin sonunda yer alabilmektedir. Belirtilen noktalama işaretlerinin duygu analizi çalışmalarına katkı sağlayabileceği düşünüldüğünden ön işleme aşamasında metinde bulunan ünlem, soru işareti ve yay ayraçlı ünlem hariç diğer tüm noktalama işaretleri kaldırılır ve tüm harfler küçük harflere çevrilir. Geliştirilen yöntemde kullanılan karakter düzeyinde UniGram kelime gömme yöntemi sayesinde belirtilen noktalama işaretleri de vektörlere çevrilmektedir.

- **Ünlem İşareti ("!"):** Ünlem işareti ön işleme adımında, Türkçede bulunmayan "x" karakterine dönüştürülmüştür. Bu sayede ön işleme aşamasında, noktalama işaretleri temizlenirken silinmesi engellenmiştir.
- **Soru İşareti ("?"):** Soru işareti ön işleme adımında, Türkçede bulunmayan "q" karakterine dönüştürülmüştür. Bu sayede ön işleme aşamasında, noktalama işaretleri temizlenirken silinmesi engellenmiştir.

- **Yay Ayraçlı Ünlem İşareti (“(!)”):** Yay ayraçlı ünlem işareti ön işleme adımında, Türkçede bulunmayan “w” karakterine dönüştürülmüştür. Bu sayede ön işleme aşamasında, noktalama işaretleri temizlenirken silinmesi engellenmiştir.

3.4.2. Vektör Oluşturma Modülü

Geliştirilen yöntemde metin, ön işleme aşamasından sonra vektör oluşturma modülünde cümlelere bölünmektedir. Her cümle kelimelere bölünmektedir. Kelime vektörünün ilk 20 boyutu karakter düzeyinde UniGram yöntemi ile sonraki 20 boyutu ise kural tabanlı yaklaşımdan gelen öz niteliklerden oluşturulmaktadır.

UniGram Kelime Vektörü

Literatürdeki çeşitli çalışmalar (Kim vd., 2016; Saffran vd., 1996) UniGram yönteminin, morfolojik olarak zengin dillerin karakter düzeyinde modellenmesinde üstünlük sağladığını ortaya koymuştur. Ayrıca kelimelerin kök ve türevleri arasındaki anlamsal benzerlikleri doğru şekilde temsil edebilmesi, dil bağımsızlığı sağlaması, daha karmaşık yöntemlere kıyasla basit bir yapıya sahip olması ve düşük kaynak gereksinimi gibi avantajlar da sunmaktadır. Bu ve benzeri faktörler sebebiyle sondan eklemeli Türkçe dili için karakter düzeyinde UniGram kelime gömme yöntemi kullanılmıştır. Bu yönteme göre kelime gövdesini oluşturan her karakter, Tablo 12’de belirtilen vektörel değerlere dönüştürülmüştür. Tablo 12’de yer alan karakterlerin vektörel karşılıkları, Türkçede harflerin kullanım sıklığına göre sıralaması dikkate alınarak oluşturulmuştur (Güneş ve Işık, 2018).

Tablo 12. Karakter düzeyinde UniGram yönteminde karakterlerin vektörel değerleri.

Karakter	Vektörel Değer	Karakter	Vektörel Değer	Karakter	Vektörel Değer	Karakter	Vektörel Değer	Karakter	Vektörel Değer
a	0.01	t	0.09	ü	0.17	v	0.25	! > x	0.33
e	0.02	ı	0.10	ş	0.18	ğ	0.26	? > q	0.34
k	0.03	s	0.11	z	0.19	ö	0.27	(!) > w	0.35
i	0.04	u	0.12	g	0.20	f	0.28		

Tablo 12 Devamı

l	0.05	y	0.13	ç	0.21	j	0.29		
m	0.06	d	0.14	p	0.22	â	0.30		
r	0.07	o	0.15	h	0.23	î	0.31		
n	0.08	b	0.16	c	0.24	û	0.32		

Tablo 12'de gösterilen, harflerin vektörel değerleri, harflerin frekansı ile ters orantılı olarak belirlenmiştir. Daha sık kullanılan harflerin daha düşük vektör değerlerine sahip olmasının, geliştirilen yönteme avantaj sağlayıp sağlamadığı, 1.000 adet örnek cümle içeren veri kümesi eğitilerek analiz edilmiştir. Elde edilen sonuçlar Tablo 13'te gösterilmektedir. Bu sonuçlara göre, harflerin kullanım sıklığına dayalı vektör değerleri kullanıldığında; modelin eğitim süresinin bir miktar arttığı görülmektedir. Bununla birlikte, loss değeri açısından harflerin kullanım sıklığı dikkate alınan modelin (0.00385) daha düşük bir hata oranına sahip olduğu, yani modelin daha iyi bir öğrenme performansı gösterdiği gözlemlenmiştir. Model boyutu açısından ise harflerin kullanım sıklığı dikkate alınan modelin bellek açısından daha kompakt bir yapı sunduğu görülmektedir. Sonuç olarak, harflerin frekansına dayalı vektörleme yöntemi, eğitim süresini bir miktar uzatsa da, modelin daha düşük hata oranıyla daha iyi öğrenme yapmasını sağlamaktadır. Ayrıca, düşük frekanslı harflerin daha yüksek vektör değerleriyle temsil edilmesi, modelin nadir görülen karakterleri daha iyi öğrenmesini destekleyerek genel performansın artmasına olanak tanımaktadır.

Tablo 13. Harflerin kullanım sıklığı analizi.

Harflerin Kullanım Sıklığı Analizi	**Harflerin Kullanım Sıklığı Dikkate Alınarak UniGram**	**Harflerin Kullanım Sıklığı Dikkate Alınmadan UniGram**
CPU Training Total Time	01:55 min	01:43 min
Loss Value	0.0038592681884765624	0.008767608642578126
Model Size	54.265 KB	54.710 KB

UniGram kelime vektörünün boyutu, 20 olarak belirlenmiştir. Dalkılıç ve Çebi'nin (Dalkılıç ve Çebi, 2003) çalışmalarında ekler ayrılmadan hazırlanan bir külliyatta en uzun sözcüğün 23 harften oluştuğu tespit edilmiştir. Sözcüklerden çekim eklerinin kaldırılarak

gövdelerin vektöre dönüştürüleceği düşünüldüğünde, 20 boyutlu vektörün bir kelimenin UniGram olarak ifade edilmesi için yeterli olduğu görülmüştür. Kelime gövdeleri, ilk karakterden başlayarak son karaktere doğru sırayla vektörel değerlere dönüştürülür. Eğer kelime gövdesi, 20 karakterden kısa ise kalan vektör boyutları "0" ile doldurulur (padding). Eğer kelime gövdesi, 20 karakterden uzun ise kesme işlemi (truncating) yapılır.

UniGram kelime vektörü kullanımının önemli avantajları, aşağıda sıralanmaktadır.

Kelime Düzeyinde Hassasiyet: UniGram yöntemi, kelimeleri tek başına ele alır ve her kelimenin anlamını ve kullanım bağlamını daha iyi yansıtabilir. Sondan eklemeli Türkçe dilinde gövde düzeyindeki özelliklerin korunarak doğru anlam ve kullanımı, daha iyi yakalamaya yardımcı olabilir.

Verimli Temsil: UniGram yöntemi, kelime temsillerini daha verimli bir şekilde sağlayabilmektedir. Sondan eklemeli Türkçe dili için UniGram yöntemi ile kelimelerin kök ve gövde türevleri arasındaki ilişkiler ile kelimelerin anlamsal benzerlikleri daha doğru bir şekilde yakalanabileceği düşünülmektedir.

Dil Bağımsızlık: UniGram yöntemi dil bağımsız bir yöntemdir. Türk dilinin özelliklerini yakalamak için özel olarak uyarlanması gerekmez. Bu, yöntemin genel olarak Türk dili için geçerli olmasını sağlar ve dilin spesifik özelliklerine bağımlı olmaz. Ayrıca, UniGram yöntemi sayesinde Türkçede halen yazılı olarak da kullanımı devam eden â, î, û harfleri ile "ünlem", "soru işareti" ve "yay ayraçlı ünlem" gibi duygu ifade eden noktalama işaretleri de karakter olarak temsil edilebilmektedir.

Veri Boyutu ve Hesaplama Verimliliği: UniGram yöntemi, veri boyutunu azaltarak hesaplama verimliliğini artırabilir. Gövdeleme ve etiketleme aşamasında kelimelerin gövdeleri tespit edilmektedir. Metnin içerisinde yer alan her kelime, gövdedeki karakter sayısı kadar boyuta sahip bir vektör ile temsil edilebilmektedir. Kelimelerin bu şekilde temsil edilmesi, daha hızlı hesaplamalar ve daha düşük bellek gereksinimi anlamına gelmektedir.

Kelime Öbeklerini Yakalama: Türkçe, atasözleri, deyimler, birleşik fiiller veya kalıp sözlerin çokça yer aldığı bir dil yapısına sahiptir. Örneğin: "havalara uçmak" deyimi, "çok sevinmek" anlamına gelmektedir. Bu deyim, hiçbir zaman "havalara çıkmak", "havalara yükselmek" ya da "havalara ulaşmak" vb. bir kalıpla kullanılmamaktadır. UniGram yönteminin, her kelimeyi ayrı ayrı ele alarak, cümle vektörlerinin içerisinde yer alan kalıplaşmış ifadelerin örüntülerini anlam ve kullanım bakımından daha doğru bir şekilde yakalayabileceği düşünülmektedir.

Basitlik ve Uygulanabilirlik: UniGram yöntemi, diğer daha karmaşık ve hesaplama açısından yoğun kelime gömme (word embedding) yöntemlerine kıyasla daha basit ve uygulanabilir bir seçenektir. Kullanımı kolaydır ve daha az kaynak gerektirmektedir.

Kural Tabanlı Yaklaşım Vektörü

Türkçede kendi başına anlam taşıyan en küçük kelime birimine "kök" denir. Yapım eki alarak yeni bir anlam kazanan kelimeler ise "türemiş kelime" veya "gövde" olarak adlandırılır. Yapım ekleri, eklendikleri sözcüğe farklı bir anlam yükleyerek, duygu analizi çalışmalarında önemli bir rol oynar. Örneğin, "bıçak" kelimesi tek başına bir duygu ifade etmezken, yapım eki alarak "bıçaklamak" haline gelmesiyle "öfke" duygusunu ifade eden bir gövdeye dönüşür. Benzer şekilde, "dar" kelimesi nötr bir anlam taşırken, "darlanmak" formuna geldiğinde "bunalma" duygusunu ifade eden bir gövde olur. Bu örneklerden yola çıkarak, duygu analizi çalışmalarının yalnızca kelime kökleri üzerinde değil, gövde düzeyinde yapılmasının önemi ortaya çıkmaktadır.

Bu bağlamda, Yücebaş ve Tintin (Yücebaş ve Tintin, 2017), veri ön işleme aşamasında kullanılabilecek "Gövde-Türk" adlı bir gövdeleme ve etiketleme yöntemi geliştirmişlerdir. Çalışmalarında kelimelerin türemiş halleri tespit edilerek tüm çekim ekleri çıkarılmıştır. Literatürde yapılan çalışmalara bakıldığında, yalnızca kelime köklerine odaklanmanın ve yapım eklerinin göz ardı edilmesinin, Türkçenin sondan eklemeli yapısı nedeniyle duygu analizinde eksikliklere yol açtığı görülmektedir (Uyaroğlu Akdeniz ve

Cebeci, 2021). Bu nedenle, gövdeleme yöntemleri veya gövde düzeyinde lemmatizasyon gerçekleştiren algoritmalar, duygu analizinde önemli bir rol oynamaktadır.

Etiketleme işlemi, kelimelerin türlerini (isim, fiil, sıfat vb.) belirlemek için kullanılmaktadır. Örneğin, "Kitap okumak güzel bir alışkanlıktır" cümlesinde "Kitap" isim, "okumak" fiil olarak etiketlenmektedir.

Geliştirilen yöntemde bu aşamada "Gövde-Türk: Bir Türkçe Gövdeleme Yöntemi" kullanılmaktadır (Yücebaş ve Tintin, 2017). Bu yöntem sayesinde tüm kelimelerin gövdeleri ve etiketleri tespit edilmektedir. Gövde-Türk, Türkçe kelimelerin sağdan sola taranarak son eklerin, sonlu durum makinaları ile tanımlanan kurallara ve en uzun eşleşme mantığına göre kelime sonundan silerek kelime gövdesi elde edebilen bir Türkçe gövdeleme yöntemidir. Bu işlem esnasında aynı zamanda kelimeleri de etiketleyebilmektedir. Gövde-Türk yönteminde, İsim-Soylu (isim), İsim-Soylu (sıfat), İsim-Soylu (zarf), İsim-Soylu (edat), İsim-Soylu (bağlaç), İsim-Soylu (zamir), İsim-Soylu (ünlem), İsim-Soylu (fiilimsi), Fiil-Soylu (yüklem) etiketleri tespit edilebilmektedir.

Bu çalışma kapsamında geliştirilen yöntemde, kelime gövde ve etiketleri tespit edilirken aynı zamanda kelimelerin duygu analizi çalışmasına katkı sağlayabileceği düşünülen bazı öz nitelikleri de elde edilmektedir. Bu öz nitelikler, kural tabanlı yaklaşım gözetilerek elde edilmektedir. Kural tabanlı yaklaşım vektöründe kullanılan öz nitelikler Tablo 14'te gösterilmektedir. Analiz edilen kelimelerin belirlenen öz nitelikleri taşıyanlar "1", taşımayanlar ise "0" vektörel değere sahiptirler. Kural tabanlı yaklaşımdan elde edilen öz nitelikler, 20 boyutlu bir vektör oluşturmaktadır.

Tablo 14. Kural tabanlı yaklaşım vektöründeki öz nitelikler.

Sıra No	**40 Boyutlu Kelime Vektöründeki İndis No**	**Öz Nitelik**
1	20	İsim

Tablo 14 Devamı

2	21	Sıfat
3	22	Zarf
4	23	Ünlem
5	24	Yüklem
6	25	Fiilimsi
7	26	Zamir
8	27	Eş Sesli Kelime
9	28	Ünlem İşareti !
10	29	Soru İşareti ?
11	30	Yay Ayraçlı Ünlem İşareti (!)
12	31	Yoksunluk Eki (-sız, -siz, -suz, -süz)
13	32	Olumsuzluk Eki (-ma, -me)
14	33	Olumsuz İfade (değil, yok)
15	34	Koşul Eki (-sa, -se)
16	35	Dilek Eki (-sa, -se)
17	36	Kuvvetlendirici İfadeler
18	37	Zayıflatıcı İfadeler
19	38	Küçültme Eki (-cağız, -ceğiz)
20	39	Karşıtlık Bağlaçları (ama, ancak, fakat, lakin, lâkin, rağmen)

Kural tabanlı yaklaşım vektöründe yer alan "isim, sıfat, zarf, ünlem, yüklem, fiilimsi, zamir" öz nitelikleri, cümle yapısının kavranmasını kolaylaştırabileceğinden; "eş sesli kelime" öz niteliği ise yanlış gövde tespitini engellemek ve bu kelimelerdeki dikkati artırmak amacıyla tercih edilmiştir. Kural tabanlı yaklaşım vektöründe bu öz nitelikler 20., 21., 22., 23., 24., 25., 26. ve 27. indis no ile temsil edilmektedir.

"Ünlem işareti, soru işareti, yay ayraçlı ünlem işareti", duygu ifade eden cümlelerde yer alabildiğinden değerlendirmeye alınmış ve bu noktalama işaretleri, kural tabanlı

yaklaşım vektöründe 28., 29. ve 30. indis no ile temsil edilmiştir. Örneğin; “Sözde (!) çok zekiymiş.” cümlesinde yer alan yay ayraçlı ünlem işareti, cümleye “tiksinme” ve “öfke” duygularının birlikteliğinden doğan “küçümseme” ikincil duygusunun ifade edilmesini sağlamaktadır. (!) işareti, bir kelimeymiş gibi değerlendirilmekte olduğundan bu kelimeye ait kural tabanlı yaklaşım vektöründeki 30. indis no ile temsil edilen vektör değeri “1” dir.

“Yoksunluk eki (-sız, -siz, -suz, -süz), olumsuzluk eki (-ma, -me), olumsuz ifade (değil, yok)”, cümlenin duygu durumunu değiştirebildiğinden değerlendirmeye alınmıştır. Bu ek veya ifadeleri alan kelimeler, kural tabanlı yaklaşım vektöründe temsil edilmiştir. Örneğin; “Bugün mutsuzum.”, cümlesindeki yoksunluk eki; “Hiç mutlu olmadım.” cümlesindeki olumsuzluk eki; “Mutlu değilim.” cümlesindeki olumsuz ifade, “sevinç” duygusunun olmadığını anlatmaktadır. Örnek cümlelerde yer alan “mutsuzum” kelimesine ait kural tabanlı yaklaşım vektöründeki 31. indis no ile temsil edilen vektör değeri “1”; “olmadım” kelimesine ait kural tabanlı yaklaşım vektöründeki 32. indis no ile temsil edilen vektör değeri “1” ve “değilim” kelimesine ait kural tabanlı yaklaşım vektöründeki 33. indis no ile temsil edilen vektör değeri “1” dir.

“Koşul eki (-sa, -se)”, geliştirilen yöntemde monoton olmayan mantık (non-monotonic logic) yaklaşımı takip edilip “koşullu-pozitif” ve “koşullu negatif” durumları ele alındığından değerlendirmeye alınmıştır. Örneğin; “Hayallerimi gerçekleştiremezsem çok üzülürüm.” cümlesinde “üzülme” durumu, bir koşula bağlanmıştır. Bu cümleyi kuran kişi, henüz üzülmüş değildir ve bu kişinin üzülmesi, kişinin hayallerinin gerçekleşip gerçekleşmemesi durumuna göre değişebilir. Bu sebeple, örnekteki cümleyi, “negatif” olarak sınıflandırmak doğru değildir. “Üzülmek” negatif bir duygu olduğundan ve bu duygu koşula bağlandığından “koşullu-negatif” olarak sınıflandırmak daha gerçekçi bir yaklaşım olacaktır. Bu tür koşullu ifadeleri yakalayabilmek amacıyla koşul eki alan kelimeler, kural tabanlı yaklaşım vektöründe temsil edilmiştir. Örnek cümlede yer alan “gerçekleştiremezsem” kelimesine ait kural tabanlı yaklaşım vektöründeki 34. indis no ile temsil edilen vektör değeri “1” dir.

“Dilek eki (-sa, -se)”, “beklenti” duygusu ifade eden cümlelerde kullanıldığından kural tabanlı yaklaşım vektöründe temsil edilmiştir. Örneğin; “Yarın bayram olsa.” cümlesinde olduğu gibi -sa ve -se eklerinin eklendiği fiillerdeki iş, oluş ve hareketin olması istenir (Bulak, 2011). Belirtilen ekin kullanımıyla birlikte “beklenti” duygusunun ifade edildiği görülmektedir. Örnek cümlede yer alan “olsa” kelimesine ait kural tabanlı yaklaşım vektöründeki 35. indis no ile temsil edilen vektör değeri “1” dir.

“Koşul eki (-sa, -se)” ile “Dilek eki (-sa, -se)” aynı eklerdir. Ancak kullanım yerlerine göre koşul ya da dilek ifade edildiği görülmektedir. Örneğin; “Yarın bayram olsa.” cümlesinde -sa eki, “dilek, beklenti” gibi duyguları ifade ederken; “Yarın bayram olsa coşku ile kutlardık.” cümlesindeki -sa eki ise koşul ifade etmektedir. Geliştirilen yöntemde bu eklerin bağlamına bakarak farkını anlayabilen kural tabanlı yaklaşım geliştirilmiştir. Bu sebeple her iki ek, kural tabanlı yaklaşım vektöründe farklı indislerde temsil edilmiştir.

“Koşul eki (-sa, -se)” ile “Dilek eki (-sa, -se)” aynı eklerdir. Ancak kullanım yerlerine göre koşul ya da dilek ifade edildiği görülmektedir. Bulak (Bulak, 2011) çalışmasında *“-sa ekinin şart işlevinin, en eski ve kipe adını veren ana işlevi olduğunu; tek başına bir yargı bildirmediğini ve ana cümlenin yükleminin bildirdiği iş, oluş ve hareketin gerçekleşmesini koşula bağladığı için bağlı birleşik cümle oluşturduğunu*” belirtmiştir. Yine aynı çalışmada *“-sa ekinin dilek işlevinde, eklendiği fiildeki iş, oluş ve hareketin olması istendiği ve -sa eki bu işlevde kullanıldığında tek başına bir yargı bildirdiği*” belirtilmiştir. Benzer (Benzer, 2010) ve Uzman (Uzman, 1992) çalışmalarında ise “*şart kipinin, bütün fiil çekimlerinin aksine, hüküm ifade etmediğini ve bitimli bir hareket göstermediğini bu yüzden müstakil cümle yapamadığını*” belirtmişlerdir. Örneğin; “Kızım doktor olsa.” cümlesinde -sa eki, “dilek, beklenti” gibi duyguları ifade ederken; “Kızım doktor olsa çok mutlu olurdum.” cümlesindeki -sa eki ise koşul ifade etmektedir. Geliştirilen yöntemde bu eklerin bağlamına bakarak farkını anlayabilen kural tabanlı yaklaşım geliştirilmiştir. Geliştirilen yaklaşımda koşul ekinin cümlenin kaçıncı kelimesinde olduğunu ve kaç kez geçtiğini kontrol eden bir yapı bulunmaktadır. Buna göre bağlı birleşik cümlelerin içerisinde yer alan ve ikileme şeklinde bulunmayan -sa eki koşul eki olarak; tek başına bir yargı bildiren ve genellikle cümlenin sonunda yer alan -sa eki ise dilek eki olarak değerlendirilmiştir.

“Kuvvetlendirici ifadeler”, duygu yoğunluğunu arttırdığından kural tabanlı yaklaşım vektöründe temsil edilmiştir. Kuvvetlendirici ifadeler, “aşırı, büyük, çok, da, daha, derin, en, fazla, pek” gibi ifadelerdir. Örneğin; “Bugün çok mutlu oldum.” Cümlesinde yer alan “çok” kelimesine ait kural tabanlı yaklaşım vektöründeki 36. indis no ile temsil edilen vektör değeri “1” dir.

“Zayıflatıcı ifadeler”, duygu yoğunluğunu azalttığından kural tabanlı yaklaşım vektöründe temsil edilmiştir. Zayıflatıcı ifadeler, “az, biraz, küçük, mini, azıcık” gibi ifadelerdir. Örneğin; “Bugün biraz üzüldüm.” Cümlesinde yer alan “biraz” kelimesine ait kural tabanlı yaklaşım vektöründeki 37. indis no ile temsil edilen vektör değeri “1” dir.

“Küçültme eki (-cağız, -ceğiz)”, eklendiği kelimeye “acıma” duygusu kattığından kural tabanlı yaklaşım vektöründe temsil edilmiştir. Örneğin; “Çocukcağız yapayalnız kaldı.” cümlesinde -cağız ekinin, “çocuk” kelimesine zavallılık ve acıma anlamları yüklediği görülmektedir (Akçataş ve Varol, 2021). “Çocukcağız” kelimesine ait kural tabanlı yaklaşım vektöründeki 38. indis no ile temsil edilen vektör değeri “1” dir.

“Karşıtlık Bağlaçları”, birbirine zıt duygu geçişlerinin kavranmasında fayda sağlayacağı düşünüldüğünden kural tabanlı yaklaşım vektöründe temsil edilmiştir. Karşıtlık bağlaçları, “ama, ancak, fakat, lakin, lâkin, rağmen” gibi ifadelerdir. Örneğin; “Beni üzmesine rağmen halen onu seviyorum” cümlesinde yer alan “rağmen” kelimesine ait kural tabanlı yaklaşım vektöründeki 39. indis no ile temsil edilen vektör değeri “1” dir. Örnek cümle incelendiğinde, “üzüntü” duygu durumundan karşıtlık bağlacı aracılığı ile “sevinç” duygu durumuna geçildiği görülmektedir. Bu cümlede, “üzüntü” ve “sevinç” duyguları bir arada bulunmaktadır.

Kelime Vektörü

Her kelime, ilk 20 boyutu karakter düzeyinde UniGram yöntemi ile oluşturulan vektör ile temsil edilmektedir. Her kelimenin sonraki 20 boyutu ise kural tabanlı yaklaşımdan gelen öz niteliklere göre oluşturulan vektör ile temsil edilmektedir. “UniGram

Kelime Vektörü" ile "Kural Tabanlı Yaklaşım Vektörü" birleştirilerek 40 boyutlu kelime vektörünü oluşturmaktadırlar.

Cümle Vektörü

Her kelime, 20 boyutlu UniGram vektörü ile 20 boyutlu kural tabanlı yaklaşım vektörünün birleşmesiyle oluşan toplam 40 boyutlu kelime vektörü ile temsil edilmektedir. Bu şekilde oluşturulan 40 boyutlu kelime vektörleri birleştirilerek cümle vektörleri elde edilmektedir.

Türkçede cümlelerin ortalama kelime sayılarının en fazla 10-15 arasında olduğu bilinmektedir (Dalkılıç ve Çebi, 2003; Karşılayan, 2022). İstisna bazı durumlarda kelime sayılarının artabileceği düşünüldüğünden cümleyi oluşturan en fazla kelime sayısı 25 olarak belirlenmiştir. Buna dayanarak cümle vektörlerinin uzunluğu 1000 boyutlu olacak şekilde düzenlenmiştir. 25 kelimeden daha az kelimeye sahip cümleler için boş kalan vektör değerleri, "0" ile doldurulur (padding). 25 kelimeden daha fazla sayıda kelimeye sahip cümleler için ise kesme işlemi (truncating) yapılır. Cümle vektörlerinin oluşumu bu şekilde tamamlanmaktadır. Tablo 15, 16, 17 ve 18'de "Hayallerimizden vazgeçmezsek her şeyin çok güzel olacağına inanıyorum" örnek cümlesinin cümle vektörü oluşumu aşama aşama gösterilmektedir.

Tablo 15. Örnek cümle.

Giriş	Hayallerimizden vazgeçmezsek her şeyin çok güzel olacağına inanıyorum.
Veri Ön İşleme	hayal vazgeç her şey çok güzel ol inan

Geliştirilen uygulamaya örnek cümle input olarak verilir. Örnek cümle, öncelikle veri ön işleme aşamasından geçmektedir. Bu aşamada cümle içerisinde bulunan ünlem, soru işareti ve yay ayraçlı ünlem hariç diğer tüm noktalama işaretleri kaldırılır; tüm harfler küçük harflere çevrilir; tüm kelimelerin gövdeleri tespit edilir.

Tablo 16. Unigram ve kural tabanlı vektör.

Kelime	UniGram (20 boyut)	Kural Taban (20 boyut)
hayal	0.23,0.01,0.13,0.01,0.05,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0	1,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0
vazgeç	0.25,0.01,0.19,0.20,0.02,0.21,0,0,0,0,0,0,0,0,0,0,0,0,0,0	0,0,0,0,1,0,0,0,0,0,0,0,1,0,1,0,0,0,0,0
her	0.23,0.02,0.07,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0	0,1,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0
şey	0.18,0.02,0.13,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0	1,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0
çok	0.21,0.15,0.03,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0	0,1,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0
güzel	0.20,0.17,0.19,0.02,0.05,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0	0,0,1,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0
ol	0.15,0.05,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0	0,0,0,0,0,1,0,0,0,0,0,0,0,0,0,0,0,0,0,0
inan	0.04,0.08,0.01,0.08,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0	0,0,0,0,1,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0

Cümle, kelimelere ayrılır. Analiz edilen kelime için 40 boyutlu vektör oluşturulur. Bu vektörün 0-19 arası indise sahip alan, UniGram; 20-39 arası indise sahip alan ise kural tabanlı kelime vektörüne tahsis edilmiştir. Her kelime sırayla analiz edilir.

Cümlenin ilk kelimesi "hayal" analiz edilir. Tablo 12'de yer alan Türkçe harflerin kullanım sıklığına göre atanan vektörel değerlere göre "h" harfi 0.23; "a" harfi 0.01; "y" harfi 0.13; "l" harfi 0.05 vektörel değere sahip olduğundan "hayal" kelimesi "0.23,0.01,0.13,0.01,0.05" şeklinde UniGram'a çevrilir. "hayal" kelimesinin karakter uzunluğu, 20 boyuttan az olduğu için UniGram kelime vektörünün kalan vektör boyutları için padding uygulanır. Ardından Tablo 14'te yer alan kural tabanına ait öz niteliklere göre analiz gerçekleştirildiğinde; "hayal" kelimesinin sadece "isim" öz niteliğine sahip olduğu belirlenir ve "isim" öz niteliğini temsil eden 20. indis "1", diğer indisler ise "0" yapılarak temsil sağlanır ve kural tabanlı kelime vektörü ise "1,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0" şeklinde oluşturulur.

Cümlenin ikinci kelimesi "vazgeç" analiz edilir. Tablo 12'de yer alan Türkçe harflerin kullanım sıklığına göre atanan vektörel değerlere göre "v" harfi 0.25; "a" harfi 0.01; "z" harfi 0.19; "g" harfi 0.20; "e" harfi 0.02; "ç" harfi 0.21 vektörel değere sahip olduğundan "vazgeç" kelimesi "0.25,0.01,0.19,0.20,0.02,0.21" şeklinde UniGram'a çevrilir. "vazgeç" kelimesinin karakter uzunluğu, 20 boyuttan az olduğu için UniGram kelime vektörünün kalan vektör boyutları için padding uygulanır. Ardından Tablo 14'te yer alan kural tabanına ait öz niteliklere göre analiz gerçekleştirildiğinde; "vazgeç" kelimesi, yan cümleciğin

yüklemi olduğundan 24. indis "1", olumsuzluk eki aldığından 32. indis "1", koşul eki aldığından 34. indis "1", diğer indisler ise "0" yapılarak temsil sağlanır ve kural tabanlı kelime vektörü ise "0,0,0,0,1,0,0,0,0,0,0,0,1,0,1,0,0,0,0,0" şeklinde oluşturulur.

Cümlenin üçüncü kelimesi "her" analiz edilir. Tablo 12'de yer alan Türkçe harflerin kullanım sıklığına göre atanan vektörel değerlere göre "h" harfi 0.23; "e" harfi 0.02; "r" harfi 0.07 vektörel değere sahip olduğundan "her" kelimesi "0.23,0.02,0.07" şeklinde UniGram'a çevrilir. "her" kelimesinin karakter uzunluğu, 20 boyuttan az olduğu için UniGram kelime vektörünün kalan vektör boyutları için padding uygulanır. Ardından Tablo 14'te yer alan kural tabanına ait öz niteliklere göre analiz gerçekleştirildiğinde; "her" kelimesi sıfat olduğundan 21. indis "1", diğer indisler ise "0" yapılarak temsil sağlanır ve kural tabanlı kelime vektörü ise "0,1,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0" şeklinde oluşturulur.

Cümlenin dördüncü kelimesi "şey" analiz edilir. Tablo 12'de yer alan Türkçe harflerin kullanım sıklığına göre atanan vektörel değerlere göre "ş" harfi 0.18; "e" harfi 0.02; "y" harfi 0.13 vektörel değere sahip olduğundan "şey" kelimesi "0.18,0.02,0.13" şeklinde UniGram'a çevrilir. "şey" kelimesinin karakter uzunluğu, 20 boyuttan az olduğu için UniGram kelime vektörünün kalan vektör boyutları için padding uygulanır. Ardından Tablo 14'te yer alan kural tabanına ait öz niteliklere göre analiz gerçekleştirildiğinde; "şey" kelimesinin sadece "isim" öz niteliğine sahip olduğu belirlenerek "isim" öz niteliğini temsil eden 20. indis "1", diğer indisler ise "0" yapılarak temsil sağlanır ve kural tabanlı kelime vektörü ise "1,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0" şeklinde oluşturulur.

Cümlenin beşinci kelimesi "çok" analiz edilir. Tablo 12'de yer alan Türkçe harflerin kullanım sıklığına göre atanan vektörel değerlere göre "ç" harfi 0.21; "o" harfi 0.15; "k" harfi 0.03 vektörel değere sahip olduğundan "çok" kelimesi "0.21,0.15,0.03" şeklinde UniGram'a çevrilir. "çok" kelimesinin karakter uzunluğu, 20 boyuttan az olduğu için UniGram kelime vektörünün kalan vektör boyutları için padding uygulanır. Ardından Tablo 14'te yer alan kural tabanına ait öz niteliklere göre analiz gerçekleştirildiğinde; "çok" kelimesi sıfat olduğundan 21. indis "1", kuvvetlendirici ifade olduğundan 36. indis "1", diğer

indisler ise “0” yapılarak temsil sağlanır ve kural tabanlı kelime vektörü ise “0,1,0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0” şeklinde oluşturulur.

Cümlenin altıncı kelimesi “güzel” analiz edilir. Tablo 12’de yer alan Türkçe harflerin kullanım sıklığına göre atanan vektörel değerlere göre “g” harfi 0.20; “ü” harfi 0.17; “z” harfi 0.19; “e” harfi 0.02; “l” harfi 0.05 vektörel değere sahip olduğundan “güzel” kelimesi “0.20,0.17,0.19,0.02,0.05” şeklinde UniGram’a çevrilir. “güzel” kelimesinin karakter uzunluğu, 20 boyuttan az olduğu için UniGram kelime vektörünün kalan vektör boyutları için padding uygulanır. Ardından Tablo 14’te yer alan kural tabanına ait öz niteliklere göre analiz gerçekleştirildiğinde; “güzel” kelimesi bu cümlede zarf olarak kullanıldığından 22. indis “1”, diğer indisler ise “0” yapılarak temsil sağlanır ve kural tabanlı kelime vektörü ise “0,0,1,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0” şeklinde oluşturulur.

Cümlenin yedinci kelimesi “ol” analiz edilir. Tablo 12’de yer alan Türkçe harflerin kullanım sıklığına göre atanan vektörel değerlere göre “o” harfi 0.15; “l” harfi 0.05 vektörel değere sahip olduğundan “ol” kelimesi “0.15,0.05” şeklinde UniGram’a çevrilir. “ol” kelimesinin karakter uzunluğu, 20 boyuttan az olduğu için UniGram kelime vektörünün kalan vektör boyutları için padding uygulanır. Ardından Tablo 14’te yer alan kural tabanına ait öz niteliklere göre analiz gerçekleştirildiğinde; “ol” kelimesi bu cümlede fiilimsi olarak kullanıldığından 25. indis “1”, diğer indisler ise “0” yapılarak temsil sağlanır ve kural tabanlı kelime vektörü ise “0,0,0,0,0,1,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0” şeklinde oluşturulur.

Cümlenin sekizinci kelimesi “inan” analiz edilir. Tablo 12’de yer alan Türkçe harflerin kullanım sıklığına göre atanan vektörel değerlere göre “i” harfi 0.04; “n” harfi 0.08; “a” harfi 0.01 vektörel değere sahip olduğundan “inan” kelimesi “0.04,0.08,0.01,0.08” şeklinde UniGram’a çevrilir. “inan” kelimesinin karakter uzunluğu, 20 boyuttan az olduğu için UniGram kelime vektörünün kalan vektör boyutları için padding uygulanır. Ardından Tablo 14’te yer alan kural tabanına ait öz niteliklere göre analiz gerçekleştirildiğinde, “inan” kelimesi ana cümlenin yüklemi olduğundan 24. indis “1”, diğer indisler ise “0” yapılarak temsil sağlanır ve kural tabanlı kelime vektörü ise “0,0,0,0,1,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0” şeklinde oluşturulur.

Tablo 17. Kelime vektörünün oluşumu.

Kelime	Kelime Vektörü (40 boyut)
hayal	0.23,0.01,0.13,0.01,0.05,0,0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0
vazgeç	0.25,0.01,0.19,0.20,0.02,0.21,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,0,0,0,0,1,0,1,0,0,0,0,0
her	0.23,0.02,0.07,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0
şey	0.18,0.02,0.13,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0
çok	0.21,0.15,0.03,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0
güzel	0.20,0.17,0.19,0.02,0.05,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0
ol	0.15,0.05,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0
inan	0.04,0.08,0.01,0.08,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,0,0,0,0,0,0,0,0,0,0,0

Tablo 16'da gösterildiği gibi her kelime için ayrı ayrı oluşturulan UniGram ve kural tabanlı kelime vektörleri birleştirilerek Tablo 17'de gösterildiği gibi her kelimeye ait 40 boyutlu kelime vektörleri hazır hale getirilir.

Tablo 18. Cümle vektörü.

Cümle	Cümle vektörü (1.000 boyut)
hayal vazgeç her şey çok güzel ol inan	0.23,0.01,0.13,0.01,0.05,0,0,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0

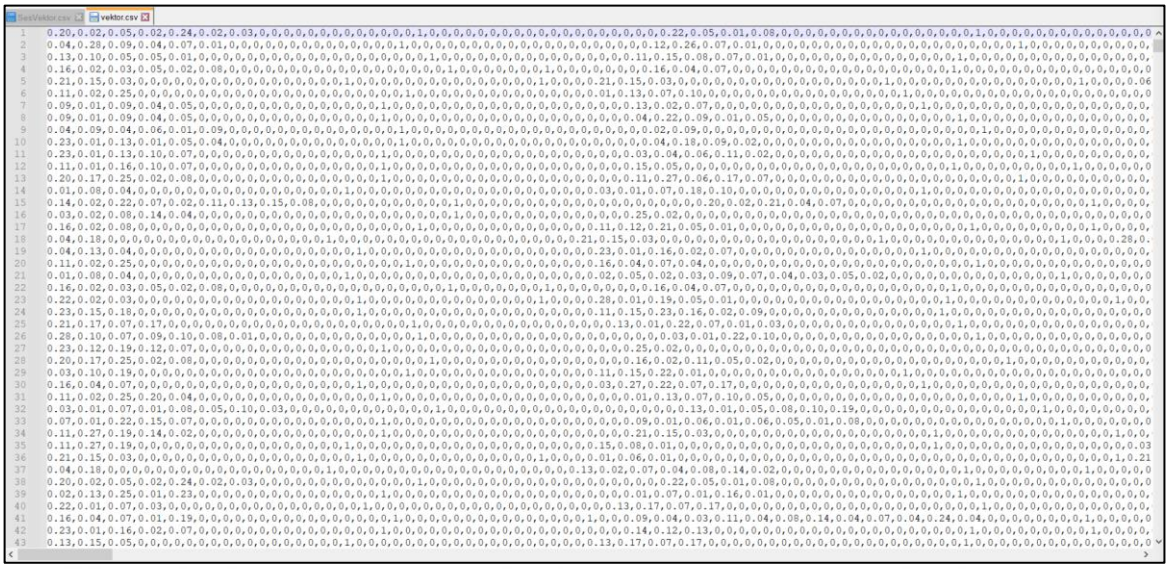

Şekil 8. Geliştirilen uygulamada yer alan cümle vektörü dosyasından bir kesit.

3.4.3. Hiperparametre Optimizasyonu

LSTM modelinin performansı hiperparametrelere bağlıdır. Bu nedenle en uygun modeli kurabilmek için hiperparametre optimizasyonu gerçekleştirilmiştir. Bu adımda evrimsel arama (evolutionary search) (Bäck ve Schwefel, 1993) yöntemi kullanılmıştır. Evrimsel arama yöntemi, karmaşık ve yüksek boyutlu hiperparametre uzaylarında etkili sonuçlar üretebilmesi nedeniyle tercih edilmiştir. LSTM gibi çok sayıda ayarlanabilir parametreye sahip modellerde, parametreler arasındaki doğrusal olmayan ilişkiler klasik yöntemlerle (örneğin grid search veya random search) verimli biçimde yakalanamamaktadır. Evolutionary Search, biyolojik evrimden esinlenen seçilim, çaprazlama ve mutasyon işlemleri aracılığıyla geniş arama uzayında daha çeşitli çözümler üretebilmekte ve lokal minimumlara takılma riskini azaltmaktadır (Bäck ve Schwefel, 1993). Ayrıca literatürde, evrimsel algoritmaların derin öğrenme modellerinde hiperparametre optimizasyonu için diğer yöntemlere göre daha hızlı yakınsama ve daha iyi genelleme performansı sağladığı gösterilmiştir (Elsken vd., 2019; Young vd., 2015). Bu nedenlerle, LSTM modelinin karmaşık yapısına uygun şekilde en iyi parametre kombinasyonunu elde etmek amacıyla evrimsel arama (evolutionary search) yöntemi tercih edilmiştir.

Optimizasyon sürecinde batch size, learning rate, momentum, dropout rate, epoch, optimizer scheme, weight initialization method gibi eğitime yönelik parametrelerin yanı sıra, katman sayısı (number of layers) ve her katmandaki nöron sayısı (number of neurons in each layer) gibi model mimarisine ait parametreler de optimize edilmiştir. Bu süreçte modellerin çalışma zamanı da dikkate alınmıştır. Evolutionary Search algoritması, 10 birey içeren bir popülasyon ile 5 nesil boyunca çalıştırılmıştır. Seçilim işlemi, tournsize=3 değerine sahip turnuva yöntemiyle gerçekleştirilmiştir. Çaprazlama ve mutasyon işlemleri belirli oranlarda uygulanmıştır. Sonuç olarak ilgili parametreler için kullanılan optimum değerler Tablo 19'da sunulmuştur.

Tablo 19. Yazılı metinler için LSTM modelin hiperparametreleri ve kullanılan optimum değerler.

Hiperparametreler	**Optimum Değerler**	**Değer Aralıkları**
Batch Size	256	128 - 256
Learning Rate	0.01	0.001 - 0.01
Momentum	-	0 - 0.9
Dropout Rate	0.3	0.2 - 0.3
Epoch	1000	100 - 1000
Weight Initialization Methods	RELU UNIFORM	LECUN NORMAL, RELU, RELU UNIFORM
Optimizer	Adam	Adam, RMSProp, SGD (Nesterov momentum), Nadam
Layer 1	Dense	Dense
Layer 2	LSTM	LSTM - BiLSTM
Layer 3	Dropout	Dropout, LSTM, Dense
Layer 4	Output	Output, Dropout
Layer 5	-	Output
Activation Function 1	ReLU	TANH, ReLU
Activation Function 2	ReLU	TANH, ReLU
Number of Neurons in Hidden Layer 1	2048	256 - 4096
Number of Neurons in Hidden Layer 2	512	128 - 1024
Number of Neurons in Hidden Layer 3	-	128
CPU Training Total Time (Optimum değerler ile eğitilen modelin eğitim süresi)	05:41 h	-
Model Size (Sıkıştırılmış dosya boyutu)	54.530 KB	-

3.4.4. Derin Öğrenme Modülü

Hiperparametre optimizasyonu sonucunda tespit edilen en başarılı parametreler, tüm modellerin eğitiminde kullanılmıştır. Geliştirilen yöntemde LSTM derin öğrenme modülü kullanılmıştır.

LSTM

LSTM (Long Short-Term Memory), derin öğrenme alanında kullanılan bir yinelemeli sinir ağı (RNN) modelidir. LSTM modelini ilk olarak Hochreiter ve Schmidhuber, 1997 yılında yaptıkları çalışmada ortaya atmışlardır (Hochreiter ve Schmidhuber, 1997). LSTM, özellikle zaman serisi verileri ve metin gibi sıralı verilerin işlenmesinde etkili bir şekilde kullanılan bir yapay sinir ağı mimarisidir.

LSTM, geleneksel RNN (Recurrent Neural Network) sinir ağlarının aşırı bağımlılık sorununu çözmek için tasarlanmıştır. RNN'ler, geçmiş zamandaki bilgileri hatırlama yeteneğine sahiptir, ancak uzun süreli bağımlılık ilişkilerini yakalamakta zorlanabilir. Örneğin, bir cümlenin başındaki bir kelime, cümlenin sonundaki bir kelimenin anlamını etkileyebilir, ancak standart RNN'ler bu tür uzun vadeli bağımlılıkları ele almakta zorlanır. LSTM ise, bu uzun vadeli bağımlılıkları daha iyi ele alabilen bir yapıya sahiptir. LSTM hücreleri, hafıza hücreleri (memory cell) olarak adlandırılan bir yapı kullanır. Hafıza hücreleri, geçmiş bilgiyi depolama ve kontrol etme yeteneğine sahiptir.

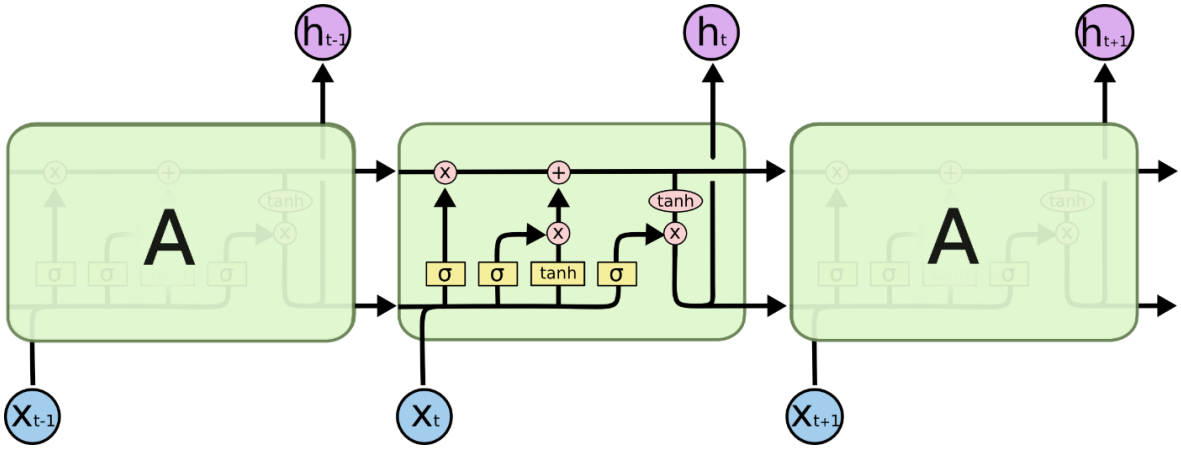

Şekil 9. LSTM modülü (Christopher Olah, 2015).

LSTM yapısında 3 çeşit kapı bulunmaktadır. LSTM, bu 3 kapının kontrolü ile çalışmaktadır. LSTM kapıları arasında unutma kapısı (f_t), hangi bilgilerin unutulacağına; giriş kapısı (i_t), hangi bilgilerin ekleneceğine; çıkış kapısı (o_t) ise hangi bilgilerin diğer duruma aktarılacağına karar verir. Bu kontrol mekanizmaları sayesinde LSTM, geçmiş bilgileri etkili bir şekilde hatırlayabilir ve giriş verisindeki uzun vadeli bağımlılıkları daha iyi yakalayabilir. Bu özellikleri, dil modelleri, metin sınıflandırma, duygu analizi, çeviri gibi NLP (Natural Language Processing) görevlerinde başarılı bir şekilde kullanılmasını sağlar. Ağırlık matrisleri, her bir kapının ne kadar etkileneceğine karar verir. Aşağıda, bu sistemin işlem adımlarını açıklayan LSTM eşitlikleri bulunmaktadır. Aşağıdaki eşitliklerde W ağırlık matrisini, b bias vektörünü ve σ sigmoid aktivasyon fonksiyonunu ifade etmektedir (Yalman ve Tüfekci, 2022).

Unutma Kapısı (Forget Gate): $f_t = \sigma\left(W_{xf} x_t + W_{hf} h_{t-1} + W_{cf} c_{t-1} + b_f\right)$ (3.1)

Giriş Kapısı (Input Gate): $i_t = \sigma\left(W_{xi}\, x_t + W_{hi}\, h_{t-1} + W_{ci}\, c_{t-1} + b_i\right)$ (3.2)

Hücre Durumunun Güncellenmesi: $c_t = f_t\, c_{t-1} + i_t\, tanh\left(W_{xc}\, x_t + W_{hc}\, h_{t-1} + b_c\right)$ (3.3)

Çıkış Kapısı (Output Gate): $o_t = \sigma\left(W_{xo}\, x_t + W_{ho}\, h_{t-1} + W_{co}\, c_t + b_o\right)$ (3.4)

Gizli Durumun Güncellenmesi: $h_t = o_t\, tanh(c_t)$ (3.5)

ReLU Aktivasyon Fonksiyonu

ReLU (Rectified Linear Unit) aktivasyon fonksiyonu, negatif girişleri 0'a eşitleyen basit bir doğrusal aktivasyon fonksiyonudur ve [0,∞) aralığında çıkış değeri almaktadır. x, sıfırdan küçük olduğunda ReLU(x) sıfır olmakta ve x, sıfırdan büyük veya sıfıra eşit olduğunda ReLU(x), x'e eşit olmaktadır. Bu özelliği sayesinde, öğrenme sürecinde daha iyi performans gösterebilir ve aşırı öğrenmeye karşı daha dayanıklı olabilir. Bu sebeple geliştirilen yöntemde oluşturulan modelin Dense ve LSTM katmanında ReLU aktivasyon fonksiyonu tercih edilmiştir. ReLU aktivasyon fonksiyonu, Eşitlik (5.6)'da gösterilmektedir.

$$ReLU(x) = \begin{cases} 0, & if \quad x < 0 \\ x, & if \quad x \geq 0 \end{cases} \tag{3.6}$$

Softmax Aktivasyon Fonksiyonu

Çıkış katmanında, çıkış değerlerini bir olasılık dağılımına dönüştürdüğü için çoklu sınıflandırmada sıklıkla tercih edilen (Bridle, 1989, 1990) softmax aktivasyonu kullanılmıştır. Softmax fonksiyonu, katmandaki çıkışları [0, 1] aralığına sıkıştırır ve bu değerlerin toplamının 1 olmasını sağlar. Softmax fonksiyonu, çıkış değerlerini bir olasılık dağılımına dönüştürür. Bu nedenle çok sınıflı sınıflandırma problemlerinde her bir sınıfa ait tahminî olasılıkları elde etmek için yaygın olarak kullanılır (Bridle, 1989, 1990). Bu sebeple oluşturulan modelin çıkış (output) katmanında softmax aktivasyon fonksiyonu tercih edilmiştir. Softmax aktivasyon fonksiyonu, Eşitlik (5.7)'de gösterilmektedir.

$$softmax(x)_i = \frac{e^{x_i}}{\sum_j e^{x_j}} \tag{3.7}$$

Geliştirilen yöntemde elde edilen modellerin çıkış (output) katmanında elde edilen sınıf etiketleri ve değerleri, Tablo 20'de gösterilmektedir.

Tablo 20. Sınıf etiketleri ve değerleri.

Sınıf Etiket No	Sınıf Etiketi	Sınıf Etiketi Değerleri
1	Biçimsel Sonuç	{Pozitif, Negatif}
2	Anlamsal Sonuç	{Pozitif, Negatif, Nötr, Koşullu Pozitif, Koşullu Negatif}
3	Sevinç	{0, 0.2, 0.4, 0.6, 0.8, 1, 1.2, 1.4, 1.6, 1.8}
4	Güven	{0, 0.2, 0.4, 0.6, 0.8, 1, 1.2, 1.4, 1.6, 1.8}
5	Korku	{0, 0.2, 0.4, 0.6, 0.8, 1, 1.2, 1.4, 1.6, 1.8}
6	Şaşkınlık	{0, 0.2, 0.4, 0.6, 0.8, 1, 1.2, 1.4, 1.6, 1.8}
7	Üzüntü	{0, 0.2, 0.4, 0.6, 0.8, 1, 1.2, 1.4, 1.6, 1.8}
8	İğrenme	{0, 0.2, 0.4, 0.6, 0.8, 1, 1.2, 1.4, 1.6, 1.8}
9	Öfke	{0, 0.2, 0.4, 0.6, 0.8, 1, 1.2, 1.4, 1.6, 1.8}

Tablo 20 Devamı

10	Beklenti	{0, 0.2, 0.4, 0.6, 0.8, 1, 1.2, 1.4, 1.6, 1.8}

1. sınıf etiketi olan biçimsel sonuç, ilgili cümledeki eylemin gerçekleşip gerçekleşmediğini ifade etmektedir. Eylem gerçekleşmiş ise "Pozitif", eylem gerçekleşmemiş ise "Negatif" sonuç üretmektedir.

2. sınıf etiketi olan anlamsal sonuç, ilgili cümle olumlu yönde duygu ifade ediyorsa "Pozitif", olumsuz yönde duygu ifade ediyorsa "Negatif", herhangi bir duygu ifade etmiyorsa "Nötr", ifade edilen olumlu yöndeki duygu bir koşula bağlanmış ise "Koşullu Pozitif", ifade edilen olumsuz yöndeki duygu bir koşula bağlanmış ise "Koşullu Negatif" sonuç üretmektedir. Koşullu sınıflandırma işleminde, monoton olmayan mantık (non-monotonic logic) yaklaşımı izlenmiştir.

3. ile 10. sınıf arasındaki etiketler, Plutchik'in duygu çarkıfeleğinde temsil edilen temel duygulardır. Temel duygu etiketlerini temsil etmek için öncelikli olarak ikili (binary) bir kodlama kullanılmıştır. Bu kodlama yöntemi, her bir örneğin ifade ettiği duygu durumuna sahip olup olmadığını göstermektedir. İlgili cümle, temsil ettiği duyguyu içeriyorsa 1, içermiyorsa 0 olarak etiketlenmiştir. Daha sonra duygu tonunu kuvvetlendiren ve zayıflatan ifadelerin de değerlendirilebilmesi için farklı etiket değerleri eklenmiştir. Temsil edilen duygu yoğunluğu arttıkça 1.2, 1.4, 1.6, 1.8 olarak etiketlenmiş olup duygu yoğunluğu azaldıkça 0.8, 0.6, 0.4, 0.2 olarak etiketlenmiştir. Bu sebeple ikili kodlamaya, belirtilen ondalıklı değerler de eklenmiştir. Duygu yoğunlukları, Plutchik'in duygu çarkıfeleğinde Şekil 10'da olduğu gibi temsil edilmektedir.

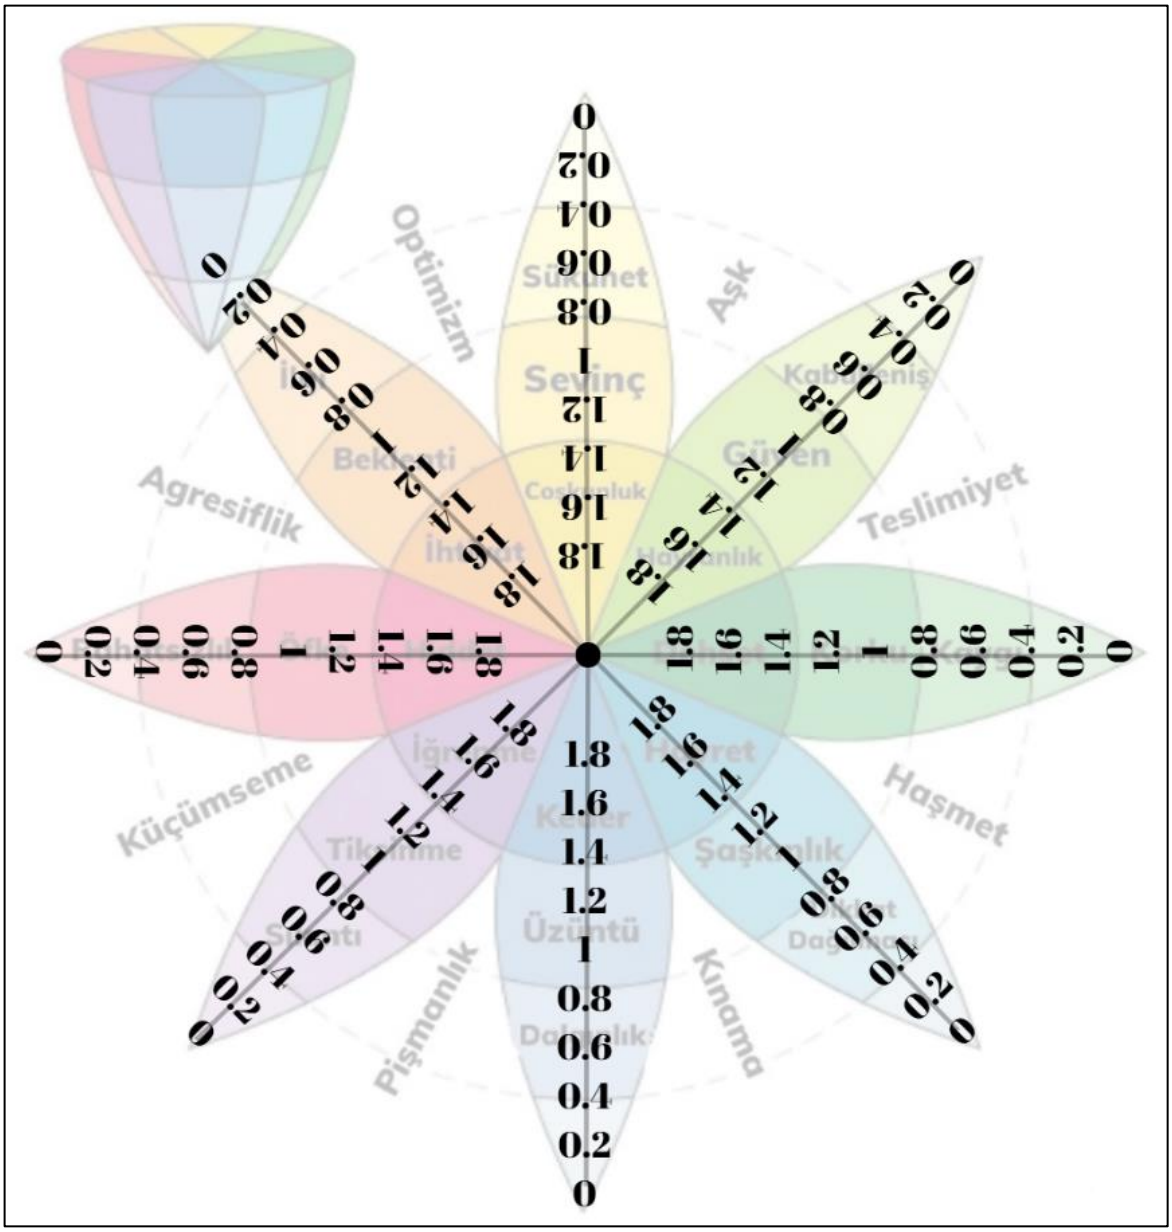

Şekil 10. Duygu yoğunluğu seviyelerinin Plutchik'in duygu çarkında gösterimi.

Ağırlıklandırılmış Sınıflandırma Yöntemi (Weighted Classification)

Ağırlıklandırılmış sınıflandırma, özellikle dengesiz sınıfların olduğu veri kümelerinde, modelin nadir görülen sınıfları daha iyi tanıyabilmesi için kullanılan bir yöntemdir. Bu yöntemde, her sınıfa, veri kümesindeki dağılımlarına göre bir ağırlık atanır. Böylece, model eğitim sırasında az temsil edilen sınıflara daha fazla önem verir ve tüm sınıfların öğrenme sürecine dengeli bir şekilde katkı yapması sağlanır.

Ağırlıklandırılmış sınıflandırma yönteminin ardında yatan fikir, azınlık sınıfların modelin karar sürecindeki etkisini artırmaktır. Genelde, sınıflar arasında büyük bir dengesizlik varsa model, çoğunluk sınıfı tahmin etme eğiliminde olur ve bu da nadir sınıfların ihmal edilmesine yol açabilir. Bu durumu önlemek için, sınıf ağırlıkları, Eşitlik (5.8)'de gösterildiği gibi belirlenebilir.

$$Ağırlık_{\ i} = \frac{1}{Sınıf\ Frekansı_{\ i}} \tag{3.8}$$

Burada, $Ağırlık_{\ i}$ her bir sınıf için hesaplanan ağırlık değeri ve $Sınıf\ Frekansı_{\ i}$, ilgili sınıfın veri setindeki sayısıdır. Sınıf sayısı arttıkça veya dengesizlik daha fazla belirgin hale geldikçe, ağırlıklar modelin eğitiminde daha fazla önem kazanır.

Ağırlıklandırılmış sınıflandırma yöntemi uzun süredir kullanılan ve çeşitli araştırmalarda rastlanan bir yaklaşımdır. 2001 yılında King ve Zeng'in (King ve Zeng, 2001) çalışması, dengesiz veri kümelerinde lojistik regresyon ve nadir olay tahminini ele alarak ağırlıklandırılmış sınıflandırma (weighted classification) yaklaşımına teorik ve pratik bir temel oluşturuştur. Bu çalışma, ağırlıklandırmanın özellikle nadir sınıflar üzerinde nasıl kullanılabileceğini ayrıntılı olarak açıklamaktadır. King ve Zeng'in çalışması, özellikle sosyal bilimlerde nadir olayların modellenmesi üzerine olsa da, makine öğrenmesi topluluğunda geniş kabul görmüştür.

Geliştirilen yöntemde kullanılan veri kümesindeki sınıflar, dengesiz bir dağılım göstermektedir. Veri kümesinde on sınıf bulunmaktadır. Bu sınıflardan sekiz adedi temel duyguları ifade eden sınıflardır. Duygu yoğunluklarını ifade edebilmek için her bir sınıfın altında on sınıf daha bulunmaktadır. Durum böyle olunca veri kümesini dengeli hale getirebilmek mümkün değildir. Ayrıca, bu kadar sınıfın olduğu bir çalışmada sınıfları dengeli hale getirmek mantıksız bir çabadır. Yapılan bazı yapay veri üretme denemelerinde ise veri kümesindeki gürültünün çok arttığı ve anlamsız verilerin başarı oranlarını düşürdüğü görülmüştür. Bu sebeple geliştirilen yöntemde ağırlıklandırılmış sınıflandırma yöntemi tercih edilmiştir. Bunun yanı sıra gerçek hayatta da doğal dilin kullanımında dengesiz bir

dağılım mevcuttur. Örneğin; “çok korktum” ifadesi, “çok fazla korktum” ifadesine göre daha fazla kullanılmaktadır. Bu nedenle geliştirilen yöntemde kullanılan veri kümesi, gerçek hayattaki kullanıma uygun bir sınıf dağılımına sahiptir.

Çalışmanın bu bölümünde Java programlama dilinde JDK 20 altyapısı ve DeepLearning4j kütüphaneleri kullanılarak yazılı metinler için Duygu-Türk uygulaması geliştirilmiştir.

3.5. Sözlü Metinler için Yöntem

Bu çalışmanın diğer bölümünde ise konuşma ses kayıtlarından duygu analizi yapabilen bir yöntem geliştirilmesi amaçlanmaktadır. Duygu-Türk yönteminin sözlü metinler için geliştirilen bu bölümünün iş akış şeması, Şekil 11’de gösterilmektedir.

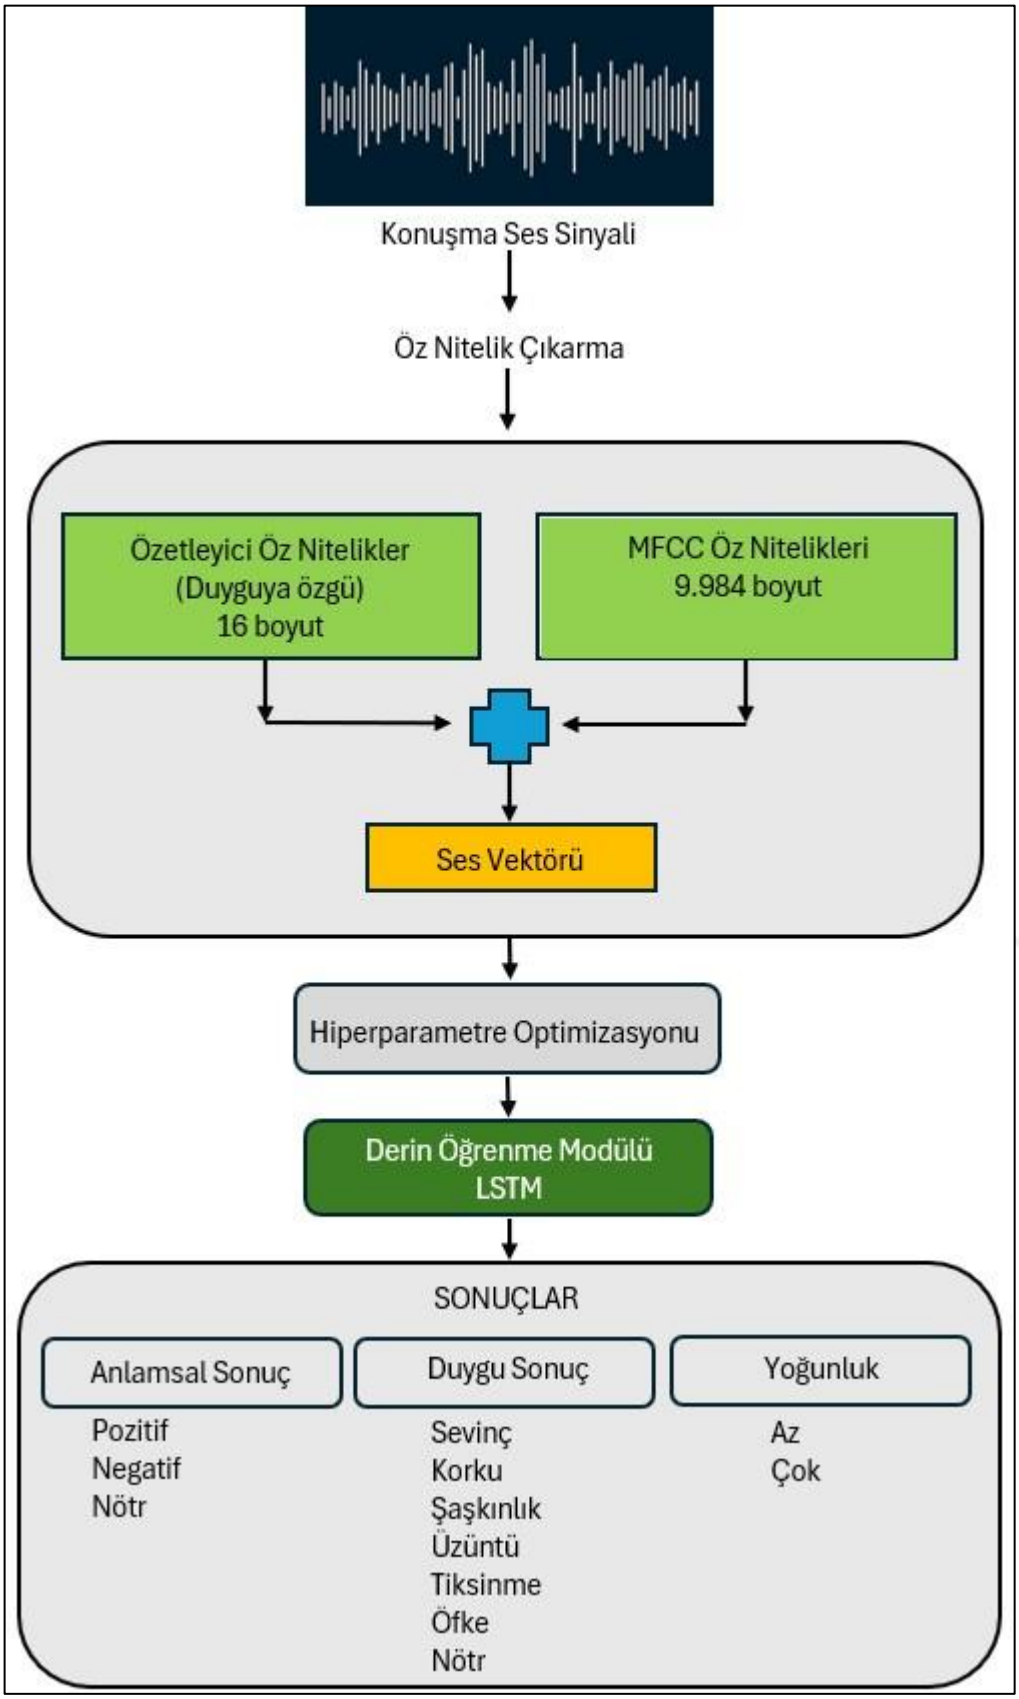

Şekil 11. Sözlü metinler için geliştirilen yöntemin iş akış şeması.

İlk aşamada konuşma ses sinyallerinden öz nitelikler çıkarılır. Bu öz niteliklerin ilk 16'sı duyguya özgü öz niteliklerdir ve tüm ses kaydını özetleyici niteliktedir. Kalan 9.984 öz nitelik ise MFCC öz nitelikleridir. Bu iki farklı öz nitelik kümesi birleştirilerek toplam 10.000 boyutlu ses vektörü oluşturulmaktadır. Hiperparametre optimizasyonunun ardından son aşamada, elde edilen ses vektörleri tezin 5.1.4.1. maddesinde anlatılan LSTM derin öğrenme yöntemiyle eğitilmektedir. Eğitimin sonucunda, "Anlamsal Sonuç", "Duygu Sonuç" ve "Yoğunluk" için üç farklı model elde edilmektedir. Üç farklı modele ait sınıf etiketleri ve değerleri Tablo 21'de gösterilmektedir.

Tablo 21. Ses sınıf etiketleri ve değerleri.

Sınıf Etiket No	Sınıf Etiketi	Sınıf Etiketi Değerleri
1	Anlamsal Sonuç	{Pozitif, Negatif, Nötr}
2	Duygu Sonuç	{Sevinç, Korku, Şaşkınlık, Üzüntü, Tiksinme, Öfke, Nötr}
3	Yoğunluk	{Az, Çok}

3.5.1. Ses Öz Nitelikleri

İlk olarak konuşma ses dosyalarından sıfır geçiş oranı (zero crossing rate), ses enerjisi (energy), sinyal ortalaması (signal mean), spektral ağırlık merkezi (spectral centroid), ses varyansı (audio variance), standart sapma (standard deviation), maksimum mutlak genlik (max absolute amplitude), ortalama mutlak genlik (average absolute amplitude), sessizlik oranı (silence ratio), jitter, shimmer, en yüksek pitch değeri (pitch peak), pitch frekansı (pitch frequency), pitch değişkenliği (pitch variability), pitch aralığı (pitch range) ve HNR olmak üzere 16 adet duyguya özgü öz nitelik elde edilmektedir. Her ses kaydı birbirinden farklı uzunluktadır. Bu sebeple ilk 16 ses öz niteliğinin ses örnek sayısına oranı kullanılmıştır. Böylece ilk 16 ses öz niteliği tüm ses kaydını özetleyici bir nitelik kazanmıştır.

İkinci olarak konuşma ses dosyalarından MFCC öz nitelikleri elde edilmektedir. Her çerçeveden (frame) 13 adet MFCC değeri elde edilmektedir. Bu yapılandırma, ses işlemede yaygın olarak kabul gören bir standarttır; 13 katsayısı, boyut ve hesaplama maliyeti arasında

iyi bir denge sağlarken, yeterli düzeyde spektral inceliği yakalamaktadır. Ayrıca, literatürde 8-13 aralığının çoğu uygulama için uygun olduğu ve 13'ün sıklıkla varsayılan değer olarak kullanıldığı belirtilmektedir (Davis ve Mermelstein, 1980; Sari vd., 2025). Bu nedenle, bu çalışmada temel temsil için 13 MFCC kullanılmıştır.

Bu çalışmada kullanılan veri kümesinde, konuşma kayıtları kısa ifadelerden nispeten uzun konuşma örneklerine kadar değişen uzunluklardadır. Tüm kayıtlarda tek tip özellik temsilini sağlamak ve modelin hem kısa hem de uzun sinyalleri tutarlı bir şekilde işleyebilmesini sağlamak için 768 çerçeve (frame) benimsenmiştir. Bu karar, en uzun ses kayıt örneklerinden bilgi kaybı olmadan MFCC'lerin çıkarılmasını sağlamaktadır. Daha kısa ses kayıtları ise boyut tutarlılığını korumak için sıfırlarla (padding) doldurulmuştur. Sonuç olarak, her ses dosyasının ikinci bölümü, 9.984 öz niteliğe karşılık gelen 768 × 13 katsayılı standartlaştırılmış bir öz nitelik vektörü ile temsil edilmiştir. Bu yaklaşım, farklı sürelerdeki örnekler arasında karşılaştırılabilirliği sağlamış ve LSTM tabanlı mimaride verimli öğrenmeyi kolaylaştırmıştır.

Son olarak, ses vektörü, 16 adet duyguya özgü özetleyici öz nitelikler ile 9.984 adet MFCC öz niteliklerinin birleşiminden oluşturulmaktadır. İki farklı öz nitelik kümesi birleştirilerek toplam 10.000 boyutlu ses vektörü oluşturulmaktadır. Bu vektörün öz nitelikleri Tablo 22'de gösterilmektedir.

Tablo 22. Ses öz nitelikleri.

Sıra No	Öz Nitelik	Öz Nitelik Sayısı
1	Sıfır Geçiş Oranı (Zero Crossing Rate)	1
2	Ses Enerjisi (Energy)	1
3	Sinyal Ortalaması (Signal Mean)	1
4	Spektral Ağırlık Merkezi (Spectral Centroid)	1
5	Ses Varyansı (Audio Variance)	1
6	Standart Sapma (Standard Deviation)	1
7	Maksimum Mutlak Genlik (Max Absolute Amplitude)	1
8	Ortalama Mutlak Genlik (Average Absolute Amplitude)	1
9	Sessizlik Oranı (Silence Ratio)	1
10	Jitter	1
11	Shimmer	1

Tablo 22 Devamı

12	En Yüksek Pitch Değeri (Pitch Peak)	1
13	Pitch Frekansı (Pitch Frequency)	1
14	Pitch Değişkenliği (Pitch Variability)	1
15	Pitch Aralığı (Pitch Range)	1
16	HNR	1
17	MFCC	9.984
	TOPLAM	**10.000**

Geliştirilen model, JDK 20 üzerinde Java programlama dili kullanılarak oluşturulmuştur. Derin öğrenme işlemleri için DeepLearning4j kütüphanesi, konuşma ses sinyallerinden özellik çıkarma için ise TarsosDSP kütüphanesi kullanılmıştır. Tüm akustik özellikler, 44.1 kHz örnekleme hızı (sampleRate), 2048 örnek çerçeve boyutu (frameSize) ve 1024 örnek atlama boyutu (hopSize) kullanılarak çıkarılmıştır. Yapılan literatür çalışmalarında belirtilen boyutların ses analizleri için en uygun değerler olduğu belirtildiğinden bu boyutların kullanımı tercih edilmiştir (Kubicek vd., 2023; Raffel, 2016).

Sıfır Geçiş Oranı (Zero Crossing Rate)

Sıfır Geçiş Oranı (Zero Crossing Rate, ZCR) (Bhangale ve Kothandaraman, 2023), konuşma sinyalindeki sıfır çizgisi üzerindeki geçişleri analiz ederek, sinyalin gürültülülük (noisiness) seviyesini ölçer. Eşitlik (5.9), ZCR'nin zaman alanındaki hesaplanmasını göstermektedir. Sign fonksiyonu, pozitif örnek genliği için 1, negatif örnek genliği için ise 0 değeri sağlar ve bu değerler, belirli bir zaman çerçevesi (t) boyunca hesaplanır. Eşitlikte $x[n]$ konuşma sinyalinin $n.$ örneğini; $\frac{1}{2N}$ ise çift saymayı önleyerek ZCR'yi sinyal uzunluğuna göre normalleştirmektedir.

$$ZCR_t = \frac{1}{2N}\sum_{n=1}^{N}|sign(x[n]) - sign(x[n-1])| \quad (3.9)$$

Ses Enerjisi (Energy)

Ses Enerjisi (Energy) (M. Jain vd., 2020), bir konuşma sinyalindeki ses dalgalarının toplam gücünü temsil eder ve konuşma analizi için temel bir akustik özelliktir. Sesin yoğunluğu ve yüksekliği ile doğrudan ilişkili olan enerji, farklı duygusal durumlar için değişiklik gösterir. Örneğin, öfke ve mutluluk gibi yüksek enerji gerektiren duygular, sinyaldeki enerji seviyelerini artırırken; üzüntü gibi duygular, daha düşük enerji seviyeleriyle karakterize edilir. Enerji, genellikle kısa zaman aralıklarında hesaplanır ve sinyalin ortalama, maksimum ve varyasyon değerleri analiz edilerek duygusal durumlar sınıflandırılır. Duygu analizi uygulamalarında enerji, ses sinyalinin duygusal yoğunluğunu anlamak için kritik bir rol oynamaktadır.

Sinyal Ortalaması (Signal Mean)

Ses sinyalinin ortalama genliğini ifade eder (A. Jain ve Ahamed, 2019). Sesin genel seviyesini analiz ederek konuşmacının sakin mi yoksa heyecanlı mı olduğunu anlamada kullanılır. Duygusal yoğunluğun bir göstergesidir.

Spektral Ağırlık Merkezi (Spectral Centroid)

Spektral Ağırlık Merkezi (Spectral Centroid) (Aggarwal vd., 2022), sinyalin frekans spektrumundaki ağırlık merkezini temsil eder. Yani, sinyalin enerjisinin ağırlıklı ortalaması olarak düşünülebilir. Yüksek spectral centroid değerleri, daha yüksek frekansta yoğunlaşan sesleri ifade ederken, düşük değerler daha düşük frekans bileşenlerinin baskın olduğunu gösterir. Spektral Ağırlık Merkezi, Eşitlik (5.10)'da gösterilmektedir. Eşitlikte, SC_t spectral centroid'i, N toplam frekans bileşeni sayısını, $M_t(nb)$ SIFT spektrumu genliği (Scale Invariant Fourier Transform magnitudes), nb frekans bileşenini ifade etmektedir (Bhangale ve Kothandaraman, 2023).

$$SC_t = \frac{\sum_{n=1}^{N} M_t(nb) \times nb}{\sum_{n=1}^{N} nb} \tag{3.10}$$

Ses Varyansı (Audio Variance)

Sinyalin genlik varyansını ölçer (A. Jain ve Ahamed, 2019). Sinyalin değişkenliğini ölçerek konuşmacının ruh hali dalgalanmalarını tespit eder. Örneğin, yüksek varyans heyecan veya endişe belirtisi olabilir.

Standart Sapma (Standard Deviation)

Ses sinyalinin genlik dağılımındaki standart sapmayı ifade eder (A. Jain ve Ahamed, 2019). Ses seviyesindeki sapmaları ölçerek duygusal stabiliteyi analiz eder. Yüksek sapma, öfke veya korku gibi yoğun duygularla ilişkilendirilebilir.

Maksimum Mutlak Genlik (Max Absolute Amplitude)

Sinyaldeki en yüksek mutlak genlik değerini temsil eder, sinyalin maksimum gücünü gösterir (A. Jain ve Ahamed, 2019). Sinyaldeki en yüksek enerji anını belirleyerek yüksek sesli duygular (örneğin öfke) veya düşük sesli ifadeler (örneğin üzüntü) arasında ayrım yapar.

Ortalama Mutlak Genlik (Average Absolute Amplitude)

Sinyalin ortalama mutlak genlik değerini ifade eder, genel ses seviyesi analizi için kullanılır (A. Jain ve Ahamed, 2019). Sesin genel yoğunluğunu ölçerek konuşmacının enerjik veya sakin bir duyguda olup olmadığını anlamaya yardımcı olur.

Sessizlik Oranı (Silence Ratio)

Sessizlik dönemlerinin toplam sinyal süresine oranını belirtir (Atmaja ve Akagi, 2020). Sessizlik oranını ölçerek konuşmacının tereddüt veya endişe gibi duygular içinde olup olmadığını tespit eder. Yüksek sessizlik oranı korku veya üzüntüyle ilişkilendirilebilir.

Jitter

Jitter (Bhangale ve Kothandaraman, 2023), konuşma sinyalinde ardışık temel frekans periyotları arasındaki değişkenliği ölçen bir ses kalitesi özelliğidir. Ses tellerinin düzensiz titreşimi nedeniyle oluşur ve konuşma sinyalinin stabilitesini gösterir. Yüksek jitter değeri, titreşimlerde büyük dalgalanmalar olduğunu ve sesin daha gergin, titrek veya düzensiz olduğunu gösterir.

Shimmer

Shimmer (Bhangale ve Kothandaraman, 2023), konuşma sinyalinin genlik (amplitude) değişkenliğini ölçen bir sesteki varyasyon metriğidir. Jitter zaman ekseninde frekans değişimlerini analiz ederken, shimmer genlik (ses şiddeti) değişkenliğini analiz eder. Konuşma sinyalinde dalgalı veya değişken ses şiddeti olan durumlar shimmer değerlerini artırır.

En Yüksek Pitch Değeri *(*Pitch Peak)

Pitch (Gerhard, 2003; M. Jain vd., 2020), bir konuşma sinyalinin temel frekansını temsil eder ve insan sesindeki titreşim hızını ifade eder. Duygu analizi açısından pitch, duygusal durumlara bağlı olarak değişiklik gösteren önemli bir özelliktir. Örneğin, öfke veya mutluluk gibi duygular genellikle yüksek pitch değerlerine sahipken, üzüntü gibi duygular daha düşük pitch değerleriyle karakterize edilir. Pitch, ses tellerinin titreşiminden kaynaklanan alt frekans bileşenidir ve konuşmanın tonlamasını belirler. Duygu analizi uygulamalarında pitch, ses sinyalinin zaman içindeki değişimlerini inceleyerek duygusal durumları ayırt etmek için sıklıkla kullanılır. Bu özellik, sesin tonlama örüntülerini analiz ederek model performansını artırır. F0 temel frekans ile benzer olsa da farklı şeylerdir. F0, ses tellerinin fiziksel titreşim frekansıdır ve Hertz (Hz) cinsinden ölçülür, ses perdesi (pitch) ise F0'ın insan kulağı tarafından algılanan öznel karşılığıdır ve işitsel algıya bağlıdır.

Pitch Frekansı (Pitch Frequency)

Ses sinyalindeki temel frekansı ifade eder (Gerhard, 2003), sesin temel perdesini belirlemek için kullanılır. Sesin temel frekansını belirleyerek duygunun yoğunluğunu ve doğasını analiz eder. Örneğin, yüksek frekans korku veya mutlulukla ilişkilendirilebilir.

Pitch Değişkenliği (PitchVariability)

Sinyalin perde değişkenliğini ölçer (Gerhard, 2003), özellikle duygusal dalgalanmaları analiz etmek için kullanılır. Tonlama değişikliklerini analiz ederek duygusal dalgalanmaları tespit eder. Örneğin, düşük varyasyon monotonluk gösterebilirken yüksek varyasyon heyecanla ilişkilendirilebilir.

Pitch Aralığı (Pitch Range)

Sinyalin minimum ve maksimum perde değerleri arasındaki farkı ifade eder (Gerhard, 2003; A. Jain ve Ahamed, 2019). Tonlama aralığını analiz ederek öfke, mutluluk veya şaşkınlık gibi duyguları anlamada yardımcı olur. Geniş aralık genellikle daha güçlü duygularla ilişkilidir.

Harmonik Gürültü Oranı (Harmonic Noise Ratio)

Harmonik Gürültü Oranı (Harmonic Noise Ratio, HNR) (L. Chen vd., 2020), bir ses sinyalinin harmonik (periyodik) bileşenlerinin gürültü (aperiyodik) bileşenlere oranını temsil eden bir ses kalitesi ölçütüdür. HNR, bir sinyalin düzenli veya düzensiz yapısını değerlendirir ve sesin temizliğini veya tutarlılığını analiz etmek için kullanılır. Daha yüksek bir HNR değeri, sinyalin harmonik bileşenlerinin daha baskın olduğunu ve sesin daha net olduğunu gösterirken, düşük bir HNR değeri gürültünün daha baskın olduğunu ve sesin daha boğuk olduğunu ifade eder. Matematiksel olarak, HNR Eşitlik (5.11)'de ifade edilmektedir.

$$HNR = 10 \cdot log_{10}\left(\frac{Harmonik\ Bileşen\ Enerjisi}{Gürültü\ Enerjisi}\right) \quad (3.11)$$

HNR, özellikle konuşma sinyallerinde sesin düzenli veya düzensiz özelliklerini ölçmek için kullanılır. HNR, ses kalitesini analiz etmek için doğrudan hesaplanan bir özellik olmasa da, jitter ve shimmer gibi diğer ses kalitesi özellikleriyle birlikte ele alındığında daha kapsamlı bir analiz sağlamaktadır.

MFCC (Mel-Frequency Cepstral Coefficients)

MFCC ses işleme alanında yaygın olarak kullanılan bir özellik çıkarma tekniğidir (Davis ve Mermelstein, 1980; M. Yıldırım, 2022). İnsan kulağı, sinyallerin frekans bileşenlerine göre duyarlıdır ve bu nedenle, MFCC, insan işitme sisteminin frekans duyarlılığına benzer bir özellik çıkarma tekniğidir. MFCC, ses verilerini frekans bileşenlerine ayırır ve daha sonra bunları kırpılmış, ölçeklendirilmiş ve sıkıştırılmış verilere dönüştürür. MFCC özellik çıkarma adımları aşağıda sıralanmaktadır.

- **Sinyal örnekleme:** Sinyalin örnekleme frekansı belirlenir ve sinyal bu frekansta örneklenir.
- **Hamming penceresi:** Sinyal, her bir örneği birbirinden ayrılmış kısa sürelerle işlenir. Bu işlem, "hamming penceresi" olarak adlandırılır.
- **FFT (Fast Fourier Transform):** Hamming penceresi boyunca sinyal işlendikten sonra, FFT uygulanır ve sinyal frekans bileşenlerine ayrılır.
- **Mel filtre bankası:** Frekans bileşenleri, Mel ölçeğinde ölçeklendirilir. Mel ölçeği, insan işitme sisteminin duyarlılığına benzer bir şekilde ölçeklendirilmiştir.
- **Logaritmik dönüşüm:** Mel filtre bankası çıktısı üzerinde logaritmik dönüşüm uygulanır.
- **Cepstral katsayıları:** Logaritmik dönüşüm sonrası çıktı, cepstral katsayıları olarak adlandırılır.

Yukarıda açıklanan ses öz niteliklerinin görüldüğü ses vektör dosyasından bir kesit, Şekil 12'de sunulmaktadır.

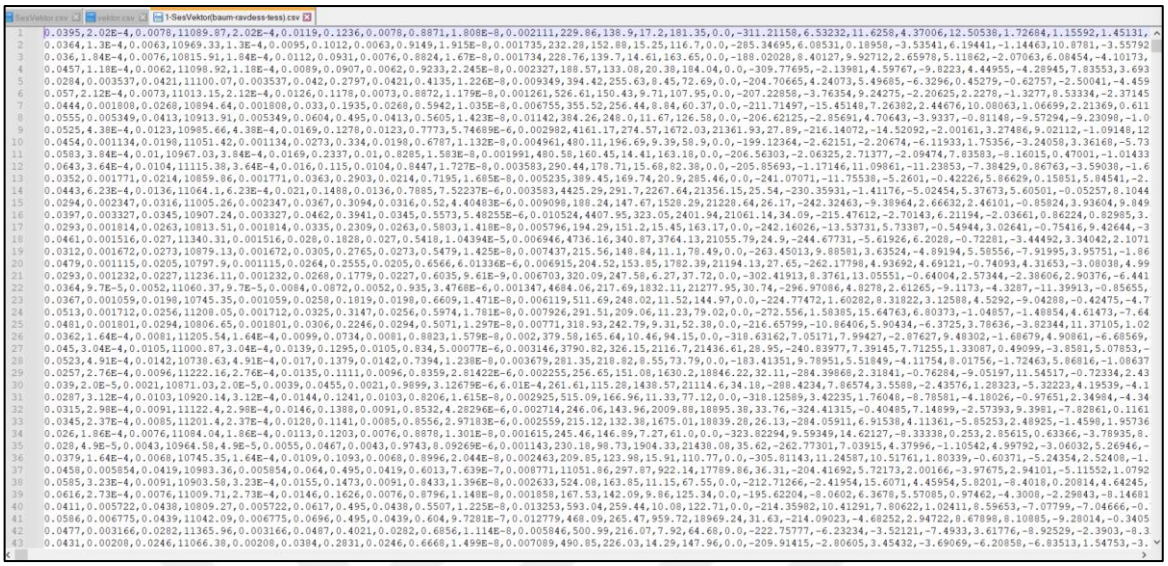

Şekil 12. Geliştirilen uygulamada ses öz niteliklerinin görüldüğü ses vektör dosyasından bir kesit.

3.5.2. Hiperparametre Optimizasyonu

Yazılı metinler için yapılan çalışmada olduğu gibi sözlü metinler için yapılan çalışmada da en uygun modeli kurabilmek için hiperparametre optimizasyonu gerçekleştirilmiştir. Bu adımda evrimsel arama (evolutionary search) (Bäck ve Schwefel, 1993) yöntemi kullanılmış ve batch size, learning rate, momentum, dropout rate, epoch, optimizer scheme, weight initialization method gibi eğitime yönelik parametrelerin yanı sıra, katman sayısı (number of layers) ve her katmandaki nöron sayısı (number of neurons in each layer) gibi model mimarisine ait parametreler de optimize edilmiştir. Bu süreçte modellerin çalışma zamanı da dikkate alınmıştır. Evolutionary Search algoritması, 10 birey içeren bir popülasyon ile 5 nesil boyunca çalıştırılmıştır. Seçilim işlemi, tournsize=3 değerine sahip turnuva yöntemiyle gerçekleştirilmiştir. Çaprazlama ve mutasyon işlemleri belirli oranlarda uygulanmıştır.

Sözlü metinler için yapılan hiperparametre optimizasyon çalışmasının sonucunda yazılı metinler için tespit edilen optimum değerlerden farklı olarak öğrenme katsayısında,

ağırlık başlangıç metodunda, aktivasyon fonksiyonlarında ve 2. katmandaki nöron sayılarında farklılıklar görülmektedir. Model, LSTM derin öğrenme yöntemi ile eğitilmiştir. Sözlü metinler için kullanılan optimum değerler, Tablo 23'te sunulmuştur.

Tablo 23. Sözlü metinler için LSTM modelin hiperparametreleri ve kullanılan optimum değerler.

Hiperparametreler	**Optimum Değerler**	**Değer Aralıkları**
Batch Size	256	128 - 256
Learning Rate	0.001	0.001 - 0.01
Momentum	-	0 - 0.9
Dropout Rate	0.3	0.2 - 0.3
Epoch	1000	100 - 1000
Weight Initialization Methods	LECUN NORMAL	LECUN NORMAL, RELU, RELU UNIFORM
Optimizer	Adam	Adam, RMSProp, SGD (Nesterov momentum), Nadam
Layer 1	Dense	Dense
Layer 2	LSTM	LSTM - BiLSTM
Layer 3	Dropout	Dropout, LSTM, Dense
Layer 4	Output	Output, Dropout
Layer 5	-	Output
Activation Function 1	TANH	TANH, ReLU
Activation Function 2	TANH	TANH, ReLU
Number of Neurons in Hidden Layer 1	2048	256 - 4096
Number of Neurons in Hidden Layer 2	256	128 - 1024
Number of Neurons in Hidden Layer 3	-	128
CPU Training Total Time (Optimum değerler ile eğitilen modelin eğitim süresi)	36:25 min	-
Model Size (Sıkıştırılmış dosya boyutu)	340.681 KB	-

DÖRDÜNCÜ BÖLÜM
ARAŞTIRMA BULGULARI

Tez çalışması kapsamında, Duygu-Türk adı verilen yazılı ve sözlü Türkçe metinler için duygu analiz yöntemi geliştirilmiştir. Bu yöntemin yazılı metinler ve sözlü metinler için iki bölümü bulunmaktadır. Çalışmanın sonucunda her iki bölümün kazanımları birleştirilerek daha kapsamlı hibrit duygu analizi yöntemi elde edilmiştir. Bu yöntem, Java programlama dilinde JDK 20 altyapısı ve DeepLearning4j kütüphaneleri kullanılarak geliştirilmiştir. Bu çalışmada elde edilen bulgular, Intel Core i7-10750H (2.60 GHz) işlemci, 16 GB RAM, NVIDIA GeForce GTX 1650 Ti (4 GB) grafik kartı ve 477 GB SSD donanımına sahip bir dizüstü bilgisayar üzerinde gerçekleştirilmiştir. Karşılaştırma analizleri kapsamında ise, özellikle yüksek hesaplama gereksinimi olan işlemler için Kaggle platformunda sunulan GPU destekli hesaplama altyapısından yararlanılmıştır.

Araştırma bulguları, "yazılı metinler için araştırma bulguları" ve "sözlü metinler için araştırma bulguları" şeklinde iki başlık altında incelenmektedir. Bunun ardından geliştirilen uygulama için örnek çalışmaya yer verilmiştir.

4.1. Yazılı Metinler için Araştırma Bulguları

Tez çalışmasının yazılı metinler için hazırlanmış bölümünde Plutchik'in Duygu Çarkı'na göre etiketlenmiş 136.000 cümleden oluşan bir veri kümesi kullanılmıştır.

Etiketlemede tutarlılık ve güvenilirliği sağlamak için, dil bilim geçmişi olan ana dili Türkçe olan üç kişi anotatör (annotator, yorumcu) olarak görevlendirilmiştir. Bu kişiler, 16 duygu kategorisinin her biri için resmi tanımlar ve örnekler ile belirsizliği gidermeye yönelik kuralları içeren standart bir kılavuz belgesini takip etmişlerdir. Bu tanımlar ve karar kuralları, özellikle koşullu duygu ifadeleri, kuvvetlendirici ve zayıflatıcı ifadeler, noktalama işaretleri, morfo-semantik ekler vb. durumları içermekte olup önceki bölümlerde ayrıntılı olarak açıklanmıştır.

Anotatörler arasındaki uyumu göstermek için Fleiss Kappa metriği (Fleiss, 1971) kullanılmıştır. Bu metrik, anotatör sayısı ikiden fazla olduğunda daha güvenilir sonuçlar vermektedir (Sim ve Wright, 2005). Fleiss Kappa puanı 0,81 olarak hesaplanmıştır. Bu, anotatörler arasında önemli bir uyum olduğunu göstermektedir.

Manuel etiketlemeye ek olarak, otomatik bir etiketleme mekanizması da uygulanmıştır. Bu amaçla, çevrimiçi açık erişimli edebi kaynakları indirmek için bir web kazıyıcı tasarlanmıştır. Bu kaynaklar cümlelere ve ardından kelimelere bölünür, işlenir ve otomatik etiketleme için LSTM modeline aktarılabilmektedir.

Yukarıda belirtilen hassasiyet ile oluşturulan 136.000 cümleden oluşan veri kümesindeki 100.000 cümle eğitim kümesi, 36.000 cümle ise test kümesi olarak ayrılmıştır.

Eğitim kümeleri, belirlenen parametrelerde ağırlıklandırılmış sınıflandırma yöntemi kullanan LSTM tabanlı derin öğrenme yöntemi ile eğitilmiştir. Eğitim sonucunda "biçim, anlam, sevinç, güven, korku, şaşkınlık, üzüntü, tiksinme, öfke ve beklenti" olmak üzere on ayrı model elde edilmiş ve ZIP formatında kaydedilmiştir. Bu dosyalar, kullanıcı arayüzünde kullanılırken binary formata dönüştürülmüştür.

Elde edilen modeller, test veri kümesi ile test edilmiştir. Buna göre biçim modeli %99,77, anlam modeli %92,84, sevinç modeli %95,37, güven modeli %97,88, korku modeli %96,92, şaşkınlık modeli %97,42, üzüntü modeli %95,86, tiksinme modeli %96,17, öfke modeli %96,08 ve beklenti modeli %96,39 doğruluk oranına ulaşmıştır. Temel duyguların etkileşimlerinden oluşan ikincil duygular ise kullanıcı arayüzü uygulamasında tespit edilmektedir. Biçim modele ve anlam modele ait sonuçlar Tablo 24'te gösterilmiştir.

Tablo 24. Biçim ve Anlam modele ait sonuçlar.

Parametreler	**Biçim Model**	**Anlam Model**
Accuracy	0.9977	0.9284

Tablo 24 Devamı

Precision	0.9985	0.9374
Recall	0.9989	0.9347
F1 Score	0.9987	0.9360
CPU Toplam zaman	02:47 h	02:33 h
Model Boyutu	57.013 KB	57.402 KB

Anlam modelin sınıf bazında sonuçları, Tablo 25'te gösterilmiştir.

Tablo 25. Anlam model sınıflarına ait sonuçlar.

Sınıflar	**Accuracy**	**Precision**	**Recall**	**F1 Score**
Negatif	0.9435	0.9356	0.9454	0.9405
Pozitif	0.9481	0.9041	0.8929	0.8985
Nötr	0.9729	0.9038	0.8910	0.8974
Koşullu Pozitif	0.9965	0.9731	0.9690	0.9710
Koşullu Negatif	0.9957	0.9707	0.9752	0.9729

"Biçim Model" sonuçları, %99,77 doğruluk oranına sahiptir. Bu durum, kural tabanlı yaklaşım vektöründe yer alan "Yoksunluk eki (-sız, -siz, -suz, -süz), olumsuzluk eki (-ma, -me), olumsuz ifade (değil, yok)", vektör temsillerinin model tarafından çok iyi algılandığını ve başarılı sonuçlar ürettiğini göstermektedir.

"Anlam Model" sonuçları, %92,84 doğruluk oranına sahiptir. Sınıfların kendi arasında başarı performansları incelenecek olursa en yüksek performans sonuçlarına, "koşullu pozitif" ve "koşullu negatif" sınıfların sahip olduğu görülmektedir. Bu durum, geliştirilen yöntemde monoton olmayan mantık (non-monotonic logic) yaklaşımının sonucunda ortaya çıkan "koşullu-pozitif" ve "koşullu negatif" durumların model tarafından çok iyi algılandığını ve kural tabanlı yaklaşım vektöründe yer alan "Koşul eki (-sa, -se)" vektör temsilinin başarılı sonuçlar ürettiğini göstermektedir.

Temel duygulara ait modellerin sonuçları Tablo 26'da gösterilmektedir.

Tablo 26. Temel duygu modellerine ait sonuçlar.

Parametreler	**Sevinç Model**	**Güven Model**	**Korku Model**	**Şaşkınlık Model**	**Üzüntü Model**	**Tiksinme Model**	**Öfke Model**	**Beklenti Model**
Accuracy	0.9537	0.9788	0.9692	0.9742	0.9586	0.9617	0.9608	0.9639
Precision	0.8773	0.9441	0.8909	0.9250	0.8587	0.9040	0.9403	0.9097
Recall	0.8329	0.9031	0.9295	0.9239	0.8596	0.8886	0.9344	0.9212
F1 Score	0.8525	0.9222	0.9094	0.9240	0.8582	0.8959	0.9372	0.9152
CPU Toplam zaman	05:41 h	06:37 h	03:02 h	02:59 h	05:39 h	05:28 h	05:38 h	05:27 h
Model Boyutu	54.530 KB	54.633 KB	57.553 KB	57.460 KB	54.451 KB	53.844 KB	54.144 KB	54.896 KB

Temel duygu modellerine ait sonuçlar incelendiğinde tüm performans metriklerinin %80'nin üzerinde olduğu; doğruluk oranlarının ise %95'in üzerinde olduğu görülmektedir. En iyi doğruluk oranına sahip model, güven model olmuştur.

Kelime düzeyinde hassasiyet, verimli temsil, dil bağımsızlık, veri boyutu ve hesaplama verimliliği, kelime öbeklerini yakalama, basitlik ve uygulanabilirlik vb. faktörler sebebiyle sondan eklemeli Türkçe dili için karakter düzeyinde UniGram kelime gömme yöntemi kullanılmıştır. Kural tabanlı yaklaşım vektöründe ise kelimelerin dile özgü dil bilgisi özellikleri vektör ile temsil edilmiştir. Geliştirilen yöntemin sonuçları, UniGram kelime vektörü ile kural tabanlı yaklaşım vektörünün duygu analizinde başarılı bir iş birliği yapmış olduklarını göstermektedir.

Bir ön çalışma olarak BERT modelinin belirtilen 8 duygu kategorisini etiketleme konusundaki performansı ölçülmüştür. Bu kapsamda, BERT modelinin, öncelikle özel bir eğitimden geçirilmeden performans sonuçları ölçülmüştür. Bu sonuçlar Tablo 27'de verilmektedir.

Tablo 27. Özel bir eğitimden geçirilmeyen BERT sonuçları.

Model / Performans Metrikleri	Accuracy	Precision	Recall	F1 Score
BERT	0.0159	0.8043	0.0159	0.0076

Tablo 27'deki sonuçlara göre, özellikle -ön eğitim olmadığı durumda- BERT modelinin tüm değerlendirme metriklerinde iyi bir performans gösteremediği görülmektedir.

Ardından, tez çalışması kapsamında oluşturulan modellerin performansları, farklı modeller ile karşılaştırılmıştır. BERT, distilled BERT ve ELECTRA önceden eğitilmiş dil modelleri, 1.000 örnekten oluşan dengeli eğitim veri kümeleri ile eğitilerek ince ayar (fine tuning) yapılmıştır. İnce ayar yapılan önceden eğitimli bu modeller, test veri kümeleri ile test edilmiştir. Duygu-Türk yönteminin sonuçları, ince ayar yapılmış BERT, distilled BERT ve ELECTRA yöntemleri ile karşılaştırılmıştır. Duygu-Türk ve diğer modellerin "biçim model" ve "anlam model" üzerindeki karşılaştırmalı performans sonuçları, Tablo 28'de gösterilmektedir.

Tablo 28. Duygu-Türk ve diğer modellerin performans sonuçları.

	Biçim Model				Anlam Model			
	Duygu Turk	BERT	ELECTRA	Distilled BERT	Duygu Turk	BERT	ELECTRA	Distilled BERT
Accuracy	0.9977	0.9445	0.9652	0.8429	0.9284	0.9198	0.2369	0.7960
Precision	0.9985	0.9692	0.9768	0.9312	0.9374	0.9242	0.3470	0.8012
Recall	0.9989	0.9445	0.9652	0.8429	0.9347	0.9198	0.2369	0.7960
F1 Score	0.9987	0.9520	0.9685	0.8763	0.9360	0.9209	0.1664	0.7969

Duygu-Türk ve diğer modellerin temel duygular üzerindeki karşılaştırmalı performans sonuçları ise Tablo 29 ve Tablo 30'da gösterilmektedir.

Tablo 29. Duygu-Türk ve diğer modellerin performans sonuçları-1.

	Sevinç Model	Güven Model	Korku Model	Şaşkınlık Model

Tablo 29 Devamı

	Duygu Turk	BERT	ELECTRA	Distilled BERT	Duygu Turk	BERT	ELECTRA	Distilled BERT	Duygu Turk	BERT	ELECTRA	Distilled BERT	Duygu Turk	BERT	ELECTRA	Distilled BERT
Accuracy	0.953	0.813	0.055	0.486	0.978	0.816	0.740	0.386	0.969	0.719	0.310	0.536	0.974	0.856	0.851	0.669
Precision	0.877	0.924	0.010	0.902	0.944	0.932	0.924	0.905	0.890	0.906	0.876	0.889	0.925	0.929	0.935	0.892
Recall	0.832	0.813	0.055	0.486	0.903	0.816	0.740	0.386	0.929	0.719	0.310	0.536	0.923	0.856	0.851	0.669
F1 Score	0.852	0.852	0.016	0.592	0.922	0.852	0.796	0.472	0.909	0.769	0.337	0.622	0.924	0.879	0.878	0.734

Tablo 30. Duygu-Türk ve diğer modellerin performans sonuçları-2.

	Üzüntü Model				**Tiksinme Model**				**Öfke Model**				**Beklenti Model**			
	Duygu Turk	BERT	ELECTRA	Distilled BERT	Duygu Turk	BERT	ELECTRA	Distilled BERT	Duygu Turk	BERT	ELECTRA	Distilled BERT	Duygu Turk	BERT	ELECTRA	Distilled BERT
Accuracy	0.958	0.086	0.185	0.100	0.961	0.640	0.216	0.483	0.960	0.838	0.264	0.212	0.963	0.603	0.709	0.659
Precision	0.858	0.848	0.881	0.874	0.904	0.881	0.867	0.863	0.940	0.903	0.817	0.821	0.909	0.887	0.899	0.887
Recall	0.859	0.086	0.185	0.100	0.888	0.640	0.216	0.483	0.934	0.838	0.264	0.212	0.921	0.603	0.709	0.659
F1 Score	0.858	0.100	0.171	0.034	0.895	0.706	0.187	0.562	0.937	0.855	0.177	0.149	0.915	0.668	0.760	0.727

Sekiz temel duygunun sınıflandırılması için yapılan değerlendirmelerde, Duygu-Türk, her kategoride en yüksek puanı almıştır. Bu sonuçlar, modelin duygu analizi görevlerinde etkinliğini açıkça göstermekte ve önerilen yöntemin mevcut modelleri geride bırakan bir performans sunduğunu ortaya koymaktadır.

4.2. Sözlü Metinler için Araştırma Bulguları

Duygu-Türk için oluşturulan ses veri kümesinde 2.567 adet ses kaydı bulunmaktadır. Bu ses kayıtlarının %80'i eğitim için %20'i ise test için kullanılmıştır. Ses duygu modellerine ait sonuçlar, Tablo 31'de gösterilmektedir.

Tablo 31. Ses duygu modellerine ait sonuçlar.

Parametreler	Anlamsal Model	Duygu Model	Yoğunluk Model
Accuracy	0.7302	0.6108	0.7665
Precision	0.7070	0.6047	0.6988
Recall	0.6596	0.6023	0.6395
F1 Score	0.6777	0.6021	0.6678

Elde edilen bulgular incelendiğinde, anlamsal model %73,02, duygu model %61,08, yoğunluk model ise %76,65 doğruluk başarısı göstermiştir. Ses modeli için elde edilen bulguların "2.2. Sözlü Metinler için Önceki Çalışmalar" bölümünde incelenen çalışmalar ile kıyaslandığında tatmin edici düzeye ulaştığı görülmektedir. Precision, recall ve F1-score değerleri de dikkate alındığında, özellikle yoğunluk modelinin genel performans açısından diğer modellerden daha başarılı olduğu görülmektedir. Yoğunluk tabanlı modelin öne çıkması, duyguların ses yoğunluğu ve prosodik özellikler üzerinden daha etkili biçimde yakalanabileceğini göstermektedir. Bununla birlikte, anlamsal model de dengeli sonuçlar üretmiş ve duygu modeline kıyasla daha yüksek doğruluk oranına ulaşmıştır. Bu bulgular, sözlü metinler üzerinde duygu analizi çalışmalarında, MFCC tabanlı öz nitelikler ile temel akustik parametrelerin birlikte kullanılmasının güçlü bir yöntem olduğunu ortaya koymaktadır.

4.3. Yazılı Metinler için Örnek Çalışma

Yazılı metinler için örnek bir çalışmaya ait Duygu-Türk v1.00 uygulamasından bazı ekran görüntüleri aşağıda sunulmaktadır.

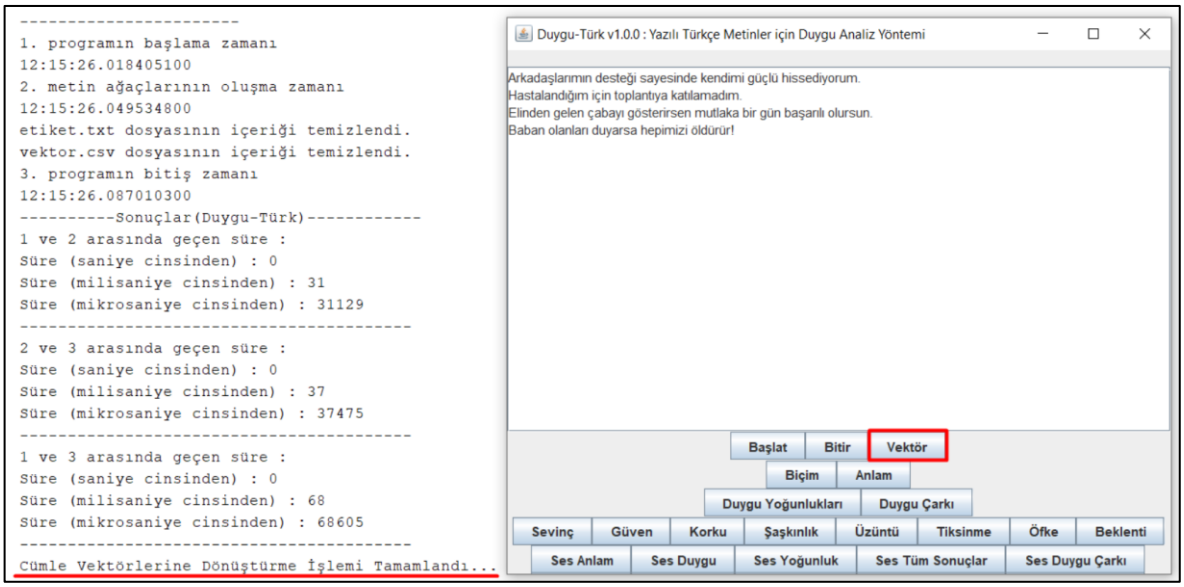

Şekil 13. Kullanıcının girdiği cümlelerin vektöre dönüştürülmesi.

Şekil 13'te görüldüğü gibi kullanıcının girdiği her cümle vektöre dönüştürülmektedir.

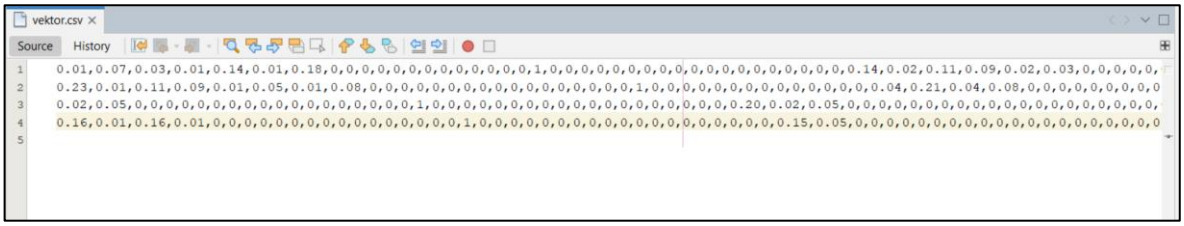
vektor.csv
Source
History
0.01,0.07,0.03,0.01,0.14,0.01,0.18,0,0,0,0,0,0,0,0,0,0,0,0,1,0,0,0,0,0,0,0,0,0,0,0,0

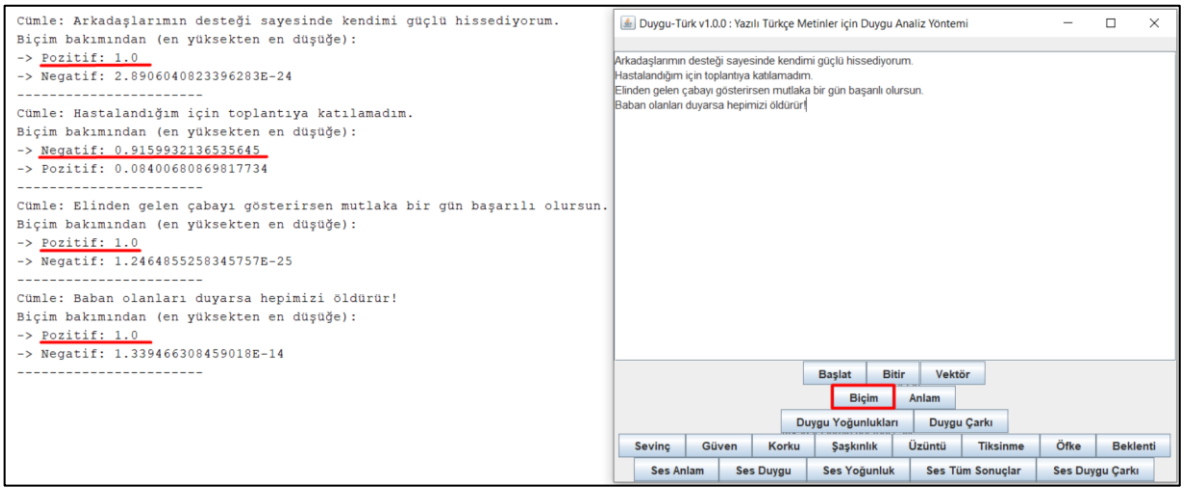

Şekil 15. Biçim model için örnek cümleler ve çıktı dosyası.

Şekil 15'te kullanıcının girdiği cümlelerin biçim modele ait sonuçları çıktı dosyasında gösterilmektedir.

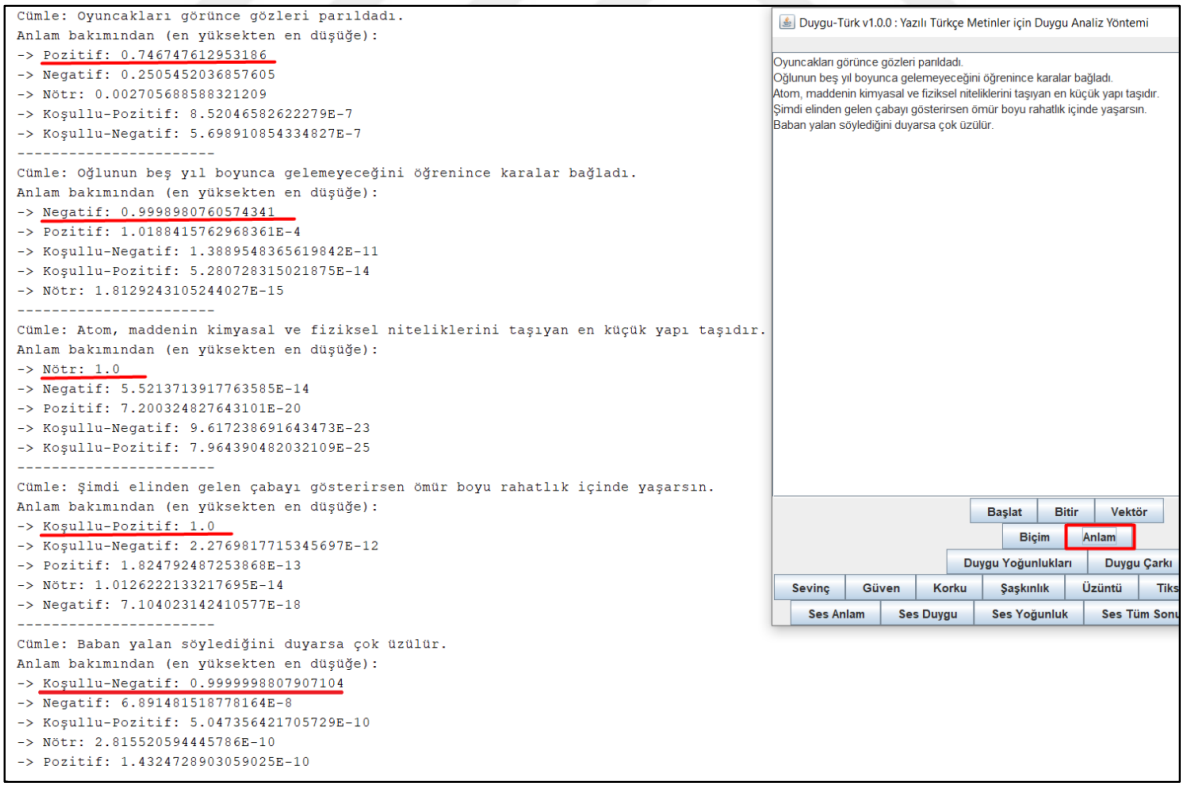

Şekil 16. Anlam model için örnek cümleler ve çıktı dosyası.

Şekil 16'da kullanıcının girdiği cümlelerin anlam modele ait sonuçları çıktı dosyasında gösterilmektedir.

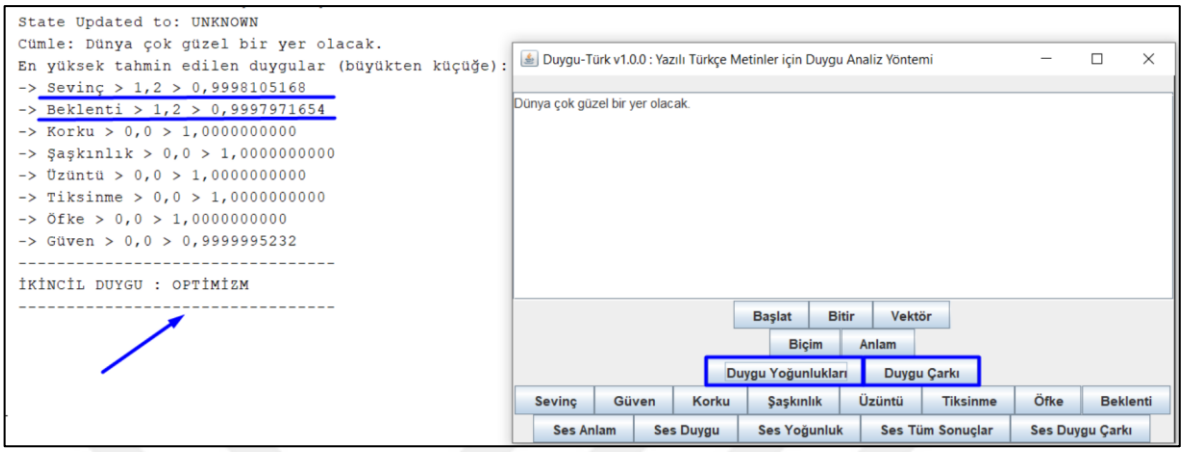

Şekil 17. Duygu model için örnek cümle ve çıktı dosyası.

Şekil 17'de kullanıcının girdiği "*Dünya çok güzel bir yer olacak*" örnek cümlesinin tüm duygu modellerine ait en yüksek olasılıktaki sonuçları, çıktı dosyasında görülmektedir. Örnek cümlenin "sevinç" ve "beklenti" duygularına 1.2 yoğunluk seviyesinde daha yüksek olasılıkla yakın olduğu tespit edilmiştir. Örnek cümle, diğer duygular için "0.0" yoğunluğuna daha yakındır. Sevinç ve beklenti duygularının birleşiminden oluşan ikincil duygu olan "Optimizm" ise çıktı dosyasında belirtilmektedir.

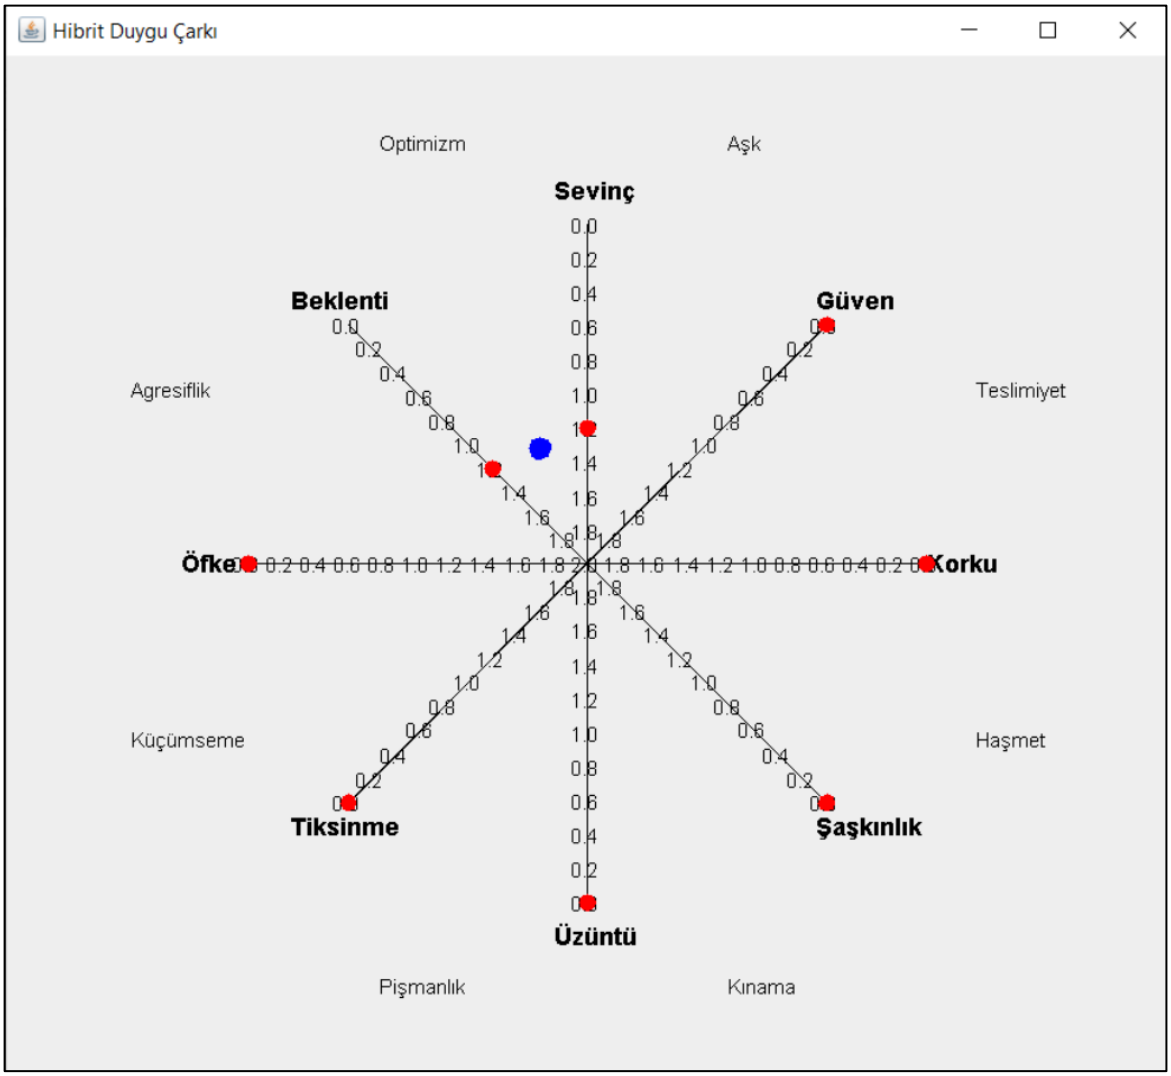

Şekil 18. Duygu model için örnek cümlenin duygu çarkındaki görüntüsü.

Şekil 18'de "*Dünya çok güzel bir yer olacak*" örnek cümlesinin sonuçları, duygu çarkında görselleştirilmektedir. İlgili cümlenin "sevinç" ve "beklenti" duygularına 1.2 yoğunluk seviyesinde daha yüksek olasılıkla yakın olduğu tespit edilmiştir. Her duyguya ait yoğunluk değeri kırmızı renkli bir nokta ile duygu çarkında temsil edilmektedir. Sevinç ve beklenti duygularının birleşiminden oluşan ikincil duygunun ise mavi renkli bir nokta ile duygu çarkında temsil edildiği görülmektedir.

4.4. Hibrit Yaklaşım için Örnek Çalışma

Hibrit yaklaşım için örnek bir çalışmaya ait Duygu-Türk v1.00 uygulamasından bazı ekran görüntüleri aşağıda sunulmaktadır.

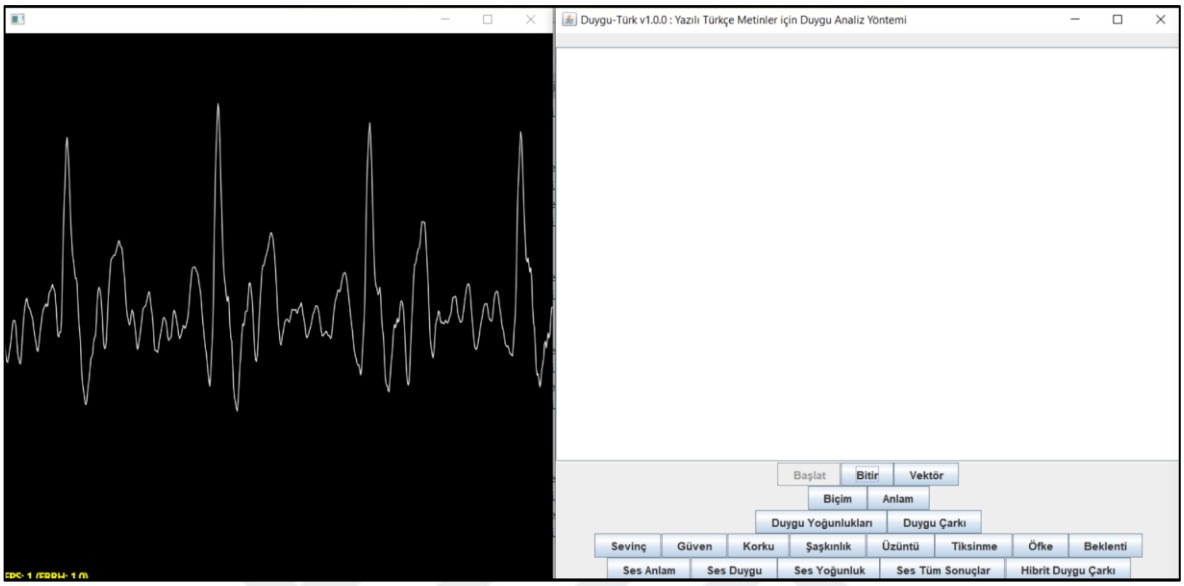

Şekil 19. Hibrit yaklaşım için örnek cümle ve ekran görüntüsü-1.

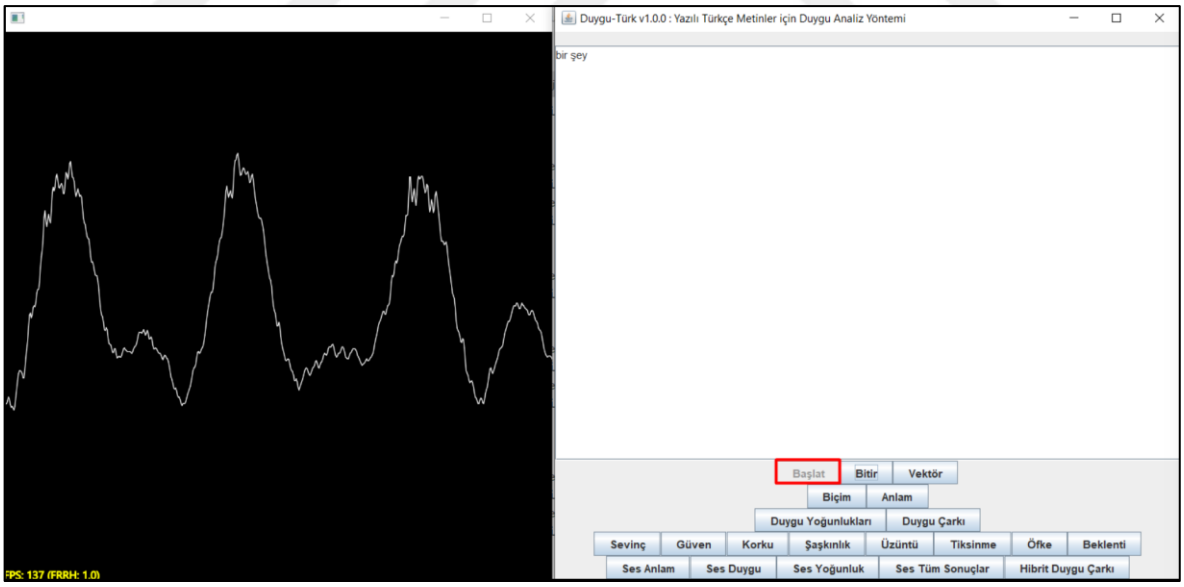

Şekil 20. Hibrit yaklaşım için örnek cümle ve ekran görüntüsü-2.

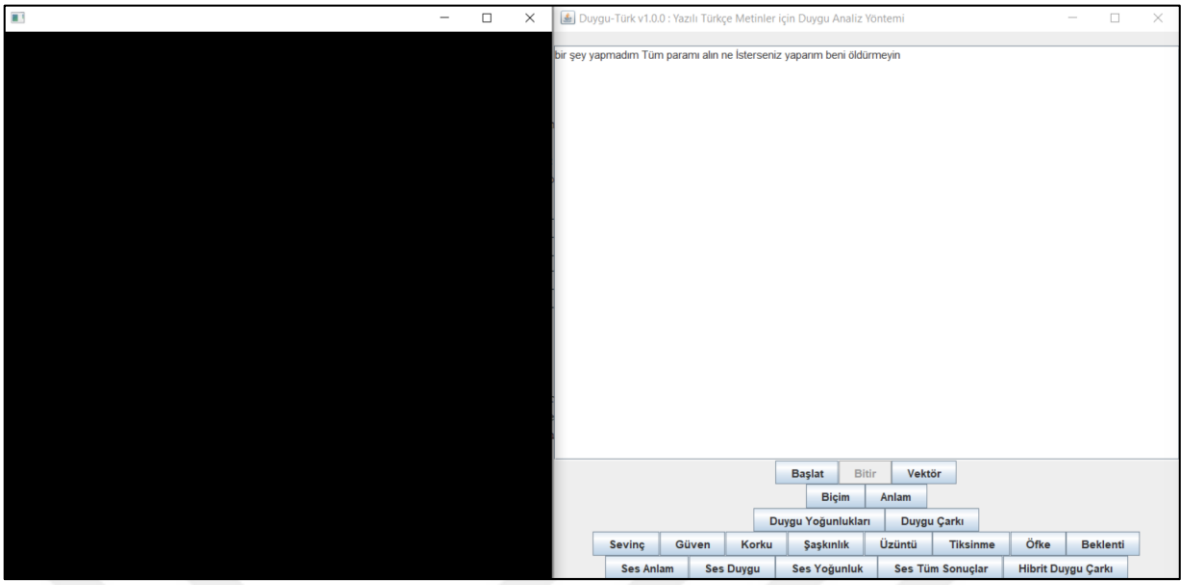

Şekil 21. Hibrit yaklaşım için örnek cümle ve ekran görüntüsü-3.

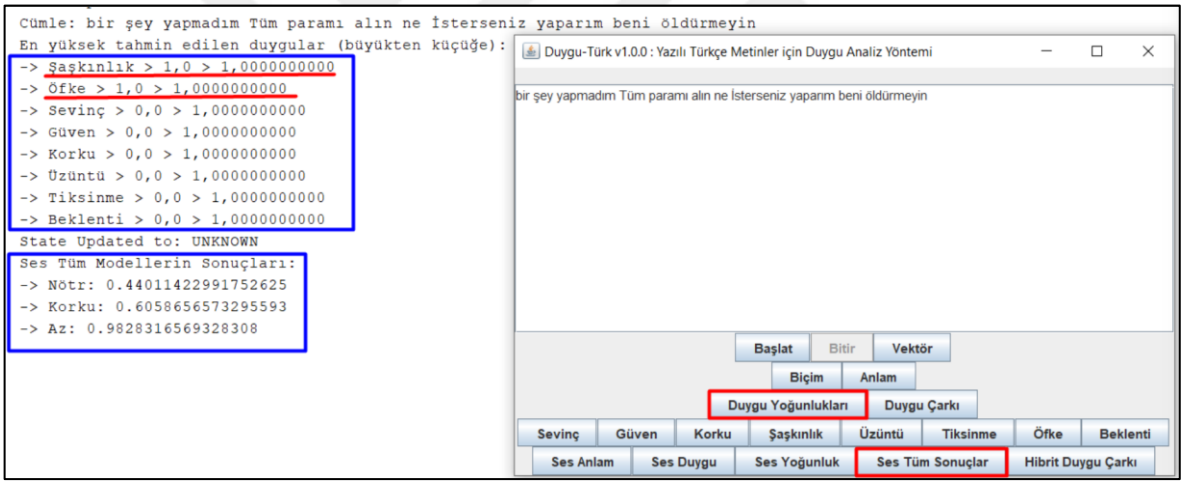

Şekil 22. Hibrit yaklaşım için örnek cümle ve çıktı dosyası.

Şekil 22'de görüldüğü üzere konuşma metninin içeriği "*bir şey yapmadım tüm paramı alın ne isterseniz yaparım beni öldürmeyin*" cümlesidir. İlgili konuşma kaydı Google API aracılığı ile yazılı metne çevrilmiştir. Örnek cümlenin yazılı metin sonucu "şaşkınlık" ve "öfke" duygularına 1.0 yoğunluk seviyesinde daha yüksek olasılıkla yakın olduğu tespit edilmiştir. Örnek cümlenin sözlü metin sonucu ise "nötr", "korku", "az" olarak tespit edilmiştir.

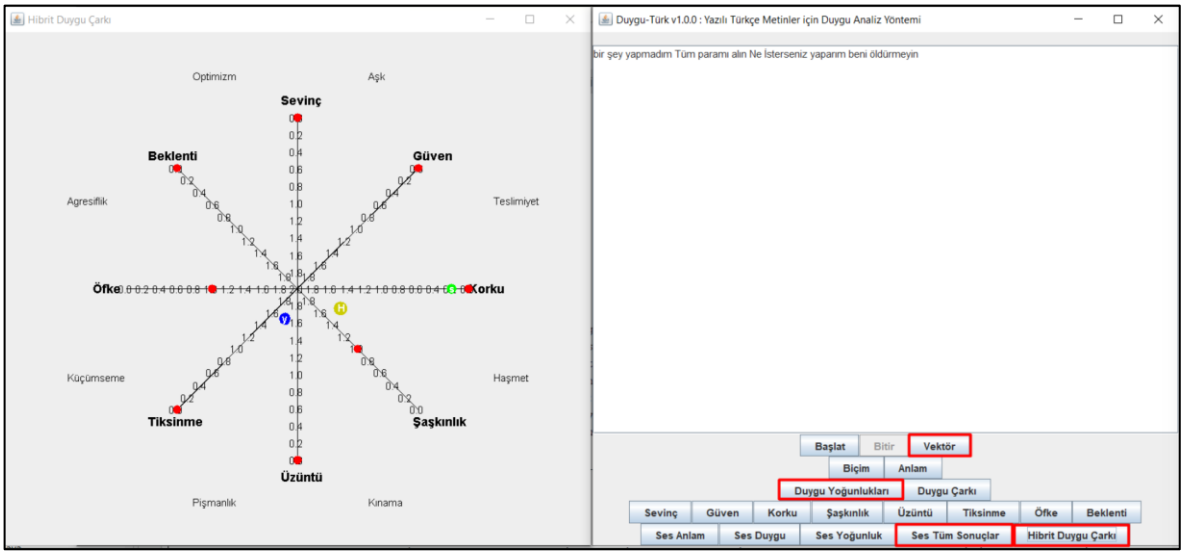

Şekil 23. Hibrit yaklaşım için örnek cümle ve duygu çarkındaki görüntüsü.

Şekil 23'te görüldüğü üzere elde edilen sonuçlar, duygu çarkında görselleştirilmektedir. Yazılı metnin her bir duyguya ait analiz sonucu, kırmızı renkli noktalar ile yazılı metnin ağırlıklı ortalama duygu analiz sonucu, mavi renkli nokta (y) ile sözlü metnin duygu analiz sonucu, yeşil renkli nokta (s) ile her iki sonucun ağırlıklı ortalamalarına göre birleşiminden elde edilen hibrit yaklaşımın sonucu ise duygu çarkı üzerinde sarı renkli nokta (H) ile temsil edilmektedir. Hibrit sonucun duygu çarkında korku ve şaşkınlık duyguları arasında konumlandığı görülmektedir.

BEŞİNCİ BÖLÜM
SONUÇ ve ÖNERİLER

Duygu analizi çalışmaları, bireylerin duygusal durumlarını doğru biçimde tespit ederek insan–bilgisayar etkileşiminden sağlık hizmetlerine, eğitimden müşteri ilişkilerine kadar pek çok alanda önemli katkılar sağlamaktadır. Bu tür çalışmalar, özellikle büyük veri çağında metin, ses ve görsel içeriklerden elde edilen bilgilerin anlamlandırılmasında kritik rol oynamaktadır. Duyguların doğru sınıflandırılması, karar destek sistemlerinin geliştirilmesine, kullanıcı deneyimlerinin iyileştirilmesine ve psikolojik süreçlerin daha iyi anlaşılmasına olanak tanımaktadır. Bu bağlamda, duygu analizi yalnızca teknik bir sınıflandırma görevi değil, aynı zamanda toplumsal, psikolojik ve ekonomik açıdan geniş kapsamlı etkilere sahip stratejik bir araştırma alanıdır.

Tez çalışması kapsamında yazılı ve sözlü metinler için ayrı ayrı duygu analizi çalışmaları yapılmıştır. Bu çalışmaların sonuçları birleştirilerek daha kapsamlı hibrit bir duygu analizi yaklaşımı elde edilmiştir. Bu bölümde sonuçlar, yazılı metinler için, sözlü metinler için ve hibrit yaklaşım için ayrı ayrı değerlendirilmektedir.

5.1. Yazılı Metinler için Sonuç ve Öneriler

Bu çalışmanın birinci bölümünde, Türkçe yazılı metinlerde duygu analizi için geliştirilen Duygu-Türk yöntemi sunularak Türk dilinin kendine özgü dilsel ve kültürel özelliklerini dikkate alan kapsamlı bir yaklaşım ortaya konulmuştur. Duygu-Türk, Plutchik'in Duygu Çarkı'nı temel alarak hem temel hem de ikincil duyguları belirleme yeteneğiyle, sadece yüzeysel bir duygu tespiti yapmaktan öteye geçerek duyguların yoğunluk seviyelerini de analiz edebilmektedir.

"Biçim Model" %99,77 doğruluk oranı ile özellikle "Yoksunluk eki," "Olumsuzluk eki" ve "Olumsuz ifade" temsillerinde yüksek başarı sağlamıştır; bu durum, kural tabanlı yaklaşımın biçim analizinde etkili olduğunu göstermektedir. "Anlam Model" ise %92,84 doğruluk oranına ulaşmış olup, "Koşullu pozitif" ve "Koşullu negatif" sınıflarda en yüksek

performansı elde etmiştir. Bu sonuçlar, monoton olmayan mantık yaklaşımının ve "Koşul eki" temsilinin duygu analizinde başarılı bir şekilde uygulanabildiğini kanıtlamaktadır.

Duygu modellerinden sevinç modeli %95,37, güven modeli %97,88, korku modeli %96,92, şaşkınlık modeli %97,42, üzüntü modeli %95,86, tiksinme modeli %96,17, öfke modeli %96,08 ve beklenti modeli %96,39 doğruluk başarısı göstermiştir. Temel duyguların etkileşimlerinden oluşan ikincil duygular ise kullanıcı arayüzü uygulamasında tespit edilmektedir.

Bu çalışmada, sondan eklemeli Türkçe dilinin yapısal özelliklerini etkin şekilde yakalayabilmek için karakter düzeyinde UniGram kelime gömme yöntemi tercih edilmiştir. Ayrıca, kural tabanlı yaklaşımda kelimelerin Türkçeye özgü dil bilgisi özellikleri vektör ile temsil edilmiştir. Elde edilen sonuçlar, UniGram kelime vektörü ile kural tabanlı yaklaşım vektörünün duygu analizinde başarılı bir iş birliği sunduğunu göstermektedir.

LSTM (Uzun Kısa Süreli Bellek) mimarisi, zaman serisi ve sıralı veri analizinde gösterdiği üstün performans sayesinde duygu analizinde etkili bir araç olduğunu kanıtlamıştır. Bu yinelemeli sinir ağı modeli, özellikle sıralı verilerin işlenmesinde sağladığı başarı ile çalışmamızda öne çıkmış ve başarılı sonuçlar elde edilmesine katkı sağlamıştır.

Elde edilen yüksek doğruluk oranları, yöntemin etkinliğini ortaya koyarken, ince ayar yapılmış BERT ve diğer popüler modellerle karşılaştırıldığında Duygu-Türk'ün düşük bellek tüketimi ile öne çıkması, yöntemin pratik ve maliyet-etkin bir çözüm sunduğunu göstermektedir. Ayrıca, https://github.com/rabia-tintin/turkish-plutchik-emotion-dataset web adresinde paylaşılan 136.000 Türkçe cümle içeren zengin veri kümesi, alana katkı sağlayarak gelecekte yapılacak çalışmalara önemli bir referans kaynağı sunmaktadır.

Sonuç olarak, Duygu-Türk, Türkçe yazılı metinlerde duygu analizi alanında bir boşluğu doldurmakta ve hem akademik hem de pratik uygulamalar için güçlü bir araç olarak öne çıkmaktadır. Bu çalışmanın bulguları, duygu analizi uygulamalarında dilin kültürel ve

yapısal özelliklerinin göz önüne alınması gerektiğini vurgulamakta ve özellikle Türkçe için geliştirilmiş özgün yöntemlerin önemini ortaya koymaktadır.

5.2. Sözlü Metinler için Sonuç ve Öneriler

Bu çalışmanın ikinci bölümünde sözlü metinlerde duygu analizi için geliştirilen Duygu-Türk yöntemi ortaya konulmuştur. Çalışmanın bu bölümünde, 2.567 adet ses kaydından oluşan veri kümesi üzerinde ses tabanlı duygu analizi gerçekleştirilmiştir. Ses kayıtlarından elde edilen akustik öz nitelikler, toplamda 10.000 boyutlu bir vektör yapısına dönüştürülmüştür. Bu vektörün ilk 16 boyutu temel akustik özelliklerden oluşurken, geri kalan 9.984 boyutu ise 768 çerçeveden çıkarılan 13 MFCC katsayısı ile elde edilmiştir.

Ses veri kümesi üzerinde yapılan analizlerde anlamsal model %73, duygu modeli %61 ve yoğunluk Modeli %76 doğruluk oranına ulaşmıştır. Precision, recall ve F1-score değerleri dikkate alındığında, yoğunluk modeli genel performans açısından öne çıkarken, anlamsal model de dengeli sonuçlar vermiştir. Bu bulgular, ses tabanlı duygu analizinde MFCC tabanlı öz nitelikler ile temel akustik parametrelerin etkili bir iş birliği içinde olduğunu göstermektedir.

5.3. Hibrit Yaklaşım için Sonuç ve Öneriler

Bu çalışmada, Duygu-Türk adı verilen yazılı ve sözlü Türkçe metinler için duygu analiz yöntemi geliştirilmiştir. Bu kapsamda yazılı ve sözlü metinler için ayrı ayrı geliştirilen duygu analizi modelleri birleştirilerek hibrit bir yöntem önerilmiştir. Yazılı metinler geliştirilen uygulamada doğrudan işlenebilirken sözlü metinler öncelikle bir API aracılığıyla yazıya çevrilmekte, ardından hem akustik tabanlı öz nitelikler hem de yazılı metin tabanlı öz nitelikler birlikte değerlendirilmektedir. Bu çalışmada Türkçe konuşma metinlerini yazıya çevirmek için Google API kullanılmıştır. Böylece hem metinsel içerikten hem de ses sinyallerinden elde edilen tamamlayıcı bilgiler tek bir model altında birleştirilmiştir. Duygu-Türk uygulaması akış şeması, “EKLER” kısmında yer alan Şekil 24’te gösterilmektedir.

Sonuç olarak, hibrit yöntem, sözlü ve yazılı verilerin güçlü yönlerini bir araya getirerek duyguların daha kapsamlı bir biçimde yakalanmasına katkı sunmakta olup çoklu veri kaynaklarına dayalı yeni nesil duygu analizi yaklaşımlarına örnek teşkil etmektedir.

KAYNAKÇA

Abdelhamid, A. A., El-Kenawy, E.-S. M., Alotaibi, B., Amer, G. M., Abdelkader, M. Y., İbrahim, A., ve Eid, M. M. (2022). Robust speech emotion recognition using CNN+ LSTM based on stochastic fractal search optimization algorithm. Ieee Access, 10, 49265-49284.

Acikalin, U. U., Bardak, B., ve Kutlu, M. (2020). BERT Modeli ile Türkçe Duygu Analizi, Turkish Sentiment Analysis Using BERT. *In 2020 28th Signal Processing and Communications Applications Conference (SIU)*. IEEE., 1-4.

Aftab, A., Morsali, A., Ghaemmaghami, S., ve Champagne, B. (2022). Light-sernet: A lightweight fully convolutional neural network for speech emotion recognition. *In ICASSP 2022-2022 IEEE international conference on acoustics, speech and signal processing (ICASSP)*, IEEE, 6912-6916.

Agarla, M., Bianco, S., Celona, L., Napoletano, P., Petrovsky, A., Piccoli, F., Schettini, R., ve Shanin, I. (2024). Semi-supervised cross-lingual speech emotion recognition. Expert Systems with Applications, Elsevier, 237, 121368.

Aggarwal, A., Srivastava, A., Agarwal, A., Chahal, N., Singh, D., Alnuaim, A. A., Alhadlaq, A., ve Lee, H.-N. (2022). Two-way feature extraction for speech emotion recognition using deep learning. Sensors, 22(6), 2378.

Ahmed, Md. R., Islam, S., Islam, A. K. M. M., ve Shatabda, S. (2023). An ensemble 1D-CNN-LSTM-GRU model with data augmentation for speech emotion recognition. Expert Systems with Applications, Elsevier, 218, 119633.

Ahn, C.-S., Rana, R., Busso, C., ve Rajapakse, J. C. (2025). Multitask Transformer for Cross-Corpus Speech Emotion Recognition. IEEE Transactions on Affective Computing, 14(8), 1-12.

Akçataş, A., ve Varol, Ç. (2021). Türkiye Türkçesinde İsimden İsim Yapan Eklerin Morfo-Semantik İşlevleri. Kesit Akademi Dergisi, 26(26), 410-427.

Alawi, A. B., ve Bozkurt, F. (2024). Performance Analysis of embedding methods for deep learning-based Turkish sentiment analysis models. Arabian Journal for Science and Engineering, 50, 7299-7321.

Alhussein, G., Alkhodari, M., Khandoker, A. H., ve Hadjileontiadis, L. J. (2025). Novel speech-based emotion climate recognition in peers' conversations incorporating affect dynamics and temporal convolutional neural networks. IEEE Access, 13, 16752-16769.

Alkan, B. B., Karakus, L., ve Direkci, B. (2023). Generating a sentiment dictionary in R and dictionary-based sentiment analysis in Turkish texts. Digital Scholarship in the Humanities, 38(2), 461-476.

Alluhaidan, A. S., Saidani, O., Jahangir, R., Nauman, M. A., ve Neffati, O. S. (2023). Speech emotion recognition through hybrid features and convolutional neural network. Applied Sciences, 13(8), 4750.

Alonso, M. A., Vilares, D., Gómez-Rodríguez, C., ve Vilares, J. (2021). Sentiment Analysis for Fake News Detection. Electronics, 10(11), 1348.

Ancilin, J., ve Milton, A. (2021). Improved speech emotion recognition with Mel frequency magnitude coefficient. Applied Acoustics, Elsevier, 179, 108046.

Anvarjon, T., Mustaqeem, ve Kwon, S. (2020). Deep-net: A lightweight CNN-based speech emotion recognition system using deep frequency features. Sensors, 20(18), 5212.

Aslan, S. (2023). Doğal Dil İşleme Teknikleri Kullanarak E-Ticaret Kullanıcı İncelemelerinde Özellik Tabanlı Duygu Analizi. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 35(2), 875-882.

Atmaja, B. T., ve Akagi, M. (2020). The effect of silence feature in dimensional speech emotion recognition. arXiv preprint arXiv:2003.01277.

Aydın, C. R., ve Güngör, T. (2021). Sentiment analysis in Turkish: Supervised, semi-supervised, and unsupervised techniques. Natural Language Engineering, 27(4), 455-483.

Bäck, T., ve Schwefel, H.-P. (1993). An overview of evolutionary algorithms for parameter optimization. Evolutionary computation, 1(1), 1-23. https://ieeexplore.ieee.org/abstract/document/6791438/

Balli, C., Guzel, M. S., Bostanci, E., ve Mishra, A. (2022). Sentimental Analysis of Twitter Users from Turkish Content with Natural Language Processing. Computational Intelligence and Neuroscience, 2022.

Benzer, A. (2010). -sA Ekinin İşlevleri ve Dilek-Şart Ayrımı. Selçuk Üniversitesi Türkiyat Araştırmaları Dergisi, 28, 131-140.

Bhangale, K., ve Kothandaraman, M. (2023). Speech emotion recognition based on multiple acoustic features and deep convolutional neural network. Electronics, 12(4), 839.

Bilgin, M., ve Şentürk, İ. F. (2019). Danışmanlı ve yarı danışmanlı öğrenme kullanarak doküman vektörleri tabanlı tweetlerin duygu analizi. Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 21(2), 822-839.

Boratav, H. B., Sunar, D., ve Ataca, B. (2011). Duyguları sergileme kuralları ve bağlamsal belirleyicileri: Türkiye'de üniversite öğrencileri ile yapılan bir araştırma. Türk Psikoloji Dergisi, 26(68), 90-101.

Bozuyla, M. (2023). Sentiment Analysis of Turkish Drug Reviews with Bidirectional Encoder Representations from Transformers. ACM Transactions on Asian and Low-Resource Language Information Processing.

Bridle, J. S. (1989). Training stochastic model recognition algorithms as networks can lead to maximum mutual information estimation of parameters. Advances in Neural Information Processing Systems, 2, 211-217.

Bridle, J. S. (1990). Probabilistic Interpretation of Feedforward Classification Network Outputs, with Relationships to Statistical Pattern Recognition. In Neurocomputing: Algorithms, architectures and applications. Berlin, Heidelberg: Springer Berlin Heidelberg., 227-236.

Bulak, Ş. (2011). "-sA" EKİNİN İŞLEVLERİ. Atatürk Üniversitesi Türkiyat Araştırmaları Enstitüsü Dergisi [TAED], 46, 25-38.

Chen, L., Su, W., Feng, Y., Wu, M., She, J., ve Hirota, K. (2020). Two-layer fuzzy multiple random forest for speech emotion recognition in human-robot interaction. Information Sciences, Elsevier, 509, 150-163.

Chen, L.-W., ve Rudnicky, A. (2023). Exploring wav2vec 2.0 fine tuning for improved speech emotion recognition. *In ICASSP 2023-2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, 1-5.

Chen, W., Xing, X., Chen, P., ve Xu, X. (2024). Vesper: A compact and effective pretrained model for speech emotion recognition. IEEE Transactions on Affective Computing, 15(3), 1711-1724.

Chen, W., Xing, X., Xu, X., Yang, J., ve Pang, J. (2022). Key-sparse transformer for multimodal speech emotion recognition. *In ICASSP 2022-2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, 6897-6901.

Christopher Olah. (2015). Understanding LSTM Networks. https://colah.github.io/posts/2015-08-Understanding-LSTMs/.

Ciftci, B., ve Apaydin, M. S. (2018). A Deep Learning Approach to Sentiment Analysis in Turkish. *In 2018 International Conference on Artificial Intelligence and Data Processing (IDAP)*, IEEE, 1-5.

Colón-Ruiz, C., ve Segura-Bedmar, I. (2020). Comparing deep learning architectures for sentiment analysis on drug reviews. Journal of Biomedical Informatics, 110.

Dalkılıç, G., ve Çebi, Y. (2003). Türkçe Külliyat Oluşturulması ve Türkçe Metinlerde Kullanılan Kelimelerin Uzunluk Dağılımlarının Belirlenmesi. Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi, 5(1), 1-7.

Davis, S. B., ve Mermelstein, P. (1980). Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences. IEEE transactions on acoustics, speech, and signal processing, 28(4), 357-366.

Demir, Ö., Baban Chawai, A. I., ve Doğan, B. (2019). Türkçe Metinlerde Sözlük Tabanlı Yaklaşımla Duygu Analizi. International Periodical of Recent Technologies in Applied Engineering, 1(2), 58-66.

Demirci, G. M., Keskin, Ş. R., ve Doğan, G. (2019). Sentiment Analysis in Turkish with Deep Learning. *In 2019 IEEE international conference on big data (big data)*, IEEE, 2215-2221.

Demirtas, E., ve Pechenizkiy, M. (2013). Cross-Lingual Polarity Detection with Machine Translation. In Proceedings of the Second International Workshop on Issues of Sentiment Discovery and Opinion Mining, 1-8.

Desai, R. D. (2018). Sentiment analysis of Twitter data. *In 2018 Second International Conference on Intelligent Computing and Control Systems (ICICCS)*, IEEE, 114-117.

Donuk, K., ve Hanbay, D. (2022). Konuşma Duygu Tanıma için Akustik Özelliklere Dayalı LSTM Tabanlı Bir Yaklaşım. Computer Science, 7(2), 54-67.

Elsken, T., Metzen, J. H., ve Hutter, F. (2019). Neural architecture search: A survey. Journal of Machine Learning Research, 20(55), 1-21. http://www.jmlr.org/papers/v20/18-598.html

Erşahin, B., Aktaş, Ö., Kılınç, D., ve Erşahin, M. (2019). A hybrid sentiment analysis method for Turkish. Turkish Journal of Electrical Engineering and Computer Sciences, 27(3), 1780-1793.

Feng, T., ve Narayanan, S. (2024). Foundation model assisted automatic speech emotion recognition: Transcribing, annotating, and augmenting. *In ICASSP 2024-2024 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, 12116-12120.

Fleiss, J. L. (1971). Measuring Nominal Scale Agreement Among many Raters. Psychological bulletin, 76(5), 378.

Gerhard, D. (2003). Pitch extraction and fundamental frequency: History and current techniques. https://www.cs.bu.edu/fac/snyder/cs583/Literature%20and%20Resources/PitchExtractionMastersThesis.pdf

Guven, Z. A. (2021). Comparison of BERT Models and Machine Learning Methods for Sentiment Analysis on Turkish Tweets. *In 2021 6th International Conference on Computer Science and Engineering (UBMK)*, IEEE, 98-101.

Gündüz, H. (2023). Derin Transformatörlerden Çift Yönlü Kodlayıcı Temsilleri ve Destek Vektör Makineleri ile Türkçe Film Yorumları Üzerine Duygu Analizi, Sentiment Analysis on Turkish Movie Reviews with Deep Bidirectional Encoder

Representations from Transformers (Bert) And Support Vector Machines. KSÜ Mühendislik Bilimleri Dergisi, 26(2), 542-549.

Güneş, F., ve Işık, A. D. (2018). Türkçede Sık Kullanılan Harfler ve Öğretilmesi. The Journal of Limitless Education and Research, 3(1), 1-26.

Hochreiter, S., ve Schmidhuber, J. (1997). Long Short-Term Memory. Neural Computation, 9(8), 1735-1780.

Issa, D., Demirci, M. F., ve Yazici, A. (2020). Speech emotion recognition with deep convolutional neural networks. Biomedical Signal Processing and Control, Elsevier, 59, 101894.

Jain, A., ve Ahamed, S. (2019). Feature Extraction Methods for Signal Analysis: AComprehensive Review. Journal of Emerging Technologies and Innovative Research, 6(1), 210-214.

Jain, M., Narayan, S., Balaji, P., P, B. K., Bhowmick, A., R, K., ve Kumar Muthu, R. (2020). Speech emotion recognition using support vector machine. arxiv.org. https://arxiv.org/abs/2002.07590

Karagoz, P., Kama, B., Ozturk, M., Toroslu, I. H., ve Canturk, D. (2019). A framework for aspect based sentiment analysis on turkish informal texts. Journal of Intelligent Information Systems, 53(3), 431-451.

Karamollaoğlu, H., Doğru, İ. A., Dörterler, M., Utku, A., ve Yıldız, O. (2018). Sentiment analysis on Turkish social media shares through lexicon based approach. *2018 3rd International Conference on Computer Science and Engineering (UBMK)*, IEEE., 45-49.

Karasulu, B., Avcı, E., Strazimiri, T., ve Cengiz, B. (2024). Arnavutça Konuşma Verilerini Kullanan Derin Öğrenme Tabanlı Duygu Durum Analizi ve Sınıflandırma. Veri Bilimi, 7(2), 30-40.

Karşılayan, S. (2022). Ak Başat Türkçe A1-A2 Kitabındaki Metinlerin Okunabilirlik Sayısı ve Metinlerdeki Ses Birimlerin Okumaya Etkisi.

Khan, M., Gueaieb, W., El Saddik, A., ve Kwon, S. (2024). MSER: Multimodal speech emotion recognition using cross-attention with deep fusion. Expert Systems with Applications, Elsevier, 245, 122946.

Kim, Y. (2014). Convolutional Neural Networks for Sentence Classification. *EMNLP 2014 - 2014 Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference*, 1746-1751.

Kim, Y., Jernite, Y., Sontag, D., ve Rush, A. M. (2016). Character-Aware Neural Language Models. *In Proceedings of the AAAI conference on artificial intelligence*, 30(1).

King, G., ve Zeng, L. (2001). Logistic regression in rare events data. Political analysis, 9(2), 137-163.

Koduru, A., Valiveti, H. B., ve Budati, A. K. (2020). Feature extraction algorithms to improve the speech emotion recognition rate. International Journal of Speech Technology, 23(1), 45-55.

Kubicek, B., Sen Gupta, A., ve Kirsteins, I. (2023). Feature Extraction and Classification of Simulated Monostatic Acoustic Echoes from Spherical Targets of Various Materials Using Convolutional Neural Networks, Journal of Marine Science and Engineering, 11(3), 571.

Kumar, S., Haq, M., Jain, A., Jason, C. A., Moparthi, N. R., Mittal, N., ve Alzamil, Z. S. (2023). Multilayer Neural Network Based Speech Emotion Recognition for Smart Assistance. Computers, Materials ve Continua, 74(1), 1523-1540.

Li, D., Liu, J., Yang, Z., Sun, L., ve Wang, Z. (2021). Speech emotion recognition using recurrent neural networks with directional self-attention. Expert Systems with Applications, Elsevier, 173, 114683.

Li, Y., Bell, P., ve Lai, C. (2022). Fusing ASR outputs in joint training for speech emotion recognition. *In ICASSP 2022-2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, 7362-7366.

Liu, M., Raj, A. N. J., Rajangam, V., Ma, K., Zhuang, Z., ve Zhuang, S. (2024). Multiscale-multichannel feature extraction and classification through one-dimensional convolutional neural network for Speech emotion recognition. Speech Communication, Elsevier, 156, 103010.

Livingstone, S. R., ve Russo, F. A. (2018). The ryerson audio-visual database of emotional speech and song (ravdess): A dynamic, multimodal set of facial and vocal expressions in north American english. PLoS ONE, 13(5), 1-35.

Lu, J., Yang, J., Batra, D., ve Parikh, D. (2016). Hierarchical question-image co-attention for visual question answering. Advances in neural information processing systems.

Morais, E., Hoory, R., Zhu, W., Gat, I., Damasceno, M., ve Aronowitz, H. (2022). Speech emotion recognition using self-supervised features. *In ICASSP 2022-2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, 6922-6926.

Mozilla. (2021). Common Voice. https://commonvoice.mozilla.org/tr/about.

Mustaqeem, ve Kwon, S. (2021). MLT-DNet: Speech emotion recognition using 1D dilated CNN based on multi-learning trick approach. Expert Systems with Applications, Elsevier, 167, 114177.

Mustaqeem, Sajjad, M., ve Kwon, S. (2020). Clustering-based speech emotion recognition by incorporating learned features and deep BiLSTM. IEEE access, 8, 79861-79875.

Onan, A. (2021). Ensemble of Classifiers and Term Weighting Schemes for Sentiment Analysis in Turkish. Scientific Research Communications, 1(1), 1-12.

Önder, O., Zhalehpour, S., ve Erdem Eroğlu, Ç. (2013). A Turkish Audio-Visual Emotional Database. 2013 21st Signal Processing and Communications Applications Conference (SIU), IEEE, 1-4.

Öztürk, N., ve Ayvaz, S. (2018). Sentiment analysis on Twitter: A text mining approach to the Syrian refugee crisis. Telematics and Informatics, 35(1), 136-147.

Parlak, C. (2024). Konuşma Duygu Tanıma Uygulamalarında Hiper Parametre Optimizasyonu ile Derin Öğrenme Metotlarının Geliştirilmesi. Karadeniz Fen Bilimleri Dergisi, 14(4), 1955-1975.

Pichora-Fuller, M. K., ve Dupuis, K. (2020). Toronto emotional speech set (TESS).

Plutchik, R. (1982). A psychoevolutionary theory of emotions. Social Science Information, 21(4-5), 529-553.

Plutchik, R. (t.y.). Duygu Çarkı Modeli. https://www.6seconds.org/2025/02/06/plutchik-wheel-emotions/.

Polat, H., ve Ağca, Y. (2022). Tripadvisor Kullanıcılarının Türkçe ve İngilizce Yorumları Kapsamında Duygu Analizi Yöntemlerinin Karşılaştırmalı Analizi. Abant Sosyal Bilimler Dergisi, 22(2), 901-916.

Punith, N. S., ve Raketla, K. (2021). Sentiment Analysis of Drug Reviews using Transfer Learning. *Proceedings of the 3rd International Conference on Inventive Research in Computing Applications*, ICIRCA 2021, 1794-1799.

Raffel, C. (2016). Learning-based Methods for Comparing Sequences, with Applications to Audio-to-midi Alignment and Matching, Columbia University.

Reiter, R. (1980). A Logic for Default Reasoning. Artificial intelligence, 13(1-2), 81-132.

Rumelli, M., Akkuş, D., Kart, Ö., ve Isik, Z. (2019). Türkçe Metinlerde Makine Öğrenmesi Algoritmaları ile Duygu Analizi, Sentiment Analysis in Turkish Text with Machine Learning Algorithms. *In 2019 Innovations in Intelligent Systems and Applications Conference (ASYU)*, IEEE, 1-5.

Saffran, J. R., Aslin, R. N., ve Newport, E. L. (1996). Statistical Learning by 8-Month-Old Infants. Science, 274(5294), 1926-1928.

Sağbaş, E. A. (2023). Filtre Tabanlı Öznitelik Seçim Yöntemleri Kullanılarak Metinlerde Duygu Sınıflandırması Üzerine Karşılaştırmalı Bir Çalışma. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 35(1), 239-250.

Sağlam, F. (2019). Otomatik Duygu Sözlüğü Geliştirilmesi ve Haberlerin Duygu Analizi [Doktora Tezi]. Hacettepe Üniversitesi Fen Bilimleri Enstitüsü.

Salur, M. U., ve Aydın, İ. (2018). Sentiment classification based on deep learning. *In 2018 26th Signal Processing and Communications Applications Conference (SIU)*, IEEE, 1-4.

Sari, I. P., Fadlil, A., ve Sutikno, T. (2025). Islamic Sound Recognition Using MFCC and SVM: Case Study on Takbir and Sholawat. Journal of Computer Networks, Architecture and High Performance Computing, 7(3), 825-839.

Savci, P., ve Das, B. (2023). Prediction of the customers' interests using sentiment analysis in e-commerce data for comparison of Arabic, English, and Turkish languages. Journal of King Saud University - Computer and Information Sciences, 35(3), 227-237.

Shehu, H. A., ve Tokat, S. (2020). A Hybrid Approach for the Sentiment Analysis of Turkish Twitter Data. *In Artificial Intelligence and Applied Mathematics in Engineering Problems: Proceedings of the International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAIAME 2019)*. Springer International Publishing, 182-190.

Shehu, H., Sharif, M., Sharif, M., Datta, R., Tokat, S., Uyaver, Ş., Kusetogulları, H., ve Ramadan, R. (2021). Deep sentiment analysis: a case study on stemmed Turkish twitter data. IEEE Access, 56836-56854.

Shixin, P., Kai, C., Tian, T., ve Jingying, C. (2024). An autoencoder-based feature level fusion for speech emotion recognition. Digital Communications and Networks, Elsevier, 10(5), 1341-1351.

Sim, J., ve Wright, C. C. (2005). The Kappa Statistic in Reliability Studies: Use, Interpretation, and Sample Size Requirements. Physical therapy, 85(3), 257-268.

Şahinaslan, Ö., Dalyan, H., ve Şahinaslan, E. (2022). Naive Bayes Sınıflandırıcısı Kullanılarak YouTube Verileri Üzerinden Çok Dilli Duygu Analizi. Bilişim Teknolojileri Dergisi, 15(2), 221-229.

Şaş, A. K. (2023). Türkiye Türkçesinde Deyimleşmiş Birleşik Duygu Fiilleri. Korkut Ata Türkiyat Araştırmaları Dergisi, 10, 602-631.

Tan, L., Yu, K., Lin, L., Cheng, X., Srivastava, G., Lin, J. C.-W., ve Wei, W. (2021). Speech emotion recognition enhanced traffic efficiency solution for autonomous vehicles in a 5G-enabled space–air–ground integrated intelligent transportation. IEEE Transactions on Intelligent Transportation Systems, 23(3), 2830-2842.

Tepecik, A., ve Demir, E. (2024a). Emotion Detection with Pre-Trained Language Models BERT and ELECTRA Analysis of Turkish Data. Intelligent Methods In Engineering Sciences, 3(1), 7-12.

Tepecik, A., ve Demir, E. (2024b). Üç duygu ile etiketlenmiş Türkçe ses kayıt verilerinin makine öğrenim algoritmalarıyla analizi. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 39(2), 709-716.

Toçoğlu, M. A., Çelikten, A., Aygün, İ., ve Alpkoçak, A. (2019). Türkçe Metinlerde Duygu Analizi İçin Farklı Makine Öğrenmesi Yöntemlerinin Karşılaştırılması. Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi, 21(63), 719-725.

Tohma, K., Okur, H. I., Kutlu, Y., ve Sertbas, A. (2023). Sentiment Analysis in Turkish Question Answering Systems: An Application of Human-Robot Interaction. IEEE Access, 11, 66522-66534.

Tuzcu, S. (2020). Çevrimiçi Kullanıcı Yorumlarının Duygu Analizi ile Sınıflandırılması.

Türk Dil Kurumu. (t.y.). Türk Dil Kurumu Sözlükleri. https://sozluk.gov.tr/

Türk Dil Kurumu. (2019). Noktalama İşaretleri (Açıklamalar). https://tdk.gov.tr/icerik/yazim-kurallari/noktalama-isaretleri-aciklamalar/.

Uca, E., Yılmazer, S., Kızılhan, H., ve Karaköse, M. (2022). Sağlık Alanındaki Etkileşimlerde Duygu Analizi Yaklaşımları ve Analizi, Sentiment Analysis Approaches and Analysis in Health Interactions.

Uyaroğlu Akdeniz, F. N., ve Cebeci, H. İ. (2021). Belediye Hizmetlerin Değerlendirilmesinde Duygu Analizi Yaklaşımı: Sakarya İli Örneği. Zeki Sistemler Teori ve Uygulamaları Dergisi, 4(2), 127-135.

Uzman, M. (1992). Türkçede şart ve emir kipinin tarih içindeki gelişimi. Master's thesis, Sosyal Bilimler Enstitüsü.

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., ve Polosukhin, I. (2017). Attention is all you need. Advances in neural information processing systems, 30.

Vural, A. G., Cambazoglu, B. B., Senkul, P., ve Tokgoz, Z. O. (2013). A Framework for Sentiment Analysis in Turkish: Application to Polarity Detection of Movie Reviews in Turkish. *In Computer and Information Sciences III: 27th International Symposium on Computer and Information Sciences*, Springer London, 437-445.

Wagner, J., Triantafyllopoulos, A., Wierstorf, H., Schmitt, M., Burkhardt, F., Eyben, F., ve Schuller, B. W. (2023). Dawn of the transformer era in speech emotion recognition: closing the valence gap. IEEE Transactions on Pattern Analysis and Machine Intelligence, 45(9), 10745-10759.

Wang, J., Xue, M., Culhane, R., Diao, E., Ding, J., ve Tarokh, V. (2020). Speech emotion recognition with dual-sequence LSTM architecture. *In ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, 6474-6478.

Wang, Y., Boumadane, A., ve Heba, A. (2021). A Fine-tuned Wav2vec 2.0/HuBERT Benchmark For Speech Emotion Recognition, Speaker Verification and Spoken Language Understanding. arXiv preprint arXiv:2111.02735.

Wankhade, M., Rao, A. C. S., ve Kulkarni, C. (2022). A Survey on Sentiment Analysis Methods, Applications, and Challenges. Artificial Intelligence Review, 55(7), 5731-5780.

Yalman, H. İ., ve Tüfekci, Z. (2022). Konuşma Tanımaya Uygulanan BiRNN, BiLSTM ve BiGRU Modellerinin Performans Değerlendirmesi. Avrupa Bilim ve Teknoloji Dergisi, 36(36), 121-127.

Ye, J., Wen, X., Wei, Y., Xu, Y., Liu, K., ve Shan, H. (2023). Temporal modeling matters: A novel temporal emotional modeling approach for speech emotion recognition. *In ICASSP 2023-2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, 1-5.

Yıldırım, M. (2022). MFCC Yöntemi ve önerilen derin model ile çevresel Seslerin Otomatik olarak sınıflandırılması. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 34(1), 449-457.

Yıldırım, S., Salman, Y. B., ve Ayvaz, S. (2019). Türkçe Duygu Kütüphanesi Geliştirme: Sosyal Medya Verileriyle Duygu Analizi Çalışması. European Journal of Science and Technology, 16, 51-60.

Young, S. R., Rose, D. C., Karnowski, T. P., Lim, S.-H., ve Patton, R. M. (2015). Optimizing deep learning hyper-parameters through an evolutionary algorithm. In Proceedings

of the workshop on machine learning in high-performance computing environments, 1-5.

Yurtalan, G., Koyuncu, M., ve Turhan, Ç. (2019). A polarity calculation approach for lexicon-based Turkish sentiment analysis. Turkish Journal of Electrical Engineering and Computer Sciences, 27(2), 1325-1339.

Yusufoğlu, H., Aydin, H., ve Çetinkaya, A. (2021). Twitter Üzerindeki Finansal Tweetlerin LSTM Sinir Ağı Algoritması ile Duygu Analizi. Veri Bilimi Dergisi, 4(3), 28-43.

Yücebaş, S. C., ve Tintin, R. (2017). Gövde-Türk: Bir Türkçe Gövdeleme Yöntemi, Gövde-Türk: A Turkish Stemming Method. *In 2017 International Conference on Computer Science and Engineering (UBMK),* IEEE., 343-347.

Zehra, W., Javed, A. R., Jalil, Z., Khan, H. U., ve Gadekallu, T. R. (2021). Cross corpus multi-lingual speech emotion recognition using ensemble learning. Complex ve Intelligent Systems, Springer, 7(4), 1845-1854.

Zou, H., Si, Y., Chen, C., Rajan, D., ve Chng, E. S. (2022). Speech emotion recognition with co-attention based multi-level acoustic information. *In ICASSP 2022-2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, 7367-7371.

EKLER

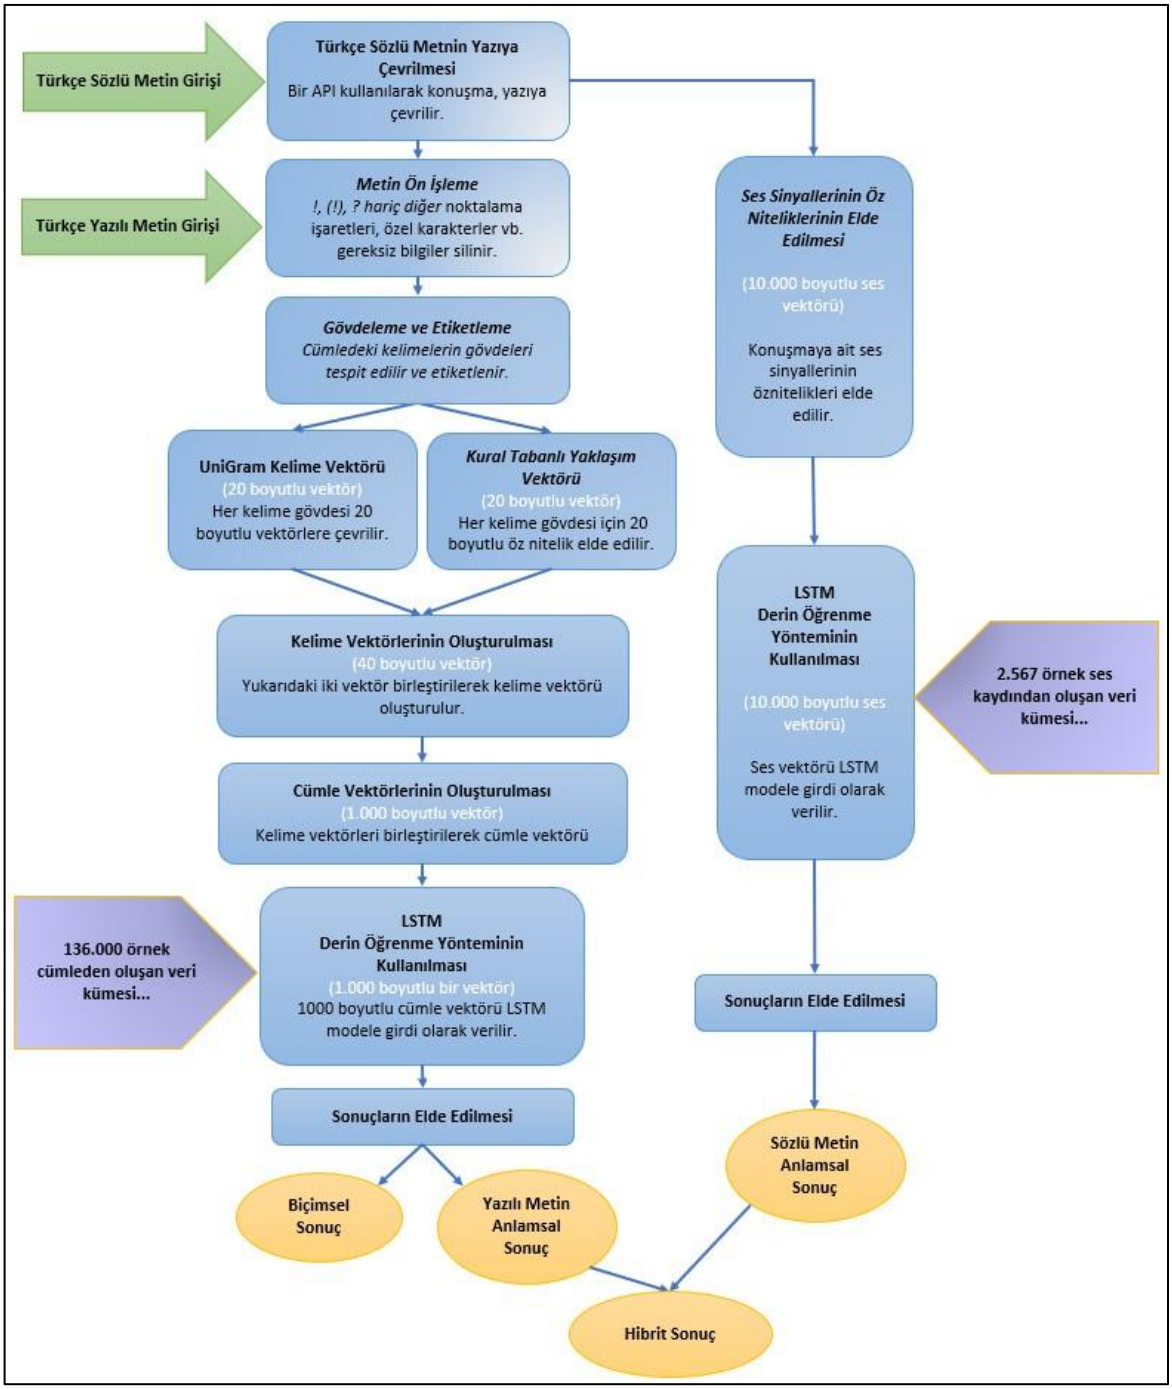

Şekil 24. Duygu-Türk uygulaması akış şeması.