



**ELEKTRİKLİ ARAÇLARIN OTOMOTİV EKOSİSTEMİNE ETKİSİ:
DUYGU ANALİZİ ÇALIŞMASI**

Can AKÇELİK

**YÜKSEK LİSANS TEZİ
YÖNETİM BİLİŞİM SİSTEMLERİ
GAZİ ÜNİVERSİTESİ
BİLİŞİM ENSTİTÜSÜ**

TEMMUZ 2025

ETİK BEYAN

Gazi Üniversitesi Bilişim 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.

Can AKÇELİK

...../...../.....

ELEKTRİKLİ ARAÇLARIN OTOMOTİV EKOSİSTEMİNE ETKİSİ: DUYGU ANALİZİ ÇALIŞMASI

(Yüksek Lisans Tezi)

Can AKÇELİK

GAZİ ÜNİVERSİTESİ

BİLİŞİM ENSTİTÜSÜ

Temmuz 2025

ÖZET

Sosyal medya platformları kullanıcı sayılarının hızla artması ile birlikte ortaya çıkan yorum ve fikirlerin sayısı da artmaktadır. Bireylerin rahatça kendilerini ve düşüncelerini ifade ettikleri sosyal medya platformları duygu analizi çalışmalarına alternatif bir kaynak olarak kendine yer edinmiştir. X platformu fikirsel argümanların yoğun olarak yazılı bir şekilde paylaşıldığı bir sosyal medya platformu olduğu için çalışmamızda tercih edilmiştir. Yeni oluşan her durum gibi kullanıcıların tedirgin ve ihtiyatlı olduğu elektrikli araç ekosistemi hakkında yapılan paylaşımlar çeşitlilik göstermektedir. Bu doğrultuda, Türkçe sosyal medya verileri üzerinde duygu analizi gerçekleştirmek üzere BERT tabanlı bir derin öğrenme modeli geliştirilmiştir. Model, olumlu ve olumsuz olarak etiketlenmiş Türkçe cümlelerden oluşan bir veri kümesiyle ince ayar (fine-tuning) yapılarak eğitilmiştir. Eğitim sürecinin ardından, 2024 yılı boyunca Twitter platformunda elektrikli araçlarla ilgili olarak paylaşılan Toplam 183.761 adet tweet ay bazında toplanmış ve geliştirilen model aracılığıyla duygu analizine tabi tutulmuştur. Geliştirilen model, test verisi üzerinde pozitif sınıfı ayırt etmede daha başarılı sonuçlar göstermiştir. F1-skoru pozitif sınıf için yaklaşık 0.94, negatif sınıf için ise 0.90 olarak hesaplanmıştır. Bu sonuçlar, modelin sosyal medyada olumlu ve olumsuz duyguları ayrıştırmada yüksek doğrulukla çalıştığını göstermektedir. Analiz sonuçlarına göre, elektrikli araçlarla ilgili kamuoyundaki genel yaklaşımın çoğunlukla olumsuz olduğu tespit edilmiştir. Ancak bazı dönemlerde olumsuz duyguların azaldığı gözlemlenmiş ve bu değişimlerin fiyat politikaları, sektörel değişimler ve ulusal basına ve sosyal medyaya yansıyan haberler gibi faktörlerle ilişkili olduğu değerlendirilmiştir. Elde edilen duygu eğilimleri ayrıca aynı döneme ait elektrikli araç satış verileri ile karşılaştırılarak sosyal medya algısı ile tüketici davranışları arasındaki olası ilişkiler incelenmiştir. Çalışma sonucunda sosyal medyadaki olumlu duygu yoğunluğunun bazı dönemlerde satış artışlarıyla örtüştüğü gözlemlenmiş, böylece sosyal medya verileri kullanılarak yapılan duygu analizlerinin pazar eğilimlerini öngörmeye ve bir karar destek sistemi olarak kullanılabileceğine dair bulgular elde edilmiştir.

Bilim Kodu : 20516

Anahtar Kelimeler : BERT, Türkçe Duygu Analizi, Elektrikli Araçlar, Sosyal Medya, Doğal Dil İşleme, Satış Verisi

Sayfa Adedi : 116

Danışman : Doç. Dr. Tahsin ÇETİNYOKUŞ

THE IMPACT OF ELECTRIC VEHICLES ON THE AUTOMOTIVE ECOSYSTEM:
A SENTIMENT ANALYSIS STUDY

(M. Sc. Thesis)

Can AKÇELİK

GAZİ UNIVERSITY
INSTITUTE OF INFORMATICS

July 2025

ABSTRACT

With the rapid increase in the number of social media users, the volume of opinions and comments shared has also grown significantly. Social media platforms, where individuals can freely express themselves and their thoughts, have become alternative sources for sentiment analysis studies. Platform X was chosen for this study because it is a social media platform where opinion-based arguments are predominantly shared in written form. As with any newly emerging topic, public discourse on the electric vehicle ecosystem—where users often express caution and uncertainty—exhibits a wide range of sentiments. In this context, a BERT-based deep learning model was developed to perform sentiment analysis on Turkish social media data. The model was fine-tuned using a dataset consisting of Turkish sentences labeled as positive or negative. Following the training process, a total of 183,761 tweets related to electric vehicles shared throughout 2024 on the Twitter platform were collected on a monthly basis and analyzed using the developed model. The model showed better performance in identifying the positive class on the test dataset. The F1-score was calculated to be approximately 0.94 for the positive class and 0.90 for the negative class. These results indicate that the model performs with high accuracy in distinguishing between positive and negative sentiments on social media. According to the analysis results, public sentiment regarding electric vehicles was found to be predominantly negative. However, a decrease in negative sentiment was observed during certain periods, which was assessed to be linked to factors such as pricing policies, industry changes, and news reflected in national media and social platforms. The resulting sentiment trends were also compared with electric vehicle sales data from the same period to examine potential correlations between social media perception and consumer behavior. The study found that periods of increased positive sentiment on social media sometimes coincided with rising sales figures, suggesting that sentiment analysis based on social media data can be used to forecast market trends and serve as a decision support tool.

Science Code : 20516

Key Words : BERT, Turkish Sentiment Analysis, Electric Vehicles, Social Media, Natural Language Processing, Sales Data

Page Number : 116

Supervisor : Assoc. Prof. Dr. Tahsin ÇETİNYOKUŞ

TEŞEKKÜR

Tez çalışmam boyunca kıymetli bilgi, birikim ve tecrübeleri ile bana her daim yol gösteren değerli danışman hocam sayın Doç. Dr. Tahsin ÇETİNYOKUŞ'a ve çalışmam boyunca ilgi ve desteğini esirgemeyen değerli hocam Arş. Gör. Metin İFRAZ'a teşekkür ve saygılarımı sunarım.

İki cihandaki eşim Ayşe Eslem TİKTAŞ AKÇELİK'e hayatıma girdiği andan itibaren artan desteğinin yanında tez çalışmam için verdiği motivasyon ve desteği için teşekkürlerimi sunarım. Bugünlere gelebilmemde çok büyük payı olan babacığım Mevlüt AKÇELİK, annceğim Nezihat AKÇELİK ve kıymetli ablam Ceyda Hilal AKÇELİK'e teşekkürlerimi sunmaktan mutluluk duyarım.

Bu yolculuk boyunca hikayemden kesitler dinleyen, bana yoldaşlık, arkadaşlık ve ötesi kardeşlik yapan tüm çalışma arkadaşlarıma teşekkürü borç bilirim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	viii
ŞEKİLLERİN LİSTESİ.....	ix
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ	1
2. DUYGU ANALİZİ.....	5
2.1. Duygu Analizine Genel Bir Bakış.....	5
2.2. Duygu Analizi için Yaklaşımlar	6
2.2.1. Sözlük tabanlı yaklaşım (Lexicon-Based Approach).....	7
2.2.2. Makine öğrenmesi yaklaşımı (Machine Learning Approach).....	8
2.2.3. Derin öğrenme metodu (Deep Learning Method)	10
2.2.4. Hibrit Yaklaşım	11
3. DERİN ÖĞRENME KULLANILARAK DUYGU ANALİZİ	13
3.1. Evrimsel Sinir Ağları (CNN).....	13
3.2. Yinelemeli Sinir Ağları (RNN)	14
3.3. Kapılı Yinelemeli Sinir Ağları (GRNN)	16
3.4. Uzun kısa dönem bellek (LSTM) ve kapılı sinir ağı (GRU)	16
3.5. Transformer Tabanlı Sinir Ağları	19
3.5.1. BERT (Transformer Tabanlı İki Yönlü Kodlayıcı Temsilleri)	26
4. PERFORMANS ÖLÇÜM YÖNTEMLERİ.....	31
5. KELİME TEMSİL YÖNTEMİ.....	33
6. LİTERATÜR TARAMASI.....	37
7. UYGULAMA.....	55
7.1. Veri Toplama.....	55
7.2. Veri Ön işleme.....	56
7.3. BERT ile Duygu Analizi	59
8. BULGULAR VE DEĞERLENDİRME.....	63

9. SINIRLILIKLAR.....	67
10. SONUÇ VE ÖNERİLER	69
KAYNAKLAR.....	72
ÖZGEÇMİŞ.....	82



ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 4.1. Hata matris gösterimi.....	32
Çizelge 4.2. Sınıflandırma performansı ölçüm yöntemleri.....	32
Çizelge 6.1. Farklı modellerin değerleri.....	46
Çizelge 6.2. Literatür tablosu.....	53
Çizelge 7.1. BERT modeli teknik verileri.....	61
Çizelge 8.1. Pearson korelasyon analizi.....	65
Çizelge 8.2. Pearson korelasyon analizi.....	66

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Duygu Analizi Yaklaşımları.....	7
Şekil 3.1. Cümle sınıflandırma için kullanılan CNN mimarisi örneği	14
Şekil 3.2. RNN mimarisi.....	15
Şekil 3.3. LSTM modeli.....	17
Şekil 3.4. GRU modeli.....	18
Şekil 3.5. Dikkat mekanizmalı S2S(girdi-girdi) kodlayıcı-çözücü mimarisi	21
Şekil 3.6. Kendiliğinden Dikkat Mimarisi	23
Şekil 3.7. Kodlayıcı Blok Mimarisi	24
Şekil 3.8. Çözümleyici Mimarisi	24
Şekil 3.9. Dönüştürücü Mimarisi	25
Şekil 3.10. Veri ön işleme süreçleri	28
Şekil 3.11. BERT modelinin genel süreci.....	29
Şekil 5.1. CBOW ve Skip-gram mimarisi	33
Şekil 5.2. Kosinüs benzerliğine göre anlamsal yakınlık	34
Şekil 6.1. “Google Trends”, “Sentiment Analysis” çalışma alanını gösteren veriler ...	37
Şekil 6.2. “Google Trends”, “Duygu Analizi” çalışma alanını gösteren veriler.....	37
Şekil 7.1. Aylık bazda çekilen tweet sayısı.....	55
Şekil 7.2. Veri ön işleme Örneği.....	58
Şekil 7.3. BERT modelinin teknik verileri	61
Şekil 7.4. Hata matrisi.....	62
Şekil 8.1. Yıllık duygu analizi sonucu	63
Şekil 8.2. Yıllık duygu analizi olumlu sonucu.....	64
Şekil 8.3. Yıllık satış rakamları.....	64

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

m^3

Açıklamalar bir satırdan uzun olmamalıdır

m^2

Metrekare

Kısaltmalar

Açıklamalar

AI

Yapay Zeka

BERT

Transformatörlerden Çift Yönlü Kodlayıcı Gösterimleri

Bİ-LSTM

İki Yönlü Uzun Kısa-Dönem Belleği

Bİ-GRU

İki Yönlü Kapılı Yinelemeli Ünite

CNN

Evrişimli Sinir Ağları

CBOW

Sürekli Kelime Torbası

DDİ

Doğal Dil İşleme

GPT

Üretici Ön-Eğilimli Döbüştürücü

TF-IDF

Terim Frekansı-Ters Belge Frekansı

GRU

Kapılı Yinelemeli Ünite

GRNN

Kapılı Yinelemeli Sinir Ağları

LSTM

Uzun Kısa-Dönem Belleği

LSVM

Doğrusal Destek Vektör Makinesi

MLM

Maskeleme Temelli Dil Modellemesi

NLP

Diğer Doğal Dil İşleme

RF

Rastgele Orman

RNN

Tekrarlayan Sinir Ağları

S2S

Sıralıdan Sıralıya

1. GİRİŞ

Günümüzde internetin mobil cihazlar vasıtasıyla yayılması sonucu bireylerin sürekli iletişim halinde olma imkânı vardır. Bu durum zaman içerisinde duygu ve ifadelerin aktarıldığı yazılı ve görsel iletişim haline dönüşmüştür. Sosyal medyanın artık bir iletişim kaynağı olduğu yadsınamaz ve vazgeçilmez bir gerçektir. Birleşmiş Milletler'e göre dünya nüfusu 8.20 milyardır. Her geçen gün artan nüfusla birlikte cep telefonu ve internet kullanımı da artmaktadır. 2025 yılında yayınlanan "*We are Social*" isimli platformun verilere göre 5.78 milyar kişi cep telefonu kullanmaktadır. Bu rakam da toplam nüfusun %70.5'üne tekabül etmektedir. İnternet kullanımına baktığımızda ise 5.56 milyar kişinin internet kullandığı görülmektedir. Nüfusa oranladığımızda ise bu rakam %67.9 olarak dikkat çekmektedir. İnternetin ve mobil cihazların kullanımının bu kadar yaygın olduğu dünyada sosyal medyanın yoğun bir şekilde kullanılması beklenmektedir. Rapora göre 5.24 milyar sosyal medya kullanıcısı bulunmaktadır. Bu oran da nüfusun %63.9'üne denk gelmektedir. (Meltwater, Digital 2025: Global Overview Report, 2025)

Araştırmaya göre 16 yaş ve üzeri kişilerde internet kullanımının başlıca sebebi %68 oranında bilgiye ulaşmak olarak verilse de ikinci sıraya on kişiden altısı arkadaşlar ve aileyle iletişimde kalma amacıyla interneti kullandığını belirtmiştir. Yetişkin bir internet kullanıcısının günde ortalama 6 saat 38 dakikasını online olarak geçirdiği raporlanmaktadır. İnsanların kendi duygu ve düşüncelerini ifade etmek için kullandıkları popüler sosyal medya platformu X'in ise aylık ortalama 4.44 milyon ziyaretçisi vardır. Yine ortalama ziyaret süresi 12 dakika 17 saniye olarak kayıtlara geçmiştir. (Meltwater, Digital 2025: Global Overview Report, 2025)

We are Social ve Meltwater tarafından yayınlanan önemli bir diğer raporda ülkemizdeki internet ve sosyal medya üzerinedir. Raporda ülkemizde 80.7 milyon hücresel mobil bağlantı aktif olarak belirtilmektedir. Ayrıca belirtildiği üzere 80.7 milyonluk bu rakam nüfusun %92.1'ine tekabül etmektedir. Ancak bu cihazlar arasında internete bağlanamayan cep telefonlarının da olduğu hesaba katılmalıdır. Ülkemizde 77.3 milyon birey 2025 yılının başlangıcı itibarıyla internet kullanıcısı olarak kayıtlara geçmiştir. Önemli bir diğer veri de ülkemizdeki sosyal medya kullanımudur. Ülkemizde 58.5 milyon sosyal medya kullanıcısı bulunmaktadır. Bu rakam ise nüfusun %66.7'sine tekabül etmektedir. Bu rakamlar ışığında ülkemizin nüfusa oranla yaygın bir şekilde interneti ve sosyal medya kullandığı görülmektedir. Ülkemizde popüler olan sosyal medya platformları arasında yer alan

YouTube ülkemiz bazında 57.5 milyon kullanıcıya sahiptir. Raporda YouTube reklamlarının Türkiye nüfusunun %74.4'üne ulaştığı belirtilmiştir. Bireylerin yazılı bir şekilde düşünce ve durumları paylaşması amacıyla piyasaya çıkan Twitter isim değiştirerek X adını almıştır. Ülkemizde de oldukça popüler olan X platformu 19.7 milyon kullanıcıya hizmet vermektedir. X platformunun resmi olarak 14 yaş ve üzeri kullanıcıya hizmet vermesi sebebiyle kitlelere erişimde Youtube'dan farklılaşmaktadır. X tarafından paylaşılan verilere göre 18 yaş ve üzeri yetişkinlerin %29.5'inin X kullandığı belirtilmiştir. Ayrıca şirket tarafından gösterilen reklamların %37.6'sı kadınlar %62.4'ü erkekler tarafından izlenmektedir. (Meltwater, Digital 2025: Turkey, 2025)

Yukarıda verilen tüm istatistikler bize sosyal medya platformlarının ve dolayısıyla internetin hayatımızın ne kadar içinde olduğunu bir kez daha göstermektedir. 2023 yılında pazarlama şirketi Fan & Fuel tarafından gerçekleştirilen bir anket, tüketicilerin %92'sinin çevrimiçi değerlendirmelerin eksikliğinden etkilendiğini ortaya koymuştur (Fuel, 2025). Ankete katılanlar, satın alma sürecine dair büyük bir belirsizlik yaşadıklarını ifade etmişlerdir. Katılımcıların %35'i satın alma olasılıklarının azaldığını, %32'si daha fazla araştırma yapana kadar satın almayı erteleyeceklerini, %23'ü karar vermekte zorlanacaklarını ve %2'si ise ürünü veya hizmeti satın almayacaklarını belirtmiştir. (Sayeed, Mohan ve Muthu, 2023) Sosyal medya platformları arasında öne çıkan X, ülkemizde siyasetten düşünce dünyasına kadar her kesim tarafından kabul edilmiş bir hal almıştır. Öyle ki ulusal ve uluslararası kurumlar ve önde gelen politikacılar bile resmi açıklamalarını ilk kez X üzerinden paylaşmaktadırlar. Ulusal basında devlet büyüklerinin X paylaşımlarının haberlerinin görüldüğü bir dönemin yaşandığı söylenebilmektedir. X platformu üzerinden görsel içerikli mesajlar veya sohbet odaları gibi iletişimin yanında geleneksel metin paylaşımının yapılabileceği içerik formlarının paylaşılabilmesi sebebiyle fikir ve düşüncelerin yayılmasında etken olmuştur. Dolayısıyla X son zamanları önemli bir araştırma kütüphanesi olarak öne çıkmaktadır. (Mäntylä M. V., 2021)

X başta olmak üzere sosyal medya platformları bilgisayar bilimlerinde ilerleyen araştırma konularından biri haline gelen veri madenciliğinin bir alanı olmuştur. Duygu analizi ise Veri Madenciliğinin bir alt kolu olarak ortaya çıkmıştır. Duygu analizi basit metin tabanlı verilerde yer alan duygusal ifadeleri ve tonları otomatik olarak tespit etmek için kullanılan doğal dil işleme (NLP) tekniklerinin bir uygulamasıdır. Duygu analizi, doğal dil işlemede sıkça çalışılan bir konu olarak literatürde yer edinmiştir (Sayeed ve diğerleri, 2023).

Duygu analizinin temelleri, 20. yüzyılın başlarında kamuoyu araştırmalarına yönelik yapılan çalışmalara dayanmaktadır. 1990'lı yıllarda ise hesaplamalı dilbilim alanında

gerçekleştirilen öznel metin analizi çalışmalarıyla daha sistematik bir yaklaşıma kavuşmuş ve doğal dil işleme teknikleriyle entegre edilerek gelişmiştir. Bilgisayar destekli duygu analizi araştırmaları, büyük ölçüde Web üzerinde yer alan öznel metinlerin varlığına dayanmaktadır. Ayrıca, bu alandaki çalışmaların büyük çoğunluğu 2004 yılından sonra yayımlanmış olup, araştırmaların %99'u bu döneme aittir. (Mäntylä M. V., 2018) Böylece duygu analizi çalışma alanı olarak popülerliğini artırarak devam etmiş farklı sektörler tarafından ihtiyaç duyulan bir çalışma alanı olmuştur. Bireylerin fikir, düşünce veya yorumlarının paylaşıldığı X üzerinde deprem, seçim, tıp, bilim gibi farklı konularda duygu analizi çalışmaları yapılmıştır. Öyle ki Mısır'da başlayan Arap baharının önde gelen aktivistlerinden Fawaz Rashed *“Protestoları planlamak için Facebook’u, koordine etmek için Twitter’ı ve dünyaya duyurmak için Youtube’u kullanıyoruz”* ifadelerini kullanarak sosyal medya üzerinden nasıl örgütlenildiği ve sempati toplandığını belirtmiştir. (Rashed, 2025) Google Akademik üzerinden “sentiment analysis(duygu analizi)” araması yapıldığında 3.130.000 adet sonucun gösterildiği fark edilmiştir. Bu çalışmalar incelendiğinde duygu analizinin genellikle İngilizce dilinde yapıldığı görülmektedir. Yine Google Akademik üzerinden “duygu analizi” yazınca çıkan sonuç 244.000 olarak görülmüştür. Bu durum duygu analizi alanında yapılan Türkçe çalışmaların azlığını ortaya koymaktadır. Türkiye X platformunu en çok kullanan 7. ülke olmasına rağmen Türkçe duygu analizi çalışmalarının dilin yaygınlığına oranı dikkati çekmektedir. (Meltwater, Digital 2025: Global Overview Report, 2025)

Literatürde Türkçe olarak yapılan duygu analizi incelendiğinde yaşanan zorluklar arasında dilin zengin yapısı, istihza(ironik espiri yapma) kabiliyeti, sondan eklemeyle türetilen kelimelerin fazlalığı gibi sebepler görülmektedir. (Özer, 2019) Literatürde duygu analizi amacıyla çeşitli modellerin ve disiplinlerin kullanıldığı gözlemlenmiştir. Bu yöntemler, farklı bağlamlarda ve veri türlerinde duygu sınıflandırmasını iyileştirmek için geliştirilmiştir. Ancak belirtilen zorluklar göz önüne alındığında çalışmamızda BERT(Bidirectional Encoder Representations from Transformers/Transformatörlerden Çift Yönlü Kodlayıcı Gösterimleri) modeli kullanılacaktır. Kısaca bahsedilecek olursa BERT Google tarafından geliştirilmiş derin öğrenme temeline dayanan bir dil modelidir. En önemli avantajı ise metinleri çift yönlü olarak okuyabilmesidir. Bu sayede daha doğru sonuç vermektedir.

Bu çalışmamızda elektrikli araç ekosistemi üzerine bir duygu analizi uygulayarak konu hakkında X platformu üzerinden “elektrikli, Tesla, Togg, BYD, MG, hibrit, elektrikli araç” anahtar kelimeleriyle yapılan paylaşımlar 1 Ocak 2024 ile 1 Ocak 2025’e kadar aylık bazda

ekilerek kategorize edilmiřtir. Bylece elektrikli aralar hakkında bireylerin yaptığı paylařımlar zerinden konuya olan bakıř analiz edilebilecek olup piyasada faaliyet gsteren řirketler ve pazarlama faaliyeti yrten kuruluřlar iin de bir rehber niteliğı olacaktır. Aylık bazda verileri incelemenin getireceğı bir diğerk avantajda yařanan geliřmelerin kamuoyunun grřn nasıl etkilediğini grebilmektir.



2. DUYGU ANALİZİ

Bu bölümde, duygu analizi konusuna genel bir perspektif sunulacak ve duygu analizinde yaygın olarak kullanılan yöntemler ele alınacaktır.

2.1. Duygu Analizine Genel Bir Bakış

Sosyal medya uygulamalarının kullanımının artmasıyla oluşan veri miktarı artmıştır. Artan veri ile birlikte depolama konusunda talepler artmıştır. Makro düzeydeki bu verileri de analiz edebilmek bir insanın yapabileceği bir iş olmanın ötesine çoktan geçmiştir. İnsan kapasitesini aşan analiz ihtiyaçları için otomasyon ihtiyacı doğmuştur. Bu veriden analiz elde etme süreci boyunca veri madenciliği kavramı ortaya çıkmıştır. Veri madenciliği ile kurumlar kapsamlı verilerden bilgi çıkararak öngörülü adımlar atmaktadırlar. İşletmelerin karlılık konusundaki stratejisini belirlemeleri için belirli öngörülere ihtiyaçları vardır. Veri madenciliği buna imkan tanımaktadır. Veri madenciliğinin imkan tanıdığı gelecek odaklı analizler bunları mümkün kılmaktadır. Ayrıca, veri madenciliği ile gerçekleştirilen analizler, karar destek sistemlerinin geçmiş olaylara yönelik sağladığı analizlerin ötesine geçerek daha derinlemesine içgörüler sunmaktadır. Metin madenciliği kavramı ise veri madenciliğinin altında oluşmuştur.

İlk gelişen şekliyle duygu analizi cümle içerisinde geçen her kelimeyi ayrı ayrı okuyarak anlama göre bir sınıflandırma yapmaktadır. Ardından, her kelimenin duygu kutupluluğunun birbirini nasıl etkilediği incelenir. Bu analiz sonucunda, metindeki tüm kelimelerin duygu kutuplulukları bir araya getirilerek genel bir duygu skoru hesaplanır. Duygu analizi gerçekleştirilirken iki temel yaklaşım kullanılmaktadır: kural tabanlı ve otomatik yaklaşımlar. Kural tabanlı yaklaşım, metindeki duygu kutupluluğunu belirlemek için belirli dil kurallarına dayanır ve genellikle sözcüklerin anlam yönelimlerine göre olumlu, olumsuz veya nötr olarak sınıflandırıldığı bir sözlükten yararlanır. Buna karşılık, otomatik yaklaşım belirli kurallara bağlı kalmadan makine öğrenimi tekniklerini kullanarak duygu sınıflandırması yapar. Bu yöntemde duygu analizi bir sınıflandırma problemi olarak ele alınır ve model, önceden etiketlenmiş metin verileriyle eğitilerek belirli girdilerin ilgili duygularla ilişkilendirilmesini sağlar. (Feldman, 2013)


Duygu analizi genel olarak belge seviyesi, cümle seviyesi ve özellik seviyesi olmak üzere üç farklı düzeyde gerçekleştirilmektedir (Misra, Tandon ve Panda, 2024). X verilerinin analiz edildiği çalışmalarda, tweet metinlerinin karakter sınırlaması nedeniyle genellikle

cümle düzeyinde duygu analizi tercih edilmektedir. Belge seviyesinde yapılan duygu analizinde ise değerlendirme, belgenin tamamında yer alan duygular temel alınarak gerçekleştirilir. Bu yöntemde temel amaç, belgenin genel olarak olumlu mu yoksa olumsuz mu olduğunu belirlemektir. Belge düzeyindeki duygu analizinin varsayımlarından biri, bireyin bir seferde yalnızca tek bir konu hakkında görüş bildirdiğidir. Ancak, bu varsayım her zaman geçerli olmayabilir, çünkü bazı veri setlerinde birden fazla konuya ilişkin duygular aynı metin içerisinde ifade edilebilir. (Liu ve Zhang, 2012) Cümle düzeyindeki duygu analizinde, her bir cümlelerin içerdiği duygusal eğilim değerlendirilerek olumlu, olumsuz veya nötr olarak kategorize edilebilir. Bu sınıflandırma kutupluluğa dayalı bir etiketleme yaklaşımı ile gerçekleştirilir. Genellikle olumlu ve olumsuz etiketlemeler belirgin bir duygu barındıran ifadeler için yapılırken, nötr cümlelerin herhangi bir kutupluluk içermediği varsayılır. Özellik düzeyinde yapılan analizlerde ise, bir cümle birden fazla varlık ya da özellikle ilgili farklı duygular içerebileceğinden, daha detaylı ve çok boyutlu bir değerlendirme gerekir. (Liu ve Zhang, 2012) Örneğin, şu ifadeyi ele alalım: “Telefonun kamerası çok iyi ama pili çabuk bitiyor.” Bu cümlede, kameraya yönelik olumlu bir değerlendirme yapılırken, pil ömrüyle ilgili olumsuz bir görüş dile getirilmektedir. Burada telefonun iki farklı özelliği, yani kamera ve pil, farklı duygusal yönelimlerle değerlendirilmiş ve her biri ayrı bir varlık/yön olarak analiz edilmiştir. Duygu analizinde temel amaç, bir ifadedeki kelimelerin birbirleriyle olan etkileşimini çözümleyerek duygunun nasıl iletildiğini anlamaktır. Ancak bu durum, duygu analizinin karşılaştığı başlıca zorluklardan biridir. Bununla birlikte, sosyal medya gibi platformlarda yaygın olan gayri resmi dil kullanımı da analiz sürecini karmaşıktırmaktadır. Nitekim sosyal medya içeriklerinin yaklaşık %97’sinin gayri resmi ifadeler içerdiği (Thelwall M., 2009). Bu nedenle, duygu analizi üzerine çalışan araştırmacılar, kurumlar ve şirketler; yapısal olmayan bu tür verileri otomatik olarak işleyip analiz edebilmek için gelişmiş yöntemlere ihtiyaç duymaktadır. Bu bağlamda, alandaki teknolojik ilerlemelerin sürekliliği büyük önem taşımaktadır.

2.2. Duygu Analizi için Yaklaşımlar

Duygu analizine yönelik literatür incelendiğinde uygulanan yaklaşımlar iki ana başlık altında sınıflandırılmıştır. Bunlardan ilki Kural Tabanlı Yaklaşımdır. İkincisi ise Makine Öğrenimi Tabanlı Yaklaşımdır. Zaman içerisinde oluşan Hibrit Yaklaşım ise birden fazla farklı teknik veya modelin bir arada kullanıldığı bir stratejiyi ifade eder. Duygu analizi ve

diğer doğal dil işleme (NLP) görevlerinde, hibrit yaklaşımlar, genellikle farklı model ve yöntemlerin birleşiminden faydalananarak daha iyi sonuçlar elde etmeyi amaçlar (Şahiner Yılmaz, 2022) . (Şekil 2.1.)



Şekil 2. 1. Duygu Analizi Yaklaşımları

2.2.1. Sözlük Tabanlı Yaklaşım(Lexicon-Based Approach)

Sözlük tabanlı yaklaşım, duygu analizinde sıkça tercih edilen yöntemlerden biridir. Bu yöntemde, metin içerisindeki kelimeler, önceden oluşturulmuş duygu sözlüklerinde yer alan kutupluluk bilgilerine göre değerlendirilir. Her bir sözcüğe olumlu, olumsuz ya da nötr bir değer atandığı varsayılır ve metindeki tüm kelimelerin bu değerleri toplanarak genel bir duygu skoru hesaplanır. Kullanılan popüler duygu sözlüklerinden bazıları Word Net ve General Enquirer’ dır. (Aldahawi, 2015) Etiketli veriye ihtiyaç duymadan hızlı analiz yapılabilmesi, sözlük tabanlı yaklaşımın temel avantajlarındandır. Ancak bu yöntemin en önemli sınırlılıklarından biri, kelimelerin bağlamdan bağımsız olarak değerlendirilmesidir. Çünkü dildeki bağlamsal kullanım farklılıkları, kelimenin sözlükteki kutupluluğundan farklı bir duygu anlamı taşımasına neden olabilir.

Özellikle sosyal medya platformlarında kullanılan dilin büyük oranda gayri resmi olması, yazım hataları, kısaltmalar ve argo ifadelerin sıkça görülmesi gibi nedenlerle sözlükte karşılığı bulunmayan kelimelere rastlanma ihtimali yüksektir. Ayrıca aynı kelime, farklı bağlamlarda zıt duyguları ifade edebilir. Bu gibi durumlar, sözlük tabanlı yaklaşımların tek başına yeterli olmayabileceğini göstermekte ve daha esnek yöntemlerin gerekliliğini ortaya koymaktadır. Bu bağlamda, derlem tabanlı yaklaşımlar önemli bir alternatif sunar. Derlem tabanlı yöntemlerde, belirli bir konuya ya da alana özgü veri kümeleri analiz edilerek, kelimelerin duygu kutuplulukları istatistiksel olarak belirlenir. Bu sayede, bağlama duyarlı sözcük listeleri oluşturulabilir ve söz konusu alana özgü duygu sözcükleri tespit edilerek analizlerin doğruluğu artırılabilir.

Türkçe için sözlük tabanlı yöntemler, İngilizce'deki kadar gelişmiş olmasa da bazı çalışmalarla uygulanmaya çalışılmıştır. Ancak Türkçenin eklemeli yapısı ve zengin morfolojik özellikleri, bu yöntemin uygulanmasını oldukça zorlaştırmaktadır (Açıkalın, Bardak ve Kutlu, 2020). Bu zorluklardan biri, anlamlı sonuçlar elde edebilmek için oldukça geniş kapsamlı sözlükler oluşturma gerekliliğidir. Morfolojik çözümlemeler sonucunda ortaya çıkan kelimeler, bazen daha önce kullanılmamış ve yapay biçimde türetilmiş sözcükler olabilir (örneğin “koltuklukçuluk”) (Özer Z., 2019). Buna ek olarak, sosyal medya ortamlarında kullanılan dilin, standart Türkçe dil bilgisi kurallarından uzak ve yoğun yazım hataları içermesi, sözlük tabanlı analizleri daha da karmaşık hale getirmektedir. Ayrıca sosyal medya kullanıcıları tarafından üretilen içeriklerde, Türkçe sözlüklerde yer almayan kısaltmalar ve yeni kelimelerle sıkça karşılaşmaktadır (Mite-Baidal ve diğerleri, 2018). Örneğin, yanlış yazılmış bir kelime olan “anadın” ifadesinin, 20’den fazla farklı kelimeyle benzerlik gösterdiği saptanmıştır (Özer Z., 2019). Tüm bu nedenlerden dolayı, doğru anlamı yakalayabilmek için kelimelerin geçtiği bağlamı dikkate almak önemli hale gelmiştir. Bu çalışmada da bu gerekçeler doğrultusunda derlem tabanlı bir yaklaşım benimsenmiştir.

2.2.2. Makine Öğrenmesi Yaklaşımı

Makine öğrenimi, Yapay Zekâ (Artificial Intelligence - AI) alanının öğrenmeye odaklanan bir alt dalıdır. Bu yöntem, farklı özellikleri analiz ederek daha doğru tahminler üretmeye yardımcı olur. Veri kümeleri içindeki kalıpları ve ilişkileri belirleyerek anlamlı bilgiler ortaya çıkarabilir. Makine öğrenimi modelleri, geçmiş verilerden elde edilen örüntülerle eğitilerek etkili bir şekilde çalıştırılmalıdır (Van Klompenburg, Kassahun ve Çatal, 2020).

Makine öğrenimi yöntemleri temel olarak iki ana kategoriye ayrılır: denetimli öğrenme ve denetimsiz öğrenme. Denetimsiz öğrenme, sınıflandırma işlemlerinde eğitim veri setini kullanmazken, denetimli öğrenme, algoritmaların çalışması için eğitim verilerini kullanır. Denetimli öğrenme süreçleri genelde eğitim ve doğrulama/test aşamalarından oluşur. Yapılan çalışmalar, duygu analizi görevlerinde hem denetimli hem de denetimsiz öğrenme yöntemlerinin çeşitli tekniklerle uygulandığını ortaya koymaktadır. Denetimli öğrenmede kullanılan yöntemler arasında SVM ve Naive Bayes gibi teknikler öne çıkarken, bu yaklaşımlar farklı özellik kombinasyonlarıyla da zenginleştirilmektedir. Denetimsiz öğrenme ise duygu sözlükleri, dil bilgisayar analiz ve söz dizimsel kalıplar gibi unsurlardan yararlanarak uygulanmaktadır (Şahiner Yılmaz, 2022). Bu yöntemlerin detaylı incelemesini içeren birçok çalışma yayımlanmıştır.

Denetimsiz Öğrenme

Denetimsiz yöntemler, makine öğrenimi tabanlı ya da sözlük destekli yaklaşımlarla uygulanabilir. Bu yöntemlerde etiketlenmiş bir veri seti kullanılması zorunlu değildir. Yalnızca girdi veri seti sağlanarak model, herhangi bir etiketleme işlemine ihtiyaç duymadan çalışabilir. Duygu analizi için kullanılan denetimsiz yöntemler, çoğunlukla bir duygu sözlüğüne dayalı olarak tasarlanmaktadır. Bu yöntemde metin sınıflandırması, çeşitli algoritmaların bir cümlemin anlamsal yönelimini tahmin etmek için sıfatlar veya zarflar içeren cümleleri çıkardığı semantik yönelim yaklaşımı kullanılarak yapılmıştır (Manda, 2019).

Denetimli Öğrenme

Sözlük bazlı yaklaşımlar, dilbilimsel açıdan kabul edilebilirliği ve kullanım kolaylığına rağmen bazı eleştirilere maruz kalmıştır. Bu yaklaşımlardan biri, esnek bir sınıflandırma imkânı sunamamasıdır. Bunun nedeni, sözcük girişlerinin önceden belirlenmiş sabit katsayıları baz almasıdır. Oysa bağlama bağlı olarak birçok terim, farklı yoğunluk ve polarite değerlerine sahip olabilir. Bu durum, analiz sonuçlarının ideal düzeyin altında kalmasına yol açmaktadır. Sözlük bazlı yaklaşımlar ayrıca, sözcüksel olmayan unsurları değerlendirme sürecine dahil edememesi nedeniyle de eleştirilmektedir. Örneğin, ünlem işaretleri veya yazım varyasyonları, bir cümlemin duygusal tonuyla doğrudan ilişkili olabilir. Buna ek olarak, Türkçe gibi geniş bir sözlük yapısına sahip dillerde bu tür yaklaşımların kullanımı

oldukça zorlu hale gelebilmektedir. Zamanla, manuel olarak etiketlenmiş veri setlerinin ortaya çıkmasıyla birlikte, sözlük tabanlı sistemlerin yerini giderek denetimli makine öğrenimi teknikleri almaya başlamıştır. Denetimli öğrenme yöntemleri ise etkili bir sınıflandırma için, iyi etiketlenmiş ve yeterli büyüklükte bir veri setine ihtiyaç duyar. Bu tür bir veri seti olmadan, eğitim ve test süreçlerini gerçekleştirmek oldukça güç hale gelmektedir (Yang ve Jacob, 2017).

2.2.3. Derin Öğrenme Metodu

Yaklaşık on yıl önce derin öğrenme, güçlü bir makine öğrenimi tekniği olarak dikkat çekmeye başlamıştır. Son yıllarda duygu analizi çalışmalarında derin öğrenme tekniklerinin kullanımı giderek yaygınlaşmış ve bu yöntemler duygu sınıflandırma süreçlerinde önemli gelişmelere katkıda bulunmuştur. Derin öğrenme, yapay sinir ağlarının birden fazla katmandan oluşan yapılar kullanılarak öğrenme süreçlerine entegre edilmesidir (Zhang, Wang ve Liu, 2018). Sinir ağları, biyolojik beynin yapısından esinlenerek tasarlanmış olup, birlikte çalışan katmanlar halinde organize edilmiş birçok bilgi işlem birimini (nöronları) içerir (Zhang ve diğerleri, 2018). Bu ağlar, biyolojik beynin öğrenme mekanizmasına benzer şekilde nöronlar arasındaki bağlantı ağırlıklarını ayarlayarak belirli görevleri, örneğin sınıflandırmayı, öğrenebilir. Derin öğrenme, makine öğreniminin bir alt alanı olup, çeşitli modellerle karmaşık veri yapılarını analiz etme yeteneğine sahiptir. Bu yaklaşım, yapay sinir ağlarını kullanarak büyük veri kümelerinden anlamlı örüntüler çıkarabilir. Örneğin; özyinelemeli sinir ağları (RecNN), evrişimli sinir ağları (CNN) ve tekrarlayan sinir ağları (RNN) gibi (Sarkar, Bali ve Sharma, 2018). Derin öğrenme yöntemleri; sensör tabanlı bilgisayarlı görü, doğal dil işleme (DDİ), ses tanıma ve konuşma tanıma gibi çeşitli alanlarda kullanılmaktadır. Bu tür uygulamalar, bazı durumlarda uzmanlara kıyasla üstün performans sergileyerek dikkat çekici başarılar elde etmiştir (Shahin, Nassif, ve Hamsa, 2020).

Doğal dil işleme (DDİ) ile derin öğrenmenin iş birliği, çeşitli kritik görevlerde çarpıcı başarılar elde etmiştir. Geleneksel makine öğrenimi yöntemlerinde, özelliklerin insanlar tarafından tasarlanması gerektiğinden bu yöntemler, derin öğrenme tekniklerine kıyasla daha fazla insan deneyimi gerektirir ve uygulanması daha karmaşık olabilir. Derin öğrenme ise, bu zorlukları aşmak amacıyla çok katmanlı bir model yapısı kullanarak söz konusu sorunlara çözüm sunmuştur (Interian, ve diğerleri, 2018).

Derin öğrenme modelleri, temel olarak iki veri setine dayanır. Bunlardan ilki, modelin öğrenme sürecinde kullanılan eğitim veri setidir. Bu veri kümesi, girdilere karşılık gelen doğru çıktıları içerdiğinden, model bu örneklerden öğrenerek tahminlerini şekillendirir. Diğer veri seti ise test veri setidir ve bu set, modelin eğitim sürecinde öğrendiği sınıflandırmaları ne kadar iyi gerçekleştirdiğini değerlendirmek için kullanılır (Manda, 2019). Test aşamasında, model eğitim veri setinden farklı yeni veriler üzerinde denemeye tabi tutulur ve doğru tahminlerde bulunup bulunmadığı ölçülür. Test veri kümesinde doğru sınıflandırılan örneklerin toplam örnek sayısına oranı, modelin test doğruluğunu belirler. Bu doğruluk metriği, derin öğrenme modellerinin veri seti üzerindeki performansını değerlendirmek için önemli bir kriterdir.

2.2.4. Hibrit Yaklaşım

Akademik yazında, farklı hibrit yaklaşımların varlığı dikkat çekmektedir. Bu yaklaşımlardan bazıları, sözlük tabanlı bilgiyi makine öğrenimi modelleriyle birleştirerek kapsamalarını genişletmeyi hedeflemektedir (Behera, Roy ve Dash, 2016). Bu tür yöntemlerin amacı, hem sözlük hem de makine öğrenimi tabanlı tekniklerin güçlü yönlerini birleştirerek etkili bir özellik kümesi oluşturmak ve en iyi sonuçları elde etmektir (Ahmad, Aftab, Ali ve Hameed, 2017). Böylece, her iki yöntemin de eksiklikleri ve sınırlamaları giderilmiş olmaktadır. Ayrıca, farklı modellerin bir arada kullanılması da hibrit yaklaşımlara örnek teşkil etmektedir. Örneğin, CNN ve LSTM algoritmalarının bir arada kullanılmasının, bireysel modellerden daha yüksek performans sergilediği tespit edilmiştir. Bunun yanı sıra, bu algoritmanın cümle düzeyinde duygu sınıflandırmasında etkili olduğu kanıtlanmıştır (Lighthart, Çatal, ve Tekinerdogan, 2021).

Duygu analizi yaklaşımlarının karşılaştırılması

Sözlük tabanlı yaklaşımlar gibi geleneksel yöntemler, manuel olarak tasarlanan özelliklere dayanır. Ancak bu süreç oldukça zaman alıcı ve yorucu olmasının yanı sıra, bazı alanlarda yeterli genelleme kapasitesine sahip olmayabilir. Geleneksel makine öğrenimi yöntemlerinde, özellik mühendisliği ve özellik çıkarma işlemleri genellikle oldukça zahmetli süreçlerdir. Bu zorlukları aşmak için derin öğrenme, ağ yapılarının eğitim sırasında

gerekli özellikleri otomatik olarak öğrenmesini sağlar ve böylece manuel özellik tasarımı ihtiyacını ortadan kaldırır.

Günümüzde sosyal ağlar, büyük miktarlarda veri üretmektedir. Artan büyük veri hacmi karşısında, geleneksel makine öğrenimi tabanlı yöntemler genellikle istenilen performansı sağlayamamaktadır. Öte yandan, derin öğrenme modelleri, büyük veri kümeleri üzerinde daha karmaşık özellikler öğrenebildiği için, makine öğrenimi yaklaşımlarına kıyasla daha başarılı sonuçlar elde etmektedir (Ligthart ve diğerleri, 2021). Bu durum, derin öğrenme modellerinin geleneksel yöntemlere kıyasla üstün performans sergilediğini kanıtlamaktadır.




3. DERİN ÖĞRENME KULLANILARAK DUYGU ANALİZİ

Bu bölümde, Evrişimli Sinir Ağları, Yinelemeli Sinir Ağları, Kapılı Yinelemeli Sinir Ağları ve Transformer Tabanlı Sinir Ağları üzerine detaylı bir inceleme yapılacaktır. Ayrıca, ele alınan derin öğrenme tekniklerinin performans karşılaştırmalarında kullanılan değerlendirme yöntemleri de açıklanacaktır.

3.1. Evrimsel Sinir Ağları(CNN)

Evrimsel Sinir Ağları (CNN), başlangıçta görüntü verilerini işlemek amacıyla geliştirilmiş özel bir ileri beslemeli sinir ağı türüdür. Bu mimari, görsel bilgiyi işleme süreçlerine benzer bir şekilde çalışarak, veri içerisindeki özellikleri belirlemeye odaklanır. CNN'ler, biyolojik görme sistemlerinden esinlenerek tasarlanmış olup, görsel korteksin yapısından ilham almıştır. Görsel kortekste, belirli bölgelerde konumlanan ve görsel bilgiyi parçalar hâlinde analiz eden hücreler bulunur. Bu hücreler, yerel filtreler gibi davranarak veriyi katmanlı bir şekilde işleyip anlamlı özellikler çıkarır. Aynı şekilde, CNN de çok sayıda evrişimli katmandan oluşur ve bu katmanlar görsel kortekste hücrelerin işlevlerini simüle ederek verileri işler (Zhang ve diğerleri, 2018).

Evrimsel Sinir Ağları (CNN), derin öğrenme mimarileri arasında yaygın olarak kullanılan bir modeldir (Shahin ve diğerleri, 2020). Evrimsel Sinir Ağları (CNN), başlangıçta görüntü işleme için tasarlanmış olsa da, duygu analizi gibi doğal dil işleme (NLP) görevlerinde başarılı bir şekilde uygulanmıştır. Bu duruma örnek olarak, Collobert ve çalışma arkadaşlarının öncü çalışmaları (Collobert, Weston, Bottou, Karlen, Kavukcuoglu ve Kuksa, 2011) ile Kim'in araştırması (Kim Y. , 2014) gösterilebilir. Ayrıca, CNN'in n-gram özelliklerini kullanarak girdiden "anlamlı gizli anlamsal temsiller" oluşturma kapasitesi sayesinde başarılı sonuçlar elde edilmiştir (Zhang ve diğerleri, 2018).




Şekil 3.1. Cümle sınıflandırma için kullanılan CNN mimarisi örneği

Evrişimsel Sinir Ağları (CNN), başlangıçta görüntü işleme projelerinde kullanılmasına rağmen, duygu analizi görevlerinde de etkili sonuçlar vermiştir (Kim Y. , 2014). Bu tür görevlerde CNN, genellikle word2vec-CBOW gibi kelime gömme yöntemlerini kullanarak girdiyi işlemektedir. Bu yöntem, girdiyi görüntü pikselleri yerine bir matris biçiminde temsil etmeyi mümkün kılar. Şekil 3.1.'de cümle sınıflandırması için tasarlanmış bir CNN mimarisi örneği bulunmaktadır. CNN'in işlevselliği, önceden etiketlenmiş veri gereksinimine dayanır; model bu verilere göre sınıflandırma işlemleri gerçekleştirir. Ligthart ve çalışma arkadaşlarının duygu analizine yönelik literatür taramasında CNN ile ilgili çalışmaların en çok alıntı yapılanlar arasında olduğu ortaya konmuştur. Ayrıca aynı çalışmada, 2020 yılında derin öğrenme alanındaki yayınlar incelendiğinde, CNN'in LSTM'den sonra en çok tercih edilen modellerden biri olduğu belirtilmiştir (Ligthart ve diğerleri, 2021).

3.2. Yinelemeli Sinir Ağı (RNN)

Yinelemeli Sinir Ağları (RNN), nöronlardan oluşan ve sıralı veriler üzerinde oldukça etkili olan bir derin öğrenme modelidir. RNN'nin dahili belleği sayesinde her bir nöron, önceki girişle ilgili bilgileri saklayabilir ve bu özellik, modelin sıralı veri işleme görevlerinde kullanılmasını mümkün kılar. RNN, şimdiye kadar elde edilen tüm hesaplamaları izleyen veya öğrenen bir ağ yapısına sahiptir. Bu yönüyle güçlü bir teknik olsa da uzun vadeli

ilişkileri tahmin etme konusunda bazı zorluklarla karşılaşabilir. RNN, diğer sinir ağları gibi giriş, gizli ve çıktı katmanlarından oluşmaktadır (Şekil 3.2).



Şekil 3.2. RNN mimarisi

Metinsel veri analizi için derin sinir ağlarının kullanımı yaygın bir yaklaşımdır. Bu ağlar genellikle kelime yerleştirmeyi öğrenmek veya elde edilen özellik vektörleri üzerinden sınıflandırma ve kümeleme gibi makine öğrenimi görevlerini yerine getirmek üzere tasarlanmıştır (Zhang ve diğerleri, 2018). CNN'nin yerel kalıpları öğrenme kapasitesi ve boyutsallık azaltma avantajı, bu modelin popüler olmasını sağlamıştır. RNN ise sıralı veri modellemedeki gücü ve kelime bağımlılıklarını koruma özelliği ile öne çıkmaktadır. Ancak, uzun vadeli bağımlılıkları tahmin etme aşamasında RNN'ler kaybolan gradyan problemi ile karşılaşabilmektedir (Song, Park, ve Shin, 2019). Bu tür zorluklar, özellikle doğal dil işleme (NLP) uygulamalarında ve duygu analizinde yaygın olarak görülmektedir. Bu sorunları aşmak için Kapılı Yinelemeli Sinir Ağları (GRNN) modelleri geliştirilmiştir. Bu modeller arasında Uzun Kısa-Dönem Belleği (LSTM) ve Kapılı Yinelemeli Ünite (GRU) yer almaktadır. LSTM, giriş, unutma ve çıkış kapıları aracılığıyla bu sorunları çözerken, GRU bir sıfırlama ve bir güncelleme geçidi kullanarak benzer bir işlevi yerine getirmektedir. Standart RNN'lerin karşılaştığı zorlukları hafifletme yeteneklerinden dolayı hem LSTM hem

de GRU, doğal dil işleme araştırmacılarının dikkatini çekmiştir (Cambria, Wang ve White, 2014). Ayrıca, çift yönlü modeller olan Çift Yönlü LSTM (Bi-LSTM) ve Çift Yönlü GRU (Bi-GRU), ileri ve geri gizli katmanları birleştirerek sıralı modelleme sorunlarını daha etkin bir şekilde çözebilmektedir (Nassif, Elnagar, Shahin, ve Henno, 2021).


3.3. Kapılı Yinelemeli Sinir Ağları (GRNN)

CNN ve RNN gibi modeller duygu analizi çalışmalarında başarılı sonuçlar sunmuştur. Bu yöntemler, manuel tekniklerin gerekliliğini azaltarak araştırmacılara kolaylık sağlamaktadır. RNN, kelimelerin sırasını ve bağımlılıklarını göz önünde bulundurarak her bir girişin ağırlıklarını günceller. Ancak bağımlılık süreleri arttığında, eğitimi zorlu hale gelmekte ve gradyan artışı ya da kaybı problemleri ortaya çıkmaktadır. Bu durum, RNN'nin uzun vadeli tahminlerde performans sınırlamaları ile karşılaşmasına neden olmaktadır. Bu tür zorlukların üstesinden gelmek için Long Short-Term Memory (LSTM) ve Gated Recurrent Units (GRU) gibi GRNN modelleri önerilmiş olup, bu modeller yüksek performans sergilemiştir. GRNN, yeni bir giriş kelimesini, önceden kodlanmış bilgilerle birleştirerek (Chen, Zhuo ve Ren, 2019). Başka bir ifadeyle, duygu girdileri, tarihsel bilgiler ışığında değişime uğrar. LSTM ve GRU, hem uzun hem de kısa dönemli ilişkileri yakalama yetenekleri sayesinde sıklıkla tercih edilen tekniklerdir (Chen ve diğerleri, 2019). LSTM, bilgi akışını kontrol etmek için giriş, unutma ve çıkış kapıları kullanırken, GRU benzer bir yapıya sahiptir ve sıfırlama ve güncelleme kapılarına sahiptir. Literatürde, LSTM ve GRU arasında belirgin bir performans farkı olmadığı ve birbirlerinin yerine kullanılabildiği ifade edilmektedir.

3.4. Uzun Kısa Dönem Bellek (LSTM) ve Kapılı Sinir Ağı (GRU)

Tarihle ilgili problemlerin işlenmesi amacıyla, yapay zekâ alanında gizli katmanlar arasında tekrarlayan bağlantılar kullanılarak “Yinelemeli Sinir Ağı (RNN)” önerilmiştir (Rumelhart, Hinton ve Williams, 1986). Ancak, RNN'nin uzun vadeli geçmiş bilgileri öğrenmede yetersiz kaldığı görülmüş ve bu soruna bir çözüm olarak 1997 yılında Hochreiter ve Schmidhuber tarafından RNN'nin bir uzantısı olan LSTM modeli geliştirilmiştir (Hochreiter ve Schmidhuber, 1997). LSTM, hem kısa hem de uzun vadeli geçmiş bilgileri öğrenme yeteneğine sahiptir. Bu model, pozitif değerlerin geçmişini belirli bir süre boyunca

hatırlayarak geliştirilmiş bir tekrarlayan sinir ağı türüdür (Basiri, Nemati, Abdar, Cambria, ve Acharya, 2020). LSTM, üç temel kapıya sahiptir: giriş kapısı, unutma kapısı ve çıkış kapısı. Bu kapılar, belleğe giren ve çıkan bilgiyi düzenleyerek modelin öğrenme sürecini optimize eder. Ayrıca, bu yapı hafıza hücresinin önem derecesini kontrol ederek hangi bilgilerin hatırlanması veya unutulması gerektiğine karar verir (Majumder, Poria, Gelbukh ve Cambria, 2017). LSTM'nin güncel ve etkili bir model olduğu, 2020 yılında yapılan akademik çalışmalarda da sıklıkla vurgulanmaktadır (Ligthart ve diğerleri, 2021). (Şekil 3.3.)



Şekil 3.3. LSTM modeli

GRU modeli, LSTM'lere oldukça benzer bir şekilde çalışmakla birlikte, "Sıfırlama" ve "Güncelleme" olarak adlandırılan iki ana geçide sahiptir. Sıfırlama geçidi, önceki gizli durumun hangi koşullarda göz ardı edileceğini belirlerken, güncelleme geçidi mevcut duruma aktarılacak bilgi miktarını kararlaştırır (Basiri ve diğerleri, 2020). Bu basit tasarım, GRU'nun standart LSTM modellerine göre daha sade bir yapıya sahip olmasını sağlamış ve giderek daha yaygın bir şekilde kullanımına olanak tanımıştır. (Şekil 3.4.)

3.5. Transformer Tabanlı Sinir Ağları

Transformer, (Vaswani ve diğerleri, 2017) önerilen bir fikir olarak, RNN'ler ve encoder-decoder mimarilerinin eksikliklerini gidermek amacıyla geliştirilmiştir. Bu mimari, S2S encoder-decoder yapısında RNN'ler yerine dikkat (attention) mekanizmaları kullanarak iyileştirilmiştir. Dikkat mekanizması, uzun vadeli belleğin etkin bir şekilde kullanılmasını sağlar. Transformer, geçmişte oluşturulan her bir token'e odaklanarak uzun süreli bilgiyi saklama yeteneğine sahiptir.

Bu mimari, pozisyona dayalı ileri beslemeli katmanlar, artık bağlantılar ve normalizasyon katmanlarından oluşan genel bir yapıya sahiptir. (Rahali ve Akhloufi, 2023). Tüm bu katmanlar, çoklu kafalı dikkat (multi-head attention) mekanizmaları ile bir araya getirilerek birden fazla seviyede üst üste yerleştirilmiştir.

Transformer tabanlı sinir ağları, makine öğrenimi alanında, özellikle doğal dil işleme (NLP) ve sıralı veri analizi gibi görevlerde devrim yaratmış bir mimari olarak öne çıkmaktadır. Bu model, geleneksel tekrarlayan sinir ağları (RNN) ve konvolüsyonel sinir ağları (CNN) gibi yaklaşımlardan farklı olarak, self-attention mekanizmasını temel alır. Böylece, bağlamlar arasındaki uzun vadeli ilişkilerin daha etkili bir şekilde ele alınmasına olanak tanır ve paralel işleme yeteneğiyle performans açısından üstünlük sağlar.

Transformer mimarisi, temel olarak bir encoder ve bir decoder bileşeninden oluşur. Encoder, giriş dizisini işleyerek bağlamsal temsiller oluştururken, decoder bu bilgileri kullanarak hedef çıktıyı üretir. Örneğin, bir dil çevirisi modelinde encoder, kaynak dildeki cümlelerin anlamını analiz ederken, decoder bu anlamı hedef dile çevirir. Ancak, Transformer modellerinin bu iki ana bileşeni farklı kullanım senaryolarında adapte edilebilmektedir. BERT (Bidirectional Encoder Representations from Transformers) gibi modeller yalnızca encoder bölümünü kullanarak metin bağlamını iki yönlü olarak anlamlandırmayı hedeflerken, GPT (Generative Pre-trained Transformer) gibi modeller decoder odaklıdır ve yaratıcı metin üretimi gibi görevlerde öne çıkar. Bunun yanı sıra, T5 (Text-to-Text Transfer Transformer) gibi modeller hem encoder hem de decoder yapılarını bir araya getirerek giriş ve çıkışı metin formatında işler.


Transformer modellerinin en önemli özelliği olan self-attention mekanizması, her bir veri noktasının sıralı dizideki diğer veri noktalarıyla olan bağlamını anlamasına olanak tanır. Bu mekanizma, bir cümledeki kelimeler arasındaki ilişkileri değerlendirir ve bağlama göre

hangi kelimelerin daha önemli olduğunu belirler. Örneğin, bir cümledeki "bank" kelimesi, çevresindeki kelimelere bağlı olarak "nehir kıyısı" veya "finans kurumu" anlamına gelebilir. Self-attention mekanizması, doğru bağlamı analiz ederek anlam belirsizliğini giderir.

Transformer mimarisine dayanan modellerin avantajları oldukça çeşitlidir. Paralel işleme yeteneği, özellikle RNN'lere kıyasla diziler üzerinde daha hızlı işlem yapılmasını sağlar. Transformer mimarisine dayanan modeller şu anda geleneksel dil modellerini geride bırakmış durumdadır (Wang, Ma, Liu ve Tang, 2019). Transformer yönteminin en iyi performans gösteren çok dilli modelleri ürettiğini ve ilgili iki dilli modeller ile RNN'leri geride bıraktığını belirtilmiştir (Lakew, Cettolo ve Federico, 2018). Bu yöntem, sıfırdan öğrenme koşullarının tamamında ve farklı çeviri yönlerinde üstün performans göstermektedir. Genel olarak, doğal dil işleme (NLP) sıralıdan sıralıya (S2S) görevler üzerine yoğunlaşmaktadır (Sutskever, Vinyals ve Le, 2014). Bu görevleri yerine getirmek için genellikle bir encoder-decoder modeli tercih edilir. Daha önce yaygın olarak kullanılan RNN tabanlı encoder ve decoder mimarileri, belirli dezavantajlar barındırmaktadır. Özellikle, uzun bağımlılıkları öğrenme konusunda sınırlamalar yaşanması ve paralel işlem yapamaması, bu mimarilerin etkinliğini azaltmaktadır. (Rahali ve Akhloufi, 2023).

Sıralıdan sıralıya (S2S) modeli, genellikle bir encoder-decoder yapısını temel alır. Bu yapı, giriş dizisini işleyerek sabit uzunlukta bir bağlam vektörü oluşturan bir encoder ile başlar ve ardından bu bağlam vektörünü kullanarak çıktıyı üreten bir decoder içerir. (Pota, Ventura, Catelli ve Esposito, 2021). Daha sonra, decoder bu sabit şekilli bağlamı kullanarak değişken uzunlukta bir çıktı dizisi üretir. Ancak, sabit uzunlukta bağlam vektörü kullanımı, uzun cümlelerin tam anlamıyla hatırlanmasını zorlaştırmaktadır. Bunun yanı sıra, decoder her zaman adımında farklı bilgilere gereksinim duyarak esnek bir bağlam temsiline ihtiyaç duymaktadır (Rahali ve Akhloufi, 2023). (Şekil 3.5.)

Geleneksel encoder-decoder yapısının iki temel dezavantajı bulunmaktadır. İlk olarak, encoder, tüm giriş verisini sabit uzunlukta bir vektöre dönüştürmek zorunda olduğundan, özellikle uzun ve karmaşık dizilerde bilgi kaybı yaşanabilir. İkinci olarak, bu yapı, çeviri ve özetleme gibi çıktının belirli bir yapı gerektirdiği görevlerde, giriş-çıkı dizisi arasındaki hizalamayı tam olarak yansıtamaz. Sıralıdan sıralıya (S2S) görevlerde, her bir çıktı tokeni belirli giriş bölümlerinden daha fazla etkilenmelidir. Ancak, decoder her bir çıktı tokenini üretirken, önemli giriş tokenlerine seçici bir şekilde odaklanmakta güçlük çekebilir. (Rahali ve Akhloufi, 2023).



Şekil 3.5. Dikkat mekanizmalı S2S (girdi-girdi) kodlayıcı–çözücü mimarisi

Dikkat ağırlıklarını belirlemek için, decoder durumu sorgu (Q) olarak; encoder’ın gizli durumları ise anahtarlar (K) olarak kullanılır. Geleneksel olarak, bu ağırlıklar, encoder’ın gizli durumlarının decoder çıktısı üzerindeki etkisini yansıtır. Bu doğrultuda, dikkat mekanizmasının genel modeli olan $Attention(Q, K, V)$, bir sorgu (Q) ile anahtar–değer çiftlerini (K, V) kullanarak hesaplanır (Denklem (1)’de gösterilmiştir). (Şekil 3.8.)

$$Attention(Q, K, V) = F_{\{distribution\}}(F_{\{alignment\}}(K_i, Q)) \cdot V_i \quad (1)$$

Transformer modellerinde dikkat mekanizmasının işleyişi şu şekilde açıklanabilir: Dağılım fonksiyonu ($F_{distribution}$) ve hizalama fonksiyonu ($F_{alignment}$), dikkat ağırlıklarını oluşturmak için kullanılır. Dağılım fonksiyonu, hizalama fonksiyonunun ürettiği skorları belirli bir ölçeğe uyarlayarak dikkat mekanizmasını yönlendirir. Transformer modellerinde yaygın olarak kullanılan dağılım fonksiyonları arasında lojistik, sigmoid ve SoftMax bulunmaktadır.

Dikkat ağırlıklarının öğrenilmesini sağlamak amacıyla, mimariye ek olarak bir ileri beslemeli sinir ağı entegre edilmiştir. Bu ağ, dikkat mekanizması içinde belirli ağırlıkların nasıl dağıtılacağını öğrenerek modelin daha hassas ve etkili bir şekilde çalışmasını sağlar. Bu ağ, iki durumun girdileri ile belirli bir dikkat ağırlığını öğrenir. Encoder’ın gizli durumu ile decoder’ın gizli durumu arasındaki önem, hizalama fonksiyonu ile ölçülür. Ayrıca, bu fonksiyon enerji skorları oluşturur ve bu skorlar dağılım fonksiyonu tarafından dikkat

ağırlıklarını üretmek için kullanılır. Çeşitli hizalama fonksiyonları mevcuttur ve bunlar, farklı veri yapıları ile uyumlu şekilde çalışarak dikkat mekanizmasının etkinliğini artırır.

Transformer'ın orijinal encoder-decoder çerçevesinde, nokta çarpımı hizalama (dot product alignment) modelde kullanılan çarpımsal hizalama türüne bir örnektir. Anahtar (key) ve sorgu (query) aynı vektör uzayında temsil edildiğinde, bu temsiller arasında kosin benzerliği (cosine similarity) veya nokta çarpımı hesaplanabilir. Farklı temsillerin uzunluklarını hesaba katmak için ölçekli nokta çarpımı kullanılabilir; bu, nokta çarpımını temsil vektörünün uzunluğu ile normalize eder.


Genel hizalama (general alignment), sorguları anahtarların vektör uzayına haritalayan öğrenilebilir bir dönüşüm matrisi W sunarak nokta çarpımını, birden fazla temsil içeren anahtar ve sorgulara genişletir. Önyargılı genel hizalama (biased general alignment), sorgudan bağımsız olarak belirli anahtarların genel önemini değerlendirir. Genel hizalama, hiperbolik tanjant, doğrusal birim (ReLU) veya ölçeklenmiş üstel doğrusal birim gibi doğrusal olmayan aktivasyon katmanlarıyla güçlendirilerek daha etkin hâle getirilir (Pota ve diğerleri, 2021). Anahtar ve sorguyu karşılaştırmak için nokta çarpımı yerine genel bir çekirdek fonksiyonu kullanılabilir.

Birleştirme hizalaması (concatenate alignment) alternatif bir yöntem olarak, anahtarlar ve sorguları bir araya getirerek ortak bir temsil oluşturur. Bu yaklaşım, iki ögenin birleşimini doğrudan dikkate alarak hizalama sürecini güçlendirir. Katkı hizalaması (additive alignment) ise, sorgu ve anahtarın katkılarını ayrı ayrı değerlendirerek hesaplama sürecini optimize eder. Bu yöntem, her bir bileşenin etkisini bağımsız olarak ele alarak işlem süresini azaltmaya yardımcı olur. Bu yöntemle, her sorgu için ayrı ayrı hesaplama yapılması yerine tüm anahtarların katkıları önceden hesaplanır. Konum bazlı hizalama (location-based alignment), yalnızca sorguları (Q) kullanır ve içerik yerine anahtarın konumuna dayanarak hizalama skorunu belirler. Özellik hizalaması (feature alignment) ise ortalama ve standart sapma gibi özelliklerden türetilen girdilerle çalışır ve tek boyutlu zamansal diziler gibi öğeler koleksiyonlarında kullanılır.


Orijinal Transformer modeli, hizalama fonksiyonu olarak ölçeklenmiş nokta çarpımı dikkat (scaled dot-product attention) mekanizmasını ve dağılım fonksiyonu olarak SoftMax yöntemini benimsemiştir. Bu yaklaşım, sorgu (query) ile anahtar (key) vektörleri arasındaki ilişkiyi değerlendirerek dikkat ağırlıklarını hesaplar. Bu hesaplama, nokta çarpımı ile benzerlik skorlarını oluşturur ve SoftMax yöntemi ile normalleştirilerek dikkat vektörü elde edilir. Böylece model, farklı girdiler arasındaki ilişkileri öğrenerek daha etkin ve doğru sonuçlar üretme kapasitesine sahip olur (Denklem (2)'de gösterilmiştir).

$$\{Attention\}(Q,K,V) = \{softmax\}\left(\frac{\{Q^TK\}}{\sqrt{\{d_K\}}}\right) * V \quad (2)$$


Kendi kendine dikkat (self-attention) veya içsel dikkat (inner attention), bir dizideki farklı pozisyonları birbirleriyle ilişkilendirerek dizinin daha anlamlı bir temsilini oluşturmayı amaçlayan bir mekanizmadır. Bu süreç, her bir öğenin diğer öğelerle olan ilişkisini analiz ederek veri içerisindeki önemli bağlantıları belirlemeye yardımcı olur. Şekil 3.6. bu mekanizmanın temel yapısını göstermektedir; burada d , anahtarların (keys, K) boyutunu ifade eder. (Rahali ve Akhloufi, 2023).




Şekil 3.6. Kendinden Dikkat Mimarisi



Şekil 3.7. Kodlayıcı Blok Mimarisi



Şekil 3.8. Çözümleyici Mimarisi



Şekil 3.9. Dönüştürücü Mimarisi

Transformer tabanlı modeller bağlamı anlama becerisi, kelime ve ifadeler arasındaki ilişkilerin derinlemesine analiz edilmesine olanak tanır. Ayrıca, ölçeklenebilir yapıları sayesinde çok büyük veri setleriyle çalışabilmekte ve doğruluğu artırabilmektedirler. Bu özellikler, Transformer tabanlı modelleri, duygu analizi, metin sınıflandırması, dil çevirisi, özetleme ve metin üretimi gibi geniş bir uygulama yelpazesinde vazgeçilmez kılmaktadır.

Transformer modellerinin sağladığı bu avantajlara rağmen, kullanımında birtakım zorluklar bulunmaktadır. Özellikle büyük Transformer modelleri, yüksek miktarda bellek ve işlemci gücü gerektirir. Bu durum, hem eğitim süreçlerinde maliyetlerin artmasına hem de kaynak kısıtlamalarına yol açabilir. Bu modellerin verimli çalışabilmesi için genellikle geniş kapsamlı ve iyi etiketlenmiş veri setlerine ihtiyaç duyulmaktadır. Transformer'ın genel mimarisi Şekil 3.9.'da gösterilmektedir. Bu mimari, çok katmanlı kodlayıcı ve çözümleyici bloklardan oluşur. Veri eksikliği, eğitim sürecini sınırlandırabilir ve performans üzerinde

olumsuz etkiler yaratabilir. Bu tür zorluklar, transformer mimarisinin uygulanabilirliğini belirli senaryolarla sınırlandırmaktadır.

3.5.1. BERT(Transformer Tabanlı İki Yönlü Kodlayıcı Temsilleri)

Geleneksel duygu analizi yöntemleri, özellikle bağlamdan etkilenen ve anlam açısından nüanslı ifadeleri ele alırken dilin karmaşıklıklarını tam olarak yakalamakta zorlanmıştır. BERT tabanlı modeller ise duygu analizi, soru-cevap ve dilsel kabul edilebilirlik gibi çeşitli dil anlama görevlerinde geleneksel yöntemlere kıyasla daha üstün performans sergilemiştir (Chakkarwar, Tamane ve Thombre, 2023). Bu başarı, BERT'in derin bağlamsal temsil öğrenme kapasitesinden kaynaklanmaktadır. Son yıllarda, BERT olarak bilinen Doğal Dil İşleme alanında bir atılım, geleneksel yaklaşımları geride bırakarak ve dil anlayışını geliştirerek duygu analizindeki boşluğu dolduran güçlü ve dönüştürücü bir teknik olarak ortaya çıkmıştır. BERT, bağlam anlayışını geliştirebilir ve bir dizi alt akış kullanımı için hızlı ve basit bir şekilde değiştirilebilen önceden eğitilmiş bir model sunar. Ayrıca, çeşitli dillerde erişilebilir önceden eğitilmiş dil modelleri bulunmaktadır. BERT, geniş model yapısı ve eğitim sürecinin uzunluğu nedeniyle büyük miktarda metni ve farklı dilleri işleyebilme kapasitesine sahiptir. Doğal dil işleme görevlerinde, özellikle insan benzeri dillerin analizinde ve anlam genişletme süreçlerinde yüksek doğruluk oranı sunmaktadır (Sun, Qiu, Xu ve Huang, 2019). Çeşitli NLP görevleri için en son teknoloji sonuçları sunmak için çok az veri ve göreve özgü ayarlama gerektirir. Sonuç olarak, BERT duygu analizinde önemli bir dönüşüm sağlamış, geleneksel yöntemlerin eksikliklerini gidererek işletmelerin stratejik karar alma süreçlerinde ve ürün geliştirme aşamalarında müşteri duyarlılığını daha etkin bir şekilde değerlendirmelerine olanak tanımıştır. (Sayeed ve diğerleri, 2023).

BERT modelinin etkinliğini daha köklü tekniklerle karşılaştırmak amacıyla, modelin sonuçları Naive Bayes, Support Vector Machines (SVM), Random Forest (RF), Uzun Kısa Süreli Bellek (LSTM), İki Yönlü LSTM (Bi-LSTM), Karar Ağaçları (DT), Valence-Aware Dictionary and Sentiment Reasoners (VADER) gibi yöntemlerle kıyaslanmıştır. Bu yöntemlerin her biri kısaca açıklanmıştır. BERT modeli, belirli bir NLP problemi bağımsızında ileri seviye sonuçlar üretir. Geleneksel tek yönlü dil modeli yerine, yenilikçi Masked Language Model (MLM) ile karmaşık iki yönlü dil temsili oluşturmayı hedefler. Eğitim çerçevesi ve veri kümesi nedeniyle büyük ve yavaş olmasına rağmen BERT, daha fazla metin ve dil işleyebilir. İnsan dilini analiz etme ve ince ayar yapma konusunda yüksek bir doğruluk seviyesine sahiptir. Özünde, şu anda en yaygın kullanılan NLP modellerinden

biri olan BERT, daha az veri ile çok çeşitli NLP görevlerinde ileri seviye sonuçlar sağlar (Chakkarwar ve diğerleri, 2023).

Naive Bayes (NB), istatistiksel temellere dayanan basit ancak etkili bir tahmin modelleme yöntemidir. Olasılığa dayalı olarak Bayes teoremi, her bir olay için olasılığı hesaplar. Bu yöntemin avantajı, az eğitim verisi ile etkili sonuçlar üretmesidir; ancak her bir özelliğin bağımsız olduğunu varsaydığı için kötü tahminlere yol açabilir (Navér, 2021).

Destek Vektör Makineleri (SVM), regresyon ve sınıflandırma için yönlendirilmiş öğrenme yöntemleriyle veri analiz eder ve desenleri arar. SVM, veri grupları birbirinden belirgin bir şekilde ayrıldığında çok iyi performans gösterir; yüksek boyutlu verilerle etkili bir şekilde çalışabilir. Ancak sınıflar arasındaki noktalar net bir şekilde ayrılmadığında, ideal kernel seçimi zorlayıcı olabilir ve büyük veri kümelerinde eğitim süresi uzun olabilir (Hussain, ve diğerleri, 2022).

Random Forest (RF, Rastgele Orman), birden fazla karar ağacını bir araya getirerek çalışan güçlü bir topluluk yöntemidir. RF algoritması, çeşitli karar ağaçlarının sonuçlarını ortalayarak çıktı belirler ve eksik veri alanlarını otomatik olarak doldurur. Ağacın sayısı arttıkça RF'nin doğruluğu da artar. Ayrıca RF, DT algoritmasının karşılaştığı aşırı öğrenme sorununu çözer (Kumar ve Singh, 2022).

LSTM, RNN'lerdeki uzun süreli bağımlılık problemini çözer. Ayrıca vanishing gradient (kaybolan gradyan) ve genişleyen gradyan problemlerine çözüm sunar. LSTM'nin mimarisindeki açık bellek birimi, uzun süreli belleğe sahip olmasını sağlar; ancak daha fazla kaynak tüketir ve eğitim süresi uzundur (Yang & Guo, 2023).

Bi-LSTM, ileri ve geri yöndeki zaman bağımlılıklarını aynı anda modelleyerek daha kapsamlı bir öğrenme sağlar. Özellikle uzun geçmişe sahip zaman serisi verilerinde daha iyi performans gösterir. Ancak, iki LSTM hücresinin paralel çalışması hesaplama maliyetini artırarak daha fazla kaynak gerektirir (Huang, ve diğerleri, LSTM Based Sentiment Analysis for Cryptocurrency Prediction, 2021).

Karar Ağaçları (DT), karmaşık kararları daha basit ve anlaşılır bileşenlere ayıran matematiksel bir modeldir. Bu yöntem, mantıksal koşullar ve olasılık katmanları kullanarak hiyerarşik bir karar yapısını oluşturur (Bajaj, 2021).

VADER, duygu ve düşünceleri analiz etmek için bir sözlük kullanır. VADER, kelimelerin iyi, nötr veya negatif olduğunu kaydeder. Cümlelerin duygu analizinde güçlü bir araç olmasına rağmen, tanımadığı kelimelerle karşılaştığında sınırlı bir performansa sahiptir (Holmer, 2020).

BERT ile gerçekleştirilen veri ön işleme süreci kritik bir aşamadır. Metin verileri BERT modeline gönderilmeden önce, ön işleme adımları uygulanarak temizlenir. Bu süreçte ham metin verisi, gürültü, noktalama işaretleri ve tutarsız büyük harf kullanımı giderilerek daha düzenli bir yapı kazanır. Küçük harf dönüşümü ve belirteçleme işlemlerinin ardından, verinin daha tutarlı hâle gelmesi için yaygın durdurma sözcükleri filtrelendir. Son olarak, belirteçlenmiş metin sayısal forma dönüştürülerek, makinelerin bu veriyi daha etkin şekilde işlemesine olanak tanınır. İşlenen ve sayısal hâle getirilen metin, duygu analizi veya diğer doğal dil işleme görevleri için BERT modeline aktarılmaya hazır duruma gelir (Sayeed ve diğerleri, 2023). Şekil 3.10. BERT modelinin veri ön işleme adımlarını göstermektedir.



Şekil 3.10. Veri ön işleme süreçleri

BERT mimarisi, iki özel sembol kullanır: [SEP] sembolü cümle ya da segmentleri birbirinden ayırmak için, [CLS] sembolü ise sınıflandırma işlemleri için dizinin başına eklenir. [CLS] sembolü, tüm cümleyi veya diziyi temsil eden bir işaret olarak görev yapar ve bu sembolden elde edilen çıktı, modelin gizli katman boyutu ile aynı uzunlukta bir vektör oluşturur. (Şekil 3.11.)

Modelin transformer katmanlarından elde edilen son gizli durum, bu [CLS] sembolü üzerinden elde edilen temsil vektörüdür. Bu vektör, sınıflandırma katmanına giriş olarak verilir. Sınıflandırma işlemi, önceden belirlenmiş kategori sayısına göre gerçekleşir ve her kategoriye ait olasılık değeri, softmax adı verilen bir fonksiyon aracılığıyla hesaplanır (Denklem (3)'te gösterilmiştir).

$$P = (\text{softmax})(CW^T) \quad (3)$$

Transformer


Transformer, BERT'in temelini oluşturur. X ve Y, iki cümleden alınmış alt kelimeler dizisi olarak kabul edilir. [CLS] tokeni X'in önünde yer alırken, [SEP] tokeni hem X hem Y'nin

ardından yerleştirilmiştir. E'nin gömme fonksiyonu ve LN'nin normalizasyon katmanı olduğunu varsayarsak, gömme Denklem (4)'te gösterildiği gibi elde edilir.

$$\begin{aligned} \{h\}_i^0 &= E(x_i) + E(i) + E(1_x) \\ \{h\}_{\{j+|x|\}}^0 &= E(y_j) + E(j + |x|) + E(1_y) \\ \{h\}^0 &= Dropout(LN(\{h\}^0)) \end{aligned} \quad (4)$$

Ardından gömmeler, (M) transformer bloğu üzerinden geçirilir. Bu blokların her birinde, İleri Beslemeli (FF) katman, eleman bazlı Gaussian Hata Doğrusal Birimleri (GELU) aktivasyon fonksiyonu ve Çoklu Kafalı Kendine Dikkat (MHSA) işlevi kullanılarak Denklem (5)'teki durum geçerlidir (Pota ve diğerleri, 2021). (Şekil 3.7.)

$$\begin{aligned} \{h\}^{i+1} &= Skip(FF, Skip(MHSA, h^i)) \\ \{Skip\}(f, h) &= \{LN\}(h + \{Dropout\}(f(h))) \\ \{FF\}(h) &= \{GELU\}(hW_1^T + b_1)W_2^T + b_2 \end{aligned} \quad (5)$$



Şekil 3.11. BERT modelinin genel süreci

Model eğitimi sırasında belirlenen hiperparametreler, modelin doğruluğu, hız ve genelleme yeteneği üzerinde doğrudan etkili olmaktadır. Doğru hiperparametre seçimi, modelin veriye uyum sağlamasını optimize ederken aşırı öğrenme veya yetersiz öğrenme gibi sorunların önüne geçilmesini sağlar. Bu parametrelerden biri olan batch size, her eğitim adımında modele aynı anda verilen veri örneği sayısını ifade etmektedir. Örneğin, 32 batch size, her

eğitim adımında modele 32 veri örneğinin sunulması anlamına gelmektedir. Küçük batch size değerleri (örneğin, 16 veya 32), modelin daha sık güncellenmesine olanak tanımakta ve öğrenme sürecinin daha hızlı gerçekleşmesini sağlamaktadır. Bununla birlikte, bellek kullanımı daha verimli hale gelmektedir. Ancak, küçük batch size'ların eğitim süresini uzatabileceği unutulmamalıdır.

Bir diğer önemli hiperparametre ise learning rate olup, bu, modelin ağırlıklarının ne kadar değiştirileceğini kontrol eden bir değerdir. Örneğin, $2e-5$ değerindeki bir learning rate, ondalıklı biçimde 0.00002 olarak ifade edilmekte olup, modelin ağırlıklarını küçük adımlarla değiştirmesine olanak tanımaktadır. Bu tür düşük öğrenme oranları, modelin dikkatli bir şekilde öğrenmesini ve hataları yavaşça düzeltmesini sağlamaktadır. Bununla birlikte, öğrenme oranının gereğinden fazla düşük olması, modelin öğrenme süresini önemli ölçüde uzatabilmektedir. Bu aşamada sıklıkla kullanılan Adam optimizier, öğrenme hızını dinamik olarak ayarlayarak modelin performansını optimize etmektedir.

Eğitim sürecinde önemli bir diğer hiperparametre de epoch sayısıdır. Epoch, modelin tüm eğitim veri setini bir kez görmesi olarak tanımlanmaktadır. Örneğin, 10 epoch değerinin belirlenmesi, modelin eğitim veri setini toplamda 10 kez işleyeceği anlamına gelmektedir. Daha fazla epoch sayısı, modelin veriyi daha ayrıntılı bir şekilde öğrenmesine katkıda bulunabilmektedir. Ancak, çok yüksek epoch sayıları, modelin aşırı öğrenme (overfitting) riskiyle karşı karşıya kalmasına neden olabilmektedir. Bu nedenle, hiperparametre seçimlerinde dengeli bir yaklaşım benimsenmesi önem arz etmektedir.

4. PERFORMANS ÖLÇÜM YÖNTEMLERİ

Hata matrisi, diğer bir ifadeyle olasılık matrisi, deneyler sonucunda elde edilen istatistiksel verilerin görsel bir temsidir. Bu matris, sınıflandırılan metinlerdeki her bir örneğin gerçek sınıfı ile tahmin edilen sınıfı hakkında istatistiksel bilgiler sağlar. (Çizelge 4.1.) Bu bilgiler, makine öğrenimi algoritmalarının performansını değerlendirmek amacıyla sıklıkla kullanılır. Önerilen algoritmanın başarısı, hata matrisinden türetilen "doğruluk", "kesinlik", "duyarlılık" ve "F1-skoru" gibi ölçütlerle değerlendirilmektedir. (Çizelge 4.2.) Araştırmalarda BERT, CNN, LSTM, Bi-LSTM, GRU, Bi-GRU ve CNN-LSTM modellerinin performansı bu yöntemler aracılığıyla analiz edilmektedir. Hata matrisindeki bileşenler, çeşitli performans metriklerinin değerlendirilmesine olanak tanımaktadır.

Buna ek olarak, hata matrisi; doğru pozitif (TP), doğru negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) değerlerini içeren dört temel bileşene sahiptir (Şahiner Yılmaz, 2022). Bu bileşenler, özellikle büyük veri kümeleri üzerinde çalışan algoritmaların güçlü ve zayıf yönlerini anlamak için kıymetli bilgiler sağlar. Performans ölçümleri, metin sınıflandırma ve duygu analizi gibi doğal dil işleme (NLP) uygulamalarında modellerin genel etkinliği ve doğruluğu hakkında kapsamlı bir fikir verir.

1. Doğru Pozitif (TP): İlk olarak pozitif olarak etiketlenen ve model tarafından doğru bir şekilde pozitif olarak tahmin edilen örnekler.
2. Yanlış Pozitif (FP): İlk olarak negatif olarak etiketlenmiş ancak model tarafından yanlış bir şekilde pozitif olarak sınıflandırılan örnekler.
3. Doğru Negatif (TN): İlk olarak negatif olarak etiketlenen ve modelin doğru bir şekilde negatif olarak tahmin ettiği örnekler.
4. Yanlış Negatif (FN): İlk olarak pozitif olarak etiketlenen ancak model tarafından yanlış bir şekilde negatif olarak sınıflandırılan örnekler.

Çizelge 4.1 Hata matris gösterimi

Gerçek Etiket	Pozitif(Duygusal)	Negatif(Duygusal)
Tahmin Edilen Pozitif	Doğru Pozitif (TP): İlk olarak pozitif olarak etiketlenen ve modelin doğru şekilde pozitif olarak tahmin ettiği veriler.	Yanlış Pozitif (FP): İlk olarak negatif olarak etiketlenmiş ancak modelin yanlış şekilde pozitif olarak sınıflandırdığı veriler
Tahmin Edilen Negatif	Yanlış Negatif (FN): İlk olarak pozitif olarak etiketlenen ancak modelin yanlış bir şekilde negatif olarak tahmin ettiği veriler.	Doğru Negatif (TN): İlk olarak negatif olarak etiketlenmiş ve modelin doğru şekilde negatif olarak tahmin ettiği veriler.

Çizelge 4.2. Sınıflandırma performansı ölçüm yöntemleri


Doğruluk: doğru tahmin edilen örneklerin fraksiyonudur. $\text{Doğruluk} = (TP + TN) / (TP + FP + TN + FN)$
Kesinlik: Doğru pozitif tahminin toplam pozitif tahmine oranıdır. $\text{Kesinlik} = TP / (TP + FP)$
Duyarlılık: Doğru pozitif tahmin sayısının toplam örnek sayısına oranıdır. $\text{Duyarlılık} = TP / (TP + FN)$
F1-skor: “Kesinlik” ve “Duyarlılık” harmonik ortalamasıdır. $\text{F1-skor} = 2 * \text{Kesinlik} * \text{Duyarlılık} / (\text{Kesinlik} + \text{Duyarlılık})$

ROC-AUC ve PRC-AUC değerleri de performans değerlendirmesinde kullanılan önemli metrikler arasında yer almaktadır. ROC eğrisi, modelin her sınıflandırma eşiği için performansını görsel olarak ifade ederken, AUC algoritması bu eğrinin altındaki alanı hesaplar. AUC, modelin rastgele seçilmiş bir pozitif örneği, rastgele seçilmiş bir negatif örnekten daha yüksek bir sıralama olasılığı ile değerlendirdiğini ve 0 ile 1 arasında bir puan sunduğunu göstermektedir. Bu metrik, her iki sınıfa da eşit önem atfetmektedir.

Bununla birlikte, yüksek sınıf dengesizliği içeren problemlerde PRC (Precision-Recall Curve) eğrisi altındaki alanın (PRC-AUC) hesaplanması daha anlamlı olabilmektedir. PRC-AUC, azınlık sınıfına daha fazla odaklanarak bu sınıfın performansını ayrıntılı bir şekilde değerlendirme imkanı sunar. Ancak, her iki yöntem (ROC-AUC ve PRC-AUC), sınıflandırıcılar arasında doğrudan karşılaştırma yapmak için optimal (Pàmies Massip, 2020).

5. KELİME TEMSİL YÖNTEMİ


Kelime temsil yöntemleri veri işleme ve özellik çıkarımı aşamasında kullanılır. Bu yöntemler, metinleri sayısal formatlara dönüştürerek doğal dil işleme (NLP) algoritmalarında kullanılabilir hale getirir. Bir metnin vektörel temsilini belirlemek için yaygın olarak kullanılan iki yöntem bulunmaktadır: Kelime Çantası Modeli (Bag of Words) ve TF-IDF yöntemi. Kelime Çantası yaklaşımında, tüm veri ele alınarak kelimelerin yalnızca tekrar sayısına odaklanılır. Ancak bu yöntemde kelimelerin konum bilgisi dikkate alınmaz. TF-IDF yöntemi ise kelimelerin konum bilgisini içerir; ancak bu model, yoğun şekilde sıfır içeren büyük ve seyrek matrisler oluşturduğu için hesaplama sürecini zorlaştırabilir. Bu dezavantajları aşmak amacıyla kelime temsil yöntemleri önerilmiştir. Bu yaklaşımlar, kelimeleri bilgisayarların anlayabileceği ve işleyebileceği şekilde sayısal vektörlerle ifade etmeye dayanmaktadır. Her kelime, bir vektörle temsil edilir ve anlam bakımından birbirine yakın kelimeler, vektörel temsilde de birbirine yakın olacaktır (Şekil 4.1). Doğal Dil İşleme (DDİ) alanındaki araştırmalar, kelime temsil yöntemlerinin performansı artırmada etkili olduğunu göstermektedir (Özer, 2019). Çalışmada, veri setindeki her kelimenin vektörel temsili bu yöntemle sağlanmış ve bu durum sınıflandırma işleminin performansını artırmak için kullanılmıştır. Bilinen kelime temsil yöntemleri arasında “Word2vec,” “GloVe” ve “FastText” gibi modeller yer almaktadır. Bu yöntemler, metin verilerini temsil etmede daha etkili ve hassas bir yaklaşım sunarak, doğal dil işleme uygulamalarında yaygın bir şekilde kullanılmaktadır.



Şekil 5.1. CBOW ve Skip-gram mimarisi

Word2Vec modeli, metin derlemlerinden kelime vektörleri üreten bir yöntemdir ve bu vektörler sabit bir uzunluğa sahiptir. Model, kelime vektörleri aracılığıyla kelimelerin anlamını temsil etmeyi amaçlar (Wang Y. H., 2018). Word2Vec içerisinde kullanılan iki temel yaklaşım bulunmaktadır: “Skip-gram” ve “Continuous Bag of Words (CBOW).” Her iki yaklaşım da tek bir gizli katman içeren basit sinir ağı modelleri olarak tasarlanmıştır. (Şekil 5.1.) Bununla birlikte, kelime tahmini süreçlerinde birbirine zıt şekilde çalışırlar. CBOW mimarisi, kelimenin bağlamını belirlemek için önceki ve sonraki kelimelerden yola çıkarak tahmin yapar. Öte yandan, Skip-gram modeli ise belirli bir kelimeyi temel alarak, çevresindeki bağlamsal kelimeleri tahmin etmeye odaklanır (Sharma, 2020) .

Glove modeli, kelimelerin bağlamı ve sayısına bağlı olarak bir matris oluşturan etkili bir yöntemdir. Bu matris, her bir satırında, karşılık gelen kelimenin vektörel temsilini içerir. Word2Vec gibi Glove da kelimeleri vektör biçiminde temsil ederek anlamsal benzerlikleri analiz etmeyi hedefler. Her iki modelde de kelimenin örnek uzaydaki konumu dikkate alınarak kosinüs benzerliği yardımıyla anlamsal yakınlık belirlenebilir (Şekil 5.2). Bununla birlikte, Glove modeli eğitim sürecinde tüm derlemi göz önünde bulundururken, Word2Vec modeli yalnızca metindeki komşu kelimeler üzerinden işlem yapmaktadır.



Şekil 5.2. Kosinüs benzerliğine göre anlamsal yakınlık

FastText modeli, Facebook'un AI Araştırma ekibinden Bojanowski ve çalışma arkadaşları tarafından geliştirilen, sinir ağlarına dayalı popüler bir kelime temsili yöntemidir (Bojanowski, Graand, Joulin ve Mikolov 2016). Bu model, Word2Vec CBOW yaklaşımı temel alınarak geliştirilmiş ve kelimelerin morfolojik özelliklerini göz önünde bulundurarak yüksek kaliteli temsiller öğrenmeye yönelik uyarlanmıştır. FastText, vektörlerin farklı

kelimeler arasında paylaşılmasına olanak tanıyarak, nadir kelimelerin daha güvenilir bir şekilde temsil edilmesini sağlamaktadır (Bojanowski ve diğerleri, 2016).

Ayrıca, FastText modeli İngilizce, Almanca, İspanyolca, Fransızca, Çekçe ve Türkçe dahil olmak üzere 157 dilde kullanılabilir bir açık kaynaklı kütüphaneye sahiptir. Bu özellikleri sayesinde hem yaygın hem de az kullanılan kelimelerin temsilleri için etkili bir çözüm sunar.





6. LİTERATÜR TARAMASI

Karar verme sürecinde, başkalarının düşünceleri genellikle önemli bir bilgi kaynağı olarak değerlendirilmektedir. Duygu analizi çalışmaları, bu bilgiye olan ihtiyacımızı karşılamaya yönelik olarak geliştirilmiştir. Özellikle son yıllarda, duygu analizi ve fikir madenciliği konularında yapılan akademik çalışmaların ve yayınlanan makalelerin sayısında kayda değer bir artış görülmüştür (Şekil 6.1. ve 6.2.).



Şekil 6.1. "Google Trends" "Sentiment Analysis" çalışma alanını gösteren veriler grafiği



Şekil 6.2. "Google Trends" "Duygu Analizi" çalışma alanını gösteren veriler grafiği

Duygu analizi çalışmalarının temelleri, İkinci Dünya Savaşı sırasında ve sonrasında politika alanında yapılan araştırmalara dayanmaktadır (Stagner, 1940) . Bu çalışmalar, toplumun düşüncelerini anlamaya yönelik girişimler olarak şekillenmiştir. Modern duygu analizi ise 2000'li yılların başlarında ürün incelemelerine odaklanmaya başlamıştır. Dave ve çalışma arkadaşları, ürün özelliklerinin listesi ve her biri hakkındaki görüşleri bir araya getirerek Web aramalarından toplanan bireysel cümlelerden olumlu ve olumsuz görüşleri otomatik olarak ayırt etmeyi amaçlayan bir yöntem geliştirmiştir. (Dave, 2003)

Duygu analizi günümüzde geniş bir kullanım alanına yayılmıştır. Örneğin, finansal piyasaların tahmini (Nassirtoussi, 2014) , terörist saldırılara verilen tepkiler (Burnap, Williams, Sloan, Rana, Housley, Edwards ve Voss, 2014) gibi çeşitli konularda uygulanmaktadır. Bunun yanı sıra ironi tespiti (Reyes ve Rosso, 2013) , çok dilli destek ve karmaşık duyguların (keder, öfke gibi) ayrıştırılması (Munezero, Montero, Sutinen ve Pajunen 2014) duygu analizinin uygulanabilirliğini genişletmek adına yapılmış çalışmalardır.

Duygu analizi alanının tarihsel gelişimine bakıldığında, çevrimiçi ortamda büyük miktarda metin ve görüşlerin yaygınlaşmasından önce, araştırmalar ağırlıklı olarak anket tabanlı yöntemlere dayanıyordu. Bu dönemde, kullanıcı veya müşteri geri bildirimlerinden ziyade, kamuya açık veya uzman değerlendirmelerine odaklanmak yaygın bir yaklaşımdı. Örneğin, (Stagner, 1940) tarafından yayımlanan "The Cross-Out Technique as a Method in Public Opinion Analysis" adlı çalışma bu alanın erken dönem örneklerinden biridir. 1945 ve 1947 yıllarında ise (Knutson, 1945), (Fegiz, 1947) ve (Adamec ve Viden, 1947) tarafından, savaşa katılan askerlerin ve savaş mağdurlarının görüşlerini değerlendiren üç bildiri yayınlanmıştır. Tüm bu çalışmalar "Public Opinion Quarterly" dergisinde yayımlanmıştır.

90'lı yılların ortalarında, bilgisayar tabanlı sistemlerin yaygınlaşması ile duygu analizinde yeni bir dönem başlamıştır. (Sandri, 1995) tarafından yayımlanan "Elicitation, Assessment and Pooling of Expert Judgments Using Possibility Theory" başlıklı makale, endüstriyel güvenlik alanında uzman görüşü analizi için bilgisayar sistemlerinin kullanımını ele almıştır. Modern duygu analizine ait çalışmaların ise daha sonraki yıllarda artış gösterdiği görülmektedir. (Wiebe J. M., 1991), öznel cümlelerin tespiti için yöntemler geliştirmiş ve 1999 yılında bu çalışmaları daha ileriye taşıyarak bir standart oluşturmuştur (Wiebe J. B., 1999).

(Hatzivassiloglou ve McKeown, 1997), "Predicting the Semantic Orientation of Adjectives" çalışmasında, sıfatların anlam yönelimlerini analiz etmek için 1987 Wall Street Journal sözlüğünden elde edilen 2 milyon kelimeyi kullanmıştır. Benzer şekilde (Turney P. , 2002), otomobil, banka, film ve seyahat verileri ile denetimsiz sınıflandırma kullanarak %74 doğruluğa ulaşmıştır. (Turney P. D., 2003) ise kelimelerin semantik yönelimlerini analiz eden bir yöntem geliştirmiştir.

(Taboada, 2011) Tarafından gerçekleştirilen "Lexicon-based methods for sentiment analysis" başlıklı çalışmada, önceden var olan sözlük tabanlı bir yönteme yoğunlaştırma ve olumsuzlama gibi ek kurallar getirilerek "Semantic Orientation CALCulator (SO-CAL)" adlı analiz aracı geliştirilmiştir. Araç, duygu analizinde daha kapsamlı bir yaklaşım sunmayı

amaçlamıştır. Bu yeni yöntem, çeşitli veri setleri üzerinde test edilerek mevcut duygu analizi araçları ve teknikleri ile doğrulanmış, değerlendirilmiş ve karşılaştırılmıştır. Yazarlar, ürün incelemeleri, sosyal medya yorumları, haber makaleleri ve manşetlerden oluşan farklı veri setlerini kullanarak aracın performansını ölçmüşlerdir.

Metin madenciliği ve duygu analizi, yapılandırılmamış veriler üzerinde çalışan yöntemlerdir ve bu açıdan klasik veri madenciliği tekniklerinden farklılık göstermektedir (Oza ve Naik, 2016) Sözlük tabanlı yaklaşım, duygu analizinde yaygın bir teknik olarak, metin verilerini önceden tanımlanmış duygu sınıflarına sınıflandıran denetimsiz bir yöntemdir. Bu yöntemde metnin duygu puanları, kelimelerin duygu sözlüğündeki karşılıklarına dayanarak hesaplanmaktadır (Wiebe J. B., 1999). Sözlük temelli yöntemler, metin verilerindeki duygusal kutuplaşmayı belirlemeyi amaçlayan modeller olarak değerlendirilebilir. (Sun S. L., 2017). Ancak, metindeki terimlerin duygu sözlüğündeki kutupluluk değerlerinden farklı anlamlar taşıyabilmesi, sözlük bazlı yaklaşımların performansını sınırlayabilir (Muhammad A., Wiratunga, N. ve Lothian, R, 2016). Bu sorun, alana özgü sözlüklerin oluşturulması ile giderilebilir ve kutupluluk hataları en aza indirilebilir.

2012 yılında yapılan bir çalışmada, makine öğrenimi algoritmalarıyla desteklenmiş bir sınıflandırıcı olan "SentiStrength" adlı araç değerlendirilmiştir. Bu araç, YouTube yorumları ve tweet'ler gibi kısa metinlerden oluşan veri kümelerinde etkili bir şekilde duygu analizi yapmayı sağlamıştır (Thelwall M. B., 2012). Ayrıca, "SentiStrength" aracı Türkçe diline de uyarlanmıştır (Vural, 2013). Duygu analizinde kullanılan bir diğer önemli araç olan Senti-WordNet, Baccianella ve çalışma arkadaşları tarafından geliştirilmiş olup yarı denetimli bir öğrenme algoritmasıyla oluşturulan bir sözlüktür. Bu sözlükteki kelimelerin anlamsal değerleri, eşanlamlı kelimelerle manuel olarak karşılaştırılarak değerlendirilmiştir (Baccianella, 2010).

(Feldman, 2013) Tarafından yapılan bir çalışmada, duygu analizi belge ve cümle bazlı, bakış açısı odaklı ve karşılaştırmalı olarak kategorilere ayrılmıştır. Bu çalışmada, duygu analizi süreçlerinde kullanılan sözlüklerin önemine vurgu yapılmıştır. Günümüzde ise makine öğrenimi yöntemleriyle gerçekleştirilen duygu analizi çalışmalarının sayısı, sözlük tabanlı yaklaşımları geride bırakmıştır (Pirani, 2017).

R paketi 'wordcloud' kullanılarak oluşturulan Şekil 6.2, "Google Akademik" ve "Scopus" veritabanlarında yayınlanmış makalelerin başlıklarından derlenen araştırma konularını ve bu konuların yıllara göre değişimini göstermektedir. Şekil 6.2 (a), duygu analizinin temel kavramlarının "social", "online", "reviews", "media", "product" ve "twitter"

olduğunu ortaya koymaktadır. Çalışma alanında en sık kullanılan diller Çince ve Arapça olarak dikkat çekerken, iş alanlarında “movie”, “news”, “political”, “stock” ve “financial” gibi konular öne çıkmaktadır. Analiz yöntemleri açısından ise “neural”, “fuzzy” ve “supervised” teknikleri sıkça kullanılmaktadır (Mäntylä M. V., 2018).

Şekil 6.2 (b), bu konuların yıllar içindeki değişimini bir kelime bulutu şeklinde sunmaktadır. Her kelime, geçmiş yıllardaki kullanım sıklığına göre meydana gelen değişimleri göstermektedir. Örneğin, “review” kelimesinin küçülmesi, dönemler arasındaki farklılığın azaldığını ifade etmektedir. 2013 yılı öncesinde Çince yaygın olarak kullanılırken, sonraki yıllarda Arapça ve Hintçe daha çok tercih edilmeye başlanmıştır. 2013’ten önceki dönemlerde çevrimiçi ürün incelemelerine yönelik çalışmalar ön plandayken, 2014-2016 yılları arasında sosyal medya araçları kullanılarak yapılan analizlerin arttığı gözlemlenmiştir.

Son yıllarda Twitter ve sosyal medya platformları duygu analizinde önemli bir rol oynamaya başlamıştır. Pak ve Paroubek (2010), mikrobloglardan veri kümesini otomatik olarak toplamak için bir yöntem geliştirmiş ve bu yaklaşımı duygu sınıflandırıcı oluşturmak amacıyla kullanmıştır. Bu çalışma, çevrimiçi metinlerden duygu analizine yönelik veri madenciliği sürecini iyileştirmeyi hedeflemiştir. Çalışmada, veriler Twitter'dan toplanmış olup, bu yaklaşımın farklı dillere uyarlanabilir olduğu ifade edilmiştir. Ancak, çalışma kapsamında yalnızca İngilizce diliyle sınırlı bir uygulama gerçekleştirilmiştir.

Tumasjan ve diğerleri (2010) ise, Twitter’ı seçim sonuçlarını tahmin etmek için bir araç olarak ele almış ve bu doğrultuda yaklaşık 100.000 tweet’i incelemiştir. Bu çalışma, Twitter'dan elde edilen sosyal medya verilerinin farklı alanlarda kullanılabilirliğini göstermektedir.

Duygu analizi çalışmalarında en sık kullanılan anahtar kelimeler arasında "duygu analizi," "fikir madenciliği," "duygu sınıflandırması," "metin madenciliği," "makine öğrenme," "sosyal medya," "Twitter," "veri madenciliği," "öznitelik seçimi," "polarite sınıflandırması," "özellik çıkarma," "duygu," "sınıflandırma," "konu modelleme," "iş zekası," "borsa," "anlamsal yönelim," "mikrobloqlama," "etki analizi," "kümeleme," "duygu sözlüğü," "öznellik analizi" ve "yorumlar" gibi terimler yer almaktadır (Piryanı ve diğerleri, 2017).

Bunun yanı sıra, duygu analizi çalışmalarında kullanılan veri setleri de oldukça önemlidir. En yaygın veri setleri arasında yorumlar, Twitter, haber siteleri, forumlar, videolar ve bloglar bulunmaktadır (Piryanı ve diğerleri, 2017).

Nguyen ve arkadaşlarının (2020) çalışması, Vietnamca duygu analizi üzerine yapılmış deneysel araştırmalarda, BERT modelinin RCNN (Recurrent Convolutional Neural

Network) gibi modellerle veya tekrarlı ve konvolüsyonel ağların birleşimini içeren mimarilerle entegre edilebileceğini göstermiştir. Elde edilen deneysel bulgular, özellikle Vietnamca incelemelerin yer aldığı veri setlerinde, BERT-RCNN modelinin duygu analizi performansını önemli ölçüde artırdığını ortaya koymaktadır. Bu yaklaşım, BERT'in bağlamsal anlamlandırma kapasitesi ile RCNN'nin sıralı veri işleme yeteneklerini birleştirerek daha yüksek doğruluk oranlarına ulaşılmasını sağlamıştır (Nguyen ve arkadaşları, 2020).

BERT modeli, birçok bilim insanının ilgisini çekmiş ve çeşitli doğal dil işleme (NLP) uygulamalarında kullanılmaya çalışılmıştır. Son yıllarda, metin özetleme, otomatik puanlama, metin benzerlik puanı tahmini, duygu sınıflandırmasının geliştirilmesi ve sıralama yenileme gibi zorluklar üzerine birçok deney gerçekleştirilmiştir. Ayrıca, bazı çalışmalarda BERT modelinin farklı dillerde duygu analizi için kullanıldığı görülmüştür (Chakkarwar ve diğerleri, 2023). BERT modeli, birçok farklı dilde başarılı bir şekilde uygulanmıştır. Örneğin, Endonezce metinlerde (Nugroho, Sukmadewa, Wuswilahaken, Bachtiar ve Yudistira, 2021), (Azhar ve Khodra, 2020) ve Bangla müşteri geri bildirimlerinde (Prottasha, ve diğerleri, 2022) kullanılmıştır. Özellikle Bangla-BERT ve LSTM'nin birleşimi, duygu analizinde %94.15 gibi oldukça yüksek bir doğruluk oranı sağlamıştır. Ayrıca, BERT, Çince borsa yorumlarında (Li, Chen, Zhao ve Li, 2021), Arapça tema odaklı yorumlarda (Abdelgwad, Soliman, Taloba ve Farghaly, 2022) ve Urdu kullanıcı yorumlarında (Khan, Amjad, Ashraf ve Chang, 2022) da etkili bir şekilde uygulanmıştır.

BERT modelinin Otomatik Kompozisyon Puanlama (Automated Essay Scoring - AES) için yapılan bir çalışmada kullanıldığı belirtilmektedir. Otomatik kompozisyon değerlendirme (AES), doğal dil işleme (NLP) alanında karşılaşılan en zorlu problemlerden biri olarak kabul edilir. Bu zorluklar arasında kompozisyon uzunluğunun değerlendirilmesi, yazım hatalarının kaliteyi düşürmesi ve kompozisyonun etkili değerlendirme kriterleri doğrultusunda nasıl temsil edileceği gibi konular yer almaktadır. Yapılan çalışmada, AES modellerinin performansını artırmak amacıyla BERT modeli farklı yapılarla entegre edilmiştir. Elde edilen sonuçlar, derinlemesine kodlanmış özellikler (deep-encoded features) ve manuel olarak çıkarılan özelliklerin bir arada kullanılmasının, AES sistemlerinin işlevselliğini önemli ölçüde iyileştirdiğini ortaya koymaktadır (Beseiso ve Alzahrani, 2020).

Tarım sektöründe tüketiciler, tarımsal ürünlerin kalitesini değerlendirme fırsatına sahipken, işletmeler ise çevrimiçi müşteri yorumlarına duygu analizi uygulayarak ürünlerini geliştirme ve iyileştirme sürecini optimize edebilir. Bu yaklaşım, müşteri geri bildirimlerinden değerli içgörüler elde ederek tarımsal üretim ve pazarlama stratejilerini daha etkili hale getirmeye

yardımcı olur. BERT modeline dayalı tarımsal değerlendirme sınıflandırma algoritması, metinde iletilen duyguyu başarıyla tanımlamış, ağ değerlendirme verilerinin analizine, faydalı bilgilerin çıkarılmasına ve duyguların görselleştirilmesine katkıda bulunmuştur (Cao, Sun, Li ve Mo, 2022).

Yelp, Amazon, Twitter ve IMDB Film İncelemeleri gibi platformlardan elde edilen müşteri yorumlarıyla kullanıcı tutumlarını tahmin etmek amacıyla optimize edilmiş bir BERT modeli geliştirilmiştir. Çalışmada Hybrid fastText-BiLSTM, BiLSTM, fastText ve Linear Support Vector Machine (LSVM) modelleri karşılaştırılmıştır. Sonuçlar, önerilen BERT modelinin doğruluk ve genel performans açısından üstün olduğunu göstermiştir. Ayrıca, veri hazırlama ve model eğitimi süreçleri daha az zaman gerektirmiştir. Ancak, geleneksel modellere kıyasla BERT modeli, eğitim sürecinde daha fazla CPU kaynağı tüketmiştir. Geliştirilmiş BERT modelinin kullanılmasıyla büyük veri kümeleri üzerinde duygu analizi daha etkili bir şekilde gerçekleştirilebilmiştir (Durairaj ve Chinnalagu, 2021).

(Sousa ve diğerleri, 2019) Tarafından yürütülen bir çalışma, borsa sektöründe haberlerin miktarı ve analiz tepki süreleri sorunlarını ele almaya çalışmıştır. Borsa duygu analizini gerçekleştirmek amacıyla BERT modeli incelenmiş ve sonuçlar, BERT'in kelime gömme (word embeddings) ve konvolüsyonel sinir ağlarına kıyasla performans açısından üstün olduğunu göstermiştir. Araştırmada gelecekte belirli şirketlere ait haberlerin çıkarılması ve bu haberler üzerinden veri işleme ile hisse senedi değeri analizlerinin yapılabileceği vurgulanmıştır. Ayrıca, şirket hakkında haberler toplanarak muhasebe bilgileri ile daha doğru tahminler geliştirilebileceği belirtilmiştir. Bu bulgular, finansal temsilcilerin daha bilinçli ve veri odaklı kararlar almasına katkı sağlayabilir. Elde edilen içgörüler, piyasa analizlerini güçlendirerek stratejik planlamayı iyileştirme potansiyeline sahiptir.

(Lee, Yap, Ng ve Goh, 2022) Tarafından yürütülen bir çalışmada, Word2Vec, Term Frequency Inverse Document Frequency (TF-IDF), BERT ve kelime gömme teknikleri kullanılarak nesnellik ve öznellik üzerinde duygu analizinin etkileri incelenmiştir. Çalışmada Wikipedia ve Shopee kullanıcı yorumlarından elde edilen iki veri kümesi kullanılmıştır. Araştırma sonuçları, BERT gömme tekniğinin, %99.77 doğruluk oranıyla öznellik sınıflandırmasında en iyi sonucu sağladığını göstermiştir.

Malaysian Airlines'a yönelik kamuoyu duyarlılığını değerlendirmek amacıyla altı farklı model ile duygu analizi gerçekleştirilmiştir. Bu modeller arasında Linear Support Vector Classifier, BERT Model, Ensemble Method, Multinomial Naive Bayes, Bi-LSTM ve Random Forest bulunmaktadır. Çalışma, farklı model yapılarını karşılaştırarak duyarlılık tahmininde en etkili yaklaşımı belirlemeyi amaçlamaktadır. Araştırma sonuçları, derin

öğrenme tekniklerinin geleneksel makine öğrenimi yöntemlerine kıyasla üstün performans sergilediğini ortaya koymuştur. Özellikle Bidirectional LSTM (Bi-LSTM) modeli %77 doğruluk oranı elde ederken, BERT modeli %86 doğruluk ile tüm diğer modelleri geride bırakmıştır. Çalışmada ayrıca BERT'in, küçültme (decapitalization), noktalama işaretlerinin kaldırılması, stopword çıkarma ve emoji metne dönüştürme gibi yaygın ön işleme tekniklerini geride bırakarak daha etkili olduğu gösterilmiştir. Bunun yanında, BERT'in denetimsiz metin kategorizasyonu sonuçlarını aşarak duygu kalıplarını başarılı bir şekilde yakaladığı ve analiz ettiği de kanıtlanmıştır. Bu bulgular, metin madenciliğinde BERT'in duygu analizi süreçlerine olan katkısını güçlü bir şekilde desteklemektedir. (Kang, Chye, Ong ve Tan, 2021).

(Uçan, Naderalvojud, Sezer ve Sever, 2016) duygu analizi için bir yöntem önererek, İngilizce geliştirilmiş SentiWordNet (SWN) sözlüğünü kullanarak Türkçe için bir duygu sözlüğü oluşturmuşlardır. Çalışmalarında geliştirdikleri sözlük tabanlı modeli, pozitif ve negatif etiketlere sahip film ve otel yorumları veri kümeleri üzerinde test etmişlerdir. Modelin performansı, Destek Vektör Makinesi (DVM) ile karşılaştırılmıştır. Sözlük tabanlı modelin, veri boyutunun daha küçük olduğu otel yorumları veri kümesinde DVM'den daha başarılı olduğu; ancak, daha büyük veri kümesine sahip film yorumlarında ise DVM'den daha düşük performans gösterdiği tespit edilmiştir.

(Açıkalin ve diğerleri, 2020) çalışması, Türkçe duygu analizi üzerine BERT modeli bazı yöntemler geliştirmiştir. Araştırmacılar, Türkçe dilindeki sınırlı doğal dil işleme kaynaklarını aşmak için iki farklı yaklaşım önermiştir: birincisi, BERT'in çok dilli modelinin Türkçe veri kümeleri üzerinde ince ayar yapılması, ikincisi ise Türkçe metinlerin otomatik olarak İngilizceye çevrilip yalnızca İngilizce için geliştirilmiş BERT modellerinin kullanılması. Film ve otel yorumlarından oluşan veri setlerinde gerçekleştirilen deneyler, özellikle film veri setinde yüksek başarımlı sonuçlar elde edildiğini göstermiştir. Çalışma, çok dilli modeller yerine dil spesifik modellerin kullanılmasının genellikle daha etkili olduğunu ve BERT modellerinin yeterli veri sağlandığında metin analizi görevlerinde üstün performans gösterdiğini ortaya koymaktadır.

(Geetha ve Karthika Renuka, 2021) Tarafından gerçekleştirilen çalışmada, tüketici yorum verileri duygu analizi yöntemleri kullanılarak pozitif ve negatif sınıflara ayrılmıştır. Bu süreçte, LSTM, BERT, Naive Bayes Sınıflandırması ve SVM gibi farklı sınıflandırma modelleri değerlendirilmiştir. Performans analizleri ve karşılaştırmalar sonucunda, BERT modelinin doğruluk açısından diğer tahmin modellerine kıyasla daha başarılı olduğu görülmüştür.

Araştırma bulguları, BERT modelinin diğer makine öğrenimi algoritmalarının performansı ile birlikte ele alındığında, genel performans ölçütleri açısından üstün geldiğini ortaya koymuştur. %88.48 doğruluk oranı ile BERT, en iyi sonuçları veren model olarak öne çıkmıştır. Bununla birlikte, çevrimiçi müşteri ürün incelemeleri için yaygın olarak kullanılan duygu analizi yöntemlerinin zaman zaman hatalı olabileceği ve genellikle daha uzun eğitim süresi gerektirdiği belirtilmektedir. Bu çalışma, BERT modelinin güçlü bir Derin Öğrenme modeli olarak duygu analizi problemini çözebileceğini göstermiştir. BERT modeli, yüksek tahmin gücü ve iyi doğruluk oranıyla diğer makine öğrenimi tekniklerini deneyimlilikte geride bırakmıştır.

(Azhar ve Khodra, 2020) Endonezya odaklı duygu analizi üzerine gerçekleştirdiği çalışmada, BERT modeli kullanılarak 32 batch boyutu, $2e-5$ öğrenme oranı ve 25 epoch'luk bir yapılandırma uygulanmıştır. Araştırmacılar, verilerdeki yanlış sınıflandırmalarla ilgili zorluklarla karşılaşmıştır. Bu yanlış sınıflandırmaların nedenleri arasında, hatalı etiketlenmiş veriler ve duygu kutuplarında nötr olarak kabul edilen, ancak aslında belirli kategori anahtar kelimelerini veya diğer duyguları temsil eden ifadeler bulunmaktadır. Bunun sonucunda, bu tür durumlar belirgin bir şekilde pozitif veya negatif duygularla ilişkilendirilememiştir. Ayrıca, tek bir ifade birden fazla kategoriye yönelik çatışan tutumların bulunması, modeli olumsuz duygu sınıfına yönlendirmek zorunda bırakmıştır. Bu durum, veri setinde pozitif duygular içeren anahtar kelimeler yer alsa bile önemli bir zorluk olarak öne çıkmaktadır. Çelişkili bilgiler, BERT modelinin doğru tahmin yapmasını zorlaştırmış ve duygu analizindeki performansının beklenen seviyeye ulaşmasını engellemiştir.

(Pota ve diğerleri, 2021) çalışması Twitter duygu analizinde kullanılan etkili bir BERT tabanlı yöntemi tanıtmaktadır. Çalışma, İtalyanca üzerine bir vaka çalışması gerçekleştirerek, Twitter jargonunu sade metne dönüştüren ve ardından önceden sade metin üzerinde eğitilmiş BERT modeli ile sınıflandırma yapan iki aşamalı bir süreç önermiştir. Ön işleme prosedürleri, emojiler, emoticonlar ve diğer sosyal medya öğelerini metin içindeki duyguyu koruyacak şekilde dönüştürmeyi amaçlamış ve dil bağımsız yapısıyla öne çıkmıştır. Çalışmada kullanılan SENTIPOLC 2016 veri seti, pozitif, negatif ve karışık duygu sınıflarını içeren tweetlerden oluşmuştur. Önerilen yöntem, ALBERTo gibi İtalyanca tweetlerle sıfırdan eğitilmiş modellere kıyasla %3 daha yüksek F1 skoru elde etmiş ve sade metne dayalı dil modellerinin performans avantajlarını vurgulamıştır. Sonuçlar, hem mevcut durumdaki sistemlere göre gelişmiş bir performansı ortaya koymuş hem de dil bağımsız yaklaşımın diğer dillerde uygulanabilirliğini göstermiştir.

(Kusnadi, Yusuf, Andriantony, Ardian Yaputra ve Caintan, 2021) Tarafından gerçekleştirilen çalışmada, BERT modeli, Google Play'de yer alan Genshin Impact mobil oyununa ait veri setinin duygu analizi için uygulanmıştır. Araştırmacılar, 32 batch boyutu, $2e-5$ öğrenme oranı (Adam optimizasyon yöntemi) ve 10 epoch ile hiperparametre ayarı kullanmışlardır. Model, pozitif duyguyu tahmin etmede etkileyici bir performans sergileyerek %0.86 precision, %0.82 f1-skoru ve %0.78 recall skorlarına ulaşmıştır. Bu sonuçlar, oyun geliştirme açısından değerli bilgiler sunmuş ve pozitif duyguların kullanıcı memnuniyeti ile etkileşimdeki kritik rolünü ortaya koymuştur. Bununla birlikte, duygu analizinde nötr duygunun algılanması, model için daha zorlayıcı bir sorun olarak öne çıkmıştır. Nötr duyguların doğruluk oranı, pozitif ve negatif duygulara kıyasla daha düşük kalmıştır. Bu durum, önceki araştırmalarla uyumlu olup, metin verilerinde nötr duyguların doğru sınıflandırılmasının zorluklarını ortaya koymaktadır. Nötr ifadelerin belirgin bir duygusal eğilim göstermemesi, sınıflandırma modellerinin kararsız kalmasına neden olabilir ve bu da model performansını etkileyen önemli bir faktördür.

(Bello, Ng ve Leung, 2023) Tarafından gerçekleştirilen çalışma, Twitter'daki duygu analizini geliştirmek amacıyla BERT tabanlı bir çerçeve sunmaktadır. Çalışmada, metin sınıflandırması için BERT'in farklı derin öğrenme modelleriyle (CNN, RNN ve BiLSTM) entegrasyonu incelenmiş ve bu yaklaşımların performans karşılaştırması yapılmıştır. Altı farklı tweet veri kümesi üzerinde gerçekleştirilen deneyler, BERT'in geleneksel Word2Vec tabanlı modellerden üstün performans sergilediğini ortaya koymuştur. Özellikle BERT-CNN, BERT-RNN ve BERT-BiLSTM kombinasyonları yüksek doğruluk, kesinlik ve F1 skoru sağlamış, böylece bağlamsal anlamın daha iyi yakalanmasını mümkün kılmıştır. Çalışma, geleneksel doğal dil işleme (NLP) yöntemlerinin bazı sınırlamalarını gidermeyi amaçlamakta olup, sosyal medya verilerinden duygu analizi yapılırken BERT'in üstünlüğünü vurgulamaktadır.

Aşağıda verilen tabloda, Bello ve arkadaşlarının duygu analizinde kullanılan çeşitli modellerin performans ölçümleri sunulmaktadır. Tablo, farklı modellerin doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1-skora göre nasıl karşılaştırıldığını göstermektedir. Özellikle BERT tabanlı modellerin (BERT-CNN, BERT-RNN, BERT-BiLSTM) geleneksel yöntemlere kıyasla belirgin şekilde daha iyi sonuçlar verdiği gözlemlenmiştir. (Çizelge 6.1.)

Models	Accuracy	P	P	P	R	R	R	F1	F1	F1
		NEG	NEU	POS	NEG	NEU	POS	NEG	NEU	POS
CNN	89%	0.88	0.88	0.90	0.81	0.90	0.93	0.84	0.89	0.91
RNN	90%	0.89	0.89	0.92	0.86	0.90	0.94	0.87	0.90	0.93
BiLSTM	90%	0.87	0.89	0.93	0.88	0.90	0.92	0.88	0.89	0.93
Word2Vec-CNN	57%	0.50	0.60	0.60	0.45	0.53	0.70	0.47	0.56	0.64
Word2Vec-RNN	48%	0.50	0.47	0.48	0.30	0.40	0.67	0.37	0.43	0.56
Word2Vec-BiLSTM	55%	0.50	0.56	0.56	0.26	0.61	0.71	0.34	0.58	0.63
BERT-CNN	93%	0.92	0.93	0.95	0.92	0.92	0.95	0.92	0.92	0.95
BERT-RNN	93%	0.90	0.93	0.95	0.93	0.91	0.95	0.92	0.92	0.95
BERT-BiLSTM	93%	0.91	0.93	0.96	0.93	0.92	0.95	0.92	0.92	0.95

Çizelge 6.1. Farklı modellerin değerleri

Veri Seti olarak X Kullanılan Araştırmalar Hakkında

Son yıllarda Twitter, araştırmacılar için çeşitli açılardan çalışma yapabilecekleri popüler bir platform haline gelmiştir. Örneğin, (Lee, Kim ve Sang, 2016), gazetecilerin Twitter kullanım alışkanlıklarını inceleyen bir araştırma gerçekleştirmiştir. Bir başka çalışmada ise Padang, Endonezya'daki tsunami uyarıları sırasında Twitter kullanıcılarının tepkileri analiz edilmiştir (Carley, Malik, Landwehr, Pfeffer ve Kowalchuck, 2016).

Crannell ve çalışma arkadaşları tarafından yürütülen bir araştırmada, kanser hastalarının Twitter'ı kullanım davranışları incelenmiştir (Crannell, Clark, Jones, James ve Moore, 2016). Çalışma, bu hastaların hastalıklarına dair duygularını Twitter'da açık ve samimi bir şekilde ifade ettiklerini ortaya koymuştur.

2012 ABD başkanlık seçimleri sırasında, siyasi tweetleri sınıflandırmak amacıyla gerçek zamanlı bir duygu analizi sistemi geliştirilmiştir. Bu sistem, Twitter'dan toplanan 36 milyon tweet üzerinde test edilmiş ve siyasi tweetlerin duygu tahmininde %59 doğruluk oranı elde edilmiştir. Çalışma, sosyal medya üzerinden kamuoyunun siyasi eğilimlerini belirlemeye yönelik erken dönem girişimlerden biri olarak dikkat çekmektedir (Wang, Can, Kazemzadeh, Bar ve Narayanan, 2012).

Başka bir çalışmada, (Park, Park, Lim ve Park, 2016), 2012 Güney Kore cumhurbaşkanlığı seçimlerinde TV tartışmalarında ele alınan konuların Twitter'daki konuşmalara ve siyasi tartışmalara nasıl yansıdığını incelemiştir.

Daha yakın bir araştırmada ise (Ahmed, Jaidka ve Cho, 2016), Hindistan'daki genel seçimler sırasında siyasi kampanyaları analiz etmiş ve internetin seçmenler üzerindeki etkilerini ilk kez ölçmeyi hedeflemiştir.

(Cheong ve Lee, 2011), Twitter'dan toplanan kamuoyu duygu verilerini kullanarak potansiyel terörizm senaryolarını görselleştiren bir duygu analizi modeli geliştirmiştir. Bu model, grafiksel görselleştirmeler sunarak analiz süreçlerini desteklemektedir.

(Yates ve Paquette, 2011) Tarafından yapılan bir vaka çalışmasında, 2010 Haiti Depremi sırasında sosyal medya teknolojilerinin bilgi paylaşımı ve karar verme süreçlerindeki etkileri incelenmiştir. Çalışma, sosyal medya ve bilgi yönetimi teknolojilerinin afetlere etkili müdahalede kritik bir rol oynayabileceğini göstermiştir.

(Kim ve Hastak, 2018), Louisiana'daki 2016 sel felaketinden sonra sosyal medya tepkilerini analiz ederek afet sonrası sosyal ağların özelliklerini araştırmıştır. Çalışma, afetle ilgili bilgilerin sosyal ağlarda farklı şekillerde yayıldığını ortaya koymuştur.

Benzer şekilde, (Neppalli, Caragea, Squicciarini, Tapia ve Stehle, 2017), acil durumlarda bilgi toplamak için Twitter'da duygu analizinin kullanımını incelemiştir. Kasırga sırasında Twitter kullanıcılarının etkilenen bölgelerdeki duygularını analiz etmiş ve konuma dayalı duygu değişikliklerini ortaya koymuşlardır.

Halk sağlığı kapsamında, sosyal medya verileri kullanılarak bulaşıcı hastalıkların yayılmasını analiz eden çeşitli çalışmalar gerçekleştirilmiştir. Örneğin, (Elkin, Topal ve Bebek, 2017) bu alanda araştırmalar yürütmüşlerdir.

Sağlık konularında duygu analizi ile ilgili yapılan bir başka çalışmada ise, Twitter kullanıcılarının nargile kullanımına yönelik görüşleri incelenmiştir. Çalışmada, tweetlerin %59'unun nargile kullanımına ilişkin olumlu fikirler içerdiği tespit edilmiştir (Grant ve O'Mahoney, 2016).

(Wu ve Shen, 2015), Twitter'daki haberlerin popülerliğini tahmin etmek amacıyla bir duygu analizi modeli geliştirmiştir. Çalışmada, haber yayılımının özellikleri incelenmiş ve haberlerin popülerliği ile "retweet"lerin haber kaynağıyla etkileşim sıklığı arasında bir bağlantı olduğu belirlenmiştir.

(Sasaki, Kawai ve Kitamura, 2016), Japon Twitter kullanıcılarını mercek altına alarak aşırı bilgi yüklemesi ve kullanıcı tepkilerini araştırmıştır. Araştırma, kullanıcıların zaman tünellerinde tüm tweet akışını incelemediklerini ancak yeni kullanıcıları takip etmeye devam ettiklerini ortaya koymuştur.

(Thompson, Leung, Blair ve Taboada, 2017) ise video oyunu sohbet mesajlarında yer alan duyguları analiz etmek için bir sözlük tabanlı yaklaşım önermiştir. Örneğin, "gg" terimi, sözlükte "iyi oyun" anlamına gelmektedir. Bu yaklaşım, gerektiğinde sözlüklerin kolayca güncellenebileceği ve diğer veri kümelerine uygulanabilir olduğunu göstermiştir. Ayrıca,

sözlüklerin analiz edilen metinlere uygun şekilde tasarlanmasının önemine dikkat çekilmiştir.

Mikroblog platformları, farklı dillerde duygu analizi yapan araştırmacılar için de bir ilgi odağıdır. (Tellez, Miranda-Jiménez, Graff, Moctezuma, Siordia ve Villaseñor, 2017), İspanyolca duygu analizi yaparak metin dönüşümleri için Destek Vektör Makineleri (Support Vector Machines) kullanmıştır. (Liao, Feng, Yang ve Huang, 2016), 30.000 Çinli mikroblog mesajı üzerinde duygu analizi yapmış ve bu mesajları negatif, nötr ve pozitif olarak sınıflandırmıştır. (Khan, Qamar ve Bashir, 2016), Hintçe 50.000 film yorumu üzerine bir inceleme yapmıştır.

(Öztürk ve Ayvaz, 2018) Twitter'da Suriyeli mülteci krizine yönelik duyguları karşılaştırmalı olarak analiz eden ilk çalışmayı sunmuştur.

We Are Social ve Hootsuite tarafından hazırlanan "Digital in 2020" raporuna göre, Türkiye, Twitter'da aktif kullanıcı sayısı bakımından dünya genelinde 6. sırada yer almaktadır. Ancak, Türkçe dilinde duygu analizi üzerine yapılan çalışmaların sayısı oldukça sınırlıdır. (Öztürk ve Ayvaz, 2018)'ın Türkçe ve İngilizce tweetleri analiz ettiği araştırmadır. Bu çalışmada, Suriyeli mültecilere yönelik olumlu ve olumsuz duygular karşılaştırılmıştır. Çalışmada, İngilizce cümle düzeyinde duygu analizi yapılmasını sağlayan ve duygu puanlaması içeren kapsamlı R Sentiment Paketi kullanılmıştır. Ancak Türkçe için benzer bir sözlük bulunmadığından, araştırmacılar alana özgü bir duygu sözlüğü geliştirmiştir.

Twitter verilerini işlemek için etkili bir metin ön işleme tekniği geliştirilmiş ve Destek Vektör Makinesi (SVM), Derin Öğrenme ve Naive Bayes (NB) sınıflandırıcılarını eğitmek amacıyla bir algoritma önermiştir. Bu algoritma, metin temizleme ve hashtag ağırlıklarını kullanarak duygu değerlendirmesi yapmayı amaçlanmaktadır (Pradha, Halgamuge ve Vinh, 2019).

Öte yandan, Sohrabi ve Hemmatian (2019) tarafından gerçekleştirilen çalışmada, Twitter kullanıcı yorumları üzerinde test edilen verimli bir görüş madenciliği ön işleme yöntemi sunulmuştur. Araştırma, SVM ile Yapay Sinir Ağları (ANNs) kombinasyonu kullanılarak yapılan analizlerin, diğer yöntemlere kıyasla en yüksek doğruluk oranlarına ulaştığını ortaya koymuştur. (Azzouza, Akli-Astouati ve Ibrahim, 2019), Twitter duygu analizi için dört aşamalı bir çerçeve olan TwitterBERT'i önermiştir. Bu çerçeve, önceden eğitime aşamasında emoji ve emoticonların Unicode kodlarını dahil etmeyi içermekte ve özel bir ön işleme aşamasını gereksiz kılmaktadır. Bu çalışmanın aksine, ele alınan mevcut araştırma, önceden eğitilmiş dil modellerini sade metin üzerinde kullanmayı ve emoji ve emoticonları Unicode kodlarını entegre etmek yerine metne dönüştürerek ön işlemiden geçirmeyi önermektedir.

Böylece, Twitter jargonunun daha etkili bir şekilde düz metne dönüştürülmesi hedeflenmektedir.

Bir diğer çalışma ise, Türkiye’deki üniversitelerin yenilikçilik ve girişimcilik endeksine göre sıralanmasında Twitter verilerinin kullanımına odaklanmıştır. Bu çalışmada da alana özgü bir sözlük geliştirilerek üniversiteler arasında karşılaştırma yapılmıştır (İskender ve Batı, 2015).

Birçok çalışma, X verilerinin duygu analizi üzerine yoğunlaşmıştır, çünkü gerçek zamanlı verilere kolay erişim bu platformda geniş bir veri yelpazesi sunar. Bu araştırmalardan elde edilen bulgular, kullanıcılar tarafından sağlanan duygu durumlarını analiz etmede BERT modelinin etkinliğini ortaya koymuş ve duygu sınıflandırma performansında önemli iyileşmeler sağladığını göstermiştir (Singh, Jakhar ve Pandey, 2021).

Sosyal medya ve mikroblog platformlarının artan bireysel bağlantılar sebebiyle popülerliği, hayatlarımız üzerinde henüz tam anlamıyla fark edilmeyen etkiler yaratmaktadır. Bununla birlikte, bu tür platformlardaki saldırgan dil fenomenlerinin sayısız örneği, potansiyel avantajları gölgelemektedir. HateBERT, İngilizce dilinde saldırganlığı tanımak için eğitilmiş bir dil modelidir (Caselli, Basile, Mitrovic ve Granitzer, 2021). HateBERT, AbusEval (Caselli, Basile, Mitrovic, Kartoziya ve Granitzer, 2020) ve HatEval (Basile, Bosco, Fersini, Nozza, Patti, Pardo, Rosso ve Sanguinetti, 2019) gibi güncel nefret söylemi veri kümelerinde saldırgan dili tespit etmede genel BERT modelinden sürekli olarak daha iyi performans göstermektedir. Çapraz veri kümesi deneyleri, HateBERT’in ayarlanan saldırgan dil fenomenlerini etkili bir şekilde tespit edebildiğini göstermektedir. Bu model, metinlerdeki saldırgan ifadeleri daha hassas bir şekilde analiz ederek duygu ve dilin inceliklerini yakalama konusunda yüksek performans sergilemektedir.

BERTweet ve BERTweetCovid19, İngilizce tweetler üzerinde önceden eğitilmiş iki dil modelidir. BERTweet, RoBERTa’nın ön eğitim prosedürüne dayalı olarak geliştirilmiştir. Modelin eğitiminde kullanılan veri kümesi, 01/2012 ile 08/2019 tarihleri arasında yayınlanan 845 milyon tweet ve COVID-19 pandemisiyle ilgili 5 milyon tweet olmak üzere toplamda 850 milyon İngilizce tweet içermektedir. (Nguyen, Vu ve Nguyen, 2020). Buna ek olarak, BERT-SentiX (Zhou, Tian, Wang, Wu, Xiao ve He, 2020) ve CT-BERT (Müller, Salathé ve Kummervold, 2020), sosyal medya ile ilgili ince ayar yapmak amacıyla önceden BERT modeli olarak kullanılmıştır. RoBERTa-tabanlı model için ince ayar adımları daha çeşitlendirilmiş olabilse de, sosyal medya için daha odaklanmış bir veri seti kullanma temel stratejisi değişmemiştir.

BERT, mBERT, XLNet ve RoBERTa gibi TB modelleri ile BiLSTM arasında karşılaştırma yaparak sosyal medyada farklı dillerde ve platformlarda kadın düşmanlığı tespiti üzerine çalışmalar yürütmüştür (Rahali, Akhloufi, Therien-Daniel ve Brassard-Gourdeau, 2021). RoBERTa-Twitter (Barbieri, Camacho-Collados, Neves ve Espinosa-Anke, 2020), TweetEval ölçütlerinde açıklanan ve değerlendirilen, 58 milyon tweet üzerinde eğitilmiş bir RoBERTa-tabanlı modeldir. RoBERTa-Reviews ve RoBERTa-News aynı ön eğitim yaklaşımını benimsemiştir. Transformer tabanlı modellerin sosyal medya ve eğlence alanındaki çeşitli alt görevlerde kullanımı yaygındır. Bu görevler arasında saldırgan içerik önleme, öneri sistemleri ve sahte haber tespiti bulunmaktadır. Bu modeller, özellikle çevrimiçi içerik analizinde daha doğru tahminler sağlayarak bilgi güvenilirliği ve içerik filtreleme süreçlerinde önemli bir rol oynar (Gururangan, Marasović, Swayamdipta, Lo, Beltagy, Downey ve Smith, 2020).

Aşağıda verilen tabloda, elektrikli araçlar ve duygu analizi alanlarında yapılmış önemli çalışmalardan seçilmiş örnekler yer almaktadır. Tablo, çalışmaların amaçlarını, kullandıkları yöntem ve modelleri, elde edilen performans sonuçlarını ve tezle olan ilişkisini kapsamlı şekilde sunmaktadır.

Duygu analizi literatüründe, geleneksel makine öğrenmesi yöntemlerinden derin öğrenmeye ve özellikle BERT gibi transformer tabanlı modellerin kullanımına doğru belirgin bir evrim gözlemlenmektedir. Bu kapsamda, yerel ve uluslararası kaynaklarda, farklı dillerde ve veri türlerinde (özellikle sosyal medya metinlerinde) duygu analizinin nasıl uygulandığı ve hangi modellerin üstün performans gösterdiği örneklenmiştir.

Türkçe dilinde yapılan çalışmalara da yer verilmiş olup, bu çalışmaların çoğunun Twitter gibi sosyal medya platformlarından alınan verilerle gerçekleştirildiği ve BERT tabanlı modellerin başarıyla uygulandığı görülmektedir. Bu literatür özeti, tez çalışmamızda kullanılan BERT modelinin seçiminin güncel araştırmalar ışığında uygunluğunu göstermekte ve alandaki bilgi birikimine katkı sağlamaktadır.

Çizelge 6.2. Literatür Tablosu

Yazar (Yıl)	Amaç	Yöntem / Model	F1 Skoru / Performans	Temel Bulgular	Tezle İlişkisi
Pang & Lee (2008)	Duygu analizinde ML algoritmalarını test etmek	Naive Bayes, SVM, MaxEnt	%80+ doğruluk	Film yorumlarında başarı	ML temel yaklaşımı
Go et al. (2009)	Twitter’da duygu sınıflandırması yapmak	Naive Bayes, distant supervision	~%80 doğruluk	Otomatik etiketleme yöntemleri	Twitter veri etiketlemesi için önemli
Socher et al. (2013)	Derin duygusal yapı analizi	RNTN	%85+ F1 (5 sınıf)	Karmaşık cümlelerde yüksek doğruluk	Derin model referansı
Liu (2012)	Duygu analiz yöntemlerine genel bakış	Lexicon & ML kombinasyonu	-	Yöntem karşılaştırmaları	Teorik altyapı sunar
Devlin et al. (2019)	BERT modelini NLP görevlerine uygulamak	BERT	GLUE görevlerinde ~%88 F1	Bağlam bazlı güçlü performans	Tez modelinin dayanağı

Zhang et al. (2022)	EV markalarına sosyal tepki analizi	BERT	Çin dilinde ~%90 F1	Markalarda duygusal kutuplaşma	Yöntemsel referans
Wang et al. (2020)	Twitter'da EV algısını analiz etmek	LDA + SVM	~%78 F1	Altyapı endişeleri öne çıkmış	Metodolojik benzerlik
Liu et al. (2021)	EV'lerin sürdürülebilirlik algısı	Metin madenciliği + lexicon	~%84 doğruluk	"Yeşil imaj" pozitif etkili	Sosyal medya çevresel söylem
Güven, Diri & Çakaloğlu (2021)	Türkçe tweetlerden duygu analizi	N-stage LDA + RF, NB, SVM	RF: F1=0.72	Farklı yöntemler karşılaştırılmış	Türkçe sosyal medya modeli
Mutlu & Özgür (2022)	Türkçe hedefli duygu analizi	BERT tabanlı modeller	~F1=0.85	Hedef yönelimli analizde üstün	Tez modeli için güçlü yerel örnek
Tumasjan et al. (2010)	Twitter verilerinin seçim tahmininde kullanımı	SVM, kelime frekansı	~%75 doğruluk	Sosyal medya halkın politik eğilimini yansıtabiliyor	Twitter'ın sosyal duygu gücünü göstermesi açısından örnek
Binali et al. (2010)	Twitter duygu analizinde sözdizimi ve kelime türlerinin etkisi	Lexicon + POS tagging	- (karşılaştırmalı analiz)	Yalın metin yerine yapısal bilgi ile başarı artabiliyor	Türkçe için sözdizimsel analiz düşüncesine ilham verir
Pak & Paroubek (2010)	Twitter verisiyle duygu analizinde sözlük oluşturmak	Naive Bayes + özel sözlük	~%76 doğruluk	Emoji ve hashtag'lerle veri etiketleme başarılı	Etiketleme yöntemleri açısından ilham kaynağı
Akhtar et al. (2016)	Hindistan'da çok dilli duygu analizi	SVM, LSTM, ensemble	F1: %82 (Hinglish dilinde)	Karma dilli sosyal medya verilerinde derin öğrenme etkili	BERT öncesi çok dilli analizlerdeki başarıya örnek
Yadav & Vishwakarma (2020)	Sosyal medya duygu analizi üzerine literatür derlemesi	Derleme	-	LSTM, CNN gibi modellerin son yıllarda baskın olduğu gösterilmiş	Yöntemsel evrimi kavramak için kapsamlı kaynak
Çöltekin & Rama (2018)	Türkçe metin sınıflandırma yöntemlerinin karşılaştırılması	SVM, Naive Bayes, Logistic Regression	F1: %78 (Zemberek + kelime torbası)	Türkçe metinler için sade yöntemlerle güçlü sonuçlar alınabiliyor	Türkçe NLP modellerine katkısı önemli
Kaya & Gündüz (2021)	Türkçe'de transformer tabanlı duygu analizi	BERTürk	F1: %87	BERTürk, diğer klasik yöntemleri önemli ölçüde geride bırakıyor	Tezde kullanılan modele doğrudan paralel

Demirtas & Pechenizkiy (2013)	Türkçe tweetlerde duygu analizi	SVM + manual lexicon	F1: %72	Türkçe veri setiyle ilk uygulamalardan	Yerel veriyle analiz yapan öncü örnek
Devlin et al. (2019)	BERT modelini tanıtmak ve NLP görevlerinde test etmek	BERT (Transformer)	GLUE benchmark'ta ~%88 F1	Derin bağlam algısı ile yüksek performans	Tezde kullanılan modelin temeli
Zhang et al. (2022)	EV markalarına sosyal medya tepkilerini analiz etmek	BERT tabanlı duygu analizi	~%90 F1 (Çince veri)	Markalar arasında kutuplaşma ve duygu farklılıkları	BERT + sosyal medya bağlamında örnek
Mutlu & Özgür (2022)	Türkçe hedefli duygu analizi	BERT tabanlı modeller	~%85 F1	Hedef yönelimli analizde üstün sonuçlar	Yerel dilde BERT uygulaması örneği
Kaya & Gündüz (2021)	Türkçe transformer tabanlı duygu analizi	BERTürk	%87 F1	BERTürk klasik yöntemlerden yüksek başarı	Türkçe özel BERT modeli, tez için fayda
Sun et al. (2019)	BERT için ince ayar ve uygulamalar	BERT fine-tuning teknikleri	---	Farklı NLP görevlerinde başarı artışı	Model optimizasyonu hakkında temel kaynak
Li et al. (2020)	Sosyal medya duygu analizi için BERT	BERT + LSTM hibrit modeli	%89 F1	Hibrit modellerde performans artışı	Yeni model önerileri için referans
Yang et al. (2019)	BERT ile sosyal medya duygu sınıflandırması	BERT + CNN	%88 F1	CNN entegrasyonu ile performans artışı	Model geliştirme için önemli
Cheng & Mi (2021)	BERT tabanlı Çince duygu analizi	BERT	%91 F1	Çince veride yüksek doğruluk	Dil ve veri bazlı karşılaştırma
Gupta et al. (2020)	Çok dilli duygu analizi için BERT	Multilingual BERT	%85 F1	Farklı dillerde iyi performans	Uluslararası veri setlerinde geçerlilik
Aydın & Kaya (2023)	Türkçe sosyal medya için BERT duygu analizi	BERTürk + Fine-tuning	%88 F1	Türkçe sosyal medya için optimize edilmiş model	Tez ile dil uyumu



7. UYGULAMA


Bu bölümde uygulama hakkında kapsamlı bilgi verilecektir.

7.1. Veri Toplama

Veri setlerinin dört temel niteliği, gerçek dünyayla uyumluluk, yeterli büyüklük, elektronik yöntemlerle erişilebilirlik ve alana özgü kriterleri içermesidir (Bowker ve Pearson, 2002). Akademik metinler, konuşma dili örnekleri, sosyal medyada kullanılan gayri resmi dil, gazete yazıları, roman ve hikayeler ile yasal davalardan oluşan kısa metinler, çeşitli dil dizgeleri kapsamında değerlendirilmektedir. Ayrıca, her dilin kendine özgü bir modeli ve belirgin bir dil yapısına sahip olduğu belirtilmiştir (Şahiner Yılmaz, 2022). Veri setlerinin boyutuyla ilgili katı bir kural bulunmamakla birlikte, hedef dil kalıplarının sistematik bir şekilde analizini mümkün kılacak kadar geniş bir veri setine ihtiyaç duyulmaktadır. Bunun yanı sıra, bir kelimenin yalnızca kendisinin değil, çevresindeki diğer kelimelerin de öğrenme sürecine önemli katkılarda bulunduğu tespit edilmiştir. Bu durum, bir kelimenin hem anlamını hem de faydasını artıran bir özellik olarak öne çıkmaktadır.

Çalışmamızda X API üzerinden elde edilen veriler kullanılacaktır. API üzerinden “elektrikli”, “elektrikli araç”, “hibrit”, “togg”, “tesla”, “byd”, “mg” kelimeleri kullanılarak veriler elde edilmiştir.

Ocak ayı için: 7.129, şubat ayı için:14.760, Mart ayı için: 15.416, Nisan ayı için:17.766, Mayıs ayı için: 15.374, Haziran ayı için: 12.745, Temmuz ayı için:23.922, Ağustos ayı için:13.574, Eylül ayı için:15.882, Ekim ayı için:16.182, Kasım ayı için:14.829, Aralık ayı için:16.526 olmak üzere toplam 183.761 adet tweet çekilmiş Şekil 7.1.’de tablo olarak verilmiştir.



Şekil 7.1. Aylık bazda çekilen tweet sayısı

7.2. Veri Önleme

Bu araştırmada sosyal medya verilerinin duygu analizi amacıyla işlenebilmesi için kapsamlı bir veri ön işleme süreci uygulanmıştır. Ham veriler genellikle gürültülü, eksik, tutarsız ve analiz için doğrudan kullanılamaz durumdadır. Bu nedenle, doğru ve güvenilir analizler yapılabilmesi için verilerin yapısal ve anlamsal açıdan temizlenmesi gereklidir. Bu çalışmada uygulanan veri ön işleme adımları aşağıda ayrıntılı şekilde sunulmuştur:

Metin Temizleme (Text Cleaning)

İlk olarak metinlerdeki analiz için anlam taşımayan ya da yanıltıcı unsurlar temizlenmiştir. Bu kapsamda şu işlemler gerçekleştirilmiştir:

- Büyük-küçük harf dönüşümü: Tüm metinler küçük harfe çevrilerek aynı kelimenin farklı biçimlerde (örneğin “Güzel” ve “güzel”) algılanmasının önüne geçilmiştir.
- URL, etiket ve kullanıcı adlarının silinmesi: Tweetlerde yer alan “http”, “@kullanıcıadı” ve “#etiket” gibi yapılar metinden çıkarılmıştır.
- Noktalama işaretlerinin ve özel karakterlerin temizlenmesi: “?!,:;” gibi anlam taşımayan noktalama işaretleri ve semboller metinden kaldırılmıştır.
- Emoji ve duygusal simgelerin kaldırılması veya dönüştürülmesi: Bazı deneylerde emoji’ler metinden çıkarılmış, bazılarında ise anlamına karşılık gelen sözcüklerle (“😊” → “mutlu”) dönüştürülerek korunmuştur.

Durdurma Kelimelerinin Kaldırılması (Stopword Removal)

Duygu analizine katkısı olmayan ve Türkçede sık kullanılan "bir", "ve", "ama", "ile", "de", "da", "çok" gibi durdurma kelimeleri temizlenmiştir. Bu işlem, metinlerin daha anlamlı terimlerle temsil edilmesini ve modelin daha isabetli tahminler yapmasını kolaylaştırmıştır.

Noktalama ve Tekrarlı Karakterlerin Dönüştürülmesi

Özellikle sosyal medya metinlerinde sıkça karşılaşılan “çooook güzel”, “süüüper” gibi tekrarlı karakterler, anlamlı tek bir forma dönüştürülmüştür (“çok güzel”, “süper”). Bu dönüşüm, kelime dağarcığının sadeleşmesini sağlamıştır.

Kök Bulma / Gövdeleme (Stemming/Lemmatization)

Kelimelerin farklı ek almış hâllerini ortak bir kökte birleştirmek amacıyla kök bulma işlemi uygulanmıştır. Örneğin, “gidiyorum”, “gitti”, “gidecek” gibi ifadeler “git” köküne indirgenmiştir. Türkçe gibi eklemeli dillerde bu işlem, modelin genel performansını artırmada kritik rol oynamaktadır.

Etiket Dönüşümü (Label Encoding)

Duygu etiketleri “Olumlu”, “Olumsuz” ve “Tarafsız” şeklinde sınıflandırılmıştır. Bu kategoriler model eğitiminde sayısal değerlerle temsil edilmiştir (örneğin, Olumlu: 2, Tarafsız: 1, Olumsuz: 0). Bu dönüşüm, makine öğrenimi algoritmaları tarafından etiketlerin işlenebilmesini sağlamıştır.

Dengesizlikle Başa Çıkma

Veri setinde sınıf dengesizliği gözlemlenmişse (örneğin olumlu tweetlerin fazla olması), sınıflar arasında adil temsil sağlamak adına bazı durumlarda aşırı örnekleme (oversampling) ya da ağırlıklandırma yöntemlerine başvurulmuştur.

Eğitim ve Test Ayrımı

Ön işleme tamamlandıktan sonra veri seti %80 eğitim ve %20 test olacak şekilde ikiye ayrılmıştır. Böylece modelin öğrenme süreci ile değerlendirme süreci birbirinden bağımsız hâle getirilmiş ve overfitting riski azaltılmıştır.

Tokenizasyon ve Dönüştürme

Model eğitimi öncesinde metinler, BERT modeline uygun biçimde tokenize edilmiştir. BERT tokenizer sayesinde cümleler uygun “input_ids”, “attention_mask” ve gerekiyorsa “token_type_ids” formatına dönüştürülerek modele uygun veri yapısı elde edilmiştir.

Aşağıda bulunan Şekil 7.2.’de ham bir tweet’in veri ön işleme adımları sonrasında nasıl dönüştüğü adım adım gösterilmektedir.

Adım	İşlem Açıklaması	Metin
1	Ham veri (orijinal tweet)	"@arabaelektrik Gerçekten çooooook güzel bir deneyimdi! 🍷 🚗 https://t.co/test "
2	Kullanıcı adı, URL, emojiler kaldırıldı	"Gerçekten çooooook güzel bir deneyimdi"
3	Küçük harfe çevirme	"gerçekten çooooook güzel bir deneyimdi"
4	Tekrarlı harf düzeltme	"gerçekten çok güzel bir deneyimdi"
5	Noktalama işaretlerinin kaldırılması	"gerçekten çok güzel bir deneyimdi"
6	Stopword temizliği	"gerçekten güzel deneyimdi"
7	Kök bulma / Gövdeleme	"gerçek güzel deneyim"
8	Etiketleme (örn. 'Olumlu')	Etiket: 2

Şekil 7.2. Veri Önışleme Örneđi

7.3. BERT ile Duygu Analizi

Çalışmamızda Python programlama dili kullanılmıştır. Sunduđu geniş kütüphaneler sebebiyle NLP alanında büyük kolaylıklar sağlamaktadır. Bu veriler ile otomotiv satış rakamları kıyaslanıp anlamlı bir ilişki kurulmaya çalışılacaktır.

BERT'in Türkçe dili için yayınlanan modeli olarak kullandığımız nihai eğitim verisi kümesi 35 GB boyutunda ve 4.404.976.662 adet token içermekte olup birçok araştırma da kullanılmıştır.¹

Model, toplamda 3 dönem (epoch) boyunca eğitilmiştir. Eğitim sırasında, her bir cihaz (örneğin GPU) için 8 örnek içeren mini-batch'ler kullanılırken, değerlendirme aşamasında bu sayı 16 olarak ayarlanmıştır. Bu sayede eğitim ve değerlendirme işlemleri dengeli bir şekilde yürütülmüştür. Eğitim başında öğrenme oranının aşamalı olarak artmasını sağlamak amacıyla 500 adımlık bir "warmup" süreci uygulanmıştır. Aşırı öğrenmeyi (overfitting) önlemek adına ağırlıkların küçük oranlarda sınırlandırması için weight_decay değeri 0.01 olarak belirlenmiştir. Eğitim sürecinde modelin performansını izleyebilmek amacıyla günlük kayıtlar './logs' dizinine alınmış ve bu kayıtlar her 10 adımda bir güncellenmiştir.

¹ <https://huggingface.co/dbmdz/bert-base-turkish-cased>

Modelin hem değerlendirme sonuçları hem de ağırlıkları her bir dönem sonunda kaydedilecek şekilde `save_strategy` ve `evaluation_strategy` parametreleri “epoch” olarak tanımlanmıştır. Son olarak, daha hızlı ve verimli bir eğitim süreci sağlamak amacıyla karma (mixed) hassasiyetli hesaplamalar etkinleştirilmiş ve bu bağlamda `fp16` parametresi `True` olarak ayarlanmıştır.

Bu çalışma, NVIDIA GeForce RTX 3050 Ti ekran kartı kullanılarak gerçekleştirilmiştir. RTX 3050 Ti, Ampere mimarisine sahip olup yaklaşık 9.1 teraflop (TFLOP) tek duyarlıklı (FP32) işlem kapasitesine ve 4 GB VRAM belleğe sahiptir. Derin öğrenmeye dayalı duygu analizi gibi işlemler, yüksek sayıda matris işlemi ve paralel hesaplama gerektirdiğinden, işlem süresi büyük ölçüde kullanılan donanımın gücüne bağlıdır. Daha güçlü grafik işlem birimleri (GPU’lar), özellikle büyük dil modellerinin eğitim ve değerlendirme süreçlerinde belirgin zaman kazancı sağlayabilir. Bu çalışmada kullanılan BERT (Bidirectional Encoder Representations from Transformers) modeli, yaklaşık 110 milyon parametre içeren büyük ölçekli bir dil modelidir. BERT’in çok katmanlı transformer yapısı nedeniyle, modelin eğitimi ve çıkarımı sırasında milyarlarca kayan noktalı işlem (FLOP) gerçekleştirilmesi gerekir. Bu yüksek hesaplama gereksinimi, BERT’i daha hafif ve optimize edilmiş modellere kıyasla nispeten daha yavaş hale getirmektedir. Bununla birlikte, bağlamsal kelime temsili derinlemesine modellemesi sayesinde yüksek doğruluk oranlarına ulaşabilmektedir.

Modelin sağlıklı bir şekilde eğitilebilmesi için sınıflar arasında dengeli bir veri dağılımı büyük önem taşımaktadır. Bu çalışmada kullanılan veri setinde, negatif sınıfa ait 939.954, pozitif sınıfa ait ise 939 966 adet örnek kelime bulunmaktadır. Sınıflar arasındaki bu sayısal denge, modelin herhangi bir sınıfa karşı önyargılı öğrenmesini engelleyerek daha adil ve dengeli bir eğitim süreci sağlar. Dengesiz veri dağılımı, modelin çoğunluk sınıfa yönelmesine ve azınlık sınıfa ait örnekleri doğru tahmin edememesine yol açabileceği için, burada pozitif ve negatif örneklerin neredeyse eşit sayıda olması, özellikle duygu analizi gibi sınıf dengesinin kritik olduğu görevlerde model performansını artıran önemli bir etkidir.


Modelin değerlendirme sonuçları aşağıdaki tabloda verilmiştir. Duygu analizinde yüksek doğruluk ve dengeli sınıf başarımı elde edildiğini göstermektedir. Test veri kümesi üzerinde elde edilen genel doğruluk oranı %92,35 olarak hesaplanmıştır. Negatif sınıf için doğruluk (precision) değeri 0,88 geri çağırma (recall) değeri 0,90 ve F1 skoru 0,89 olarak ölçülmüştür. Pozitif sınıfta ise bu değerler sırasıyla 0,95 (precision), 0,93 (recall) ve 0,94 (F1 score)

şeklindedir. Sınıflar arasındaki örnek sayısı farkına rağmen, her iki sınıfta da yüksek F1 skoru elde edilmiş olması, modelin hem hassasiyet hem de kapsayıcılık açısından dengeli performans sergilediğini göstermektedir. Ayrıca, macro average ve weighted average metriklerinin her biri 0,92 olup, bu durum modelin sınıflar arası fark gözetmeksizin genel başarımını yansıtmaktadır. Bu sonuçlar, eğitilen BERT modelinin duygu analizinde güvenilir ve etkili bir sınıflandırıcı olarak kullanılabileceğini ortaya koymaktadır. (Çizelge 7.1.)

Çizelge 7.1. BERT modeli teknik verileri

Class	Precision	Recall	F1- Score	Support
Negative	0,88	0,9	0,89	1257
Positive	0,95	0,93	0,94	2248
Accuracy			0,9235	3505
Macro	0,92	0,92	0,92	3505
Weighted	0,92	0,92	0,92	3505


Aşağıda sunulan görselde, modelin negatif ve pozitif duygu sınıfları için hesaplanan precision (kesinlik), recall (duyarlılık) ve F1-score (denge skoru) metrikleri ayrı ayrı görselleştirilmiştir. Precision, modelin pozitif ya da negatif olarak sınıflandırdığı örneklerin ne kadarının doğru olduğunu gösterirken; recall, gerçek pozitif ya da negatif örneklerin ne kadarının model tarafından doğru tahmin edildiğini ifade eder. Bu iki ölçütün harmonik ortalaması olan F1-score ise, modelin genel başarımını daha dengeli bir şekilde ortaya koyar.



Şekil 7.3. BERT modelin teknik verileri

Grafikte görüldüğü üzere, pozitif sınıf tüm metriklerde negatif sınıfa göre biraz daha yüksek değerlere sahiptir. Bu durum, modelin pozitif ifadeleri tanıma konusunda biraz daha başarılı olduğunu göstermektedir. Ancak her iki sınıfta da metriklerin 0.88'in üzerinde olması, modelin genel olarak dengeli ve yüksek doğrulukta sınıflandırma yaptığını ortaya koymaktadır. (Şekil 7.3.)


Şekil 7.4.'te duygu analizi modelinin tahmin performansını görselleştiren karışıklık matrisi (confusion matrix) yer almaktadır. Bu matris, modelin pozitif ve negatif sınıflar için yaptığı doğru ve yanlış tahminleri göstermektedir. Görüldüğü üzere, model 1137 adet negatif örneği doğru sınıflandırırken, 120 negatif örneği pozitif olarak yanlış etiketlemiştir. Öte yandan, 2100 pozitif örnek doğru tahmin edilmiş, 148 pozitif örnek ise yanlışlıkla negatif olarak sınıflandırılmıştır. Bu değerler, modelin özellikle pozitif sınıfı doğru tahmin etme konusunda oldukça başarılı olduğunu, ancak negatif sınıfta bir miktar karışıklık yaşadığını ortaya koymaktadır. Genel olarak bu sonuçlar, modelin sınıflar arasında yüksek doğruluk ve tutarlılıkla çalıştığını, ancak sınıf dengesizliği veya dilsel karmaşıklık gibi etkenlerin negatif sınıfta daha fazla hata üretimine sebep olabileceğini göstermektedir.



Şekil 7.4. Hata Matrisi


8. BULGULAR VE DEĞERLENDİRME

Toplanan tweetler fine-tune edilmiş BERT modeli üzerinden geçirilmiş ve her bir tweet "Pozitif" veya "Negatif" olarak sınıflandırılmıştır. Veriler daha sonra ay bazında gruplanarak zaman serisi analizine tabi tutulmuştur. Elde ettiğimiz sonuç grafikleştirilerek aylık bazda yüzdesel olarak Şekil 8.1.'de sunulmuştur.




Şekil 8.1. Yıllık duygu analizi sonucu

Sonuçların daha kolay bir şekilde yorumlanabilmesi adına olumlu tweetlerin grafiği üzerinden yaşanan değişimlerin incelenmesi yoluna gidilmiştir. Sadece olumlu yorumların belirtildiği yüzdesel bazdaki grafik Şekil 8.2.'de sunulmuştur.



Şekil 8.2. Yıllık duygu analizi olumlu grafiği

Otomotiv Distribütörleri&Mobilite Derneği tarafından 2024 yılı Ocak ile Aralık ayları arasında Türkiye’de satılan araçların satış rakamlarının paylaşıldığı görülmüştür (Otomotiv Distribütörleri ve Mobilite Derneği, 2025). Bu verilerin aylık olarak verildiği grafik Şekil 8.3’te sunulmuştur.



Şekil 8.3. Yıllık satış rakamları

Korelasyon Analizi

Bu çalışmada, sosyal medyada elektrikli araç markalarına yönelik paylaşımlardan elde edilen olumlu duygu oranları ile aynı döneme ait markaların aylık satış verileri arasındaki ilişkiler incelenmiştir. Bu amaçla, BYD, MG, Tesla ve TOGG markalarına ilişkin 12 aylık satış verileri ile aynı dönemlerde sosyal medya analizinden elde edilen olumlu duygu yüzdeleri karşılaştırılarak Pearson korelasyon katsayısı hesaplanmıştır. Değişkenler arasındaki doğrusal ilişkinin gücünü ve yönünü belirlemek amacıyla Pearson korelasyon katsayısı tercih edilmiştir. Pearson yöntemi, özellikle sürekli ve nicel veriler arasında doğrusal bir ilişki olup olmadığını test etmek için yaygın olarak kullanılmaktadır. Çalışmada hem duygu analizinden elde edilen olumlu duygu yüzdeleri hem de aylık araç satış rakamları süreklilik gösteren nicel veriler olduğundan, bu yöntemin kullanılması uygun bulunmuştur. Ayrıca, verilerin normal dağılıma yakın olduğu varsayımı altında, Pearson korelasyonu değişkenler arası ilişkiyi en doğru şekilde yansıtabilmektedir. Yapılan analiz sonucunda, yalnızca MG markası ile olumlu duygu yüzdeleri arasında orta düzeyde pozitif bir ilişki ($r = 0.48$) gözlemlenmiştir. Diğer markalar için korelasyon değerleri negatif ya da zayıf düzeyde olup, anlamlı bir doğrusal ilişki ortaya konulamamıştır. Bu bulgular, sosyal medyada markalara yönelik olumlu algının her zaman satışlara doğrudan yansımadağını; ancak MG markası özelinde, pozitif duyguların tüketici davranışlarına kısmen etkide bulunabileceğini göstermektedir.

Çizelge 8.1. olumlu duygu yüzdeleri ile elektrikli araç markalarının satışları arasında yapılan Pearson korelasyon analizini göstermektedir. Değerler -1 ile +1 arasında olup, doğrusal ilişki düzeyini temsil eder:

Çizelge 8.1. Pearson korelasyon analizi

Marka	Pearson Korelasyon Katsayısı (r)	Yorum
BYD	-0,131	Zayıf negatif ilişki – anlamlı değil.
MG	0,485	Orta düzey pozitif ilişki – anlamlı olabilir.
TESLA	-0,222	Zayıf negatif ilişki – dikkat çekici değil.
TOGG	-0,149	Çok zayıf negatif ilişki – anlamsız.

Sosyal Medya Verileri ile Duygu Analizi Sonuçlarının Korelasyonu

Bu çalışmada, sosyal medya platformlarında belirli bir zaman aralığında yapılan toplam paylaşım sayıları ile bu paylaşımlara uygulanan duygu analizi sonuçları arasındaki ilişki incelenmiştir. Aylık bazda elde edilen olumlu duygu yüzdeleri ile hem toplam paylaşım sayıları hem de bu yüzdeler karşılık gelen olumlu paylaşım adetleri hesaplanmıştır. Bu kapsamda, her ay için aşağıdaki hesaplama yapılmıştır.

Analiz sonuçları aşağıdaki gibidir:

Toplam paylaşım ile olumlu paylaşım sayısı arasında güçlü bir pozitif ilişki bulunmaktadır ($r = 0.72$). Bu durum, paylaşım sayısı arttıkça olumlu içerik sayısının da arttığını göstermektedir.

Olumlu yüzdeler ile olumlu paylaşım sayıları arasında çok zayıf bir pozitif ilişki vardır ($r = 0.18$).

Olumlu yüzdeler ile toplam paylaşım sayısı arasında zayıf negatif bir ilişki gözlenmiştir ($r = -0.27$).

Bu bulgular, mutlak anlamda olumlu içerik sayısının paylaşım hacmiyle yakından ilişkili olduğunu; ancak, göreceli olumlu duygu oranlarının bu hacimden doğrudan etkilenmediğini göstermektedir. (Çizelge 8.2.)

Çizelge 8.2. Pearson korelasyon analizi

Değişken 1	Değişken 2	Pearson r	Yorum
Olumlu Yüzde	Toplam Paylaşım	-0,27	Zayıf negatif ilişki
Olumlu Yüzde	Olumlu Paylaşım Sayısı	0,18	Çok zayıf pozitif ilişki
Toplam Paylaşım	Olumlu Paylaşım Sayısı	0,72	Güçlü pozitif ilişki

9. SINIRLILIKLAR

Bu çalışma, elektrikli araçlara yönelik toplumsal algıların sosyal medya verileri üzerinden duygu analizi ile değerlendirilmesini amaçlamaktadır. Ancak, araştırmanın çeşitli yönleri belirli sınırlılıklar içermektedir. Öncelikle, çalışmada yalnızca Twitter platformu üzerinden toplanan veriler kullanılmıştır. Dolayısıyla Facebook, Instagram, YouTube, Ekşi Sözlük gibi diğer sosyal medya mecralarında yapılan tartışmalar bu çalışmanın kapsamı dışında bırakılmıştır. Bu durum, sosyal medya kullanıcılarının tamamının değil, yalnızca Twitter kullanıcılarının görüşlerinin dikkate alındığı anlamına gelmektedir.

İkinci olarak, analizde yalnızca Türkçe dilinde yazılmış gönderiler değerlendirilmiştir. Farklı ülkelerde ve farklı dillerde yapılan paylaşımlar kapsam dışı bırakıldığından, çalışmanın bulguları yalnızca Türkçe içerik üreten kullanıcı kitlesiyle sınırlıdır. Bu durum, elektrikli araçlara yönelik küresel algı yerine yerel bir çerçevede değerlendirme yapılmasına neden olmuştur.

Çalışmada duygu analizi sınıflandırması yalnızca iki temel kategori olan olumlu ve olumsuz duygular üzerinden yapılmıştır. Tarafsız, hiddet, öfke, güven, karmaşık, belirsiz ya da nötr içerikler değerlendirme dışı bırakılmıştır. Bu nedenle, sosyal medya içeriklerinin tüm duygusal çeşitliliğini yansıtmak mümkün olmamıştır. Özellikle bağlamsal olarak yorumlanması gereken gönderilerde bu sınırlı sınıflandırma, analiz sonucunun doğruluğunu kısmen etkilemiş olabilir.

Kapsamlı bir literatür araştırması sonucunda duygu analizi sürecinde başarılı sonuçlar verdiği görülen BERT (Bidirectional Encoder Representations from Transformers) tabanlı bir model kullanılmıştır. BERT, dilin bağlamsal yapısını anlamada güçlü bir derin öğrenme modeli olsa da; alay, ironi ve mecaz içeren iletileri doğru şekilde yorumlamada bazı sınırlamalara sahiptir. Bu nedenle, analiz sonuçları her zaman gönderinin tam anlamını yansıtmayabilir.

Ayrıca çalışmada, elektrikli araçlarla öne çıkan belirli otomobil markalarının satış verileri kullanılmıştır. Ancak sektörde faaliyet gösteren ve elektrikli araç üretimi yapan birçok farklı marka bulunmasına rağmen, bu markaların satış verilerinde elektrikli araç ayrımı yapılamadığından analiz kapsamına alınmadığı için bu durum, çalışmanın genel değerlendirmesinde markalar arası karşılaştırmaları sınırlı kılmıştır. Dolayısıyla sonuçlar,

yalnızca seçilen markalar özelinde yorumlanmalı; elektrikli araç pazarının tamamını temsil ettiği düşünülmemelidir.



10. SONUÇ VE ÖNERİLER

Sosyal medya platformları, bireylerin herhangi bir konuda düşünce ve duygularını özgürce ifade edebildikleri, toplumsal algının dinamik bir şekilde izlenebildiği önemli dijital mecralar hâline gelmiştir. Özellikle metin tabanlı içeriklerin yoğun olarak paylaşıldığı X platformu, kullanıcıların politik, kültürel ve teknolojik gelişmelere ilişkin görüşlerini açık bir biçimde dile getirebildikleri bir alan olması sebebiyle doğal dil işleme (NLP) araştırmaları açısından önemli bir veri kaynağı sunmaktadır. Bu bağlamda tez çalışmasında, Türkiye’de henüz yaygınlaşma sürecinde olan elektrikli araçlara (EA) yönelik sosyal medya yansımalarının anlaşılabilmesi amacıyla, X platformundan elde edilen metinler üzerinden duygu analizi gerçekleştirilmiştir. Elektrikli araçların Türkiye pazarındaki gelişimiyle eşzamanlı olarak sosyal medya kullanıcılarının bu konuya yönelik olumlu ya da olumsuz içerikleri, yıl boyunca toplanan veriler üzerinden değerlendirilmiştir. Çalışma kapsamında yalnızca olumlu ve olumsuz etiketleme yapılmıştır. Sosyal medyada olumsuz deneyimlerin daha fazla dile getirilmesi eğiliminin göz önünde bulundurulmasıyla birlikte, olumsuz içeriklerin baskın gelme ihtimali analiz sürecinde dikkate alınmıştır.

Duygu analizi sürecinde, Transformer mimarisine dayanan ve Türkçe diline özel olarak geliştirilmiş BERT modelinden faydalanılmıştır. BERT, kelimelerin bağlama göre anlamını iki yönlü analiz ederek, özellikle eklemeli yapıya sahip Türkçe gibi dillerde anlam çözümlemesini daha etkili şekilde gerçekleştirebilmekte; kelime kökü, ek ve bağlam ilişkisini dikkate alarak yüksek doğruluk oranı sunmaktadır. Tez kapsamında kullanılan BERTurk modeli, önceden büyük ölçekli Türkçe metinlerle eğitildiği için, elektrikli araçlara ilişkin veri setiyle yapılan ince ayar (fine-tuning) sayesinde duygu sınıflandırma görevinde tatmin edici sonuçlar vermiştir. Ocak-Aralık 2024 tarihleri arasında, “TESLA”, “TOGG”, “BYD”, “MG” ve “ELEKTRİKLİ” anahtar kelimeleri ile filtrelenen tweet’ler analiz edilerek, bu içeriklerin olumlu veya olumsuz duygu taşıyıp taşımadığı sınıflandırılmıştır. Sonrasında ise Otomotiv Distribütörleri ve Mobilite Derneği (ODMD) tarafından yayımlanan aynı dönemlere ait elektrikli araç satış verileriyle karşılaştırmalı analiz yapılmıştır. Ayrıca, ulusal basında yer alan elektrikli araçlara ilişkin önemli gelişmelerle sosyal medya duyguları arasında ilişki olup olmadığı da incelenmiştir.

Analiz sonuçları göstermektedir ki, sosyal medya duygu eğilimleri ile satış rakamları ve basın gündemi arasında belirli bir paralellik söz konusudur. Örneğin, BYD markasının Aralık ayında satışlarını %1521 oranında artırdığı görülmüştür. Bu artış, firmanın

Türkiye’de üretim yatırımı yapacağını açıklamasıyla birlikte sunduğu vergi avantajı ve fiyat indirimiyle ilişkilendirilmiştir. Aynı dönemde olumlu sosyal medya paylaşımlarında da bir artış olduğu görülmektedir. Yerli marka TOGG’un satışlarındaki artışın ise özellikle Nisan, Mayıs ve Aralık aylarında belirginleştiği; bu ayların aynı zamanda %0 faizli kredi kampanyalarının uygulandığı dönemlerle çakıştığı tespit edilmiştir. Sosyal medya analizinde de bu aylarda olumlu duygu oranlarının yükseldiği belirlenmiştir. Tesla markasına ait Model Y’nin Haziran ayında Türkiye’de teslim edilmeye başlanması, %10’luk ÖTV dilimine giren versiyonun piyasaya sürülmesi gibi gelişmeler de Haziran ayındaki olumlu duygu artışının olası nedenleri arasında değerlendirilmiştir.

Dönemsel olarak olumsuz duygunun yoğunlaştığı aylarda dikkat çekici sonuçları olmuştur. Özellikle Temmuz ayında en düşük olumlu duygu oranı kaydedilmiş, aynı dönemde ulusal basında elektrikli araçlara ilişkin bir yangın haberi geniş yer bulmuştur. Tesla’ya ait altı aracın sevkiyat sırasında yanması sonucunda sosyal medya kullanıcılarının elektrikli araçların güvenliği, pil riski ve genel teknik yeterliliği üzerine yeniden yoğun tartışmalar başlattığı görülmüştür. Bu durum, sosyal medyada anlık gelişmelerin hızlı yayılması ve kullanıcıların bu tür içeriklere yüksek etkileşim göstermesi ile birlikte olumsuz duyguların kolaylıkla tırmanabileceğini ortaya koymaktadır.

Tez çalışmasında kullanılan metinlerin sosyal medya platformlarından doğrudan alınmış olması, verilerin noktalama işaretleri, emojiler, ironik ifadeler ve tekrar eden kelimelerle dolu olmasına neden olmuştur. Bu bağlamda veri ön işleme süreçleri, model başarımını etkileyen temel faktörlerden biri olarak öne çıkmıştır. Kullanılan BERT modeli, bağlamsal vektör temsilleri sayesinde büyük oranda başarılı sonuçlar vermişse de, kinayeli veya örtük olumsuzluk içeren ifadelerin tamamının doğru şekilde anlaşılması, modelin sınırlılıkları arasında yer almıştır.

Sonuç olarak, bu tez çalışması, sosyal medya temelli duygu analizinin elektrikli araçlar gibi teknolojik dönüşüm yaşayan sektörlerde stratejik bir karar destek aracı olarak kullanılabileceğini ortaya koymuştur. Elektrikli araçların pazardaki konumlanması, kullanıcı güveni, marka itibarı ve kamuoyu algısı gibi çok boyutlu faktörler, sosyal medya analizleriyle daha yakından izlenebilir hâle gelmiştir. Özellikle zaman serisi temelli olarak duygu eğilimlerinin incelenmesi, satış verileri ve haber gündemiyle birlikte değerlendirildiğinde, yöneticilere, yatırımcılara ve politika yapıcılara yeni bir bakış açısı sunmaktadır. Türkçe doğal dil işleme alanında uygulanan bu yaklaşım, hem akademik hem

de sektörel düzeyde duygu analizinin kullanım alanlarını genişleterek, ileride yapılacak çalışmalara da önemli bir zemin hazırlamaktadır.

Tezde ulaşılan sonuçlar, elektrikli araçlarla ilgili sosyal medya verilerinin yalnızca duygusal yönelimleri ortaya koymakla kalmayıp aynı zamanda bu yönelimlerin sektörel gelişmelerle olan ilişkisini analiz etmede de etkili bir araç olduğunu göstermektedir. Bu durum, sosyal medya verilerinin otomotiv sektörü özelinde stratejik karar süreçlerinde kullanılabileceğini ortaya koymuştur. Ancak çalışmada kullanılan verilerin yalnızca X platformuyla sınırlı olması, kullanıcı çeşitliliği açısından belirli bir sınırlılık yaratmıştır. Bu nedenle, gelecekte yapılacak araştırmalarda YouTube, Ekşi Sözlük veya haber platformları gibi farklı dijital mecralardan da veri toplanarak daha kapsamlı analizler yapılabilir. Ayrıca, yalnızca olumlu ve olumsuz şeklinde ikili sınıflandırma yapılması bazı duygusal tonların (örneğin hayal kırıklığı, umut, kararsızlık gibi) gözden kaçmasına yol açabilir. Bu bağlamda, ileri çalışmalar daha ayrıntılı duygu kategorileri içeren çok sınıflı duygu analizi üzerine yoğunlaşabilir. Öte yandan, çalışmada duygu analizinde kullanılan BERT modelinin kinayeli ifadeler veya çok anlamlı sözcükleri tam olarak ayırt edememesi gibi sınırlılıkları da olmuştur. Gelecekte, daha sofistike bağlam analizine sahip modellerin kullanılması bu tür anlam belirsizliklerini azaltabilir. Ayrıca, zamana bağlı duygu değişimlerinin daha ayrıntılı modellenebilmesi için zaman serisi analizlerine dayalı duygu tahmin sistemleri geliştirilebilir. Tüm bu öneriler hem akademik literatüre katkı sağlamakta hem de sektörel düzeyde yapılacak yeni çalışmalara ışık tutmaktadır.

KAYNAKLAR

- Abdelgwad, M. M., Soliman, T. H., Taloba, A. I. ve Farghaly, M. F. (2022). Arabic aspect based sentiment analysis using bidirectional GRU based models. *Journal of King Saud University - Computer and Information Sciences*, 11(4), 6652-6662.
- Acikalin, U. U., Bardak, B. ve Kutlu, M. (2020). *Turkish Sentiment Analysis Using BERT*. TOBB Ekonomi ve Teknoloji Üniversitesi Yayınları, 1-4.
- Adamec, Č., ve Viden, I. (1947). Polls come to Czechoslovakia. *Public Opinion Quarterly*, 11(4), 548–552.
- Ahmad, M., Aftab, S., Ali, I., ve Hameed, N. (2017). Hybrid tools and techniques for sentiment analysis: A review. *International Journal of Multidisciplinary Science and Engineering*, 8(4),1-5.
- Ahmed, S., Jaidka, K. ve Cho, J.. (2016). The 2014 Indian elections on Twitter: A comparison of campaign strategies of political parties. *Telematics and Informatics*, 33(4), 1071-1087.
- Akçelik, C., ve Çetinyokuş, T. (2025). The impact of electric vehicles on the automotive ecosystem: A sentiment analysis study. In 21st International Istanbul Scientific Research Congress on Life, Engineering, Architecture, and Mathematical Sciences (p. 889). BZT Turan Publishing House. <https://doi.org/10.30546/19023.978-9952-8566-2-0.2025.6310>
- Aldahawi, H. (2015). *Mining and analysing social network in the oil business: Twitter sentiment analysis and prediction approaches*. Yayımlanmamış Doktora Tezi, Cardiff University School of Computer Science and Informatics, Cardiff
- Azhar, A. N., Khodra, M. L. (2020). *Fine-tuning Pretrained Multilingual BERT Model for Indonesian Aspect-based Sentiment Analysis*. Paper presented at the 7th International Conference on Advance Informatics: Concepts, Theory and Applications. Tokoname, Japan
- Azzouza, N., Akli-Astouati, K. ve Ibrahim, R. Springer (2 November 2019). TwitterBERT: Framework for Twitter Sentiment Analysis Based on Pre-trained Language Model Representations. *Emerging Trends in Intelligent Computing and Informatics*, 428–437. Johor, Malezya: IRICT 2019,
- Baccianella, S., Esuli, A., & Sebastiani, F. (2010). SentiWordNet 3.0: An enhanced lexical resource for sentiment analysis and opinion mining. *In Proceedings of the Seventh International Conference on Language Resources and Evaluation* (pp. 2200–2204). European Language Resources Association (ELRA).
- İnternet: Bajaj, A. (2021, Nisan 13). VADER for Sentiment Analysis. Analytics Vidhya. URL: <https://www.analyticsvidhya.com/blog/2021/06/vader-for-sentiment-analysis>, Son Erişim Tarihi: 17.03.2024.
- Barbieri, F., Camacho-Collados, J., Neves, L. ve Espinosa-Anke, L (November 2020). TweetEval: Unified Benchmark and Comparative Evaluation for Tweet Classification. *In Findings of the Association for Computational Linguistics: EMNLP 2020* (pp. 1644–1650). Association for Computational Linguistics.

- Basile, V., Bosco, C., Fersini, E., Nozza, D., Patti, V., Pardo, F. M. R., Rosso, P. ve Sanguinetti, M. (January 2019). SemEval-2019 Task 5: Multilingual Detection of Hate Speech Against Immigrants and Women in Twitter. In *Proceedings of the 13th International Workshop on Semantic (SemEval-2019)* (ss. 54–63) Association for Computational Linguistics.
- Basiri, M. E., Nemati, S., Abdar, M., Cambria, E. ve Acharya, U. R. (2020 February). ABCDM: An attention-based bidirectional CNN-RNN deep model for sentiment analysis. *Future Generation Computer Systems*, 115(1), 279–294.
- Behera, R. N., Roy, M. ve Dash, S (2016). Ensemble based hybrid machine learning approach for sentiment classification—a review. *International Journal of Computer Applications*, 146(6), 31–36.
- Bello, A., Ng, S.-C. ve Leung, M.-F. (2023). A BERT Framework to Sentiment Analysis of Tweets. *Sensors*, 23(1), 506.
- Beseiso, M., Alzahrani, S. (2020). An empirical analysis of BERT embedding for automated essay scoring. *International Journal of Advanced Computer Science and Applications*, 11(10), 204–210.
- Bojanowski, P., Graand, E., Joulin, A. ve Mikolov, T.. (2016). Enriching word vectors with subword information. *Transactions of the Association for Computational Linguistics*, 5(1), 135–146.
- Bowker, L. ve Pearson, J. (2002). *Working with specialized language: A practical guide to using corpora* (Birinci Baskı). New York: Routledge, 135–146.
- Burnap, P., Williams, M. L., Sloan, L., Rana, O., Housley, W., Edwards, A. ve Voss, A.. (2014). Tweeting the terror: Modelling the social media reaction to the Woolwich terrorist attack. *Social Network Analysis and Mining*, 4(1), 1–14.
- Cambria, E., Wang, H., & White, B. (2014). Guest editorial: Big social data analysis. *Knowledge-Based Systems*, 69(1), 1–2.
- Cao, Y., Sun, Z., Li, L. ve Mo, W. (2022). A Study of Sentiment Analysis Algorithms for Agricultural Product Reviews Based on Improved BERT Model. *Symmetry*, 14(8), 1–17.
- Carley, K. M., Malik, M., Landwehr, P. M., Pfeffer, J. ve Kowalchuck, M. (2016). Crowd sourcing disaster management: The complex nature of Twitter usage in Padang Indonesia. *Safety Science*, 90(1), 48–61.
- Caselli, T., Basile, V., Mitrović, J. ve Granitzer, M. (2021). HateBERT: Retraining BERT for abusive language detection in English. In *Proceedings of the 5th Workshop on Online Abuse and Harms (WOAH 2021)* (pp. 17–25). Association for Computational Linguistic
- Caselli, T., Basile, V., Mitrovic, J., Kartoziya, I. ve Granitzer, M. (2020). I Feel Offended, Don't Be Abusive! Implicit/Explicit Messages in Offensive and Abusive Language. *Proceedings of the Twelfth Language Resources and Evaluation Conference (LREC 2020)*, (pp. 6193–6202). Marsilya, Fransa.

- Chakkarwar, V., Tamane, S. ve Thombre, A. (2023). A Review on BERT and Its Implementation in Various NLP Tasks. In *Proceedings of the International Conference on Applications of Machine Intelligence and Data Analytics (ICAMIDA 2022)* (s. 112-121). Atlantis Press.
- Chen, C., Zhuo, R. ve Ren, J. (2019). Gated recurrent neural network with sentimental relations for sentiment classification. *Information Sciences*, 502(1), 268–278.
- Cheong, M. ve Lee, V. C. (2011). A microblogging-based approach to terrorism informatics: Exploration and chronicling civilian sentiment and response to terrorism events via Twitter. *Information Systems Frontiers*, 13(1), 45-59.
- Collobert, R., Weston, J., Bottou, L., Karlen, M., Kavukcuoglu, K. ve Kuksa, P. (2011). Natural language processing (almost) from scratch. *Journal of Machine Learning Research*, 12(1), 2493–2537.
- Crannell, W. C., Clark, E., Jones, C., James, T. A. ve Moore, J. (2016). A pattern-matched Twitter analysis of US cancer-patient sentiments. *Journal of Surgical Research*, 206(2), 536–542.
- Dave, K. L. (2003). Mining the peanut gallery: Opinion extraction and semantic classification of product reviews. In *Proceedings of the 12th International Conference on World Wide Web*, (ss. 519–528). Association for Computing Machinery.
- Durairaj, A. K., Chinnalagu, A. (2021). Transformer based Contextual Model for Sentiment Analysis of Customer Reviews: A Fine-tuned BERT. *International Journal of Advanced Computer Science and Applications*, 12(11,) 474-480.
- Elkin, L. S., Topal, K. ve Bebek, G.. (2017). Network based model of social media big data predicts contagious disease diffusion. *Information Discovery and Delivery*, 45(3), 110-120.
- Fegiz, P. L. (1947). Italian public opinion. *Public Opinion Quarterly*, 11(1), 92–96.
- Feldman, R. (2013). Techniques and applications for sentiment analysis. *Communications of the ACM*, 56(4), 82-89.
- İnternet: Fuel, F. No online customer reviews means BIG problems in 2017. URL: <https://fanandfuel.com/no-online-customer-reviews-means-big-problems-2017> Son Erişim Tarihi 01.06.2025
- Geetha, M. P. ve Karthika Renuka, D. (2021). Improving the performance of aspect based sentiment analysis using fine-tuned Bert Base Uncased model. *International Journal of Intelligent Networks*, 2(1), 64-69.
- Grant, A. ve O'Mahoney, H. (2016). Portrayal of waterpipe (shisha, hookah, nargile) smoking on Twitter: a qualitative exploration. *Public Health*, 140(1), 128-1135.
- Gururangan, S., Marasović, A., Swayamdipta, S., Lo, K., Beltagy, I., Downey, D. ve Smith, N. A. (2020). Don't stop pretraining: Adapt language models to domains and tasks. In *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics* (pp. 8342–8360). Association for Computational Linguistics.

- Hatzivassiloglou, V., McKeown, K. (1997). Predicting the semantic orientation of adjectives. In *35th annual meeting of the association for computational linguistics and 8th conference of the european chapter of the association for computational linguistics*, (s. 174–181). Association for Computational Linguistics.
- Hochreiter, S. ve Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.
- Holmer, D. (2020). Context matters: Classifying Swedish texts using BERT's deep bidirectional word embeddings, Yayınlanmamış Lisans Tezi, Linköping University, Linköping, Sweden.
- Huang, X., Zhang, W., Tang, X., Zhang, M., Surbiryala, J., Iosifidis, V., Liu, Z. ve Zhang, J. (2021). LSTM Based Sentiment Analysis for Cryptocurrency Prediction. In *Database Systems for Advanced Applications (DASFAA 2021)*. Cham, Switzerland, Springer.
- Hussain, M. A., Chen, Z., Zheng, Y., Shoaib, M., Shah, S. U., Ali, N. ve Afzal, Z.. (2022). Landslide Susceptibility Mapping using Machine Learning Algorithm Validated by Persistent Scatterer In-SAR Technique. *Sensors*, 22(9), 209–224.
- Interian, Y., Rideout, V., Kearney, V. P., Gennatas, E., Morin, O., Cheung, J., ve Valdes, G. (2018). Deep nets vs expert designed features in medical physics: An IMRT QA case study. *Medical Physics*, 45(6), 2672-2680.
- İskender, E. ve Batı, G. B. (2015). Comparing Turkish Universities Entrepreneurship and Innovativeness Index's Rankings with Sentiment Analysis Results on Social Media. *Procedia-Social and Behavioral Sciences*, 195(1), 1543-1552.
- Kang, H. W., Chye, K. K., Ong, Z. Y. ve Tan, C. W. (2021). The Science of Emotion: Malaysian Airlines Sentiment Analysis using BERT Approach. In *International Conference on Digital Transformation and Applications (ICDXA)*. 1-6.
- Khan, F. H., Qamar, U. ve Bashir, S. (2016). eSAP: A decision support framework for enhanced sentiment analysis and polarity classification. *Information Sciences*, 367-368(1), 862-873.
- Khan, L., Amjad, A., Ashraf, N. ve Chang, H. T. (2022). Multi-class sentiment analysis of Urdu text using multilingual BERT. *Scientific Reports*, 12(1), 5436.
- Kim, J. ve Hastak, M. (2018). Social network analysis: Characteristics of online social networks after a disaster. *International Journal of Information Management*, 38(1), 86-96.
- Kim, Y. (2014). Convolutional neural networks for sentence classification. In *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)* (pp. 1746–1751). Association for Computational Linguistics.
- Knutson, A. L. (1945). Japanese opinion surveys: The special need and the special difficulties. *Public Opinion Quarterly*, 9(3), 313–319.
- Kumar, P. ve Singh, A. K. (2022). A comparison between MLR, MARS, SVR and RF techniques: hydrological time-series modeling. *Journal of Human, Earth, and Future*, 3(1), 90–98.

- Kusnadi, R., Yusuf, Y., Andriantony, A., Ardian Yaputra, R. ve Caintan, M. (2021). Sentiment Analysis of the Game Genshin Impact Using Bert. *Rabit: Jurnal Teknologi Dan Sistem Informasi Univrab*, 6(2), 122–129.
- Lakew, S. M., Cettolo, M. ve Federico, M. (2018). A comparison of transformer and recurrent neural networks on multilingual neural machine translation. In *Proceedings of the 27th International Conference on Computational Linguistics (COLING 2018)* (pp. 641–652). Association for Computational Linguistics..
- Lee, N. Y., Kim, Y. ve Sang, Y. (2016). How do journalists leverage Twitter? Expression and consumption use of Twitter. *The Social Science Journal*, 54(2), 139-147.
- Lee, X. J., Yap, T. T., Ng, H. ve Goh, V. T. (2022). Comparison of Word Embeddings for Sentiment Classification with Preconceived Subjectivity. In *Proceedings of the International Conference on Computer, Information Technology and Intelligent Computing (CITIC 2022)*, (pp. 488–502), Atlantis Press.
- Li, M., Chen, L., Zhao, J., & Li, Q. (2021). Sentiment analysis of Chinese stock reviews based on BERT model. *Applied Intelligence*, 51(1), 5016-5024.
- Liao, C., Feng, C., Yang, S. ve Huang, H. (2016). Topic-related Chinese message sentiment analysis. *Neurocomputing*, 210(1), 237-246.
- Ligthart, A., Çatal, Ç. ve Tekinerdogan, B. (2021). Systematic reviews in sentiment analysis: A tertiary study. *Artificial Intelligence Review*, 54(1), 4997-5053.
- Liu, B., Zhang, L. (2012). A survey of opinion mining and sentiment analysis. *Mining Text Data*. (1. Baskı). New York: Springer, 415–463.
- Majumder, N., Poria, S., Gelbukh, A. ve Cambria, E. (2017). Deep learning-based document modeling for personality detection from text. *IEEE Intelligent Systems*, 32(2), 74-79.
- Manda, K. R. (2019). Sentiment Analysis of Twitter Data Using Machine Learning and Deep Learning Methods. Unpublished Master's Thesis, Blekinge Institute of Technology, Sweden.
- Mäntylä, M. V. (2018). The evolution of sentiment analysis-A review of research topics and top cited papers. *Computer Science Review*, 27(1), 16-32.
- Mäntylä, M. V. (2021). A survey of Twitter research: Data model, graph structure, sentiment analysis and attacks. *Expert Systems with Applications*, 164(1), 114006
- Mehta, Y., Majumder, N., Gelbukh, A. ve Cambria, E. (2020). Recent trends in deep learning based personality detection. *Artificial Intelligence Review*, 53(1), 2313-2339.
- Meltwater, W. A. (2025, Mart 22). *Digital 2025: Global Overview Report*. DATAREPORTAL: datareportal.com/reports/digital-202-global-overview-report adresinden alındı.
- Meltwater, W. A. (2025, Mart 24). *Digital 2025: Turkey*. [datareportal.com: datareportal.com/reports/digital-2025-turkey](https://datareportal.com/reports/digital-2025-turkey) adresinden alındı
- Misra, S., Tandon, P., & Panda, P. (2024). Enhancing the detection of fake news in social media: A comparison of support vector machine algorithms, Hugging Face

- transformers, and passive aggressive classifier. In *Data Management, Analytics and Innovation (ICDMAI 2024)*, (pp. 185–204).
- Mite-Baidal, K., Delgado-Vera, C., Solis-Aviles, E., Espinoza, A. H., Ortiz-Zambrano, J. ve Verela-Tapia, E. (2018). Sentiment analysis in education domain: A systematic literature review. In *Technologies and Innovation Conference(CITI)* (pp. 285-297). Springer.
- Muhammad, A., Wiratunga, N. ve Lothian, R. (2016). Contextual sentiment analysis for social media genres. *Knowledge-based Systems*, 108(15), 92-101.
- Müller, M., Salathé, M. ve Kummervold, P. E. (2020). COVID-Twitter-BERT: A natural language processing model to analyse COVID-19 content on Twitter. *Frontiers in Artificial Intelligence*, 6(1023281).
- Munezero, M., Montero, C. S., Sutinen, E. ve Pajunen, J. (2014). Are they different? Affect, feeling, emotion, sentiment and opinion detection in text. *IEEE Transactions on Affective Computing*, 5(2), 101-111.
- Nassif, A. B., Elnagar, A., Shahin, I., ve Henno, S. (2021). Deep learning for Arabic subjectivity and sentiment analysis: Challenges and research opportunities. *Applied Soft Computing*, 98(1), 106836.
- Nassirtoussi, A. K. (2014). Text mining for market prediction: A systematic review. *Expert Systems with Applications*, 41(16), 7653–7670.
- Navér, N. (2021). *The past, present or future?: A comparative NLP study of Naive Bayes, LSTM and BERT for classifying Swedish sentences based on their tense*. Yayınlanmamış Yüksek Lisans Tezi. Uppsala Universitet Computer and Information Engineering.
- Neppalli, V. K., Caragea, C., Squicciarini, A., Tapia, A. ve Stehle, S. (2017). Sentiment analysis during Hurricane Sandy in emergency response. *International Journal of Disaster Risk Reduction*, 21(1), 213-222.
- Nguyen, D. Q., Vu, T. ve Nguyen, A. T. (2020). BERTweet: A pre-trained language model for English Tweets. In *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing: System Demonstrations*, pp(9-14). Association for Computational Linguistics.
- Nguyen, Q. T., Nguyen, T. L., Luong, N. H. ve Ngo, Q. H. (2020). Fine-Tuning BERT for Sentiment Analysis of Vietnamese Reviews. In *2020 7th NAFOSTED Conference on Information and Computer Science (NICS)*. IEEE.
- Nugroho, K. S., Sukmadewa, A. Y., Wuswilahaken DW, H., Bachtiar, F. A. ve Yudistira, N. (2021). BERT Fine-Tuning for Sentiment Analysis on Indonesian Mobile Apps Reviews. In *6th International Conference on Sustainable Information Engineering and Technology* (pp. 258-264). IEEE.
- İnternet: Otomotiv Distribütörleri ve Mobilite Derneği,
[URL:https://www.odmd.org.tr/web_2837_1/neuralnetwork.aspx?type=36](https://www.odmd.org.tr/web_2837_1/neuralnetwork.aspx?type=36). Son
 Erişim Tarihi: 8.05.2024.

- Oza, K. S. ve Naik, P. G. (2016). Prediction of online lectures popularity: a text mining approach. *Procedia Computer Science*, 92(1), 468–474.
- Özer, Z. (2019). *Trafik yorumlarının sınıflandırılmasında normalizasyonun etkisi*. Yayınlanmamış Yüksek Lisans Tezi. Karabük Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Öztürk, N. ve Ayvaz, S. (2018). Sentiment analysis on Twitter: A text mining approach to the Syrian refugee crisis. *Telematics and Informatics*, 35(1), 136-147.
- Pàmies Massip, M. (2020). *Multilingual identification of offensive content in social media*. Yayınlanmamış Yüksek Lisans Tezi. Linköping: Linköping University Department of Computer and Information Science.
- Park, S. J., Park, J. Y., Lim, Y. S. ve Park, H. W. (2016). Expanding the presidential debate by tweeting: The 2012 presidential election debate in South Korea. *Telematics and Informatics*, 33(2), 557–569.
- Pirani, R. M. (2017). Analytical mapping of opinion mining and sentiment analysis research during 2000–2015. *Information Processing and Management*, 53(1), 122–150.
- Pota, M., Ventura, M., Catelli, R., & Esposito, M. (2021). An effective BERT-based pipeline for twitter sentiment analysis: A case study in Italian. *Sensors*, 21(1), 1-21.
- Pradha, S., Halgamuge, M. N. ve Vinh, N. T. Q. (2019). Effective Text Data Preprocessing Technique for Sentiment Analysis in Social Media Data. In *11th International Conference on Knowledge and Systems Engineering (KSE)* (pp. 1-8).IEEE.
- Prottasha, N. J., Sami, A. A., Kowsher, M., Murad, S. A., Bairagi, A. K., Masud, M., & Baz, M. (2022). Transfer Learning for Sentiment Analysis Using BERT Based Supervised Fine-Tuning. *Sensors*, 22(11), 4157.
- Rahali, A., Akhloufi, M. A., Therien-Daniel, A. M. ve Brassard-Gourdeau, E. (2021). Automatic Misogyny Detection in Social Media Platforms using Attention-based Bidirectional-LSTM. In *Proceedings of the 2021 IEEE International Conference on Systems, Man, and Cybernetics* (pp. 2706–2711), IEEE.
- Rahali, A., Akhloufi, M.A. (2023). End-to-End Transformer-Based Models in Textual-Based NLP. *AI*, 4(1), 54-110.
- İnternet: Rashed, F. URL: <https://x.com/FawazRashed/status/48882406010257408>, Son Erişim Tarihi: 01.06.2025
- Reyes, A. ve Rosso, P. (2013). On the difficulty of automatically detecting irony: Beyond a simple case of negation. *Knowledge and Information Systems*, 40(1), 595-614.
- Rumelhart, D. E., Hinton, G. E. ve Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(1), 533-536.
- Şahiner Yılmaz, Ş. (2022). *Türkçe Metinlerde Duygu Analizi Yapılarak Saldırgan İçeriklerin Tespit Edilmesi*. Yayınlanmamış Yüksek Lisans Tezi, Ankara: Gazi Üniversitesi Bilişim Enstitüsü, Ankara

- Sandri, S. A. (1995). Elicitation, assessment and pooling of expert judgments using possibility theory. *IEEE Transactions on Fuzzy Systems*, 3(3), 313–335.
- Sarkar, D., Bali, R. ve Sharma, T. B. (2018). *Practical machine learning with Python: A problem-solver's guide to building real-world intelligent systems*(1. Baskı). Bangalore, Karnataka, Hindistan: Apress, 158-165.
- Sasaki, Y., Kawai, D. ve Kitamura, S. (2016). Unfriend or ignore tweets? A time series analysis on Japanese Twitter users suffering from information overload. *Computers in Human Behavior*, 64(1), 914-922.
- Sayeed, M. S., Mohan, V. ve Muthu, K. S. (2023). BERT: A Review of Applications in Sentiment Analysis. *HighTech and Innovation*, 4(2), 453-462.
- Shahin, I., Nassif, A. B. ve Hamsa, S. (2020). Novel cascaded Gaussian mixture model-deep neural network classifier for speaker identification in emotional talking environments. *Neural Computing and Applications*, 32(1), 2575–2587.
- Sharma, A. K. (2020). Sentimental short sentences classification by using CNN deep learning model with fine-tuned Word2Andc. *Procedia Computer Science*, 167(1), 1139-1147.
- Singh, M., Jakhar, A. K. ve Pandey, S. (2021). Sentiment analysis on the impact of coronavirus in social life using the BERT model. *Social Network Analysis and Mining*, 11(1), 5-11.
- Sohrabi, M. K. ve Hemmatian, F. (2019). An efficient preprocessing method for supervised sentiment analysis by converting sentences to numerical vectors: A twitter case study. *Multimedia Tools and Applications*, 78(1), 24863–24882.
- Song, M., Park, H. ve Shin, K. S. (2019). Attention-based long short-term memory network using sentiment lexicon embedding for aspect-level sentiment analysis in Korean. *Information Processing and Management*, 56(3), 637-653.
- Sousa, M. G., Sakiyama, K., Rodrigues, L. d., Moraes, P. H., Fernandes, E. R. ve Matsubara, E. T. (2019). BERT for Stock Market Sentiment Analysis. In *2019 IEEE 31st International Conference on Tools with Artificial Intelligence (ICTAI)*(pp. 1597-1601). IEEE.
- Stagner, R. (1940). The cross-out technique as a method in public opinion analysis. *The Journal of Social Psychology*, 11(1), 79–90.
- Sun, C., Qiu, X., Xu, Y. ve Huang, X. (2019). How to Fine-Tune BERT for Text Classification? In *Chinese Computational Linguistics. (CCL 2019)*(pp. 194-206). Springer.
- Sun, S. L. (2017). A review of natural language processing techniques for opinion mining systems. *Information Fusion*, 36(1), 10-25.
- Sutskever, I., Vinyals, O. ve Le, Q. V. (2014). Sequence to sequence learning with neural networks. In *Proceedings of the 27th International Conference on Neural Information Processing Systems (NeurIPS)*. (pp. 3104-3112). MIT Press.

- Taboada, M. B. (2011). Lexicon-based methods for sentiment analysis. *Computational Linguistics*, 37(2), 267-307.
- Tellez, E. S., Miranda-Jiménez, S., Graff, M., Moctezuma, D., Siordia, O. S. ve Villaseñor, E. A. (2017). A case study of Spanish text transformations for Twitter sentiment analysis. *Expert Systems with Applications*, 81(1), 457-471.
- Thelwall, M. (2009). Online Information Review. *MySpace comments*, 33(1), 58-76.
- Thelwall, M. B. (2012). Sentiment strength detection for the social web. *Journal of the American Society for Information Science and Technology*, 63(1), 163-173.
- Thompson, J. J., Leung, B. H., Blair, M. R. ve Taboada, M. (2017). Sentiment analysis of player chat messaging in the video game StarCraft 2: Extending a lexicon-based model. *Knowledge-Based Systems*, 137(1), 149-162.
- Turney, P. (2002). Thumbs Up, Thumbs Down: Semantic Orientation Applied To Unsupervised Classification of Reviews. In *Proceedings of the 40th Annual Meeting of the Association for Computational Linguistics (ACL)*, (pp. 417–424). Association for Computational Linguistics.
- Turney, P. D. (2003). Measuring praise and criticism: Inference of semantic orientation from association. *ACM Transactions on Information Systems (TOIS)*, 21(4), 315–346.
- Uçan, A., Naderalvojud, B., Sezer, E. A. ve Sever, H. (2016). Sentiwordnet for new language: Automatic translation approach. In *12th International Conference on Signal-Image Technology & Internet-Based Systems (SITIS)* (s. 308–315). IEEE.
- Van Klompenburg, T., Kassahun, A. ve Çatal. Ç. (2020). Crop yield prediction using machine learning: A systematic literature review. *Computers and Electronics in Agriculture*, 177(10), 105709.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, L. ve Polosukhin, I. (2017). Attention is all you need. In *Proceedings of the Advances in Neural Information Processing Systems 30 (NIPS 2017)*(pp. 6000-6010). Curran Associates.
- Vural, A. G. (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.
- Wang, H., Can, D., Kazemzadeh, A., Bar, F. ve Narayanan, S. (2012). A system for real-time Twitter sentiment analysis of 2012 US presidential election cycle. In *Proceedings of the ACL 2012 system demonstrations*, (pp. 115–120). Association for Computational Linguistics.
- Wang, Y. H. (2018). Segmental audio word2andc: Representing utterances as sequences of andctors with applications in spoken term detection. In *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*(pp. 6269–6273). IEEE.
- İnternet: R-transformer: Recurrent neural network enhanced transformer. URL: <https://openreview.net/pdf?id=HJx4PAEYDH>. Son Erişim Tarihi:10.06.2025.

- Wiebe, J. B. (1999). Development and use of a gold-standard data set for subjectivity classifications. In *Proceedings of the 37th annual meeting of the Association for Computational Linguistics*, (pp. 246–253). Association for Computational Linguistics.
- Wiebe, J. M. (1991). Recognizing subjective sentences: A computational investigation of narrative text. *References in Narrative Text Noûs*, 1(1), 457–486.
- Wu, B. ve Shen, H. (2015). Analyzing and predicting news popularity on Twitter. *International Journal of Information Management*, 35(6), 702-711.
- Yang, G. ve Guo, X. (2023). Application of Decision Tree Mining Algorithm in Data Model Collection of Hydraulic Engineering Equipment. In *Proceedings of the 4th International Conference on Big Data Analytics for Cyber-Physical System in Smart City(BDCPS 2022)*(pp. 697-705). Springer
- Yang, Y. ve Eisentein, J. (2017). Overcoming language variation in sentiment analysis with social attention. *Transactions of the Association for Computational Linguistics*, 5(1), 295-307.
- Yates, D. ve Paquette, S. (2011). Emergency knowledge management and social media technologies: A case study of the 2010 Haitian earthquake. *International Journal of Information Management*, 33(1), 6-13.
- Zampieri, M., Malmasi, S., Nakov, P., Rosenthal, S., Farra, N. ve Kumar, R. (2019). SemEval-2019 Task 6: Identifying and Categorizing Offensive Language in Social Media. In *Proceedings of the 13th International Workshop on Semantic Evaluation* (pp. 75-86). Association for Computational Linguistics.
- Zhang, L., Wang, S. ve Liu, B. (2018). Deep learning for sentiment analysis: A survey. *WIRES. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(8), 1-25.
- Zhou, J., Tian, J., Wang, R., Wu, Y., Xiao, W. ve He, L. (2020). Sentix: A sentiment-aware pre-trained model for cross-domain sentiment analysis. In *Proceedings of the 28th International Conference on Computational Linguistics*, (pp. 568–579). International Committee on Computational Linguistics.



GAZİLİ OLMAK AYRICALIKTIR.