



**T.C.  
KIRIKKALE ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**TÜRKÇE E-TİCARET MÜŞTERİ YORUMLARININ  
DERİN ÖĞRENME İLE ÇOK ETİKETLİ ANALİZİ**

**EMRE DENİZ  
BİLGİSAYAR BİLİMLERİ ANABİLİM DALI**

**DOKTORA TEZİ**

**DANIŞMAN  
Prof. Dr. Hasan ERBAY**

**Kırıkkale-2023**



**T.C.  
KIRIKKALE ÜNİVERSİTESİ  
FEN BİLİMLER ENSTİTÜSÜ**

**TÜRKÇE E-TİCARET MÜŞTERİ YORUMLARININ  
DERİN ÖĞRENME İLE ÇOK ETİKETLİ ANALİZİ**

**EMRE DENİZ  
BİLGİSAYAR BİLİMLERİ ANABİLİM DALI**

**DOKTORA TEZİ**

**DANIŞMAN  
Prof. Dr. Hasan ERBAY**

**KIRIKKALE-2023**

Emre DENİZ tarafından hazırlanan “TÜRKÇE E-TİCARET MÜŞTERİ YORUMLARININ DERİN ÖĞRENME İLE ÇOK ETİKETLİ ANALİZİ” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalında DOKTORA TEZİ olarak kabul edilmiştir.

Danışman: Prof. Dr. Hasan ERBAY İmza.....

Bilgisayar Mühendisliği Anabilim Dalı, Türk Hava Kurumu Üniversitesi

Bu tezi kapsam ve kalite olarak DOKTORA TEZİ olduğunu onaylıyorum

Ortak Danışman: Dr. Öğr. Üyesi Mustafa COŞAR İmza.....

Bilgisayar Mühendisliği Anabilim Dalı, Hitit Üniversitesi

Bu tezi kapsam ve kalite olarak DOKTORA TEZİ olduğunu onaylıyorum

Başkan: Dr. Öğr. Üyesi Ömer Faruk AKMEŞE İmza.....

Bilgisayar Mühendisliği Anabilim Dalı, Hitit Üniversitesi

Bu tezi kapsam ve kalite olarak DOKTORA TEZİ olduğunu onaylıyorum

Üye: Doç. Dr. Bülent Gürsel EMİROĞLU İmza.....

Bilgisayar Mühendisliği Anabilim Dalı, Kırıkkale Üniversitesi

Bu tezi kapsam ve kalite olarak DOKTORA TEZİ olduğunu onaylıyorum

Üye: Dr. Öğr. Üyesi Hakan KÖR İmza.....

Bilgisayar Mühendisliği Anabilim Dalı, Hitit Üniversitesi

Bu tezi kapsam ve kalite olarak DOKTORA TEZİ olduğunu onaylıyorum

Üye: Dr. Öğr. Üyesi Fahrettin HORASAN İmza.....

Bilgisayar Mühendisliği Anabilim Dalı, Kırıkkale Üniversitesi

Bu tezi kapsam ve kalite olarak DOKTORA TEZİ olduğunu onaylıyorum

Üye: Dr. Öğr. Üyesi Ahmet Haşim YURTTAKAL İmza.....

Bilgisayar Mühendisliği Anabilim Dalı, Afyon Kocatepe Üniversitesi

Bu tezi kapsam ve kalite olarak DOKTORA TEZİ olduğunu onaylıyorum

Tez Savunma Tarihi: 17/02/2023

Jüri tarafından kabul edilen bu tezin DOKTORA Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

Prof. Dr. Recep ÇALIN  
Fen Bilimleri Enstitüsü Müdürü

## ETİK BEYANI

Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- 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 çalışmada 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 beyan ederim.

(İmza)

Emre DENİZ

(Tarih)

## ÖZET

### TÜRKÇE E-TİCARET MÜŞTERİ YORUMLARININ DERİN ÖĞRENME İLE ÇOK ETİKETLİ ANALİZİ

Kırıkkale Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı Doktora Tezi

Danışman: Prof. Dr. Hasan ERBAY

Eş Danışman Dr. Öğr. Üyesi Mustafa COŞAR

Şubat 2023, 63 sayfa

Dijital teknolojilerin gelişmesiyle birlikte internet ortamında oluşan veri miktarı, çeşitliliği her geçen gün artmaktadır. Çevrimiçi ticaret siteleri de bu verilerin toplanmasında en büyük katkı sağlayan uygulamalar arasındadır. Toplanan farklı tiplerdeki, yani sayısal, metinsel verilerin analiz edilerek hem müşteriler için hem de şirketler için daha faydalı bilgilere dönüştürecek uygulamaların geliştirilmesi gerekmektedir. Bu nedenle bu tez çalışmasında Türkçe müşteri yorumları üzerine farklı makine öğrenimi teknikleri uygulanarak çok etiketli analizler gerçekleştirilmiştir. İlk olarak bu tez çalışması için Türkçe alışveriş sitelerinden özgün bir veri seti toplanmıştır. Ardından bu veriler üzerinde sırasıyla klasik makine öğrenimi teknikleri ve derin öğrenme teknikleri uygulanarak müşteri yorumlarının çok etiketli analizi gerçekleştirilmiştir. Elde edilen sonuçlar, çok etiketli sınıflandırma uygulamalarında yaygın olarak kullanılan değerlendirme metrikleri ile karşılaştırmalı olarak analiz edilmiştir. Deneysel sonuçlara göre, Türkçe müşteri yorumlarının çok etiketli sınıflandırılması için en başarılı yöntemin ince ayarlaması yapılmış BERT modeli olduğu tespit edilmiştir.

**Anahtar Kelimeler:** Customer reviews analysis, deep learning, machine learning, multi-label classification,

## ABSTRACT

### MULTI-LABEL ANALYSIS OF TURKISH E-COMMERCE CUSTOMER REVIEWS WITH DEEP LEARNING

Kırıkkale University

Graduate School of Natural and Applied Sciences

Department of Computer Engineering, Ph. D. Thesis

Supervisor: Prof. Dr. Hasan ERBAY

Co-Supervisor: Asst. Prof. Dr. Mustafa COŞAR

February 2023, 63 pages

With the development of digital technologies, the amount of data created on the internet is increasing day by day. Online commerce sites are also the applications that make the biggest contribution to this amount of data. By analyzing these textual data, it is necessary to develop more useful applications for both customers and companies. For this reason, in this thesis study, multi-label analyzes were carried out on customer comments in Turkish by applying different machine learning techniques. First of all, a unique data set was collected from Turkish shopping websites for this thesis study. Then, multi-label analysis of customer comments was performed by applying classical machine learning techniques and deep learning techniques, respectively, on these data. The obtained results were analyzed in comparison with the evaluation metrics commonly used in multi-label classification applications. According to the experimental results, it has been determined that the most successful method for multi-label classification of Turkish customer reviews is the fine-tuned BERT model.

**Key Words:** Customer reviews analysis, deep learning, machine learning, multi-label classification,

## TEŐEKKÜR

Doktora tezimin tamamlanması sürecinde deęerli grŐleri, destekleri, katkıları ve ynlendirmeleri ile yardımcı olan danıŐmanım Prof. Dr. Hasan ERBAY'a ve ortak danıŐmanım Dr. Öğr. Üyesi Mustafa COŐAR'a teŐekkr ederim.

Doktoraya baŐlarken yaŐamlarımızı birleŐtirdiđimiz sevgili eŐim Merve Deniz'e bu sreŐte her zaman yanımda olduđu iŐin ve her trl yardım ve fedakarlıđı yaptıđı iŐin sonsuz teŐekkr ederim.



# İÇİNDEKİLER DİZİNİ

Sayfa

ÖZET.....	III
ABSTRACT .....	IV
TEŞEKKÜR.....	V
İÇİNDEKİLER DİZİNİ.....	VI
ÇİZELGELER DİZİNİ .....	VIII
ŞEKİLLER DİZİNİ .....	IX
KISALTMALAR DİZİNİ.....	X
1. GİRİŞ.....	1
1.1. E-Ticaret Müşteri Yorumlarının Analiz Edilmesi.....	3
2. LİTERATÜR TARAMASI .....	7
3. MATERYALLER VE YÖNTEMLER.....	11
3.1. Doğal Dil İşleme .....	11
3.1.1 Doğal Dil İşleme Ön İşlem Aşamaları .....	12
3.2. Veri Seti .....	13
3.2.1. Veri Çekmede Kullanılan Yöntemler .....	13
3.2.2 Veri Seti Kategorileri.....	14
3.3. Makine Öğrenimi.....	16
3.3.1. Binary Relevance.....	17
3.3.2. OneVsRest.....	18
3.3.3. Multi Label k-Nearest Neighbors (ML-kNN).....	19
3.3.4. Sınıflandırma Algoritmaları .....	20
3.3. Derin Öğrenme.....	24
3.3.1 Long Short-Term Memory (LSTM).....	26
3.3.2 Bidirectional Long Short Term Memory (Bi-LSTM).....	26
3.3.2 Gated Recurrent Unit (GRU).....	27
3.4. Özellik Çıkarımı.....	28
3.4.1 Bag of Words .....	28
3.4.2 Term Frequency-Inverse Document Frequency(TF-IDF) .....	28
3.4.3 Kelime Gömme .....	29
3.4.3 BERT .....	30
3.5. Ölçüm Metrikleri.....	31
3.5.1 Hamming Loss .....	31
3.5.2 Micro-Averaged Precision.....	32
3.5.3 Macro-Averaged Precision .....	32
3.5.4Micro-Averaged Recall.....	32
3.5.5 Macro-Averaged Recall .....	33
3.5.6 Micro-F1 Score .....	33
3.5.7 Macro-F1 Score .....	33



<b>4. TEZ AŞAMISINDA YÜRÜTÜLEN ÇALIŞMALAR .....</b>	<b>34</b>
<b>4.1. Kullanılan Araçlar ve Kütüphaneler .....</b>	<b>34</b>
4.1.1 Python.....	34
4.1.2 Pytorch .....	34
4.1.3 Tensorflow.....	35
4.1.4 Keras.....	35
4.1.5 Scikit-Learn .....	36
<b>4.2. Deneysel Çalışmalar .....</b>	<b>36</b>
4.2.1. TF-IDF ve Makine Öğrenimi Kullanımı.....	37
4.2.2. Kelime Gömme ve Makine Öğrenimi Kullanımı.....	37
4.2.3. BERT ve Makine Öğrenimi Kullanımı .....	38
4.2.4 BERT Fine Tuning.....	39
4.2.5. Kelime Gömme ve Derin Sinir Ağı Kullanımı.....	39
<b>5. SONUÇLAR ve TARTIŞMA .....</b>	<b>40</b>
<b>KAYNAKLAR.....</b>	<b>60</b>



# ÇİZELGELER DİZİNİ

## Çizelge

## Sayfa

Çizelge 1.1 Metin Sınıflandırma Çeşitleri.....	2
Çizelge 1.1.1 E-ticaret müşteri değerlendirmeleri sınıflandırma yöntemleri ve olası etiketler.....	4
Çizelge 5.1 İlk deneysel çalışmada elektronik verileri üzerinde elde edilen sonuçlar.....	40
Çizelge 5.2 İlk deneysel çalışmada kadın giyim verileri üzerinde elde edilen sonuçlar.....	43
Çizelge 5.3 İlk deneysel çalışmada ev&yaşam verileri üzerinde elde edilen sonuçlar.....	45
Çizelge 5.4 İkinci ve üçüncü yaklaşımda elektronik verileri üzerinde elde edilen sonuçlar .....	48
Çizelge 5.5 İkinci ve üçüncü yaklaşımda kadın giyim verileri üzerinde elde edilen sonuçlar ...	48
Çizelge 5.6 İkinci ve üçüncü yaklaşımda ev&yaşam verileri üzerinde elde edilen sonuçlar.....	48
Çizelge 5.7 Dördüncü deneysel çalışmada ince ayarlanmış BERT ile edilen sonuçlar .....	49
Çizelge 5.8 Beşinci Deneysel Çalışma Sonucu Elde Edilen Sonuçlar.....	49

## ŞEKİLLER DİZİNİ

<u>ŞEKİL</u>	<u>Sayfa</u>
Şekil 5.1 OvR-LR elektronik veri seti ROC eğrisi.....	41
Şekil 5.2 OvR-SVC elektronik veri seti ROC eğrisi .....	41
Şekil 5.3 OvR-SGD elektronik veri seti ROC eğrisi.....	42
Şekil 5.4 OvR-SVC kadın giyim veri seti ROC eğrisi .....	43
Şekil 5.5 OvR-LR kadın giyim veri seti ROC eğrisi.....	44
Şekil 5.6 OvR-SGD kadın giyim veri seti ROC eğrisi.....	44
Şekil 5.7 OvR-SVC ev&yaşam veri seti ROC eğrisi .....	46
Şekil 5.8 OvR-LR ev&yaşam veri seti ROC eğrisi.....	46
Şekil 5.9 OvR-SGD ev&yaşam veri seti ROC eğrisi .....	47
Şekil 5.10 LSTM-Elektronik Verisi Doğruluk Grafiği .....	50
Şekil 5.11 LSTM-Elektronik Verisi Kayıp Grafiği.....	50
Şekil 5.12 Bi- LSTM-Elektronik Verisi Doğruluk Grafiği .....	51
Şekil 5.13 Bi- LSTM-Elektronik Verisi Kayıp Grafiği.....	51
Şekil 5.14 GRU-Elektronik Verisi Doğruluk Grafiği.....	52
Şekil 5.15GRU-Elektronik Verisi Kayıp Grafiği .....	52
Şekil 5.16LSTM-Ev&Yaşam Verisi Doğruluk Grafiği.....	53
Şekil 5.17 LSTM-Ev&Yaşam Verisi Kayıp Grafiği .....	53
Şekil 5.18 Bi-LSTM-Ev&Yaşam Verisi Doğruluk Grafiği.....	54
Şekil 5.19 Bi-LSTM-Ev&Yaşam Verisi Kayıp Grafiği .....	54
Şekil 5.20 GRU-Ev&Yaşam Verisi Doğruluk Grafiği.....	55
Şekil 5.21 GRU-Ev&Yaşam Verisi Kayıp Grafiği .....	55
Şekil 5.22 LSTM-Kadın Giyim Verisi Doğruluk Grafiği .....	56
Şekil 5.23 LSTM-Kadın Giyim Verisi Kayıp Grafiği.....	56
Şekil 5.24 Bi-LSTM-Kadın Giyim Verisi Doğruluk Grafiği .....	57
Şekil 5.25 Bi-LSTM-Kadın Giyim Verisi Kayıp Grafiği.....	57
Şekil 5.26 GRU-Kadın Giyim Verisi Doğruluk Grafiği.....	58
Şekil 5.27 GRU-Kadın Giyim Verisi Kayıp Grafiği .....	58

## KISALTMALAR DİZİNİ

NLP	Doğal Dil İşleme
SVM	Support Vector Machines
LDA	Latent Dirichlet Allocation
BR	Binary Relevance
RF	Random Forest
SVC	Support Vector Classifier
OVR	OnevsRest
LR	Lojistik Regresyon
SGD	Stochastic Gradient Descent
XGB	eXtreme Gradient Boosting
ML-kNN	Multi Label k-Nearest Neighbors
FFNN	Feed Forward Neural Networks
CNN	Convolutional Neural Networks
LSTM	Long Short-Term Memory
Bi-LSTM	Bidirectional Long Short Term Memory
GRU	Gated Recurrent Unit
BoW	Bag of Words
TF-IDF	Term Frequency-Inverse Document Frequency
BERT	Bidirectional Encoder Representation from Transformers

# 1. GİRİŞ

Elektronik ticaret (E-ticaret), internet aracılığı ile gerçekleştirilen ticari faaliyetlerdir. E-ticaret, her geçen gün daha çok büyüyen bir sektör olarak dikkat çekmektedir ve özellikle küresel pandeminin etkisiyle daha çok ilgi odağı olmuştur. E-ticaret sayesinde, müşteriler ürün ve hizmetleri daha kolay ve hızlı bir şekilde alabilmektedir. Ayrıca e-ticaret, müşterilerin ürün ve hizmetler hakkında daha fazla bilgi edinmelerine ve karşılaştırma yapmalarına olanak sağlamaktadır.

Müşteri yorumları ise, e-ticaret sitelerinin ürün ve hizmetleri hakkında gerçek deneyimleri paylaşan müşteriler tarafından yazılan yazılar ve puanlar olarak tanımlanır. Müşteri yorumları, e-ticaret işletmelerinin müşteri memnuniyetini ve ürün/hizmet kalitesini ölçmelerine olanak tanır. Ayrıca müşterilerin yorumları, diğer potansiyel müşterilerin ürün/hizmet hakkında bilgi edinmelerine ve karar vermelerine yardımcı olur. Müşteri yorumları, e-ticaret siteleri için büyük bir önem içermektedir çünkü bu değerlendirmeler e-ticaret işletmelerinin müşteri memnuniyetini ve ürün/hizmet kalitesini ölçmelerine imkân sağlar. Ayrıca müşteri yorumları, e-ticaret işletmelerinin müşteri beklentilerini ve ihtiyaçlarını anlamalarına yardımcı olur. Bu sayede e-ticaret işletmeleri, müşteri memnuniyetini artırmak ve ürün/hizmet kalitesini iyileştirmek için gerekli değişiklikleri yapabilirler.

Müşteri yorumlarının en dikkat çekici yanı, potansiyel müşterileri etkilemesidir. Bir ürün hakkında kararsız kalan müşteriler, mevcut yorum ve değerlendirmeleri analiz ederek ürünü alıp almama yönünde bir karar verebilirler. Potansiyel müşteriler, bu yorumları okuyarak ürünün ne kadar iyi olduğunu ve müşteri memnuniyetini ölçebilirler. Bununla birlikte, ürün hakkında daha detaylı bilgi de edinebilirler. Belirtilen tüm bu nedenler, müşteri yorumlarının hem e-ticaret işletmeleri için hem de müşteriler için ne kadar önemli olduğunu belirtmektedir.

Dünyada büyük bir hızla gelişen e-ticaret, Türkiye’de de benzer gelişimi göstermiştir. İnternet kullanımının yaygınlaşması, mobil uygulamaların geliştirilmesi ve e-ticaret yasalarının geliştirilmesi sektörün Türkiye’de büyük bir hızla büyümesine olanak sağlamıştır. Hepsiburada, N11, Trendyol, Getir, YemekSepeti, GittiGidiyor, Morhipo ve Markafoni Türkiye’de en çok kullanılan e-ticaret siteleridir (Fastcompany, 2022).

E-ticaret siteleri genel olarak kullanımı arttıkça arařtırmacılara da kullanabileceđi daha çok veri imkânı sunmaktadır. Yukarıdaki belirtilen sitelerde Türk müřteriler sayesinde gerekleřtirilen Türke yorumlar ve deđerlendirmeler ile her geen gün artan bir veri akıřı sađlamaktadır. Bu yorumların ve deđerlendirmelerin analiz edilmesi, hem e-ticaret iřletmeleri iin hem de müřteriler iin büyük bir önem tařımaktadır. E-ticaret siteleri, yorumları analiz ederek kendi iřletmelerini daha ileri tařımak iin yeni fikirler ve pazarlama teknikleri geliřtirebilirler. Ürünlerde eksik olan ya da beđerilmeyen yönleri tespit ederek hem müřteri memnuniyetini artırmayı hem de kendi stratejilerini, kazançlarını artırmayı sađlayabilirler. Müřteriler de bu yorumları deđerlendirerek kendi řartlarına uygun en iyi alıřveriř deneyimini yařayabilirler.

Dođal Dil İřleme (Natural Language Processing -NLP), metin madenciliđi ve bilgi teknolojilerindeki geliřmeler birok yeni uygulamanın geliřtirilmesine yol amıřtır. Yapay zekada geliřtirilen yeni yöntemler ve günlük üretilen metinsel verilerin miktarı ve eřitliliđindeki artıř, gerek hayat problemleri üzerinde ok sayıda arařtırma yapılmasına olanak sađlamaktadır. Metin sınıflandırma, NLP ve metin madenciliđinin en temel uygulama alanlarından biridir. Metin sınıflandırma problemi, ilgili metni belirlenmiř etiketlerle iliřkilendirmek olarak tanımlanabilir. Veri kümelerinin yapısı ve eřitliliđi, metin sınıflandırma yöntemlerini etkilemektedir. Sorunun ve metnin durumuna bađlı olarak her metin bir veya daha fazla etiket ile temsil edilebilir. Etiket sayısına bađlı olarak metin sınıflandırma uygulamasında eřitli farklılıklar ortaya ıkmıřtır; ikili sınıflandırma, ok sınıflı sınıflandırma ve ok etiketli sınıflandırma. Bu sınıflandırma türleri izelge 1.1’de örneklemlenmiřtir.

izelge 1.1 Metin Sınıflandırma eřitleri

Sınıflandırma Türü	Görev	Etiketler
İkili	Spam Filtreleme	Normal, Spam
ok Sınıflı	Duygu Analizi	Pozitif, Nötr, Negatif
ok Etiketli	Toksik Yorum Tespiti	Tehdit, Toksik, Müstehcen, Hakaret

izelge 1.1’de de gösterildiđi üzere metin sınıflandırma veri setinin yapısına göre üçe ayrılmaktadır. Bunlar ikili sınıflandırma, oklu sınıflandırma ve ok etiketli sınıflandırmadır. İkili metin sınıflandırma, veri kümesinde yer alan metinleri iki sınıf

arasında sınıflandırmak için kullanılan bir makine öğrenimi yöntemidir. E-postaları “normal” ve “spam” olarak sınıflandırmak ya da yorumları “pozitif” ya da “negatif” olarak sınıflandırmak ikili metin sınıflandırmasına örnek çalışmalardır. Çok sınıflı metin sınıflandırma, veri kümesinde yer alan metinleri ikiden fazla sınıf arasında sınıflandırmak için kullanılan bir makine öğrenimi yöntemidir. Bu tür sınıflandırma işleminde her metin yine ikili sınıflandırmada olduğu gibi yalnızca bir etiket ile temsil edilir. Bir metinsel ifadenin “nötr”, “pozitif” ya da “negatif” duygu içermesi buna örnek olarak gösterilebilir. Çok etiketli metin sınıflandırma ise veri kümesinde yer alan metinleri birden fazla etiket atanarak sınıflandırmak için kullanılan bir makine öğrenimi yöntemidir. Diğer bir ifadeyle çok etiketli sınıflama çalışmasında her metnin birden fazla etiketi olabilir. Bir haber makalesinin hem “siyaset” hem de “ekonomi” kategorilerine ait olması bu duruma örnek gösterilebilir. Dikkat edelim ki hem ikili hem de çoklu sınıflama, tek etiketli sınıflamadır.

İkili metin sınıflandırma, en çok karşılaşılan ve daha basit olan bir sınıflandırma türüdür. Sahte haber tespiti (Rusli vd., 2020), spam e-posta tespiti (Al-Rawashdeh vd., 2019), spam yorum tespiti (Shehnepoor vd., 2017) ve yazar doğrulaması (Alterkavi ve Erbay, 2021) ikili metin sınıflandırmalarına örneklerdir. İkili sınıflandırmadan farklı olarak, çok sınıflı metin sınıflandırmasında ikiden fazla etiket mevcuttur. İkili metin sınıflandırma ile çok sınıflı metin sınıflandırmanın ortak noktası, her iki modelde de metinlerin yalnızca bir etiketle temsil edilmesidir. Duygu analizi (Liu vd., 2014), konu modelleme (Esposito vd., 2016) ve eş anlam çıkarımı (Leeuwenberg vd., 2016) çok sınıflı metin sınıflandırma görevlerine örnektir.

Hem ikili hem de çok sınıflı metin sınıflandırması birçok uygulamada başarılı şekilde kullanılmıştır. Ancak bazı durumlarda her iki yöntem de yetersiz kalmaktadır. Dil yapısının karmaşıklığı, kelimelerle anlatılmak istenenlerin çeşitliliği ve cümlelerde vurgulanmak istenen anahtar kelimelerin farklılıkları bu metinlerin birden fazla etiketler içerebileceği durumları doğurmaktadır. Bu ifadeleri tek bir etiketle sınırlamak, metinlerden daha ayrıntılı bilgi çıkarımı yapılmasını engellemektedir. Bu nedenle bilgi teknolojilerindeki gelişmelerle birlikte bireylerin beklentilerini karşılayabilmek için çok etiketli verilere ihtiyaç duyulmaktadır.

### **1.1. E-Ticaret Müşteri Yorumlarının Analiz Edilmesi**

Bilgi teknolojilerindeki gelişmeler hem yapay zekâ uygulamalarını hem de insan

davranışlarını, yaşamlarını ve beklentilerini etkilemiştir. Özellikle dijitalleşmenin yol açtığı sözde sosyal dijital yaşam ve COVID-19 salgını koşullarında insanlar günlük rutinlerinde interneti çalışmak, alışveriş yapmak, eğlenmek ve öğrenmek için yoğun bir şekilde kullanmaya başlamıştır. Dijital yaşama olan ilginin en büyük kanıtı, e-ticaret verilerinde gözlemlenebilir. Elde edilen son istatistikler (WPForms, 2022), internet kullanıcılarının %93,5'inin çevrimiçi alışveriş yaptığını göstermektedir. ABD'de müşterilerin %41'i Amazon e-ticaret sitesinden haftada bir veya iki kez alışveriş yaptığı ve bu oranın 18-25 yaş arası kullanıcılar için %50'ye, 26-35 yaş arası müşteriler için ise %57'ye çıktığı belirtilmiştir. 2040 yılına kadar tüm satın alma işlemlerinin %95'inin e-ticaret aracılığı ile yapılacağı tahmin edilmektedir (Nasdaq, 2017).

Ürün değerlendirmelerinin müşterilerin çevrimiçi satın alma işlemi yapmalarında büyük bir etkisi mevcuttur. E-ticaret kullanıcılarının %55'i bir ürün veya şirketten memnun olup olmadıklarını ailelerine ya da arkadaşlarına belirtmektedir. Ayrıca, müşterilerin %90'ının e-ticaret aracılığı ile bir satın alma işlemi yapmadan önce mevcut müşteri yorumlarını okuduğu belirtilmiştir. Tüm bu gelişmelerle birlikte günlük olarak artan veri miktarı ve bunun müşteriler üzerindeki etkisi araştırmacıların dikkatini çekmiştir. Bu nedenle e-ticaret müşteri yorumları üzerinde birçok çalışma gerçekleştirilmiştir. Yapılan bu araştırmalar üzerinde çalışılan veri setine ve araştırmanın yapısına göre bazı farklılıklar göstermektedir. Çizelge 1.1.1, e-ticaret müşteri yorumlarının sınıflandırılma çeşitlerini ve olası etiketlerini göstermektedir.

Çizelge 1.1.1 E-ticaret müşteri değerlendirmeleri sınıflandırma yöntemleri ve olası etiketler

İkili Sınıflandırma	Çok Sınıflı Sınıflandırma	Çok Etiketli Sınıflandırma
• Spam Yorum	• Pozitif Yorum	• Kaliteli Ürün
• Normal Yorum	• Negatif Yorum	• Fiyat/Performans
	• Nötr Yorum	• Bedeninizi Alın
		• Hızlı Kargo
		• İyi Paketleme

Çizelge 1.1.1'de müşteri yorumlarının analiz edilmesi için gerçekleştirilen üç farklı yaklaşım gösterilmiştir. Bu yaklaşımlar Çizelge 1.1'de metin sınıflandırma türleri olarak gördüğümüz ikili sınıflandırma, çok sınıflı sınıflandırma ve çok etiketli



sınıflandırmadır. İkili sınıflandırmada müşteri yorumları daha önceden belirtilen iki etiketten birisi ile temsil edilmek üzere sınıflandırılır. Çok sınıflı sınıflandırmalarda ise ikiden fazla etiket mevcuttur. Genellikle duygu analizi odaklı gerçekleştirilen bu sınıflandırma türünde yine her bir müşteri yorumu sadece bir etiket ile belirtilmektedir. Çok etiketli sınıflandırmada ise her bir yorum birden fazla ve değişik özelliklere sahip etiketler ile temsil edilir. Çizelgede de görüldüğü üzere bu farklı etiketler, müşteri yorumlarından daha farklı özelliklerin elde edilmesine olanak sağlamaktadır.

Bu tez çalışmasında, Türkçe e-ticaret yorumlarının klasik makine öğrenimi yöntemleri ve derin öğrenme teknikleri ile çok etiketli analizi gerçekleştirilmiştir. Tezin katkılarını şu şekilde sıralayabiliriz:

- Tez için özgün bir veri seti hazırlanmıştır. Literatürde Türkçe için NLP uygulamalarında kullanılmak üzere birçok veri vardır, ancak özellikle metin sınıflandırma uygulamaları için kullanılan veriler çoğunlukla ikili ve çok sınıflı analizler için kullanılmaya müsait verilerdir. Toplamda üç farklı kategoriden oluşturduğumuz veri seti, özgün ve çok etiketli yapısı ile literatüre faydalı bir katkı sunmuştur.
- Literatürde Türkçe müşteri yorum analizi çalışmalarının duygu analizi odaklı olduğu görülmüştür. Bu tez çalışmasında ise yorumların polarite analizinden farklı olarak özniteliklerine göre sınıflandırılması gerçekleştirilmiştir. Böylece müşteri yorumları farklı anahtar kelimelere göre kategorilendirilebilmiştir.
- Önerilen modeller neticesinde elde edilen başarımlarla, müşterilerin alışveriş deneyimlerinin daha kolaylaştırılabilir hale getirilmesi hedeflenmiştir. Özellikle e-ticaret sitelerinde müşterilerin katkıları ile artan yorum verisi miktarı, yeni müşterilerin alışveriş yaparken ürün hakkında bilgi edinebilmek için daha fazla zaman kaybetmesine, hatta ürünle ilgili öğrenmek istediği bazı fikirleri görememesine neden olmaktadır. Müşteri yorumlarının çok etiketli analiz edilmesi ile bu soruna bir çözüm bulmaya çalışılmıştır. Elde edilen bulgular, derin öğrenme yöntemleri ile bu sınıflandırma işleminin başarılı bir şekilde gerçekleştirilebileceğini göstermiştir.
- Klasik makine öğrenimi ve derin öğrenme algoritmalarının çok etiketli sınıflandırma görevlerinde nasıl performans sergileyeceği ve hangi özellik

ıkarım yntemlerinin daha bařarılı sonular elde edeceėi, karřılařtırılmalı analizlerle eřitli deėerlendirme metrikleri ile irdelenmiřtir.



## 2. LİTERATÜR TARAMASI

NLP, yararlı uygulamalar geliştirmek için doğal dildeki metinleri veya konuşmayı anlamak ve değiştirmek için bilgisayarların nasıl kullanılabileceğini inceleyen bir araştırma ve uygulama alanıdır (Chowdhary, 2020). NLP araştırmacılarının amacı, bilgisayarların doğal dili kullanarak görevleri etkili bir şekilde işlemesi ve gerçekleştirmesi için araçlar ve yöntemler geliştirmek amacıyla, insanların dili kullanma ve anlama şeklini çoğaltmaktır. Bu amaçla birçok farklı alanda NLP uygulamaları geliştirilmiştir. İlk NLP araştırmaları, sözcüksel ve morfolojik analizler üzerinde yoğunlaşmıştır. Cümle ve paragraf yapılarının NLP teknikleri ile başarılı şekilde analiz edilmesinin ardından, daha karmaşık uygulamalar geliştirilmiştir. Otomatik konuşma tanıma(Yu & Deng, 2012), eş referans çözümleme(Soon vd., 2001), isim-varlık tanıma(Nadeau & Sekine, 2007), soru cevaplama(Lende & Raghuwanshi, 2016), makine çevirisi(Lopez, 2008), bilgi çıkarımı(Grishman, 2015), niyet tespiti(Xu & Sarıkaya, 2013), konuşma bölümü etiketleme(Schmid, 1994), ilişki çıkarımı(Konstantinova, 2014), duygu analizi(Nasukawa & Yi, 2003), metin özetleme(Tas & Kiyani, 2007) ve metin sınıflandırma(Lavanya & Sasikala, 2021) gibi en önemli NLP görevleri araştırmacılar tarafından araştırılmış ve birçok faydalı uygulama geliştirilmesine olanak sağlamıştır.

Bu tez çalışmasında, e-ticaret yorumları üzerinde sınıflandırma çalışması gerçekleştirilmiştir. Literatür incelendiğinde bu alanda farklı veriler üzerinde değişik yöntemler kullanılarak birçok yararlı uygulamanın geliştirildiği tespit edilmiştir. Yapılan tüm çalışmalar, veri yapısına ve uygulamanın ihtiyacına göre kullanılan yöntemlerde birçok farklılık göstermektedir. Tezin bu bölümünde, müşteri yorumları üzerine yapılan çalışmalar hakkında bir literatür özeti sunulacaktır.

Duygu analizi veya düşünce madenciliği, insanların belirli bir varlıkla ilgili tutumlarının, görüşlerinin ve duygularının sistematik olarak incelenmesidir (Medhat vd., 2014). Birçok çalışmada müşteri yorumlarının duygu analizi yapılmıştır. Bu çalışmaların neredeyse tamamı polarite analizine odaklanmıştır. Muslim (2020), grid aramayı ve özellik çıkarımı için uni-gram kullanarak e-ticaret müşteri incelemesi veri

kümelerini sınıflandırmak için SVM doğruluğunu geliştirmeyi amaçlamıştır. Olumlu veya olumsuz olarak etiketlenmiş Amazon müşteri yorumları ve Lazada müşteri yorumlarından oluşan veri kümelerini kullanmıştır. Deneysel sonuçları, SVM algoritmasında uni-gram ve grid arama uygulamasının, Amazon yorumlarının sınıflandırma doğruluğunu %26,4 artırarak %80,8, Lazada yorumlarının doğruluğunu ise %4,26 artırarak %90,13 doğruluk oranı yakalığını belirtmiştir.

Xu vd. (2020), büyük ölçekli ve çok alanlı e-ticaret sitesi ürün değerlendirme duyarlılığı sınıflandırması için sürekli bir Naive Bayes öğrenme çerçevesi sunmuştur. Çalışmalarında Amazon ürün ve film değerlendirme yorumlarından oluşan veri kümelerini kullanmışlardır. Deneysel sonuçları, modellerinin geçmiş alanlardan öğrenilen bilgileri yeni alanlarda öğrenmeye rehberlik etmek için kullanabileceğini göstermiştir.

Vanaja ve Belwal (2018), Amazon müşteri yorumları üzerinde boyut düzeyinde duygu analizi gerçekleştirmiştir. Yorumların olumlu, olumsuz veya nötr olup olmadığını analiz etmişlerdir. Karşılaştırmalı analizlerin sonucunda Naive Bayes kullanarak %90,2 oranında doğruluk bulduklarını belirtmişlerdir.

Jabbar vd. (2019), e-ticaret uygulamalarının ürün yorumlarının gerçek zamanlı duygu analizi sınıflandırması gerçekleştirmiştir. Amazon'dan toplanan müşteri yorumu verilerinin duygu analizi için bir model tasarlamak üzere SVM kullanmışlardır. Yorumları olumlu veya olumsuz olarak etiketlemişlerdir. SVM kullanılarak gerçekleştirilen duygu analizi sonucunda %93,54 F1 puanı elde ettiklerini belirtmişlerdir.

Parven vd. (2021), Latent Dirichlet Allocation (LDA) kullanarak kadınların e-ticaret değerlendirmeleri üzerinde duygu analizi gerçekleştirmişlerdir.

Tripathi vd. (2020), e-ticaret web sitelerinden müşteri yorumlarını toplayarak yeni bir değerlendirmeyi daha fazla sınıflandırmak için farklı yararlılık oylarına sahip e-ticaret web sitelerindeki yorumların metin içeriğini incelemişlerdir. Rastgele Orman (Random Forest -RF) sınıflandırıcı ile elde edilen en iyi doğruluğun %90,45 oranında olduğunu belirtmişlerdir.

Kumar vd. (2016), duygu analizi gerçekleştirmek için Amazon web sitesinden veri toplamışlardır. Naive Bayes, lojistik regresyon ve SentiWordNet kullanarak yorumları olumlu veya olumsuz olarak sınıflandırmışlardır. Naive Bayes'in düşünce madenciliği

ve duygu analizi için daha verimli bir yöntem olduğunu belirtmişlerdir.

Miyoshi ve Nakagami (2007), Japon ürün yorumlarının anlamsal yönünü tahmin etmek için bir yöntem önermişlerdir. 1400 yorum içeren bir veri seti üzerinde yaptıkları çalışmada yorumları olumlu veya olumsuz olarak sınıflandırmışlardır.

Guan vd. (2016), müşteri yorumlarının duygu analizini gerçekleştirmek için bir derin derin öğrenme modeli geliştirmişlerdir. Amazon e-ticaret sitesinden topladıkları müşteri yorumlarını olumlu veya olumsuz olarak sınıflandırmışlardır. Derin öğrenme modeli, duygu analizinde %87,7 doğruluk oranı elde etmiştir.

Zhang vd. (2020) e-ticaret yorumları için yönlendirilmiş ağırlıklı çoklu sınıflandırma modeli önermiştir. Çalışmalarında Amazon müşteri yorumlarından oluşan 10.000 yorum içeren bir veri seti kullanmışlardır. Duygu analizi için çok etiketli sınıflandırma modeli geliştirmişlerdir. Yönlendirilmiş ağırlıklı modelleri %80 oranında ortalama duyarlılık değeri elde etmiştir.

Shoja ve Tabrizi (2019), 142,8 milyon Amazon müşteri yorumu verisi kullanarak, müşteri değerlendirmelerinin tavsiye sistemlerini geliştirmeye dahil etmek için bir derin sinir ağı yaklaşımı geliştirmiştir.

Gu vd. (2020), MBGCV adlı yeni bir duygu analizi modeli önermiştir. Çalışmalarında, olumlu veya olumsuz olarak etiketlenmiş 31.107 müşteri yorumu kullanmışlardır. Önerdikleri model, müşteri yorumu duygu analizinde %94 oranında doğruluk elde etmiştir.

Bilen ve Horasan (2021), Türk müşteri yorumları üzerinde LSTM ağı tabanlı duygu analizi gerçekleştirmiştir. Duygu analizi için iki farklı veri seti kullanmışlardır. Türk tüketici yorumlarının duygu analizi için yaklaşık 7000 yorumdan oluşan yeni bir veri seti toplamışlardır. LSTM tabanlı bir model kullanarak topladıkları verileri pozitif veya negatif olarak sınıflandırmış ve ikili duygu analizi için %90,5 oranında doğruluk bulmuşlardır.

Vural vd. (2013), Türkçe metin belgelerinde denetimsiz duygu analizi için yeni bir model sunmuştur. Çalışmalarında veri seti olarak film yorumlarını kullanmışlardır.

Açıkalın vd. (2020), BERT kullanarak olumlu ve olumsuz etiketler için Türkçe film ve otel yorumları üzerinde duygu analizi yapmıştır. Çalışmalarında buldukları en iyi sonucun %93,3 doğruluk oranı olduğunu belirtmişlerdir.

Santur (2019), GRU kullanarak Türkçe e-ticaret müşteri yorumları üzerinde duygu analizi gerçekleştirmiştir. Yorumları olumlu, olumsuz ve tarafsız olarak sınıflandırmıştır. En iyi sonucun %95 doğruluk olarak bulunduğunu bildirmiştir.

Özyurt ve Akçayol (2021), LDA kullanarak Türkçe müşteri yorumları üzerinde özellik tabanlı duygu analizi gerçekleştirmiştir. Akıllı telefonlar hakkında 1292 kullanıcı yorumu toplanmış ve akıllı telefonlar için dokuz farklı özellik belirlemişlerdir. Sonuçlarında %82,39 oranında doğruluk bulduklarını belirtmişlerdir.



### **3. MATERYALLER VE YÖNTEMLER**

Bu bölümde, bu tez çalışmasında kullanılan materyaller ve yöntemler anlatılmaktadır. Bölüm üç ana kısım içermektedir. İlk olarak tez çalışmasının temelini oluşturan doğal dil işleme teknikleri anlatılmaktadır. Daha sonra ise uygulama aşamasında kullanılan veri hakkında detaylı bilgi içermektedir. Son olarak ise verileri analiz için kullanılan makine öğrenimi ve derin öğrenme yöntemlerinden bahsedilmektedir.

#### **3.1. Doğal Dil İşleme**

Doğal dil işleme, bilgisayarların ve yazılımların insan dilini anlaması ve kullanması için kullanılan bir alandır. NLP, insan dilini yazılı ve sözlü olarak kullanan bilgisayarların ve yazılımların oluşturulmasını amaçlar. Bu alan dilin yapısını, dilbilgisi ve semantik gibi konuları ele alır ve bu konuları kullanarak metin veya ses verilerini analiz etme, anlama, çevirme ve özetleme gibi işlemler gerçekleştirir. Bu teknolojiler insanların günlük hayatlarını kolaylaştırmakta ve işletmeler için önemli veriler elde etmelerine olanak tanımaktadır.

NLP teknolojileri birçok farklı çalışma alanlarına sahiptir. Bu çalışma alanları ve amaçları aşağıdaki şekilde sayılabilir:

**Metin Sınıflandırma:** Metin verilerinin belirli bir kategoriye atanmasını amaçlamaktadır. E-postaların spam olarak sınıflandırılması metin sınıflandırma uygulamasına örnek olarak gösterilebilir.

**Metin Parçası Etiketleme:** Kelimelerin dilbilgisi rollerinin tespit edilmesini amaçlamaktadır. Cümle içerisindeki kelimeler isim, fiil, sıfat vb. şekilde sınıflandırılır.

**Makine Çevirisi:** Belirli bir kaynak dilden başka bir hedef dile çeviri yapmayı amaçlamaktadır.

**Metin Özetleme:** Metin verilerinin anahtar noktalarının özetlenmesi amaçlamaktadır.

**Ses Tanıma:** Konuşma verilerinin bilgisayarlar tarafından anlaşılması ve işlenmesi hedeflenmektedir. Sesli arama uygulamaları, navigasyon sistemleri, müşteri hizmetleri otomasyonu vb. uygulamalarda kullanılmaktadır.

İsmlendirilmiş Varlık Tespiti: Metin verilerinde kişi, yer, şirket vb. gibi özel isimlerin belirlenmesi ve etiketlenmesi amaçlanmaktadır.

Ortak Referans Çözümleme: Metin verilerinde anlamsal olarak aynı kişi veya nesnenin farklı yerlerde yer alan referanslarının belirlenmesi amaçlanmaktadır.

Metin Üretme: Metin verilerinden yararlanarak yapay dil kullanılarak yeni metinler üretmektir.

Diyalog Üretme: Metin verilerinden yararlanarak sosyal medya, chatbot vb. uygulamalar için diyaloglar üretmektir.

Sesi Metne Dönüştürme: Konuşma verilerinin metin olarak dönüştürülmesini amaçlamaktadır.

### 3.1.1 Doğal Dil İşleme Ön İşlem Aşamaları

NLP ön işlem aşamaları, metin verilerinin anlaşılır ve işlenebilir hale gelmesi için yapılan işlemlerdir.

- **Metin Temizleme**

Metin verilerinden anlamı etkilemeyen, gereksiz şeylerin çıkarılmasını içerir, örneğin, özel karakterlerin, beyaz boşlukların, satır sonlarının, HTML etiketlerinin ve diğer alakasız bilgilerin kaldırılmasını kapsamaktadır. Bu adım, verilerden herhangi bir parazitin çıkarılmasına ve verilerin daha kolay işlenebilir hale gelmesini sağladığı için doğal dil işleme uygulamalarında önemli bir yer kapsamaktadır.

- **Belirteçleştirme (Tokenization)**

Metin verilerini kelimeler veya cümleler gibi daha küçük birimlere ayırmayı içermektedir. Metin verilerinin daha kolay değiştirilmesine izin verir ve metnin bağlamını anlamaya yardımcı olur.

- **Köklendirme (Stemming) ve Kök Çözümleme (Lemmatization)**

Kelimeleri kök biçimlerini indirgemeyi amaçlar. Köklendirme, sözcüklerin son eklerini kaldırmak için basit kural tabanlı yöntemler kullanırken, kök çözümleme sözcükleri temel biçimlerine indirgemek için morfolojik analiz gibi daha karmaşık yöntemler kullanır. Bu adım, verilerdeki farklı sözcük sayısında bir azalış sağladığı için doğal dil işleme modellerinde performans artışına yol açar.

- **Metin Normalleştirme**



Tüm metnin doğal dil işleme modeli tarafından kolay ve başarılı bir şekilde işlenebilmesi için bütün kelimelerin küçük harf gibi ortak bir biçime dönüştürülmesini içerir.

Doğal dil işlemedeki bu ön işleme adımları, modelin başarısına doğrudan etki ettikleri için çok önemlidir. Metin verilerinin daha yapılandırılmış, tutarlı ve kolay işlenebilir hale getirilmesini sağladığı için gerçekleştirecek olan doğal dil işleme görevlerinde verilerin kolayca kullanılabilir hale gelmesine yardımcı olurlar.

### **3.2. Veri Seti**

Literatür taraması yapıldığında, Türkçe e-ticaret müşteri yorumlarının sınıflandırılması için kullanılabilir bir veri setinin mevcut olmadığı tespit edilmiştir. Bu tez çalışmasında kullanılan veriler, özgün olarak e-ticaret sitesinden belirlenen kriterler doğrultusunda oluşturulmuş ve tez çalışması için hazırlanmıştır.

Veri seti oluşturulurken ilk olarak çok, anlamlı ve güvenilir verilerin elde edilmesi hedeflenmiştir. Mevcut Türkçe e-ticaret siteleri incelendiğinde veri çekmek için aranan kriterleri sağlayan en uygun sitenin Trendyol olduğu belirlenmiştir.

#### **3.2.1. Veri Çekmede Kullanılan Yöntemler**

E-ticaret sitesinden verileri toplamak için Python programlama dili tercih edilmiştir. Python kullanılmasının nedeni, veri çekmek için bazı önemli kütüphaneleri içinde barındırıyor olmasıdır. Bu çalışmada kullanılan verileri elde etmek için Selenium kütüphanesi kullanılmıştır. Selenium, web uygulamalarını test etmek için kullanılan bir araçtır. Web tarayıcılarını otomatik olarak kontrol edebilen bir kod kütüphanesidir ve Python ile uyumlu bir şekilde çalışabilmektedir. Web uygulamalarının yük ve performans testleri, hata ayıklama işlemleri için kullanılan Selenium, web sayfalarından verileri çekmek için de kullanılabilir. Web tarayıcısını otomatik olarak kontrol ederek web sayfasının HTML kodunu alabilir. Bu HTML kodu, daha sonra veri çekme için kullanılabilir. Bu sayede web sayfasındaki verileri otomatik olarak çekmek mümkündür.

Python ile web sitelerine ait HTML kodlarını almak için yararlanabilecek başka kod kütüphaneleri de mevcuttur. Ancak Selenium kütüphanesinin en büyük avantajı, otomatik kontrol sağlaması ve Javascript kodlarını aşağı doğru otomatik olarak kaydırabilmesidir. Veri çekmek için seçilen sitenin yapısı incelendiğinde ilk yorumlarının hepsinin gözükmediği tespit edilmiştir. Bütün yorumlara ulaşmak için

aşağı doğru fare yardımı ile kaydırma işlemi gerçekleştirilmesi gerekmektedir. Diğer kütüphaneler bu işlemi gerçekleştiremediği için, Selenium tercih edilmiştir ve istenen bütün verilere ulaşım sağlanmıştır.

### **3.2.2 Veri Seti Kategorileri**

Tez çalışmasında kullanılmak üzere üç farklı veri seti oluşturulmuştur. Üç farklı veri setinin oluşturulması, farklı veri seti ve etiketler karşısında geliştirilen modellerin başarımlarını karşılaştırmak ve analiz etmektir. Bu bağlamda elektronik, ev&yaşam ve kadın giyim kategorilerine ait üç farklı veri seti oluşturulmuştur. Bu kategoriler, en çok müşteri yorumu içeren ürünlere sahip oldukları için tercih edilmiştir.

#### **3.2.2.1 Elektronik Veri Seti**

Elektronik veri seti, elektronik kategorisine ait Türkçe e-ticaret müşteri yorumlarını içermektedir. Toplamda 14,557 farklı yorum içeren bu veri setinde her bir yorum 6 farklı etiketten en az bir tanesinin özelliklerini taşımaktadır. Elektronik veri setine ait etiketler “ürün güzel”, “fiyat/performans”, “hızlı teslimat”, “iyi paketleme”, “kaliteli ürün” ve “uygun fiyat” olarak veri setinde yer almıştır.

“Ürün güzel” etiketi, ilgili ürünün kullanıcılar tarafından beğenildiğini ve güzel bulunduğunu belirtmektedir.

“Fiyat/performans” etiketi, ilgili ürünün fiyat performans ürünü olduğunu belirtmektedir.

“Hızlı teslimat” etiketi, ilgili ürünün hızlı bir şekilde teslim edildiğini belirtmektedir.

“İyi paketleme” etiketi, ilgili ürünün kargo ambalajının beğenildiğini belirtmektedir.

“Uygun fiyat” etiketi, ilgili ürünün fiyatının makul seviyede olduğunu belirtmektedir.

#### **3.2.2.2 Ev&Yaşam Veri Seti**

Ev&Yaşam veri seti, ev ve yaşam kategorisine ait Türkçe e-ticaret müşteri yorumlarını içermektedir. Toplamda 12,563 farklı yorum içeren bu veri setinde her bir yorum 10 farklı etiketten en az bir tanesinin özelliklerini taşımaktadır. Ev&Yaşam veri setine ait etiketler “ürün güzel”, “şık duruyor”, “fiyat/performans”, “günlük kullanım”, “hızlı teslimat”, “iyi paketleme”, “kaliteli ürün”, “kırık geldi”, “sağlam geldi” ve “uygun fiyat” olarak veri setinde yer almıştır.

“Ürün güzel” etiketi, ilgili ürünün kullanıcılar tarafından beğenildiğini ve güzel

bulunduğunu belirtmektedir.

“Şık duruyor” etiketi, ilgili ürünün alışveriş yapan müşteriler tarafından şık bulunduğunu belirtmektedir.

“Fiyat/performans” etiketi, ilgili ürünün fiyat performans ürünü olduğunu belirtmektedir.

“Günlük kullanım” etiketi, ilgili ürünün müşteriler tarafından günlük kullanım için uygun bulunduğunu belirtmektedir.

“Hızlı teslimat” etiketi, ilgili ürünün hızlı bir şekilde teslim edildiğini belirtmektedir.

“İyi paketlenme” etiketi, ilgili ürünün kargo ambalajının beğenildiğini belirtmektedir.

“Kaliteli ürün” etiketi, ilgili ürünün müşteriler tarafından kaliteli bulunduğunu belirtmektedir.

“Kırık geldi” etiketi, ilgili ürünün müşteriye kırık bir şekilde teslim edildiğini belirtmektedir.

“Sağlam geldi” etiketi, ilgili ürünün müşteriye sağlam bir şekilde teslim edildiğini göstermektedir.

“Uygun fiyat” etiketi, ilgili ürünün fiyatının makul seviyede olduğunu belirtmektedir.

### **3.2.2.3 Kadın Giyim Veri Seti**

Kadın giyim veri seti, kadın giyim kategorisine ait Türkçe e-ticaret müşteri yorumlarını içermektedir. Toplamda 24,274 farklı yorum içeren bu veri setinde her bir yorum 5 farklı etiketten en az bir tanesinin özelliklerini taşımaktadır. Kadın giyim veri setine ait etiketler “ürün güzel”, “bedeninizi alın”, “küçük alınabilir”, “kaliteli ürün” ve “kumaş kalitesi” olarak veri setinde yer almıştır.

“Ürün güzel” etiketi, ilgili ürünün kullanıcılar tarafından beğenildiğini ve güzel bulunduğunu belirtmektedir.

“Bedeninizi alın” etiketi, ilgili ürünün alışveriş yapan müşteriler tarafından her zamanki bedenlerini aldıklarını ve kıyafetin bedenlerine uygun olduğunu belirtmektedir.

“Küçük alınabilir” etiketi, ilgili ürünün alışveriş yapan müşteriler tarafından denendikten sonra birkaç beden büyük geldiğini ve daha küçük bir beden alınması gerektiğini belirtmektedir.

“Kaliteli ürün” etiketi, ilgili ürünün müşteriler tarafından kaliteli bulunduğunu belirtmektedir.

“Kumaş Kalitesi” etiketi, ilgili ürünün kumaş kalitesi hakkındaki değerlendirmeleri belirtmektedir.

### **3.3. Makine Öğrenimi**

Makine öğrenimi, bir bilgisayar programının veriye bakarak kendini geliştirmesine olanak tanıyan bir teknolojidir. Veri, genellikle önceden etiketlenmiş ve sınıflandırılmıştır ve program, bu veriye bakarak bir görevi öğrenir. Öğrenme işlemi, veriye çeşitli matematiksel modeller uygulayarak gerçekleştirilir.

Makine öğrenimi, iki temel kategoriye ayrılır. Bu kategoriler öğrenme sürecinde öğretici veri kullanılıp kullanılmaması durumuna göre şekillenir. Öğretici veri kullanılarak yapılan öğrenmeye “Denetimli Öğrenme“ denir. Öğretici veri kullanılmadan yapılan öğrenme ise “Denetimsiz Öğrenme” olarak isimlendirilir.

Denetimli öğrenmede veriler etiketli olduğu için daha çok kullanılmaktadır. Bu öğrenme türü sınıflandırma ve regresyon gibi görevlerde kullanılmaktadır. Öğretici veri, sınıflandırma ve regresyon için kullanılır ve program, öğretici veriye dayanarak öğrenme işlemini gerçekleştirir.

Denetimsiz veride ise etiketli veri bulunmamaktadır. Bu tür öğrenme, verilerin yapısını veya gruplarını keşfetmek için kullanılır. Örneğin, kümeleme veya boyut indirgeme gibi görevlerde kullanılır.

Makine öğrenimi birçok alanda kullanılmaktadır. Bu alanları aşağıdaki şekilde sayabiliriz:

**Ses ve Görüntü İşleme:** Makine öğrenimi, ses ve görüntü işleme alanlarında kullanılmaktadır. Örneğin, ses tanıma, görüntü tanıma veya video analitik gibi uygulamalarda kullanılır.

**Sosyal Medya ve E-Ticaret:** Makine öğrenimi, sosyal medya ve e-ticaret alanlarında kullanılmaktadır. Örneğin, öneri sistemleri, trend analizi veya müşteri segmentasyonu gibi uygulamalarda kullanılır.

**Sağlık:** Makine öğrenimi sağlık alanında da kullanılmaktadır. Örneğin hastalık tanısı, tedavi planlaması veya ilaç geliştirme gibi uygulamalarda kullanılır.

Finans: Makine öğrenimi, finans alanında kullanılmaktadır. Örneğin portföy yönetimi, risk analizi ya da hisse fiyat tahmini gibi uygulamalarda kullanılır.

Otomotiv: Makine öğrenimi, otomotiv alanında da kullanılmaktadır. Örneğin otomatik sürüş veya çevre analizi gibi uygulamalarda kullanılır.

Robotik: Makine öğrenmesi, robotik alanında kullanılmaktadır. Örneğin robotların yer algılaması, öğrenmesi veya insanlarla etkileşimi gibi uygulamalarda kullanılır.

Bu bölümün geri kalan kısmında, tez çalışmasında kullanılan makine öğrenimi yöntemleri hakkında detaylı bilgi verilecektir.

### **3.3.1. Binary Relevance**

Binary Relevance(BR) algoritması, verilen bir örneğe ait çoklu etiketleri tahmin etmeyi amaçlayan bir yöntemdir. Bu algoritmanın arkasındaki fikir, her etiket için bağımsız olarak bir ikili sınıflandırıcı eğitmek ve ardından bu sınıflandırıcıları yeni örnekler için tahminler yapmak üzere kullanmaktır.

Algoritma şu şekilde çalışır:

Veri kümesindeki her etiket için, örneklerin özellikleri ve bu etiketin varlığını veya yokluğunu gösteren ikili etiket kullanılarak bir ikili sınıflandırıcı eğitilir.

Yeni bir örnek geldiğinde, her etiket için bir tahmin elde etmek amacıyla sınıflandırıcılar ilgili veriye uygulanır.

Sınıflandırıcıların pozitif tahmin döndürdüğü etiketlerin örnekte mevcut olduğu kabul edilir.

BR algoritmasının en önemli avantajlarından bir tanesi, sağlamış olduğu basitliktir. BR algoritmasının anlaşılması ve çok etiketli veriler üzerinde uygulanması kolaydır. Bu avantajların yanında bazı sınırlamaları da beraberinde getirmektedir. Sınıflandırıcılar bağımsız olarak eğitildiği için etiketler arasında korelasyon veya bağımlılıklar dikkate alınmaz. Bu da bazı durumlarda yetersiz performansa yol açabilir.

BR algoritması, Lojistik Regresyon (LR), SVM, RF ve benzeri gibi herhangi bir ikili sınıflandırıcı ile kullanılabilir. Bu tez çalışmasında BR algoritması RF, Support Vector Classifier(SVC) ve Naive Bayes(NB) sınıflandırıcıları ile birlikte kullanılmıştır.

### 3.3.2. OneVsRest

OneVsRest(OvR) algoritması, çok etiketli sınıflandırma uygulamalarında kullanılan bir yöntemdir. OvR'nin ardındaki temel fikir, her sınıf için, sınıflandırıcının o sınıfın örneklerini diğer tüm sınıfların örneklerinden ayırt edecek şekilde eğitildiği ikili bir sınıflandırıcı yetiştirmektir.

OvR algoritması, veri kümesindeki her sınıf için bir ikili sınıflandırıcı eğiterek çalışır. Her sınıflandırıcı, o sınıfın örneklerini diğer tüm sınıfların örneklerinden ayırt edecek şekilde eğitilir. Örneğin, üç etiket mevcutsa (A, B ve C), üç sınıflandırıcı eğitilecektir. Biri A sınıfını B ve C sınıflarından ayırmak için, diğeri B sınıfını A ve C sınıflarından ayırmak için ve son olanı ise C sınıfını A ve B sınıflarından ayırt etmek için kullanılır. Bu ayırt etme işlemi için bir eşik değeri kullanılır ve her sınıflandırıcı bu eşik değerine göre örnek veri için bir güven puanı belirler.

Tüm sınıflandırıcılar eğitildikten sonra, her sınıflandırıcı örneğe uygulanarak ve en yüksek güven puanı veren sınıf seçilerek yeni örnekler sınıflandırılabilir.

OvR algoritması, herhangi bir sınıflandırma algoritması ile kullanılabilir. Bununla birlikte uygulanması daha kolay ve iyi performans sergilediği için genellikle LR veya SVM ile birlikte kullanılır. Bu tez çalışmasında OvR algoritması LR, Stochastic Gradient Descent (SGD), SVC ve XGBoost sınıflandırıcıları ile birlikte kullanılmıştır.

BR ve OvR algoritmaları, her ikisi de çok etiketli sınıflandırma görevleri için birden çok ikili sınıflandırıcının eğitimini içermesi bakımından benzerdir. Bununla birlikte, iki yöntem arasında bazı temel farklar vardır.

BR metodu, bir ikili sınıflandırıcının her etiket için bağımsız olarak eğitildiği bir yöntemdir. Örneğin, veri setinde üç etiket varsa, her etiket için bir tane olmak üzere üç ikili sınıflandırıcı eğitilecektir. Yeni bir örnek sunulduğunda, her etiket için bir tahmin elde etmek amacıyla sınıflandırıcılar bu veriye uygulanır. Sınıflandırıcının olumlu bir tahmin döndürdüğü etiketlerin örnekte mevcut olduğu kabul edilir.

OvR ise, her etiket için bir ikili sınıflandırıcının eğitildiği, ancak sınıflandırıcının bu etikete sahip örnekleri bu etiketi olmayan örneklerden ayırt edecek şekilde eğitildiği bir yöntemdir. Örneğin, veri kümesinde üç etiket varsa, üç ikili sınıflandırıcı eğitilecektir. Biri etiket 1'e sahip örnekleri etiket 1'siz örneklerden ayırmak için, bir diğeri etiket 2'ye ait örnekleri etiket 2'siz örneklerden ayırmak için ve diğeri de etiket

3'e ait örnekleri etiket 3'süz örneklerden ayırmak için kullanılır. Sınıflandırıcıların her biri, her örnek için bir puan verir ve bir eşik değeri kullanılarak puanın eşikten büyük olup olmama durumuna göre örnekler etiketlenir.

Özetle, iki algoritma arasındaki temel fark, BR'nin birden fazla sınıflandırıcıyı bağımsız olarak eğitmesi, OvR'nin ise her sınıflandırıcının belirli bir etikete sahip örnekleri bu etikete sahip olmayan örneklerden ayırt etmek üzere eğitildiği bir dizi sınıflandırıcıyı eğitmesidir.

### 3.3.3. Multi Label k-Nearest Neighbors (ML-kNN)

ML-kNN, veri setinde mevcut olan bir verinin aynı anda birden çok sınıfa ait olabileceği bir sınıflandırma türü olan çok etiketli sınıflandırma görevi için kullanılan bir makine öğrenmesi algoritmasıdır.

Algoritmanın arkasındaki temel fikir, sınıf etiketlerini belirlemek için bir örneğin k-en yakın komşularını kullanmaktır. Bir örneğin k-en yakın komşuları, Öklid mesafesi gibi bir mesafe ölçüsü kullanılarak örnek ile veri kümesindeki diğer tüm örnekler arasındaki mesafe hesaplanarak belirlenmektedir.

ML-kNN algoritması iki temel adımdan oluşur. İlk adım, bir örneğin k-en yakın komşusunu bulmaktır. Bu, örnek ile veri kümesindeki diğer tüm örnekler arasındaki mesafeyi hesaplayarak ve ardından örneğe en yakın k örneği seçilerek gerçekleştirilir.

İkinci adım, örneğin sınıf etiketlerini belirlemek için k-en yakın komşunun sınıf etiketlerini kullanmaktır. Bu, her sınıf etiketinin k-en yakın komşular arasında kaç kez görüldüğü sayılarak ve ardından örnek için tahmin edilen sınıf etiketi olarak en sık görünen sınıf etiketi seçilerek yapılır.

Algoritma ayrıca, tahmin edilen sınıf etiketlerindeki güven derecesini kontrol etmek için kullanılan "güven düzeyi" adı verilen bir parametreye sahiptir. Güven düzeyi, sıfır ile bir arasında bir değerdir ve örnek için o etiketin tahmin edilebilmesi için belirli bir sınıf etiketine sahip olması gereken k-en yakın komşularının oranını temsil eder.

ML-kNN basit ve etkili bir algoritmadır. Uygulanması kolaydır ve büyük veri kümeleri için verimlidir. Ancak, k seçimine ve kullanılan mesafe ölçümüne duyarlıdır. Ayrıca, özelliklerin birbirinden bağımsız olduğunu varsaymaktadır. Gerçek dünya verilerinde özellikler arasında bağımlılık olduğu durumlarda düşük performans sergileyebilir.

### **3.3.4. Sınıflandırma Algoritmaları**

Bu bölümde, bu tez çalışması için BR ve OvR çok etiketli sınıflandırma metotlarında kullanılan sınıflandırma algoritmaları anlatılacaktır.

#### **3.3.4.1 Rasgele Orman**

Rasgele Orman (Random Forest), sınıflandırma ve regresyon uygulamaları için kullanılan bir topluluk öğrenme yöntemidir. Her ağacın verilerin rastgele bir alt kümesi üzerinde eğitildiği bir karar ağaçları bütünüdür. Nihai çıktı, tüm karar ağaçlarının çıktılarının birleştirilmesiyle belirlenir.

Rastgele bir ormandaki karar ağaçları mümkün olduğu kadar büyütülür ve budama yapılmaz. Eğitim sürecinde, her ağaç için, eğitim seti olarak rastgele bir veri örneği seçilir ve karar ağacındaki her düğümde, en iyi bölünmeye karar vermek için özelliklerin rastgele bir örneği kullanılır. Bu süreç, belirli sayıda ağaç için tekrarlanır ve son tahminler, tek tek ağaçların tahminlerinin ortalaması alınarak veya oylanarak yapılır.

RF kullanmanın en önemli avantajı, birden çok karar ağacının sonuçlarının ortalamasını alarak aşırı öğrenme riskini azaltmasıdır. Aşırı öğrenmenin azaltılması, özellikle yüksek boyutlu ve karmaşık veri kümeleriyle uğraşırken, modelin genel performansında önemli bir iyileşmeye yol açabilmektedir.

RF ayrıca geleneksel karar ağacı algoritmaları tarafından ele alınmayan eksik değerleri ve kategorik değişkenleri işleme yeteneğine de sahiptir.

#### **3.3.4.2 Destek Vektör Sınıflandırma**

Destek Vektör Sınıflandırma (Support Vector Classifiers - SVC) metodu, sınıflandırma ve regresyon uygulamaları için kullanılabilen bir denetimli öğrenme algoritmasıdır. SVC'lerin ardındaki temel fikir, yeni veya görünmeyen veriler üzerinde doğru tahminler yapmak için eğitim verilerindeki farklı sınıfları ayıran en iyi sınırı belirlemektir.

SVC algoritması, giriş verilerini daha yüksek boyutlu bir özellik uzayına eşleyerek çalışır ve burada sınıfları ayıran doğrusal bir sınır bulmayı mümkün kılar. Sınır, her



sınıftan en yakın veri noktaları arasındaki mesafeye olan marjı maksimize edecek şekilde seçilir. Bu en yakın noktalara destek vektörleri denir ve sınırın konumunu belirlerler.

SVC algoritması, verileri daha yüksek boyutlu bir alana dönüştürerek bir sınır bulabildiğinden, verilerin orijinal özellik uzayında doğrusal olarak ayrılamaz olduğu durumlarda çok kullanışlıdır. Bunu başarmak için algoritma, daha yüksek boyutlu uzayda koordinatları açıkça hesaplamadan verilerin doğrusal olmayan bir dönüşümünü gerçekleştirmesine izin veren, çekirdek hilesi adı verilen bir teknik kullanır.

SVC'nin bir diğer avantajı, farklı çekirdek fonksiyonlarını kullanarak hem doğrusal hem de doğrusal olmayan karar sınırlarını işleyebilmesidir. Diğer bir avantajı ise, aşırı öğrenmeden kaçınmayı sağlayan bir parametreye sahip olmasıdır.

SVC'ler iyi bir genelleme yeteneğine sahiptir, yani yeni veriler üzerinde iyi performans verebilmektedir. Bununla birlikte, SVC'ler birden fazla ikili sınıflandırıcıyı eğiterek ve bunları birleştirerek çok etiketli sınıflandırma uygulamaları için kullanılabilirler.

### **3.3.4.3 Naive Bayes**

Naive Bayes, sınıflandırma görevleri için kullanılan ve Bayes teoremine dayanan olasılıksal bir makine öğrenme algoritmasıdır. "Naive" yani saf olarak adlandırılmasının sebebi, veri kümesindeki tüm özelliklerin birbirinden bağımsız olduğunu yapmasıdır. Bu varsayımınla birlikte algoritma sınıflandırma uygulamaları için başarılı bir performans sergilemektedir.

Üç farklı Naive Bayes algoritması mevcuttur. Bunlar Gaussian Bayes, Multinomial Bayes ve Bernoulli Bayes algoritmalarıdır. Gaussian Naive Bayes sürekli veriler için kullanılan algoritmadır. Multinomial Naive Bayes metin sınıflandırması gibi ayrık veriler için kullanılmaktadır. Belirli bir etikete ait bir belgedeki her kelimenin olasılığını modeller. Bernoulli Naive Bayes algoritması da ayrık veriler için kullanılır. Multinomial algoritmasına benzerlik göstermekle birlikte aralarındaki fark, Bernoulli algoritmasının bir özelliğin bir sınıfta var olup olmama olasılığını modellemesidir.

Eğitim süreci açısından, algoritma ilk olarak eğitim verisindeki her bir sınıfın ilk olasılığını öğrenir. Ardından, her özellik için, her sınıfa verilen özelliğin olasılığı

öğrenilir. Bu olasılıklar daha sonra her bir sınıfın son olasılığını hesaplayarak yeni verileri sınıflandırmak için kullanılır. Son olasılık değeri en yüksek olan sınıf, test verilerinin sınıf tahmininde atama değeri olarak kullanılır.

Naive Bayes algoritması, sınıflandırma görevleri için oldukça etkili ve uygulaması kolay bir yöntemdir. İkili, çok sınıflı ve çok etiketli sınıflandırma problemlerinde başarılı bir şekilde kullanılabilir. Aynı zamanda yüksek boyutlu veri kümeleri için de kullanışlı bir algoritmadır.

#### **3.3.4.4 Lojistik Regresyon**

Lojistik Regresyon, ikili sınıflandırma ve çok sınıflı sınıflandırma uygulamalarında yaygın olarak kullanılan istatistiksel bir yöntemdir. Lojistik regresyonun arkasındaki temel fikir, bir lojistik fonksiyon kullanarak bir dizi bağımsız değişken ile bir ikili bağımlı değişken arasındaki ilişkiyi modellemektir. Sigmoid işlevi olarak da bilinen lojistik işlev, herhangi bir girdi değerini 0 ile 1 arasında bir olasılık olarak yorumlanabilecek bir değerle eşler.

Lojistik regresyonun amacı, bağımsız değişkenler ile bağımlı değişken arasındaki ilişkiyi açıklayan en uygun modeli bulmaktır. Bu, bir dizi parametre olarak verilen verileri gözlemleme olasılığını ifade eden bir olasılık fonksiyonu tanımlayarak ve ardından olabilirlik fonksiyonunu maksimize eden parametre setini bulmak için gradyan optimizasyon algoritması kullanılarak gerçekleştirilir.

Lojistik regresyon, basit ve yorumlanabilir bir algoritmadır. Çeşitli görevler için uygulaması kolay ve büyük veri kümeleri için etkilidir. Ancak, bağımsız değişkenler ile bağımlı değişkenler arasındaki ilişkinin doğrusal olduğunu varsayar ve gerçek dünya verilerinde bu durum böyle olmayabilir. Ayrıca, verilerin aykırı değer içermediğini ve çok fazla eksik değere sahip olmadığını varsayar.

#### **3.3.4.5 Stochastic Gradient Descent(SGD)**

SGD, optimizasyon amaçlı kullanılan bir algoritmadır. Esas olarak lineer regresyon, lojistik regresyon, sinir ağları vb. gibi makine öğrenimi modellerini eğitmek için kullanılır.

Algoritmanın ana fikri, model parametrelerini, parametrelere göre fonksiyonun negatif gradyanı yönünde yinelemeli olarak güncellemektir. Fonksiyonun gradyanı, parametrelere göre kısmi türevlerin bir vektörüdür ve fonksiyondaki en dik artış yönünü gösterir. Algoritma ters yönde hareket ederek fonksiyonun minimumunu bulmayı amaçlamaktadır.

Standart Gradient Descent'den farkı, SGD'nin algoritmanın tüm eğitim setini kullanmak yerine her seferinde yalnızca bir eğitim örneği kullanarak parametreleri güncellemesidir. Bu, belleğe sığmayan büyük veri kümelerinde bile ilerleme sağlayabildiği için algoritmayı çok daha hızlı hale getirir.

SGD, büyük veri kümelerini ve yüksek boyutlu parametre alanlarını işleyebilen güçlü bir optimizasyon algoritmasıdır. Öğrenme oranı, parametrelere duyarlı bir algoritmadır. Bununla birlikte her zaman küresel minimuma yakınsamayabilir, bunun yerine yerel bir minimuma takılıp kalabilir.

#### **3.3.4.6 eXtreme Gradient Boosting(XGB)**

XGB, sınıflandırma ve regresyon gibi makine öğrenimi görevlerinde yaygın olarak kullanılan, gradyan artırmaya yönelik açık kaynaklı bir algoritmadır. Büyük veri kümelerini ve yüksek boyutlu özellik alanlarını işlemek için özel olarak tasarlanmış bir gradyan güçlendirme uygulamasıdır.

Gradyan artırma, daha güçlü bir model oluşturmak için birden çok öğreniciyi birleştiren bir toplu öğrenme yöntemidir. Gradyan artırmanın ardındaki fikir, topluluğa yinelemeli olarak yeni zayıf öğreniciler eklemek ve her yeni öğrenicinin önceki öğrencilerin yaptığı hataları düzeltmek için eğitilmesidir.

Algoritma, eğitim verileri üzerinde basit bir model eğiterek başlar. Ardından, eğitim verileri için öngörülen değerler ile gerçek değerler arasındaki farkı hesaplar. Daha sonra hesapladığı farklar üzerinde yeni bir model eğitir ve yeni modelin tahminlerini önceki modelin tahminlerine ekler. Bu işlem belirli sayıda iterasyon için tekrarlanır. Nihai tahminler, tüm modellerin tahminlerinin toplanmasıyla elde edilir.

XBG, diğer gradyan artırma algoritmalarından farklı olarak bazı benzersiz özelliklere sahiptir.

Ağaç budama: XGB, modelin karmaşıklığını azaltmak ve fazla öğrenmeyi azaltmak

için ağaç budama adı verilen bir teknik kullanır.

Düzenleştirme: XGB, kayıp fonksiyonuna bir ceza terimi ekleyerek aşırı öğrenmeyi engellemek için düzenleştirme adı verilen bir teknik kullanır.

Eksik değerleri işleme: XGB, verilerdeki eksik değerleri otomatik olarak işleyebilir.

Kategorik değişkenleri işleme: XGB, tek seferlik kodlamaya ihtiyaç duymadan kategorik değişkenleri doğrudan işleyebilir.

Paralel işleme: XGB, eğitim sürecini hızlandırmak için paralel işlem yapmaktadır.

XGB, çeşitli makine öğrenimi görevleri için endüstride ve akademide yaygın olarak kullanılan güçlü ve esnek bir algoritmadır. Büyük veri setlerini ve yüksek boyutlu özellik alanlarını verimli bir şekilde işleyebilmektedir. Ağaç sayısı ve öğrenme hızı gibi parametrelere duyarlı bir algoritmadır.

### **3.3. Derin Öğrenme**

Derin öğrenme, birbirine bağlı düğümlerin çoklu katmanlarından oluşan yapay sinir ağlarının tasarımı ve geliştirilmesi ile ilgilenen makine öğreniminin bir alt alanıdır. Bu ağlar, yalnızca birkaç katmana sahip geleneksel sinir ağlarının aksine, birçok katmana sahip oldukları için derin olarak adlandırılmaktadır.

Derin öğrenme algoritmaları, insan beyninin yapısından ve işlevinden ilham alır ve görüntü tanıma, doğal dil işleme ve konuşma tanıma gibi çok çeşitli sorunları çözmek için kullanılır.

Birçok farklı derin öğrenme algoritma çeşidi vardır. Bunlardan en çok kullanılanları İleri Beslemeli Sinir Ağları (FFNN), Evrişimli Sinir Ağları (CNN), Tekrarlayan Sinir Ağları (RNN), Otomatik Kodlayıcılar ve Üretken Çekişmeli Ağlar (GAN)'dır.

FFNN, bilginin girdi katmanından çıktı katmanına tek yönde aktığı derin öğrenme algoritmalarının en basit türüdür.

CNN, görüntü verilerini işlemek için özel olarak tasarlanmış derin öğrenme algoritmalarıdır. Görüntüden özellikleri çıkarmak için evrişim adı verilen bir teknik kullanır ve ardından bu özellikleri görüntüyü sınıflandırmak için kullanırlar.

RNN, zaman serileri, konuşma veya metin gibi sıralı verileri işlemek için özel olarak tasarlanmış derin öğrenme algoritmalarıdır. Önceki öğeleri takip ederken verileri her

seferinde bir öge olarak işlemek için yineleme adı verilen bir teknik kullanırlar.

Otomatik kodlayıcı, denetimsiz öğrenme için kullanılan ve amacın girdi verilerinin kompakt bir temsilini öğrenmek olduğu derin öğrenme algoritmalarıdır. Bir kodlayıcı ve kod çözücünden oluşmaktadırlar. Kodlayıcı giriş verilerini düşük boyutlu bir temsile eşlerken kod çözücü düşük boyutlu temsili orijinal verilere geri eşlemektedir.

GAN, denetimsiz öğrenme için kullanılan ve amacın girdi verilerinin üretken bir modelini öğrenmek olduğu derin öğrenme algoritmalarıdır. Bunlar, üreticinin yeni veri örnekleri ürettiği ve ayırmcının üretilen örnekler ile gerçek örnekler arasında ayırım yapmaya çalıştığı, bir oluşturucu ve bir ayırmcı olmak üzere iki sinir ağından oluşur.

Derin öğrenme algoritmaları, eğitim için büyük miktarda veri ve hesaplama gerektirmektedir. Ağın ağırlıklarını güncellemek için geri yayılım adı verilen bir teknik kullanır. Derin öğrenmenin başarısı, büyük miktarda veri ve hesaplama kaynaklarının yanı sıra derin mimarilerin verilerin hiyerarşik temsillerini öğrenme yeteneğinden kaynaklanmaktadır.

Derin öğrenme ve makine öğrenme yapay zekanın bir alt dalı olmakla birlikte yaklaşım, teknik ve uygulamalarda farklılıklar göstermektedirler. Makine öğrenimi; denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve takviyeli öğrenme gibi çeşitli teknikleri içeren daha geniş bir alandır. Derin öğrenme ise, özellikle derin sinir ağlarının kullanımına odaklanan, makine öğreniminin bir alt dalıdır.

Makine öğrenimi algoritmaları arasında doğrusal regresyon, lojistik regresyon, karar ağaçları, k-en yakın komşular ve destek vektör makineleri bulunmaktadır. Derin öğrenme algoritmaları ise ileri beslemeli sinir ağlarını, evrimsel sinir ağlarını, tekrarlayan sinir ağlarını, otomatik kodlayıcıları ve üretken çekişmeli ağlardan oluşmaktadır.

Makine öğrenimi algoritmaları genellikle eğitmek için derin öğrenme algoritmalarından daha az veri gerektirir. Derin öğrenme algoritmaları, eğitim için büyük miktarda veri ve hesaplama kaynaklarına ihtiyaç duymaktadır.

Makine öğrenimi algoritmaları, derin öğrenme algoritmalarından genellikle daha basit ve yorumlaması daha kolaydır. Derin öğrenme algoritmalarının karmaşık yapısı ve az doğrusal yapısı, yorumlanabilir modellerin geliştirilmesini zorlaştırmaktadır.

Derin öğrenme algoritmaları, özellikle yeterli miktarda veri mevcut olduğunda, birçok

uygulamada en yüksek performans deęerlerini elde edebilir. Makine öğrenimi algoritmaları da hala birçok uygulamada yeterli performansı göstermektedir ve yaygın olarak kullanılmaya devam etmektedir.

### **3.3.1 Long Short-Term Memory (LSTM)**

LSTM zaman serileri, konuşma verileri veya metin gibi sıralı verileri işlemek için tasarlanmış bir tür RNN mimarisidir. Dil çevirisi veya konuşma tanıma gibi, modelin bilgileri uzun süreli hatırlamasını gerektiren görevler için özellikle kullanışlıdır.

Geleneksel bir RNN, hücreler adı verilen yinelenen modüller zincirinden oluşur. Her hücre bir önceki hücreden bir girdi ve bir gizli durum alır ve bir çıktı ve yeni bir gizli durum üretir. Gizli durum, geçmişten gelen bilgileri depolamak için kullanılır ve zincirdeki bir sonraki hücreye iletilir. Bununla birlikte, geleneksel RNN'ler, eğitim sırasında parametrelerin gradyanları çok küçük olduğunda ortaya çıkan ve parametrelerin güncellenmesini zorlaştıran, kaybolan gradyan sorunu adı verilen bir sorundan muzdariptir. LSTM'ler, bilgileri uzun süre depolamak için kullanılan hücre durumu adı verilen ek bir durum sunarak bu sorunu çözer. Hücre durumu, hücrelerden deęişmeden geçirilir ve aę üzerinden bilgi akışını kontrol etmek için kullanılır. LSTM'ler ayrıca hücre durumuna giren ve çıkan bilgi akışını kontrol etmek için giriş kapısı, unutma kapısı ve çıkış kapısı olarak adlandırılan üç kapı kullanır.

Giriş kapısı, hücre durumuna girmesine izin verilen bilgi miktarını kontrol eder, unutma kapısı, bir sonraki hücreye geçmesine izin verilen bilgi miktarını kontrol eder ve çıkış kapısı, çıkmasına izin verilen bilgi miktarını kontrol eder. Bu kapılar, öğrenilen ağırlıklar tarafından kontrol edilir ve hangi bilgilerin saklanması ve hangilerinin atılması gerektiğine karar vermek için kullanılır.

LSTM aęları, dil modelleme, konuşma tanıma, makine çevirisi ve dięerleri gibi çok çeşitli görevler için kullanılabilir. Uzun vadeli bağımlılıkları olan sıralı verileri işlemek için özellikle yararlıdırlar ve bilgileri uzun süre hatırlayabilirler. Bununla birlikte, LSTM'ler hesaplama açısından pahalı olabilir ve eğitilmesi için çok fazla veri gerektirebilir.

### **3.3.2 Bidirectional Long Short Term Memory (Bi-LSTM)**

Bi-LSTM, giriş dizisinin hem geçmişinden hem de geleceğinden gelen bilgileri

birleştirek sıralı verileri işlemek üzere eğitilmiş bir (RNN) mimarisidir. Geleneksel bir LSTM'de, belirli bir zaman adımındaki gizli durum, önceki gizli durumun ve mevcut girdinin bir fonksiyonudur. Bununla birlikte, bir Bi-LSTM'de, belirli bir zaman adımındaki gizli durum, hem önceki gizli durum ve mevcut girdinin hem de gelecekteki gizli durum ve gelecekteki girdinin bir fonksiyonudur.

Bi-LSTM mimarisi, giriş dizisini zıt yönlerde işlemek için eğitilmiş iki LSTM katmanından oluşur: Bir katman, diziyi soldan sağa (yani, giriş dizisinin sırasına göre) işler ve diğer katman, diziyi sağdan sola (yani, giriş sırasının tersi sırada) işler. Bu iki katmandan gelen çıktılar daha sonra birleştirilir ve nihai çıktıyı üretmek için tamamen bağlı bir katmandan geçirilir.

Sıralı verileri her iki yönden işleyebilme özelliği, Bi-LSTM'nin giriş dizisinin içeriğini daha iyi yakalamasına ve daha doğru tahminler yapmasına olanak tanır. Bi-LSTM'ler genellikle dil çevirisi, metin sınıflandırması ve konuşma tanıma gibi doğal dil işleme görevlerinde kullanılır.

Bi-LSTM'in bazı önemli avantajları bulunmaktadır. Hem geçmiş hem de gelecekteki girdilerden bağlamı yakalama yeteneği sayesinde iyileştirilmiş tahmin performansı sağlamaktadır. Değişken uzunluklu girdi dizilerini işleme yeteneğine sahiptir. Uzun diziler durumunda hata yayılımına karşı sağlamlık gösterir.

### 3.3.2 Gated Recurrent Unit (GRU)

GRU, geleneksel RNN'lerde yaygın bir sorun olan yok olan gradyan sorununu çözmek için tasarlanmış bir RNN mimarisidir. LSTM'ler gibi, GRU'lar da geçmişten ve mevcut girdiden gelen bilgileri birleştirerek sıralı verileri işleyebilir, ancak hesaplama açısından daha verimli olmalarını sağlayan daha basit bir mimariye sahiptirler.

Bir GRU'nun temel bileşeni, ağız gizli durum aracılığıyla bilgi akışını kontrol etmesine izin veren geçitleme mekanizmasıdır. GRU'nun iki kapısı vardır: güncelleme kapısı ve sıfırlama kapısı. Güncelleme kapısı, önceki gizli durumdan tutulan bilgi miktarını kontrol eder ve önceki gizli durumdan hangi bilgilerin atılacağına karar vermek için kullanılır. Sıfırlama kapısı, geçerli gizli durumda depolanan bilgi miktarını kontrol eder ve mevcut gizli durumda hangi bilgilerin depolanacağına karar vermek için kullanılır. Son gizli durum, önceki gizli durum ile yeni hesaplanan gizli durumun doğrusal bir birleşimidir ve her birinin ağırlığı güncelleme kapısı tarafından kontrol

edilir.

GRU'lar genellikle dil çevirisi, metin sınıflandırması ve konuşma tanıma gibi doğal dil işleme görevlerinde kullanılır. Ayrıca, zaman serisi tahmini ve video analizi gibi diğer alanlarda da yaygın olarak kullanılırlar.

GRU mimarisi bazı önemli avantajlar sağlamaktadır. LSTM ile karşılaştırıldığında daha basitleştirilmiş bir mimariye sahiptir. Bu durum hesaplama açısından daha verimli olmalarını sağlamaktadır. Geçitleme mekanizması sayesinde belirli görevlerde geliştirilmiş performans sağlar. Uzun diziler durumunda hata yayılımına karşı sağlamlık gösterir.

### **3.4. Özellik Çıkarımı**

NLP'de özellik çıkarma yöntemleri, ham metin verilerinden anlamlı bilgiler çıkarmak için kullanılan tekniklerdir. NLP'deki bazı yaygın özellik çıkarma yöntemleri sözcük çantası, terim/doküman frekansı, kelime gömme ve dönüşüm tabanlı yaklaşımlardır.

#### **3.4.1 Bag of Words**

Bag of Words (BoW) yöntemi, NLP'de yaygın olarak kullanılan bir özellik çıkarma yöntemidir. Metin verilerinden özellikleri çıkarmanın basit ve etkili bir yoludur. BoW yönteminin arkasındaki temel fikir, bir metin belgesini, dilbilgisi ve kelime sırasını dikkate almadan, ancak her kelimenin sıklığını takip ederek, kelimelerinden oluşan bir "torba" (veya sırasız küme) olarak temsil etmektir.

BoW yöntemi basit ve etkilidir, ancak bazı sınırlamaları vardır. Örneğin, kelimelerin bağlamını veya gramer yapısını dikkate almaz ve kelime dağarcığının boyutuna duyarlı olabilir. Bu sınırlamaların üstesinden gelmek için, BoW ile birlikte veya BoW yerine n-gramlar veya kelime gömme gibi diğer öznelik çıkarma yöntemleri kullanılabilir.

#### **3.4.2 Term Frequency-Inverse Document Frequency(TF-IDF)**

TF-IDF, BoW yöntemini temel alan ve NLP'de yaygın olarak kullanılan bir özellik çıkarma yöntemidir. Bir belgedeki veya belgeler koleksiyonundaki bir kelimenin önemini veya alaka düzeyini ölçmek için kullanılır. TF-IDF'nin arkasındaki temel fikir, bir belgedeki sözcükleri, belgedeki sıklıklarına ve kelimenin tüm belge



koleksiyonundaki ters sıklığına göre tartmaktır. Bu, bir belgedeki en bilgilendirici sözcükleri tanımlamaya ve sık kullanılan veya alakasız sözcükleri filtrelemeye yardımcı olabilir.

TF-IDF yöntemi, bir belgede sık, ancak belge koleksiyonunda nadiren geçen kelimelere yüksek ağırlık ve belgede nadiren ancak belge koleksiyonunda sık sık geçen kelimelere düşük ağırlık verir. Bu, bir belgedeki en bilgilendirici sözcükleri tanımlamaya ve sık kullanılan veya alakasız sözcükleri filtrelemeye yardımcı olabilir. Ancak yöntem, kelimelerin bağlamını dikkate almaz ve kelime dağarcığının boyutuna duyarlıdır.

### **3.4.3 Kelime Gömme**

Kelime gömme, sözcükleri, sözcüklerin anlamını ve bağlamını yakalayabilen yüksek boyutlu vektörler olarak temsil etme yöntemidir. NLP’de, ayrı semboller olan sözcükleri, makine öğrenimi algoritmaları tarafından işlenebilen sürekli yoğun vektörlere dönüştürmek için kullanılan bir tekniktir. Kelime gömme, denetimsiz öğrenme teknikleri kullanılarak büyük miktarda metin verisinden öğrenilir. Kelime gömmenin amacı, vektör uzayında benzer kelimeler için vektörler birbirine yakın olacak ve farklı kelimeler için vektörler birbirinden uzak olacak şekilde her kelime için bir vektör temsilini öğrenmektir.

Word2Vec, Global Vectors(GloVe), FastText, Embeddings from Language Models(ELMO) ve Bidirectional Encoder Representation from Transformers (BERT) en yaygın kelime gömme yöntemleridir. Bu tez çalışmasında Word2Vec, GloVe ve BERT yöntemleri kullanılmıştır.

#### **3.4.3.1 Word2Vec**

Word2Vec, büyük bir metin verisi külliyatından sözcüklerin yüksek boyutlu vektör temsilleri olan sözcük yerleştirmelerini öğrenme yöntemidir. Kelime gömmelerini öğrenmek için en popüler ve yaygın olarak kullanılan yöntemlerden biridir. Word2Vec’in iki ana mimarisi vardır: Continuous Bag-of-Words (CBOW) ve Skip-Gram. Her iki mimari de kelime gömmesini elde etmek için için sığ bir sinir ağı kullanır.

CBOw mimarisi, bağlamdan mevcut kelimeyi tahmin etmeyi amaçlar. Sinir ağının girişi, bağlam sözcüklerinin temsilidir. Bununla birlikte çıktı ise mevcut kelimenin bir temsilini göstermektedir. Sinir ağının ağırlıkları, kelime gömmesi olarak kullanılır.

Skip-Gram mimarisi ise CBOw'nun zıttı şekilde çalışmaktadır. Mevcut kelimedenden bağlamı tahmin etmeyi amaçlar. Sinir ağının girdisi, mevcut kelimeyi temsil ederken çıktı bağlam sözcüklerini temsil etmektedir. CBOw gibi sinir ağının ağırlıklarını kelime gömmesi olarak kullanır.

Word2Vec'in ana avantajı, bir derlemdeki sözcüklerin anlamını ve bağlamını yakalayan kelime gömmelerini öğrenebilmesidir. Metin sınıflandırma, dil çevirisi ve dil modelleme gibi birçok NLP görevinde çok etkili olduğu kanıtlanmıştır. Ancak, nadir sözcükleri ve kelime dağarcığının dışında kalan sözcükleri yakalayamama gibi bir sınırlaması vardır.

### **3.4.3.2 GloVe**

GloVe büyük bir metin verisi topluluğundan sözcüklerin yüksek boyutlu vektör temsilleri olan kelime gömmelerini öğrenme yöntemidir. GloVe, Word2Vec gibi diğer kelime gömme yöntemlerine benzer, ancak bir derlemdeki kelimelerin birlikte oluşum matrisini çarpanlara ayırarak kelime vektörlerini öğrenmeyi amaçlayan farklı bir eğitim algoritması kullanır.

GloVe'nin arkasındaki temel fikir, kelimelerin birlikte oluşum istatistiklerini kullanarak bir derlemdeki her kelime için bir vektör temsilini öğrenmektir. Algoritma, bir log-bilineer regresyon modeli kullanarak, vektörleri verildiğinde, bir kelime çiftinin birlikte oluşum sayısını tahmin etmek üzere eğitilmiştir. Öğrenilen vektörler daha sonra kelime gömmeleri olarak kullanılır.

### **3.4.3 BERT**

BERT, bağlamsal sözcük gömmelerini öğrenen, önceden eğitilmiş dönüşüm tabanlı bir modeldir. Google AI Language ekibi tarafından geliştirilmiştir ve doğal dil işleme görevleri için önceden eğitilmiş en gelişmiş modellerden biri olarak kabul edilir.

BERT'nin arkasındaki ana fikir, dönüşüm tabanlı bir modeli büyük bir metin verisi külliyatında önceden eğitmek ve ardından metin sınıflandırması, adlandırılmış varlık

tanıma ve soru yanıtlama gibi belirli görevlerde ince ayar yapmaktır. BERT, girdideki bazı kelimelerin rasgele maskelendiği ve modelin, olmayan kelimeler tarafından sağlanan bağlama dayalı olarak maskelenmiş kelimelerin orijinal kelime kimliğini tahmin etmesi gereken, maskeli dil modelleme adı verilen bir görev üzerinde eğitim alarak bağlamsal kelime gömmelerini öğrenir.

BERT çift yönlüdür, yani model bağlamı her iki yönden, soldan sağa ve sağdan sola dikkate alacak şekilde eğitilmiştir. Bu, modelin bir cümledeki bir kelimenin anlamını yalnızca önceki veya sonraki kelimelerin değil, tüm cümlenin bağlamına dayalı olarak anlamasına olanak tanır.

BERT, derlemler ve Wikipedia makaleleri gibi büyük bir metin verisi külliyatı üzerinde önceden eğitilmiştir ve önceden eğitilmiş model, az miktarda etiketlenmiş veri kullanılarak belirli görevler üzerinde ince ayar yapılabilir. Bu, modelin yeni görevlere hızla uyum sağlamasına ve çok çeşitli doğal dil işleme görevlerinde son teknoloji sonuçlara ulaşmasına olanak tanır.

### **3.5. Ölçüm Metrikleri**

Çok etiketli sınıflandırma, geleneksel tek etiketli sınıflandırmada kullanılan değerlendirme tekniklerinden farklı ölçümler gerektirir (Tsoumakas & Katakis, 2007). Bu bölümde kullanılan farklı ölçüm metrikleri hakkında detaylı bilgi verilecektir.

#### **3.5.1 Hamming Loss**

Hamming Loss (HL), çok etiketli sınıflandırma modellerinin performansını değerlendirmek için kullanılan bir ölçüm tekniğidir. Model tarafından yanlış tahmin edilen etiketlerin oranını ölçer. HL değeri sıfır ile bir arasında değişir; burada sıfır, modelin hiçbir yanlış tahminde bulunmadığını gösterirken bir ise model tarafından yapılan tüm tahminlerin yanlış olduğunu gösterir. Bir kayıp fonksiyonu olduğu için amaç, HL değerini en aza indirmektir, bu nedenle optimal değer sıfırdır. Başka bir deyişle, HL değeri sıfıra ne kadar yakınsa, modelin performansının da o kadar iyi olduğu kabul edilir. HL, tahminlerin güvenilirliğini değil, yalnızca etiket tahminlerini dikkate aldığından, modelin performansını kapsamlı bir şekilde anlamak için diğer değerlendirme ölçümleriyle birlikte kullanılmalıdır. HL değerinin nasıl elde edildiği denklem 3.1’de gösterilmiştir.

$$HL = \frac{1}{|N| \cdot |L|} \sum_{l=1}^L \sum_{i=1}^N Y_{i,l} \oplus X_{i,l} \quad (3.1)$$

### 3.5.2 Micro-Averaged Precision

Micro-Averaged Precision (MicroP), bir modelin performansını değerlendirmek için çok etiketli sınıflandırmada kullanılan bir değerlendirme tekniğidir. Tüm sınıflarda modelin genel kesinliğini ölçer. Mikro ortalama kesinliği hesaplamak için, önce her sınıf için ayrı ayrı gerçek pozitif ve yanlış pozitif sayıları hesaplanır. Ardından, toplam gerçek pozitif sayı ve toplam yanlış pozitif sayı elde etmek için bu sayımlar tüm sınıflarda toplanır. Bu metrik, içerdikleri örnek sayısına bakılmaksızın tüm sınıflara eşit ağırlık verir. Amaç genel hataları en aza indirmek olduğunda ve sınıf dağılımı dengesiz olduğunda kullanışlıdır. MicroP değerinin nasıl elde edildiği denklem 3.2’de gösterilmiştir.

$$MicroP = \frac{\sum_{c_i \in C} TP_S(c_i)}{\sum_{c_i \in C} TP_S(c_i) + FP_S(c_i)} \quad (3.2)$$

### 3.5.3 Macro-Averaged Precision

Makro-ortalama kesinlik, sınıf başına ortalama kesinliği ifade eder. Makro ortalama kesinliği bulmak için, önce her sınıfın kesinliği hesaplanır. MacroP değeri daha sonra tüm kesinliklerin ortalaması alınarak elde edilir. MacroP değerinin nasıl elde edildiği denklem 3.3’de gösterilmiştir.

$$MacroP = \frac{\sum_{c_i \in C} P(D, c_i)}{|C|} \quad (3.3)$$

### 3.5.4 Micro-Averaged Recall

Mikro-ortalama duyarlılık, sınıf başına ortalama duyarlılığı ölçer. MicroR’yi hesaplamak için, önce her sınıfın hatırlama değeri hesaplanır. Daha sonra bulunan tüm duyarlılık değerlerinin ortalaması alınarak MicroR değeri hesaplanır. MicroR değerinin nasıl elde edildiği denklem 3.4’te gösterilmiştir.

$$MicroR = \frac{\sum_{c_i \in C} TP_S(c_i)}{\sum_{c_i \in C} TP_S(c_i) + FN_S(c_i)} \quad (3.4)$$

### 3.5.5 Macro-Averaged Recall

Makro-ortalama duyarlılık, sınıf başına ortalama hatırlama anlamına gelir. MacroR'yi hesaplamak için, önce her bir sınıfın hatırlanması hesaplanmalıdır. MacroR daha sonra tüm geri çağırılmaların ortalaması alınarak elde edilir.

$$MacroR = \frac{\sum_{c_i \in C} R(D, c_i)}{|C|} \quad (3.5)$$

### 3.5.6 Micro-F1 Score

Mikro-ortalama F1 puanı, tüm sınıfların toplu katkılarının F1 skorunu gösterir. Mikro-ortalama F1 puanı, önce tüm etiketler üzerinden tüm gerçek pozitiflerin, yanlış pozitiflerin ve yanlış negatiflerin toplamı hesaplanarak elde edilir. Ardından, MicroP ve MicroR toplamlardan hesaplanır. MicroF1 skorunun nasıl elde edildiği denklem 3.6'da gösterilmiştir.

$$MicroF1 = 2 \cdot \frac{MicroP \cdot MicroR}{MicroP + MicroR} \quad (3.6)$$

### 3.5.7 Macro-F1 Score

Makro-ortalama F1 skoru, etiket bazında F1 skorlarının ortalamasını gösterir. Makro-F1 puanı, önce etiket başına F1 puanı hesaplanarak ve ardından bunların ortalaması alınarak elde edilir. Macro-F1 skorunun nasıl elde edildiği denklem 3.7'de gösterilmiştir.

$$MacroF1 = \frac{1}{N} \sum_{i=0}^N F1 \quad (3.7)$$

## 4. TEZ AŞAMISINDA YÜRÜTÜLEN ÇALIŞMALAR

### 4.1. Kullanılan Araçlar ve Kütüphaneler

#### 4.1.1 Python

Python, ilk olarak 1991 yılında Guido van Rossum tarafından piyasaya sürülen genel amaçlı bir programlama dilidir. Okuması ve yazması kolay sözdizimi, üst düzey işlevsellik ve geniş kullanım yelpazesi ile bilinir. Python veri analizi, makine öğrenimi, web uygulamaları ve oyun geliştirme alanlarında yaygın olarak kullanılmaktadır.

Python'un en temel özelliklerinden bir tanesi, okunabilirliği ve basitliğidir. Bu özellik Python'u hem yeni başlayanlar hem de deneyimli programcılar için ideal bir dil yapmaktadır. Öğrenmesi ve anlaması daha kolay olduğu için eğitim amaçlı olarak da popüler bir seçimdir.

Python birçok platformda çalışmayı destekleyen bir yapıya sahiptir. Windows, Mac ve Linux gibi çeşitli işletim sistemleriyle uyumludur. Ayrıca veri görselleştirme, doğal dil işleme ve web kazıma gibi çeşitli görevler için kullanılabilen çok çeşitli kütüphaneleri ve araçları desteklemektedir.

#### 4.1.2 Pytorch

PyTorch, Facebook Yapay Zeka Araştırma ekibi tarafından geliştirilen, Python için açık kaynaklı bir makine öğrenimi kütüphanesidir. İlk olarak 2016'da piyasaya sürülmüştür ve o zamandan beri derin öğrenme topluluğunda popülerlik kazanmaya devam etmektedir. PyTorch, sinir ağlarının oluşturulmasında ve dağıtılmasında esneklik ve kullanım kolaylığı sağlayan dinamik hesaplamalı grafiğiyle tanınır.

PyTorch'un temel özelliklerinden biri, dinamik hesaplamaları işleme yeteneğidir; bu, kullanıcının bir programın yürütülmesi sırasında grafiği anında değiştirebileceği anlamına gelir. PyTorch'un bu dinamik yapısı, daha sezgisel kodlama ve hata ayıklamaya izin verir ve yeni fikirleri denemeyi kolaylaştırır.

PyTorch, evrişimli sinir ağları, tekrarlayan sinir ağları ve daha fazlası gibi görevler için önceden oluşturulmuş çeşitli modüller dahil olmak üzere sinir ağları oluşturmak

ve eğitmek için çok çeşitli araçlar sağlar. Ayrıca, büyük sinir ağları için eğitim sürecini önemli ölçüde hızlandırabilen CUDA ve diğer GPU hızlandırma kütüphaneleri için destek içerir.

PyTorch ayrıca NumPy, pandas ve scikit-learn gibi diğer popüler Python kitaplıklarıyla entegre olur ve bu da mevcut kod ve verilerin PyTorch ekosistemine kolay entegrasyonuna olanak tanır.

### **4.1.3 Tensorflow**

TensorFlow, Google Beyin Takımı tarafından geliştirilen açık kaynaklı bir makine öğrenimi kütüphanesidir. İlk olarak 2015 yılında yayınlanmıştır ve o zamandan beri en popüler derin öğrenme kütüphanelerinden biri haline gelmiştir. TensorFlow, büyük ölçekli hesaplamalar gerçekleştirme yeteneği ve Python, C++, Java ve diğerleri gibi çeşitli programlama dillerini desteklemesi özelliklerine sahiptir.

TensorFlow'un temel özelliklerinden biri, statik bir hesaplama grafiği kullanmasıdır; bu, kullanıcının bir programın yürütülmesinden önce hesaplama grafiğini tanımlaması anlamına gelir. TensorFlow grafiği önceden derleyebildiği ve hesaplamaları daha verimli bir şekilde planlayabildiği için daha iyi optimizasyon ve performans sağlamaktadır. TensorFlow ayrıca, büyük modeller için eğitim sürecini büyük ölçüde hızlandırabilen birden fazla cihaz ve sunucu arasında dağıtılmış hesaplama için izin verir.

TensorFlow, evrişimli sinir ağları, tekrarlayan sinir ağları ve daha fazlası gibi görevler için önceden oluşturulmuş çeşitli modüller dahil olmak üzere sinir ağları oluşturmak ve eğitmek için çok çeşitli araçlar sağlar. Ayrıca, büyük sinir ağları için eğitim sürecini önemli ölçüde hızlandırabilen CUDA ve diğer GPU hızlandırma kütüphaneleri için destek sağlamaktadır.

### **4.1.4 Keras**

Keras, Python'da yazılmış açık kaynaklı bir sinir ağı kütüphanesidir. Derin öğrenme modelleri oluşturmayı, eğitmeyi ve çalıştırmayı kolaylaştırmak için geliştirilmiştir. Keras, TensorFlow, Microsoft Cognitive Toolkit (CNTK) veya Theano gibi diğer derin öğrenme kütüphanelerinin üzerinde çalışabilen üst düzey bir kitaplıktır.

Keras'ın ana özelliklerinden biri, geliştiricilerin temeldeki kütüphanelerin ayrıntılarına dalmak zorunda kalmadan sinir ağı modelleri oluşturmasını ve bunlarla denemeler yapmasını kolaylaştıran kullanıcı dostu API'sidir. Keras ayrıca, bir sinir ağı modeli oluşturmak için kolayca birleştirilebilen tamamen bağlı katmanlar, evrişimli katmanlar ve tekrarlayan katmanlar gibi çok çeşitli önceden oluşturulmuş katmanlar içerir.

Keras ayrıca sinir ağlarını eğitmek ve değerlendirmek için veri ön işleme ve veri artırma işlevleri gibi bir dizi yararlı işlev ve yardımcı program sağlar. Ayrıca geliştirilen modellerde kullanılmak üzere birçok optimizasyon algoritmaları için destek içerir.

#### **4.1.5 Scikit-Learn**

Sklearn olarak da bilinen Scikit-learn, makine öğrenimi için açık kaynaklı bir Python kütüphanesidir. Denetimli ve denetimsiz öğrenme yöntemleri dahil olmak üzere çeşitli makine öğrenimi algoritmalarına basit ve tutarlı bir arabirim sağlamak için geliştirilmiştir. Scikit-learn, NumPy ve pandas gibi diğer popüler Python kütüphanelerinin üzerine inşa edilmiştir ve Python'un bilimsel bilgi işlem ekosistemiyle uyumludur.

Scikit-learn'ün ana özelliklerinden biri, doğrusal regresyon, k-means kümeleme, RF ve SVM gibi popüler modeller dahil olmak üzere çok çeşitli makine öğrenimi algoritmalarını barındırmasıdır. Kütüphane ayrıca çapraz doğrulama gibi model seçimi araçları ve ön işleme ve özellik çıkarma araçları içerir.

Scikit-Learn ayrıca, farklı algoritmaların kolayca denemesini ve karşılaştırılmasını sağlayan modeller ve değerlendirme modelleri için tutarlı ve kullanımı kolay bir arayüz sağlar. Bu özellik, en iyi sonuçlar için hızlı yinelemeler ve modellerin ince ayarlanması için önemlidir.

## **4.2. Deneysel Çalışmalar**

Türkçe e-ticaret müşteri yorumlarının çok etiketli analizi, temel olarak klasik bir metin sınıflandırma uygulamasını temel almaktadır. Gerçekleştirilen analizlerde amaç, mevcut müşteri yorumlarının ilgili etiketlerle sınıflandırılmasını en başarılı şekilde gerçekleştirmektir. Müşteri yorumları analiz edilirken literatürde en yaygın sınıflandırma türü olan duygu ya da polarite analizinden farklı olarak öznitelik temelli



bir sınıflandırma uygulamasının geliştirilmesi amaç edinilmiştir. Mevut çalışmaların çoğu müşteri değerlendirmelerini duygusal olarak pozitif, negatif ya da nötr olarak sınıflandırırken, bu çalışmada müşteri yorumları özellik tabanlı sınıflandırılmıştır. Bu amaç doğrultusunda özgün olarak hazırlanan veri seti üzerinde deneysel çalışmalar dört farklı çalışma alt grubu içerisinde gerçekleştirilmiştir.

#### **4.2.1. TF-IDF ve Makine Öğrenimi Kullanımı**

İlk deneysel çalışma olarak veri setleri üzerinde klasik TF-IDF ve makine öğrenimi algoritmaları uygulanmıştır. Deneysel çalışma, her bir veri seti için ayrı olarak gerçekleştirilmiştir. İlk olarak veri setleri önışlem adımından geçirilmiştir. Ardından TF-IDF yöntemi kullanılarak verilerin sayısal gösterimi elde edilmiştir. Veriler eğitim ve test verileri olarak ayrıldıktan sonra sırayla sınıflandırma için seçilen algoritmalarından faydalanılarak eğitim verileri eğitilmiştir.

Eğitim aşaması için temel olarak üç farklı yaklaşımda bulunulmuştur. Bunlar sırası ile BR, ML-kNN ve OvR teknikleridir. ML-kNN, en yakın komşuluk esasına dayalı, çok etiketli sınıflandırmalar için geliştirilen bir modeldir. BR ve OvR ise çok etiketli sınıflandırma görevini ikili sınıflandırma parçacıklarına bölerek çok etiketli sınıflandırma gerçekleştiren yöntemlerdir. Bununla birlikte, eğitim esnasında ekstra bir sınıflandırıcıya ihtiyaç duymaktadırlar. Bu aşamada eğitimleri gerçekleştirebilmek için BR yöntemi RF, SVC ve NB sınıflandırıcıları ile kullanılırken OvR yöntemi ise XGB, LR, SGD ve SVC sınıflandırıcıları ile kullanılmıştır. Eğitim işleminin tamamlanmasının ardından test işlemi gerçekleştirilmiştir. Elde edilen sonuçlar HL, MicroP, MacroP, MicroR, MacroR, MicroF1 ve MacroF1 değerlendirme metrikleri ile karşılaştırmalı olarak analiz edilmiştir. Elde edilen sonuçlar tezin bulgular bölümünde gösterilmiştir.

#### **4.2.2. Kelime Gömme ve Makine Öğrenimi Kullanımı**

İkinci deneysel çalışma olarak veri setleri üzerinde klasik kelime gömme ve makine öğrenimi algoritmaları uygulanmıştır. Deneysel çalışma, her bir veri seti için ayrı olarak gerçekleştirilmiştir. İlk olarak veri setleri önışlem adımından geçirilmiştir. Ardından farklı kelime yöntemleri kullanılarak verilerin sayısal gösterimi elde edilmiştir. Bu aşamada literatürde mevcut olarak bulunan Türkçe Word2Vec ve

Türkçe GloVe kelime gömme modelleri kullanılmıştır. Veriler eğitim ve test verileri olarak ayrıldıktan sonra sırayla sınıflandırma için seçilen algoritmalarından faydalanılarak eğitim verileri eğitilmiştir.

Eğitim aşaması için temel olarak iki farklı yaklaşımda bulunulmuştur. Bunlar BR ve XGB teknikleridir. BR ve OvR, çok etiketli sınıflandırma görevini ikili sınıflandırma parçacıklarına bölerek çok etiketli sınıflandırma gerçekleştiren yöntemlerdir. Bununla birlikte, eğitim esnasında ekstra bir sınıflandırıcıya ihtiyaç duymaktadırlar. Bu aşamada eğitimleri gerçekleştirebilmek için BR yöntemi RF, OvR yöntemi ise XGB sınıflandırıcıları ile kullanılmıştır. Eğitim işleminin tamamlanmasının ardından test işlemi gerçekleştirilmiştir. Elde edilen sonuçlar HL, MicroP, MacroP, MicroR, MacroR, MicroF1 ve MacroF1 değerlendirme metrikleri ile karşılaştırmalı olarak analiz edilmiştir. Elde edilen sonuçlar tezin bulgular bölümünde gösterilmiştir.

#### **4.2.3. BERT ve Makine Öğrenimi Kullanımı**

İkinci deneysel çalışma olarak veri setleri üzerinde derin öğrenmeye dayalı bir yaklaşım gerçekleştirilmiştir. Deneysel çalışma, her bir veri seti için ayrı olarak gerçekleştirilmiştir. İlk olarak veri setleri önışlem adımından geçirilmiştir. Ardından BERT modeli kullanılarak verilerin sayısal gösterimi elde edilmiştir. Bu çalışma aşamasında BERT modeli, sadece klasik kelime gömme amaçlı ve verilerin özellik çıkarımını gerçekleştirmek amaçlı kullanılmıştır. Bu işlemler için literatürde mevcut olarak bulunan Türkçe BERT modeli kullanılmıştır. Veriler eğitim ve test verileri olarak ayrıldıktan sonra sırayla sınıflandırma için seçilen algoritmalarından faydalanılarak eğitim verileri eğitilmiştir.

Eğitim aşaması için temel olarak iki farklı yaklaşımda bulunulmuştur. Bunlar BR ve XGB teknikleridir. BR ve OvR, çok etiketli sınıflandırma görevini ikili sınıflandırma parçacıklarına bölerek çok etiketli sınıflandırma gerçekleştiren yöntemlerdir. Bununla birlikte, eğitim esnasında ekstra bir sınıflandırıcıya ihtiyaç duymaktadırlar. Bu aşamada eğitimleri gerçekleştirebilmek için BR yöntemi RF, OvR yöntemi ise XGB sınıflandırıcıları ile kullanılmıştır. Eğitim işleminin tamamlanmasının ardından test işlemi gerçekleştirilmiştir. Elde edilen sonuçlar HL, MicroP, MacroP, MicroR, MacroR, MicroF1 ve MacroF1 değerlendirme metrikleri ile karşılaştırmalı olarak analiz edilmiştir. Elde edilen sonuçlar tezin bulgular bölümünde gösterilmiştir.

#### 4.2.4 BERT Fine Tuning

NLP görevlerinde kullanılmak için geliştirilen BERT; isim tanıma, duygu analizi ve metin sınıflandırma gibi birçok doğal dil işleme uygulaması için “fine tuning” yani ince ayar yapılabilir. İnce ayar, BERT modelinin önceden eğitilmiş bir hali ile yeni bir veri kümesi üzerinde eğitilmesi ve daha özel bir amaç için daha ayrıntılı olarak ayarlanması anlamına gelir. Tezi bu aşamasında daha önceden Türkçe veriler üzerinde eğitilen Türkçe BERT modeli oluşturulan müşteri yorumları verileri üzerinde de eğitilerek metin sınıflandırma uygulaması için ince ayarı gerçekleştirilmiştir.

İnce ayar işlemi, BERT modelinin önceden eğitilmiş ağırlıkları kullanması ile başlar ve daha sonra bu ağırlıklar üzerinde yeni veri kümesi üzerinde eğitilir. Bu işlem, BERT modelinin önceden eğitilmiş bilgisini korurken, yeni veri kümesi ile özel bir amaç için daha iyi performans sergilemesini sağlar.

Tez çalışması için oluşturulan üç farklı kategoride BERT modelinin ayrı ayrı ince ayarı gerçekleştirilmiştir. İnce ayarlanması BERT modeli üzerinde gerçekleştirilen sınıflandırma performansı HL, MicroP, MacroP, MicroR, MacroR, MicroF1 ve MacroF1 ölçüm metrikleri ile karşılaştırmalı olarak analiz edilmiştir. Elde edilen sonuçlar tezin bulgular bölümünde gösterilmiştir.

#### 4.2.5. Kelime Gömme ve Derin Sinir Ağı Kullanımı

Beşinci deneysel çalışma olarak veri setleri üzerinde derin öğrenmeye dayalı bir yaklaşım gerçekleştirilmiştir. Deneysel çalışma, her bir veri seti için ayrı olarak gerçekleştirilmiştir. İlk olarak veri setleri ön işlem adımından geçirilmiştir. Ardından farklı kelime yöntemleri kullanılarak verilerin sayısal gösterimi elde edilmiştir. Bu aşamada literatürde mevcut olarak bulunan Türkçe Word2Vec ve Türkçe GloVe kelime gömme modelleri kullanılmıştır. Veriler eğitim ve test verileri olarak ayrıldıktan sonra sırayla sınıflandırma için seçilen algoritmalarından faydalanılarak eğitim verileri eğitilmiştir.

Eğitim aşaması için üç farklı yaklaşımda bulunulmuştur. Bunlar LSTM, Bi-LSTM ve GRU derin sinir ağlarıdır. Eğitim işleminin tamamlanmasının ardından test işlemi gerçekleştirilmiştir. Elde edilen sonuçlar doğruluk ve kayıp değerlendirme metrikleri ile karşılaştırmalı olarak analiz edilmiştir. Elde edilen sonuçlar tezin sonuçlar ve tartışma bölümünde gösterilmiştir.


## 5. SONUÇLAR ve TARTIŞMA

Tezin bu bölümünde deneysel çalışmalarda elde edilen bulgular paylaşılmaktadır.

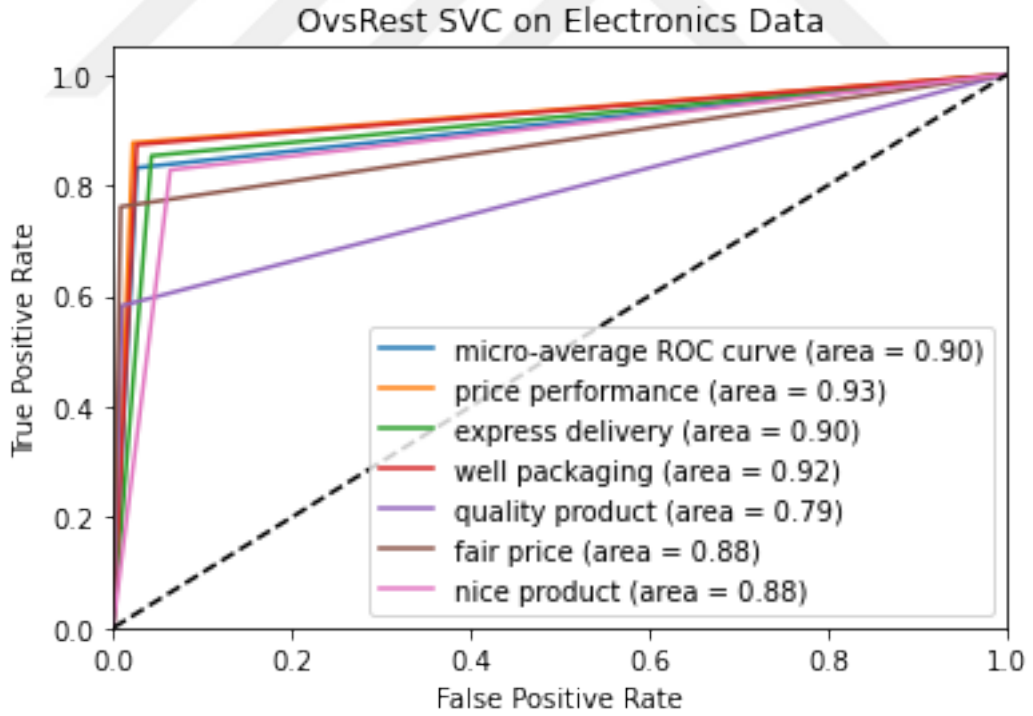
Çizelge 5.1’de elektronik verileri üzerinde, farklı sınıflandırıcılar kullanılarak elde edilen test sonuçları sunulmaktadır. Şekil 5.1, Şekil 5.2 ve Şekil 5.3 ise bu sonuçlara ait ROC eğrilerini göstermektedir.

Çizelge 5.1 İlk deneysel çalışmada elektronik verileri üzerinde elde edilen sonuçlar

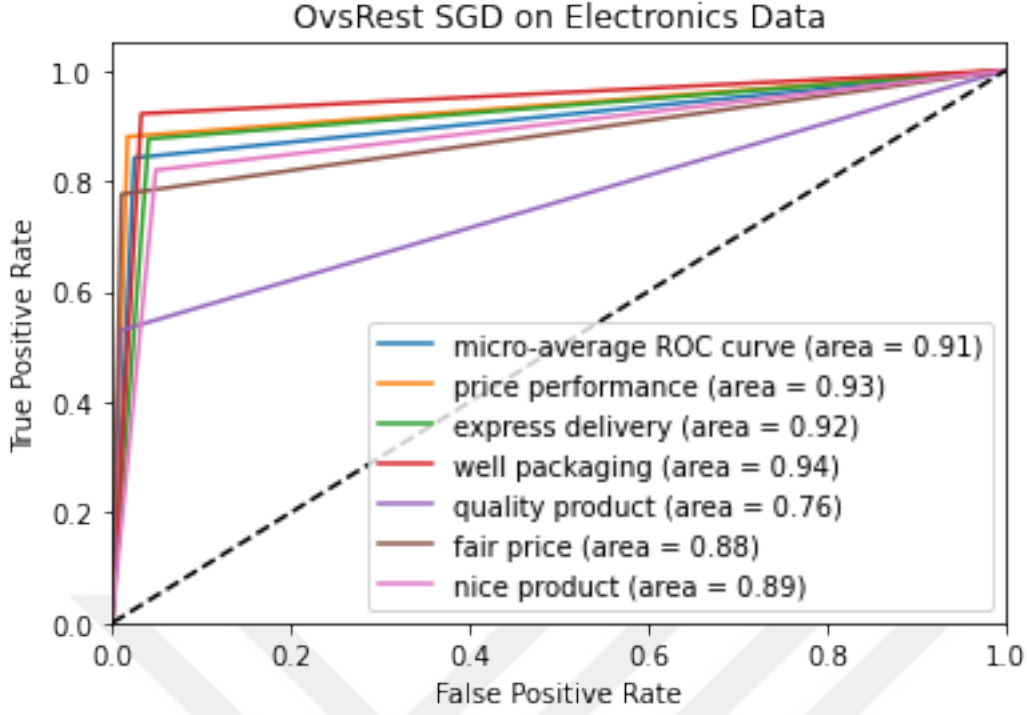
Sınıflandırıcı	HL	MicroF1	MacroF1	MicroP	MacroP	MicroR	MacroR
BR-RF	0.0497	0.8747	0.8532	0.914	0.9102	0.8396	0.8093
BR-SVC	0.05	0.8744	0.8463	0.9094	0.9066	0.8419	0.8022
BR-NB	0.5539	0.3746	0.3631	0.2444	0.2534	0.8026	0.8021
MLkNN	0.0841	0.7853	0.7596	0.8316	0.8196	0.7439	0.7124
OvsR-XGB	0.044	0.8925	0.8779	0.9014	0.896	0.8837	0.8628
OvsR-LR	0.057	0.8533	0.8144	0.9118	0.8963	0.8018	0.7518
OvsR-SGD	0.0529	0.8684	0.8372	0.8941	0.8772	0.8441	0.8056
OvsR-SVC	0.056	0.8598	0.8328	0.8903	0.8779	0.8314	0.7956



Şekil 5.1 OvR-LR elektronik veri seti ROC eğrisi



Şekil 5.2 OvR-SVC elektronik veri seti ROC eğrisi



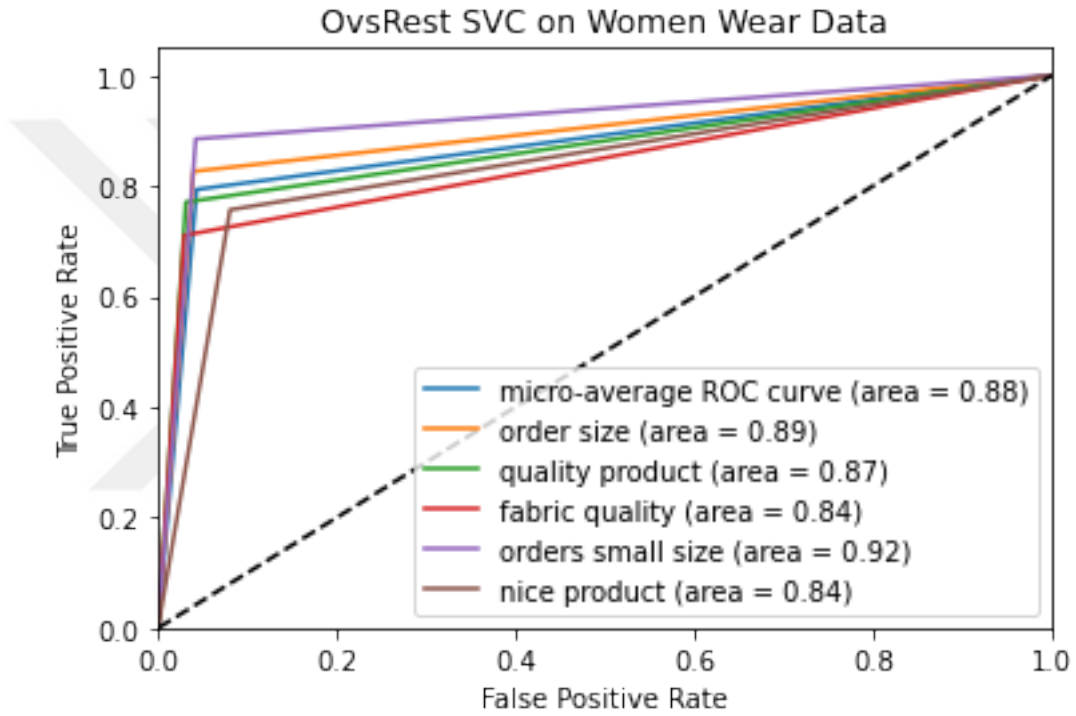
Şekil 5.3 OvR-SGD elektronik veri seti ROC eğrisi

Elde edilen bu sonuçlardan en az kaybın OvR-XGB algoritması ile yakalandığını belirtmektedir. En başarılı Micro-F1 skoru yine OvR-XGB algoritması ile elde edilmiştir. BR-NB metodunun ilgili veri seti üzerinde başarısız bir yaklaşım sergilediği görülmüştür. Elektronik veri seti üzerinde ayrıca OvR-SGD, OvR-SVC ve OvR-LR teknikleri ile ROC analizi gerçekleştirilmiştir. Bu üç yöntem arasında en başarılı sınıflandırma performansını OvR-SGD göstermiştir. ROC eğrileri etiket odaklı analiz edildiğinde, “fiyat performans”, “hızlı kargo”, “iyi paketleme”, “uygun fiyat” ve “güzel ürün” etiketine sahip yorumların başarılı bir şekilde sınıflandırıldığı, “kaliteli ürün” etiketine ait yorumların ise daha düşük oranda etiketlendiği anlaşılmıştır.

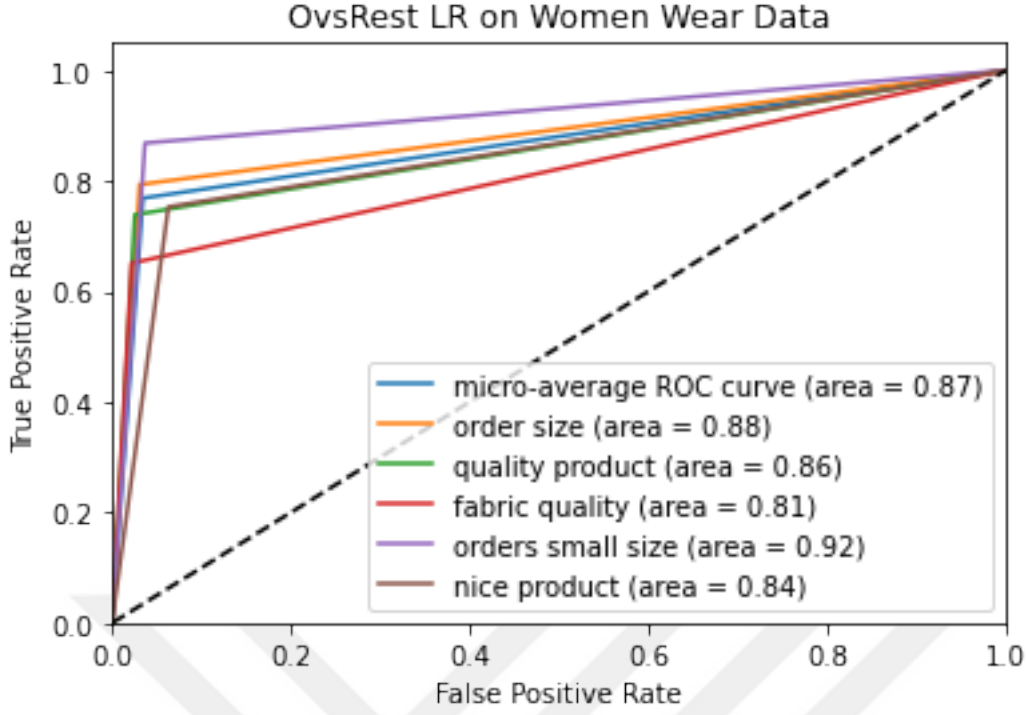
Çizelge 5.2’de kadın giyim verileri üzerinde, farklı sınıflandırıcılar kullanılarak elde edilen test sonuçları sunulmaktadır. Şekil 5.4, Şekil 5.5 ve Şekil 5.6 ise bu sonuçlara ait ROC eğrilerini göstermektedir.

Çizelge 5.2 İlk deneysel çalışmada kadın giyim verileri üzerinde elde edilen sonuçlar

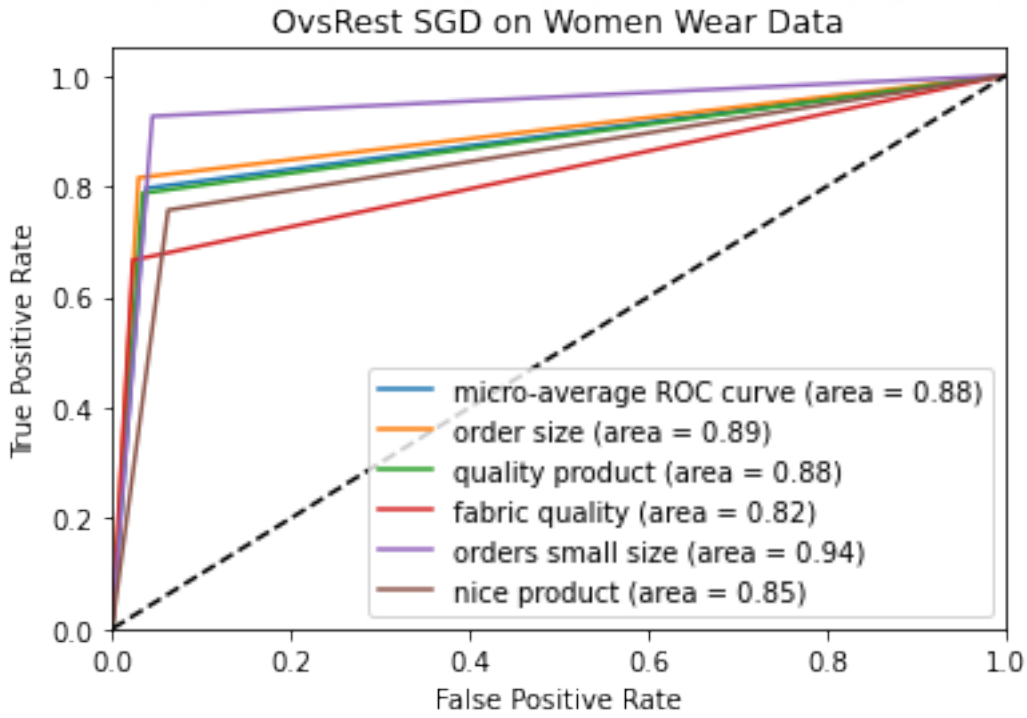
Sınıflandırıcı	HL	MicroF1	MacroF1	MicroP	MacroP	MicroR	MacroR
BR-RF	0.0711	0.8359	0.8281	0.9042	0.905	0.7772	0.7691
BR-SVC	0.0694	0.846	0.8413	0.8769	0.8747	0.8171	0.8133
BR-NB	0.4126	0.441	0.444	0.3223	0.3353	0.6981	0.7077
MLkNN	0.1454	0.6604	0.6536	0.7249	0.7279	0.6065	0.5961
OvsR-XGB	0.0615	0.8679	0.8657	0.8691	0.8666	0.8668	0.8651
OvsR-LR	0.0804	0.8168	0.8101	0.8712	0.8963	0.7687	0.7608
OvsR-SGD	0.0757	0.8327	0.8272	0.8588	0.856	0.8081	0.8031
OvsR-SVC	0.0813	0.8198	0.8164	0.848	0.8464	0.7935	0.7898



Şekil 5.4 OvR-SVC kadın giyim veri seti ROC eğrisi



Şekil 5.5 OvR-LR kadın giyim veri seti ROC eğrisi



Şekil 5.6 OvR-SGD kadın giyim veri seti ROC eğrisi

Elde edilen bulgular, en az kaybın elektronik verilerinde olduğu gibi yine OvR-XGB




algoritması ile yakalandığını belirtmektedir. En başarılı Micro-F1 skoru aynı şekilde OvR-XGB algoritması ile elde edilmiştir. BR-NB metodunun ilgili veri seti üzerinde başarısız bir yaklaşım sergilediği görülmüştür. Kadın giyim veri seti üzerinde ayrıca OvR-SGD, OvR-SVC ve OvR-LR teknikleri ile ROC analizi gerçekleştirilmiştir. ROC analizlerinde, OvR-SGD ve OvR-SVC'nin 0.88 ile eşit başarıyı yakaladığı görülmüştür. ROC eğrileri etiket odaklı analiz edildiğinde, her etiketin benzer oranlarda başarılı bir şekilde sınıflandırıldığı anlaşılmaktadır.


Çizelge 5.3'de ev&yaşam verileri üzerinde, farklı sınıflandırıcılar kullanılarak elde edilen test sonuçları sunulmaktadır. Şekil 5.7, Şekil 5.8 ve Şekil 5.9 ise bu sonuçlara ait ROC eğrilerini göstermektedir.

Çizelge 5. 3 İlk deneysel çalışmada ev&yaşam verileri üzerinde elde edilen sonuçlar


Sınıflandırıcı	HL	MicroF1	MacroF1	MicroP	MacroP	MicroR	MacroR
BR-RF	0.032	0.8631	0.8515	0.9059	0.9128	0.8242	0.8033
BR-SVC	0.029	0.8777	0.8656	0.9063	0.9049	0.8509	0.8324
BR-NB	0.6259	0.2463	0.217	0.1444	0.1354	0.8369	0.798
MLkNN	0.0575	0.7445	0.7599	0.8146	0.8233	0.6854	0.7088
OvsR-XGB	0.0278	0.8862	0.8814	0.8858	0.8815	0.8867	0.8831
OvsR-LR	0.0376	0.8337	0.8	0.907	0.9084	0.7714	0.7195
OvsR-SGD	0.031	0.8702	0.8592	0.8911	0.8866	0.8502	0.8365
OvsR-SVC	0.0336	0.8577	0.847	0.8895	0.885	0.8281	0.8141



Şekil 5.7 OvR-SVC ev&yaşam veri seti ROC eğrisi



Şekil 5.8 OvR-LR ev&yaşam veri seti ROC eğrisi



Şekil 5.9 OvR-SGD ev&yaşam veri seti ROC eğrisi

Elde edilen bulgular, en az kaybın elektronik ve kadın giyim verilerinde olduğu gibi OvR-XGB algoritması ile yakalandığını belirtmektedir. En başarılı Micro-F1 skoru yine OvR-XGB algoritması ile elde edilmiştir. BR-NB metodunun ilgili veri seti üzerinde başarısız bir yaklaşım sergilediği görülmüştür. Ev&yaşam veri seti üzerinde ayrıca OvR-SGD, OvR-SVC ve OvR-LR teknikleri ile ROC analizi gerçekleştirilmiştir. Bu üç yöntem arasında en başarılı sınıflandırma performansını OvR-SGD göstermiştir. ROC eğrileri etiket odaklı analiz edildiğinde, elektronik verilerinde olduğu gibi sınıflandırıcıların performansını düşüren bir etiketin olmadığı tespit edilmiştir. OvR-SVC algoritması, “günlük kullanım” etiketi üzerinde 0.97 oranında ROC skoru elde ederek tüm ROC analizlerindeki en iyi etiketi bazlı ROC skorunu yakalamıştır.

Çizelge 5.4, 5.5 ve 5.6 sırasıyla ikinci ve üçüncü deneysel çalışmalarda elektronik, kadın giyim ve ev&yaşam verileri üzerinde kelime gömme ve dönüşüm tabanlı yaklaşımlar sonucu elde edilen bulguları sunmaktadır.

Çizelge 5. 4 İkinci ve üçüncü yaklaşımda elektronik verileri üzerinde elde edilen sonuçlar

Sınıflandırıcı	HL	MicroF1	MacroF1	MicroP	MacroP	MicroR	MacroR
W2V&BR-RF	0.1144	0.6505	0.5749	0.8651	0.8675	0.5212	0.4546
W2V&XGB	0.1042	0.7119	0.6694	0.8176	0.8171	0.6304	0.5787
GloVe&BR-RF	0.1086	0.6734	0.6173	0.8725	0.8911	0.5483	0.4876
GloVe&XGB	0.0921	0.75	0.7199	0.8412	0.8514	0.6767	0.6329
BERT&BR-RF	0.1125	0.6555	0.5585	0.8837	0.9111	0.5209	0.4355
BERT&XGB	0.0821	0.7812	0.748	0.8637	0.883	0.7131	0.6657

Çizelge 5.5 İkinci ve üçüncü yaklaşımda kadın giyim verileri üzerinde elde edilen sonuçlar

Sınıflandırıcı	HL	MicroF1	MacroF1	MicroP	MacroP	MicroR	MacroR
W2V&BR-RF	0.1565	0.5593	0.5102	0.8101	0.7955	0.427	0.4032
W2V&XGB	0.1406	0.6552	0.6203	0.7623	0.7442	0.5744	0.5496
GloVe&BR-RF	0.1516	0.5734	0.5472	0.8301	0.8272	0.438	0.421
GloVe&XGB	0.1265	0.6991	0.6799	0.7827	0.7757	0.6316	0.614
BERT&BR-RF	0.1443	0.5965	0.5737	0.8503	0.8465	0.4594	0.4438
BERT&XGB	0.1057	0.7522	0.7418	0.8257	0.8251	0.6907	0.6786

Çizelge 5.6 İkinci ve üçüncü yaklaşımda ev&yaşam verileri üzerinde elde edilen sonuçlar

Sınıflandırıcı	HL	MicroF1	MacroF1	MicroP	MacroP	MicroR	MacroR
W2V&BR-RF	0.0822	0.5453	0.5054	0.8498	0.879	0.4015	0.3644
W2V&XGB	0.0717	0.6544	0.6482	0.8017	0.8482	0.5528	0.5347
GloVe&BR-RF	0.0757	0.5898	0.5249	0.8809	0.8835	0.4433	0.3804
GloVe&XGB	0.0606	0.7148	0.6999	0.8466	0.8507	0.6186	0.698
BERT&BR-RF	0.0788	0.5551	0.4201	0.9157	0.9525	0.394	0.2882
BERT&XGB	0.0589	0.7242	0.679	0.8505	0.8502	0.6306	0.5738

İkinci deneysel çalışmada özellik çıkarımı olarak kelime gömme yöntemleri olan Word2Vec ve GloVe, üçüncü deneysel çalışmada ise dönüşüm tabanlı metot olan BERT algoritması kullanılmıştır. BERT algoritmasından bu deneysel yaklaşımda sadece metinsel verileri sayısallaştırmak için klasik kelime gömme tekniklerine benzer şekilde faydalanılmıştır. Elde edilen değerlendirme metriklerine göre her üç veri setinde de en az kayıp BERT&XGB ile elde yakalanmıştır. Bu sonuçlar ilk deneysel

çalışmadaki bulgular ile kıyaslandığında, kelime gömme yöntemlerinin başarımı artırmadığı gözlemlenmiştir.

Çizelge 5.7’de dördüncü deneysel çalışma sonucunda ince ayarlanmış BERT ile elde edilen bulgular sunulmaktadır.

Çizelge 5.7 Dördüncü deneysel çalışmada ince ayarlanmış BERT ile edilen sonuçlar


Veri Seti	HL	MicroF1	MacroF1	MicroP	MacroP	MicroR	MacroR
Elektronik	0.018	0.9563	0.945	0.9474	0.9345	0.9654	0.9564
Kadın giyim	0.0314	0.9332	0.9344	0.9182	0.9226	0.9488	0.9472
Ev&yaşam	0.0133	0.9583	0.9487	0.948	0.9344	0.9689	0.9643

Dördüncü deneysel çalışmada, derin öğrenme algoritmaları her üç veri setine de uygulanmıştır. Çizelge 5.7’de gösterildiği üzere elektronik veri seti için 0.018, kadın giyim veri seti için 0.0315 ve ev&yaşam veri seti için 0.0133 HL değeri elde edilmiştir. Bu sonuçlar, üç veri seti için de, gerçekleştirilen deneysel yaklaşımlarda bulunan en iyi kayıp değerleri olarak elde edilmiştir. MicroF1 skorları ise elektronik verisi için 0.9563, kadın giyim verisi için 0.9332 ve ev&yaşam verisi için 0.9583 olarak bulunmuştur.


Beşinci deneysel çalışmada, yapay derin sinir ağları kullanılarak veri setleri üzerinde çok etiketli analiz gerçekleştirilmiştir. Çizelge 5.8’de beşinci deneysel çalışma sonucu elde edilen sonuçlar gösterilmiştir.

Çizelge 5. 8 Beşinci Deneysel Çalışma Sonucu Elde Edilen Sonuçlar

Metot	Veri Seti	MicroF1	MicroP	MicroR
LSTM	Elektronik	0.914	0.912	0.915
Bi-LSTM	Elektronik	0.915	0.908	0.922
GRU	Elektronik	0.926	0.917	0.935
LSTM	Ev&Yaşam	0.897	0.897	0.896
Bi-LSTM	Ev&Yaşam	0.894	0.901	0.887
GRU	Ev&Yaşam	0.905	0.906	0.904
LSTM	Kadın Giyim	0.901	0.893	0.908
Bi-LSTM	Kadın Giyim	0.897	0.874	0.921
GRU	Kadın Giyim	0.906	0.899	0.914




Şekil 5.10 LSTM-Elektronik Verisi Doğruluk Grafiği




Şekil 5.11 LSTM-Elektronik Verisi Kayıp Grafiği


Çizelge 5.8’de yapay derin sinir ağları kullanılarak elde edilen analiz sonuçları karşılaştırmalı olarak gösterilmiştir. Elde edilen bulgular incelendiğinde her veri seti için en başarılı sonuçların GRU modeli ile elde edildiği görülmüştür.




Şekil 5.12 Bi- LSTM-Elektronik Verisi Doğruluk Grafiği



Şekil 5.13 Bi- LSTM-Elektronik Verisi Kayıp Grafiği




Şekil 5.14 GRU-Elektronik Verisi Doğruluk Grafiği




Şekil 5.15 GRU-Elektronik Verisi Kayıp Grafiği

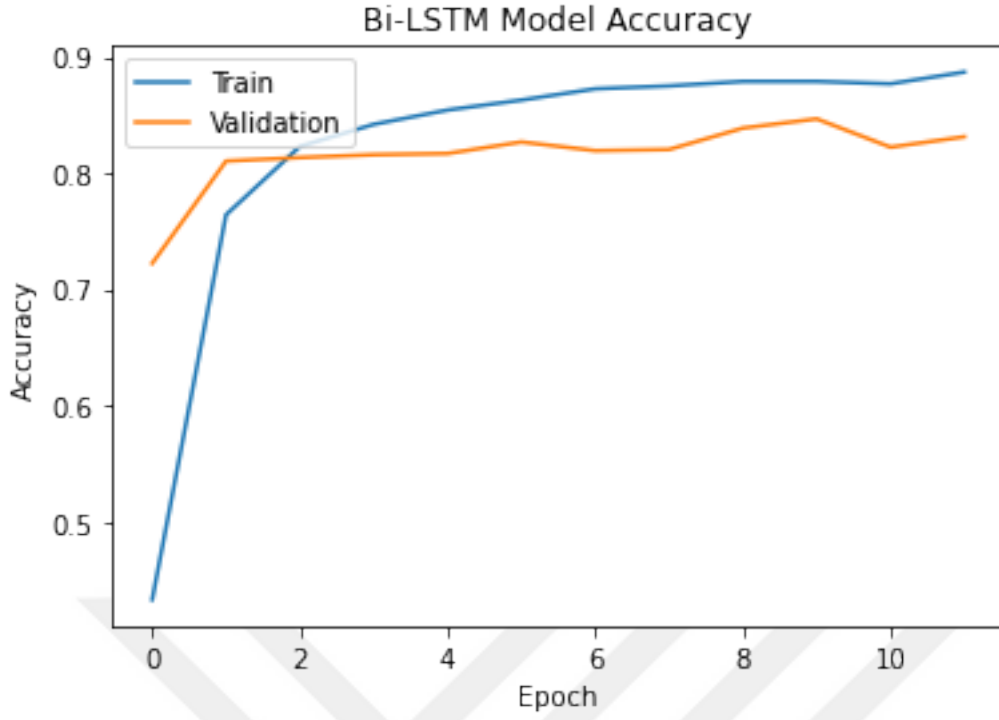




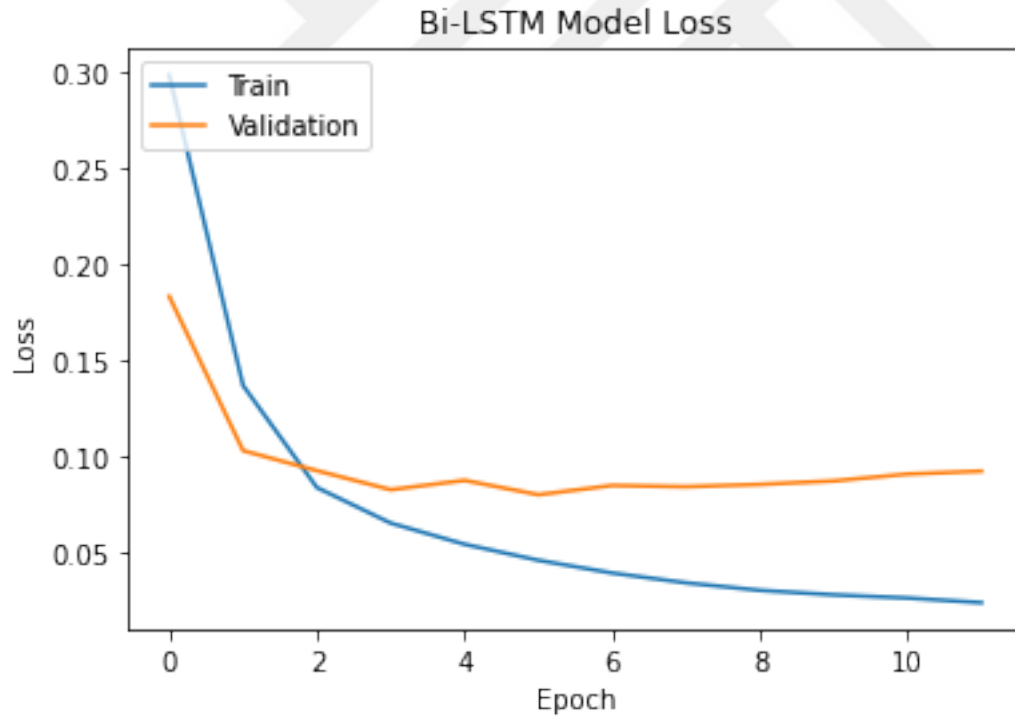
Şekil 5.16 LSTM-Ev&Yaşam Verisi Doğruluk Grafiği



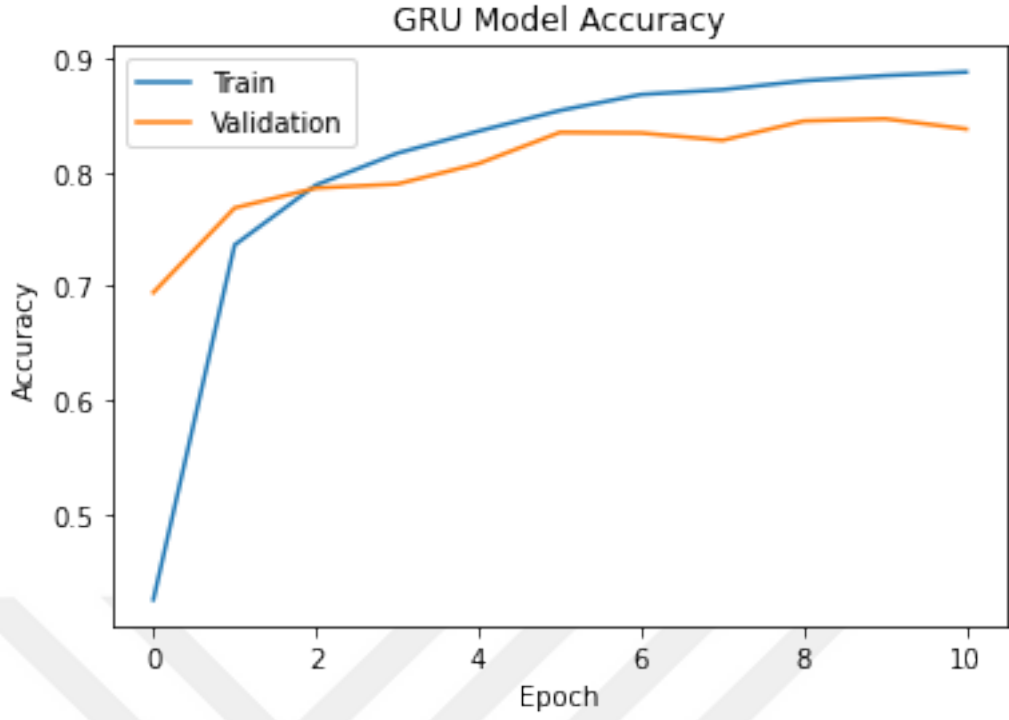
Şekil 5.17 LSTM-Ev&Yaşam Verisi Kayıp Grafiği




Şekil 5.18 Bi-LSTM-Ev&Yaşam Verisi Doğruluk Grafiği




Şekil 5.19 Bi-LSTM-Ev&Yaşam Verisi Kayıp Grafiği




Şekil 5.20 GRU-Ev&Yaşam Verisi Doğruluk Grafiği




Şekil 5.21 GRU-Ev&Yaşam Verisi Kayıp Grafiği




Şekil 5.22 LSTM-Kadın Giyim Verisi Doğruluk Grafiği




Şekil 5.23 LSTM-Kadın Giyim Verisi Kayıp Grafiği



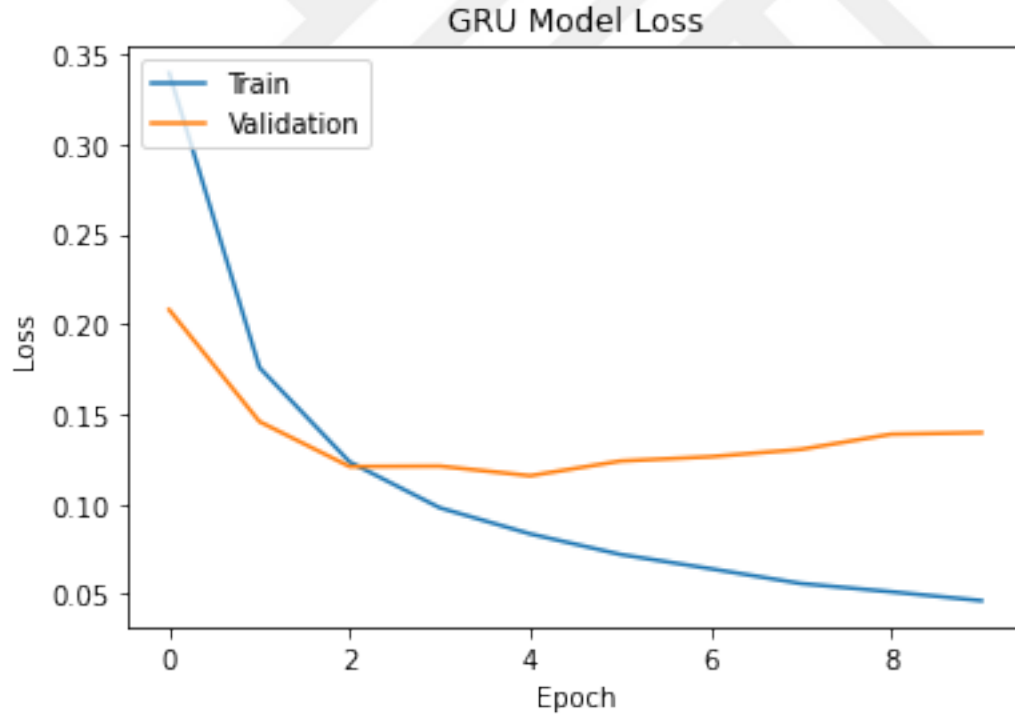
Şekil 5.24 Bi-LSTM-Kadın Giyim Verisi Doğruluk Grafiği



Şekil 5.25 Bi-LSTM-Kadın Giyim Verisi Kayıp Grafiği



Şekil 5.26 GRU-Kadın Giyim Verisi Doğruluk Grafiği



Şekil 5.27 GRU-Kadın Giyim Verisi Kayıp Grafiği

Bu tez çalışmasında, Türkçe e-ticaret müşteri yorumlarının çok etiketli analizi gerçekleştirilmiştir. Bunun için ilk olarak özgün bir veri seti hazırlanmıştır. Mevcut diğer veri setleri ile kıyaslandığı zaman, her üç veri seti içinde bulunan örneklerin sayıca fazla olduğu ve derlem olarak literatüre faydalı bir katkı olarak sunulduğu görülmüştür. Ayrıca derlem içerisinde üç farklı kategoride veri seti bulunması,

analizlerin kategoriler için ayrı ayrı ve etiket bazlı analiz yapılmasına olanak sağlamıştır.

Veri seti elde edildikten sonra sırasıyla klasik yöntemler ve derin öğrenme yöntemleri analizler için kullanılmıştır. Çok etiketli analiz için kullanılan klasik sınıflandırma yöntemleri olan BR ve OvR algoritmalarının en başarılı sonuçları vermese de özellikle parametrelerin düzgün seçildiğinde yeterli sonuçları verdiği görülmüştür. Bununla birlikte adapte edilen bu metotların derin öğrenme tekniklerinin gerisinde kaldığı net bir şekilde görülmüştür. Kelime gömme yaklaşımlarının ise bu veri seti üzerinde başarılı sonuç elde edemediği görülmüştür. Word2Vec ve GloVe özellik kullanılarak elde edilen bulguların, TF-IDF ile elde edilen sonuçlardan daha başarısız olması kelime gömme dil modellerinin oluşturulurken kullanılan kaynakların yetersizliğinden kaynaklanmaktadır. Aynı deneysel çalışmada sadece özellik çıkarımı amaçlı kullanılan BERT'in de yetersiz kaldığı görülmüştür. Bunun en önemli nedeni ise BERT dil modelinin özellik çıkarımından sonra ince ayarlama gereksiniminden kaynaklanmıştır. Nitekim bir sonraki deneysel çalışmada gerçekleştirilen ince ayar BERT yaklaşımı en başarılı sonuçları elde etmiştir.

ROC analizlerinde elde edilen etiket bazlı sonuçlar, veri seti hakkında bazı çıkarımlar yapılmasına olanak sağlamıştır. Nitekim elektronik veri setine ait kaliteli ürün etiketi ile kadın giyim veri setine ait kumaş kalitesi etiketi modellerin başarı oranlarını düşürdüğü gözlemlenmiştir. Veri seti hazırlanırken, özellikle yoğun miktarda veri içeren derlemlerde, insan faktöründen kaynaklanabilecek hatalar göz ardı edilmemelidir. Bu hatalar, modellerin başarı oranını düşürürken aynı zamanda araştırmacılar için yeni çalışmalara da olanak sağlamaktadır. Nitekim bu tez çalışmasında toplanan veriler üzerinde denetimsiz öğrenme algoritmaları ile müşteri yorumları için etiketleme çalışması gerçekleştirilerek daha tutarlı bir veri setinin elde edilmesi sağlanabilir.

Son olarak, elde edilen bulguların insanlar açısından daha kolay anlaşılabilmesi için oluşturulan veri setleri üzerinde açıklanabilir yapay zekâ teknikleri uygulanabilir. Bu yöntemler sayesinde hangi veri seti için hangi kelimelerin daha belirleyici olduğu,, sınıflandırma başarısını etkileyen faktörlerin neler olduğu daha net ve somut bir şekilde ifade edilebilir.

## KAYNAKLAR

Acikalin, U. U., Bardak, B., & Kutlu, M. (2020, October). Turkish sentiment analysis using bert. In *2020 28th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.

Alterkavı, S., & Erbay, H. (2021). Novel authorship verification model for social media accounts compromised by a human. *Multimedia Tools and Applications*, 80(9), 13575-13591.

Al-Rawashdeh, G., Mamat, R., & Abd Rahim, N. H. B. (2019). Hybrid water cycle optimization algorithm with simulated annealing for spam e-mail detection. *IEEE Access*, 7, 143721-143734.

Bilen, B., & Horasan, F. (2021). LSTM network based sentiment analysis for customer reviews. *Politeknik Dergisi*, 1-1.

Chowdhary, K. (2020). *Natural language processing. Fundamentals of artificial intelligence*, 603-649.

Esposito, F., Corazza, A., & Cutugno, F. (2016, December). Topic Modelling with Word Embeddings. In *CLiC-it/EVALITA*.

Fastcompany. En büyük 100 internet şirketi. Mevcut: <https://fastcompany.com.tr/dergi/en-buyuk-100-internet-sirketi-2/> (erişim :22 August 2022).

Gu, T., Xu, G., & Luo, J. (2020). Sentiment analysis via deep multichannel neural networks with variational information bottleneck. *IEEE Access*, 8, 121014-121021.

Guan, Z., Chen, L., Zhao, W., Zheng, Y., Tan, S., & Cai, D. (2016, July). Weakly-Supervised Deep Learning for Customer Review Sentiment Classification. In *IJCAI* (pp. 3719-3725).

Grishman, R. (2015). Information extraction. *IEEE Intelligent Systems*, 30(5), 8-15.

Jabbar, J., Urooj, I., JunSheng, W., & Azeem, N. (2019, May). Real-time sentiment analysis on E-commerce application. In *2019 IEEE 16th International Conference on Networking, Sensing and Control (ICNSC)* (pp. 391-396). IEEE.

Konstantinova, N. (2014, April). Review of relation extraction methods: What is new



out there?. In *International Conference on Analysis of Images, Social Networks and Texts* (pp. 15-28). Springer, Cham.

Kumar, K. S., Desai, J., & Majumdar, J. (2016, December). Opinion mining and sentiment analysis on online customer review. In *2016 IEEE International Conference on Computational Intelligence and Computing Research (ICCCIC)* (pp. 1-4). IEEE.

Lavanya, P. M., & Sasikala, E. (2021, May). Deep learning techniques on text classification using Natural language processing (NLP) in social healthcare network: A comprehensive survey. In *2021 3rd International Conference on Signal Processing and Communication (ICPSC)* (pp. 603-609). IEEE.

Leeuwenberg, A., Vela, M., Dehdari, J., & van Genabith, J. (2016). A minimally supervised approach for synonym extraction with word embeddings. *The Prague Bulletin of Mathematical Linguistics*, 105(1), 111.

Lende, S. P., & Raghuvanshi, M. M. (2016, February). Question answering system on education acts using NLP techniques. In *2016 world conference on futuristic trends in research and innovation for social welfare (Startup Conclave)* (pp. 1-6). IEEE.

Liu, S., Cheng, X., Li, F., & Li, F. (2014). TASC: topic-adaptive sentiment classification on dynamic tweets. *IEEE Transactions on Knowledge and Data Engineering*, 27(6), 1696-1709.

Lopez, A. (2008). Statistical machine translation. *ACM Computing Surveys (CSUR)*, 40(3), 1-49.

Medhat, W., Hassan, A., & Korashy, H. (2014). Sentiment analysis algorithms and applications: A survey. *Ain Shams engineering journal*, 5(4), 1093-1113.

Miyoshi, T., & Nakagami, Y. (2007, October). Sentiment classification of customer reviews on electric products. In *2007 IEEE International Conference on Systems, Man and Cybernetics* (pp. 2028-2033). IEEE.

Muslim, M. A. (2020). Support vector machine (svm) optimization using grid search and unigram to improve e-commerce review accuracy. *Journal of Soft Computing Exploration*, 1(1), 8-15.

Nadeau, D., & Sekine, S. (2007). A survey of named entity recognition and classification. *Lingvisticae Investigationes*, 30(1), 3-26.

Nasdaq. UK Online Shopping and E-Commerce Statistics for 2017. Available online: <https://www.nasdaq.com/articles/uk-online-shopping-and-e-commerce-statistics-2017-2017-03-14> (accessed on 4 August 2022).

Nasukawa, T., & Yi, J. (2003, October). Sentiment analysis: Capturing favorability using natural language processing. In *Proceedings of the 2nd international conference on Knowledge capture* (pp. 70-77).

Ozyurt, B., & Akcayol, M. A. (2021). A new topic modeling based approach for aspect extraction in aspect based sentiment analysis: SS-LDA. *Expert Systems with Applications*, 168, 114231.

Parveen, N., Santhi, M. V. B. T., Burra, L. R., Pellakuri, V., & Pellakuri, H. (2021). Women's e-commerce clothing sentiment analysis by probabilistic model LDA using R-SPARK. *Materials Today: Proceedings*.

Rusli, A., Young, J. C., & Iswari, N. M. S. (2020, July). Identifying fake news in Indonesian via supervised binary text classification. In *2020 IEEE International Conference on Industry 4.0, Artificial Intelligence, and Communications Technology (IAICT)* (pp. 86-90). IEEE.

Santur, Y. (2019, September). Sentiment analysis based on gated recurrent unit. In *2019 International Artificial Intelligence and Data Processing Symposium (IDAP)* (pp. 1-5). IEEE.

Schmid, H. (1994). Part-of-speech tagging with neural networks. *arXiv preprint cmp-lg/9410018*.

Shehnepoor, S., Salehi, M., Farahbakhsh, R., & Crespi, N. (2017). NetSpam: A network-based spam detection framework for reviews in online social media. *IEEE Transactions on Information Forensics and Security*, 12(7), 1585-1595.

Shoja, B. M., & Tabrizi, N. (2019). Customer reviews analysis with deep neural networks for e-commerce recommender systems. *IEEE access*, 7, 119121-119130.

Soon, W. M., Ng, H. T., & Lim, D. C. Y. (2001). A machine learning approach to coreference resolution of noun phrases. *Computational linguistics*, 27(4), 521-544.

Tas, O., & Kiyani, F. (2007). A survey automatic text summarization. *PressAcademia Procedia*, 5(1), 205-213.

- Tripathi, P., Singh, S., Chhajer, P., Trivedi, M. C., & Singh, V. K. (2020). Analysis and prediction of extent of helpfulness of reviews on E-commerce websites. *Materials Today: Proceedings*, 33, 4520-4525.
- Tsoumakas, G., & Katakis, I. (2007). Multi-label classification: An overview. *International Journal of Data Warehousing and Mining (IJDWM)*, 3(3), 1-13.
- Vanaja, S., & Belwal, M. (2018, July). Aspect-level sentiment analysis on e-commerce data. In *2018 International Conference on Inventive Research in Computing Applications (ICIRCA)* (pp. 1275-1279). IEEE.
- Vural, A. G., Cambazoglu, B. B., Senkul, P., & 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* (pp. 437-445). Springer, London.
- Yu, D., & Deng, L. (2012). *Automatic speech recognition* (Vol. 1). Berlin: Springer.
- Zhang, S., Zhang, D., Zhong, H., & Wang, G. (2020). A multiclassification model of sentiment for E-commerce reviews. *IEEE Access*, 8, 189513-189526.
- WPForms. 68 Useful eCommerce Statistics You Must Know in 2022. Available online: <https://wpforms.com/ecommerce-statistics/> (accessed on 4 August 2022).
- Xu, F., Pan, Z., & Xia, R. (2020). E-commerce product review sentiment classification based on a naïve Bayes continuous learning framework. *Information Processing & Management*, 57(5), 102221.
- Xu, P., & Sarikaya, R. (2013, December). Convolutional neural network based triangular crf for joint intent detection and slot filling. In *2013 ieee workshop on automatic speech recognition and understanding* (pp. 78-83). IEEE.