



T.C.
ÜSKÜDAR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY ZEKA MÜHENDİSLİĞİ ANABİLİM DALI
YAPAY ZEKA MÜHENDİSLİĞİ YÜKSEK LİSANS PROGRAMI
YÜKSEK LİSANS TEZİ

**DUYGU ANALİZİ MODELLERİNİN TÜRKÇE METİNLER
ÜZERİNDEKİ PERFORMANSI VE CHATBOT UYGULAMASI**

Tuğba ATAR MISIR

Tez Danışmanı
Dr. Öğr. Üyesi GÖKALP TULUM

İSTANBUL-2024

T.C.
ÜSKÜDAR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY ZEKA MÜHENDİSLİĞİ ANABİLİM DALI
YAPAY ZEKA MÜHENDİSLİĞİ YÜKSEK LİSANS PROGRAMI
YÜKSEK LİSANS TEZİ

DUYGU ANALİZİ MODELLERİNİN TÜRKÇE METİNLER
ÜZERİNDEKİ PERFORMANSI VE CHATBOT UYGULAMASI

Tuğba ATAR MISIR

Tez Danışmanı
Dr. Öğr. Üyesi GÖKALP TULUM

İSTANBUL-2024

ÖZET

DUYGU ANALİZİ MODELLERİNİN TÜRKÇE METİNLER ÜZERİNDEKİ PERFORMANSI VE CHATBOT UYGULAMASI

Sosyal medya kullanımı son dönemde oldukça yaygınlaşmıştır. Kullanıcıların sosyal medya platformlarında bıraktıkları izler (beğeni, yorum, emoji vs.) büyük verilerin toplanmasını sağlamıştır. Bu çalışmada, beyazperde.com veri seti kullanılarak Türkçe metinler üzerinden duygu analizi yapmak için çeşitli makine öğrenimi modellerinin performansını değerlendirmek ve aynı zamanda chatbot aracılığıyla gerçek zamanlı duygu analizi yapmak amaçlanmıştır.

Bu kapsamda, veri setine makine öğrenimi modellerinden SVM (Support Vector Machine), LSTM (Long Short-Term Memory), Naive Bayes (NB) ve Logistic Regresyon yöntemlerine duygu analizi yapabilen chatbot uygulaması gerçekleştirilmiştir. Chatbot uygulamasının gerçek zamanlı kullanımı için eğitilen modellerin performans değerlerine bakılarak en uygun model bulunmaya çalışılmıştır. Bu çalışmada en uygun yöntemi belirlemek için eğitimi gerçekleştirilen makine öğrenmesi modellerinin performans değerlendirmelerini karşılaştırmada doğruluk oranları, eğitim ve tahmin süreleri, chatbot gözlemci formu kullanılmıştır.

Bu sonuçlar, Türkçe metinler üzerinden elde edilen duygu analizi modellerinin chatbot ile gerçek zamanlı kullanımının başarıyla uygulanabileceğini göstermiştir. Bu yaklaşım, kullanıcıların deneyimlerini değerlendirmek için duygu analizi modellerinin pratik uygulamalarını gösterir. Chatbotlar aracılığıyla yapılan duygu analizi, hizmetlerin iyileştirilmesi ve kullanıcı deneyiminin artırılmasına katkı sağlayabilir.

Anahtar Kelimeler: Yapay Zeka, Duygu Analizi, Makine Öğrenimi, Chatbot, Türkçe Metinler

ABSTRACT

PERFORMANCE OF SENTIMENT ANALYSIS MODELS ON TURKISH TEXTS AND CHATBOT APPLICATION

The use of social media has become quite widespread recently. The traces left by users on social media platforms (likes, comments, emojis, etc.) have enabled the collection of large data. In this study, it was aimed to evaluate the performance of various machine learning models for sentiment analysis on Turkish texts using the Beyazperde.com dataset and to also perform real-time sentiment analysis via chatbot.

In this context, a chatbot application that can perform sentiment analysis on machine learning models SVM (Support Vector Machine), LSTM (Long Short-Term Memory), Naive Bayes (NB) and Logistic Regression methods was implemented on the data set. The most suitable model was tried to be found by looking at the performance values of the models trained for real-time use of the chatbot application. In this study, accuracy rates, training and prediction times, and the chatbot observer form were used to compare the performance evaluations of the trained machine learning models in order to determine the most appropriate method.

These results have shown that real-time use of sentiment analysis models obtained from Turkish texts can be successfully implemented with a chatbot. This approach demonstrates practical applications of sentiment analysis models to evaluate users' experiences. Sentiment analysis through chatbots can contribute to improving services and increasing user experience.

Keywords: Artificial Intelligence, Sentiment Analysis, Machine Learning, Chatbot, Turkish Texts

TEŞEKKÜR

Tez çalışmamda çalışmalarına yön veren, bana güvenen danışmanım Dr. Öğr. Üyesi Gökâl TULUM ve yüksek lisans eğitimim süresince desteklerini esirgemeyen Dr. Nuri BİNGÖL hocalarıma sonsuz teşekkürlerimi sunarım.

Hayat arkadaşım Ercan MISIR ve sevgili oğlum İlber Kaan MISIR' a tüm yüksek lisans eğitimim boyunca gösterdikleri destek ve anlayış için sonsuz teşekkürlerimi sunarım.



BEYAN FORMU

Bu alıřmadaki btn bilgi ve belgeleri akademik kurallar erevesinde elde ettiđimi, grsel, iřitsel ve yazılı tm bilgi ve sonuları bilimsel ahlak kurallarına uygun olarak sunduđumu, kullandıđım verilerde herhangi bir tahrifat yapmadıđımı, yararlandıđım kaynaklara bilimsel normlara uygun olarak atıfta bulunduđumu, tezimin kaynak gsterilen durumlar dıřında zgn olduđunu, tarafımdan retildiđini ve skdar niversitesi Fen Bilimleri Enstits Tez Yazım Kılavuzuna gre yazıldıđını beyan ederim.

19.01.2024

Tuđba ATAR MISIR

İÇİNDEKİLER

ÖZET	i
ABSTRACT.....	ii
TEŞEKKÜR	iii
BEYAN FORMU	iv
İÇİNDEKİLER	v
TABLolar DİZİNİ	vii
ŞEKİLLER DİZİNİ	viii
SİMGELER VE KISALTMALAR DİZİNİ	ix
1. GİRİŞ	1
1.1. Amaç	2
1.2. Kapsam	2
1.3. Tezin Yapısı	3
2. GENEL BİLGİLER	4
2.1. Yapay Zeka	4
2.2. Makine Öğrenmesi	6
2.2.1. Klasik makine öğrenmesi	9
2.2.1.1. Naive bayes	11
2.2.1.2. Logistic regression	13
2.2.1.3. Destek vektör makinesi-svm	14
2.2.1.4. Yapay sinir ağları	16
2.2.2. Derin öğrenme	18
2.2.2.1. Tekrarlayan sinir ağları (recurrent neural network- rnn)	19
2.2.2.2. Uzun kısa süreli bellek (long short-term memory- lstm)	21
2.3. Doğal Dil İşleme (NLP)	24
2.3.1. Duygu analizi (sentiment analysis)	27

2.4. Chatbot.....	29
3. GEREÇ VE YÖNTEM.....	32
3.2. Yazılım.....	35
3.2.1. Google colab.....	35
3.2.2. Python programlama dili	36
3.3. Doğal Dil İşleme (NLP) İşlemleri	37
3.4. Model Eğitimi ve Test Süreci	38
3.4.1. Naive bayes modeli eğitim süreci	38
3.4.2. Logistic regression modeli eğitim süreci	39
3.4.3. Svm Modeli Eğitim Süreci	39
3.4.4. Lstm modeli eğitim süreci	39
3.5. Duygu Analizi (Sentiment Analysis) İşlemleri.....	41
3.6. Chatbot İşlemleri.....	41
4. BULGULAR.....	44
6. SONUÇ VE ÖNERİLER.....	54
KAYNAKLAR	56
EKLER	65

TABLÖLAR DİZİNİ

Sayfa

Tablo 1: Veri setine ait token sayıları toplamı.....	32
Tablo 2: Kullanıcı yorumlarının ilk beş satırının incelemesi.....	33
Tablo 3: Veri seti istatistikleri-1	34
Tablo 4: Veri seti istatistikleri-2	34
Tablo 5: Confusion matrix değerleri.....	46
Tablo 6: Model eğitim metrikleri-1	47
Tablo 7: Model eğitim metrikleri-2	48
Tablo 8: Chatbot gözlemci formu	49
Tablo 9: Çalışmanın performans karşılaştırması	52

ŞEKİLLER DİZİNİ

Sayfa

Şekil 1: Turing testi	4
Şekil 2: Yapay zekanın gelişiminin üç katmanı	5
Şekil 3: Makine öğrenmesi	6
Şekil 4: Makine öğrenimi çalışma prensibi	7
Şekil 5: Makine öğrenimi teknikleri.....	9
Şekil 6: Denetimli öğrenme sınıflandırma teknikleri	10
Şekil 7: Logistic fonksiyonun eğrisi.....	13
Şekil 8: Destek vektör makineleri	15
Şekil 9: Birden fazla hiper düzlemin verileri iki sınıfa bölmesi	15
Şekil 10: Biyolojik sinir hücresi ve yapay sinir ağı	16
Şekil 11: Yapay zeka alanındaki sinir ağı modellerinin işleyişi	18
Şekil 12: Rnn açık gösterimi	20
Şekil 13: Rnn' in türleri	20
Şekil 14: Lstm mimari yapısı	22
Şekil 15: Gru mimarisi	23
Şekil 16: Doğal dil işleme	25
Şekil 17: Duygu analizinin genel işleyişi	28
Şekil 18: Model eğitim ve uygulama iş akışı	40
Şekil 19: Nünü çalışma prensibi.....	42
Şekil 20: Confusion Matrix	44

SİMGELER VE KISALTMALAR DİZİNİ

İBSA	: İleri Beslemeli Sinir Ağı
GRU	: Gated Recurrent Units
RNN	: Reccurent Neural Network
YSA	: Yapay Sinir Ağları
ESA	: Evrişimli Sinir Ağı
RTFSA	: Radyal Tabanlı Fonksiyon Sinir Ağı
RNN	: Recurrent Neural Network
NB	: Naive Bayes
LSTM	: Long Short Term Memory
TSA	: Tekrarlayan Sinir Ağı
GPU	: Graphics Processing Unit
TPU	: Tensor Processing Unit
SPSS	: Statistical Package for the Social Sciences
DML	: Data Manipulation Language
DDL	: Data Definition Language
IQR	: Interquartile Range
TF-IDF	: Term Frequency-Inverse Document Frequency
KNN	: K-Nearest Neighbor
SVC	: Support Vector Classification
SVM	: Support Vector Machine
NLTK	: Natural Language Toolkit

NLP	: Doğal Dil İşleme
NLU	: Doğal Dil Anlama
LSA	: Gizli Anlamsal Analiz
AIML	: Artificial Intelligence Markup Language
AI	: Yapay Zeka



1. GİRİŞ

Son zamanlarda bilgi ve iletişim teknolojilerinde yaşanan ilerlemeler, verinin üretildiği anda kalmasına imkân sağlamıştır. Teknolojideki ilerlemelerin sonucu olarak, hızla akan veriye en hızlı şekilde tepki verme, işleme ve analiz yeteneği, kurumlara önemli avantajlar sunmaktadır. Bu teknolojik ilerlemeler, kurumlara doğru kararlar almak, müşteri sayısını arttırmak ve mevcut müşterileri elde tutmak gibi fırsatlar sunmaktadır. Kurumlar analiz ettiği veriler sayesinde iş stratejilerini güçlendirebilir ve rekabet edebilir bir konuma gelebilirler (Doğan ve Arslantekin, 2016). Kurumların sosyal medya araçlarıyla müşterilere ulaşması kolay ve ekonomik olabilmektedir. Buda sosyal medya platformlarının çeşitliliğinde ve kullanımında artışa neden olmaktadır. Sosyal medya platformlarının kullanımındaki artış, büyük miktarda işlenmemiş metin verilerine erişimi artırmıştır. Bu büyük ölçekteki veri yığınlarından anlamlı bilgilerin çıkarılması, karmaşık ve maliyetli bir süreç gerektirir. Literatürde, bu sorunu çözmek için birçok sınıflandırma algoritması geliştirilmiştir. Bu algoritmaların ana hedefi, metin verilerini benzer yapılar ve anlamlar doğrultusunda farklı kategorilere ayırmaktır. Yapılan bu kategorizasyonlar, yapılandırılmamış metin dosyalarını sınıflandırmayı mümkün hale getirir (Alpkoçak vd.,2019).

Yapay zeka alanındaki ilerlemeler, doğal dil işleme tabanlı uygulamaların artmasına neden olmaktadır. Doğal dil işleme, bilgisayarların anlayabileceği anlamları eldeki verilerden çıkarmayı sağlayan bir araçtır. Bu uygulamalar, insan gücü ve eliyle zor gerçekleştirilen analizleri hızlı ve doğru bir şekilde yapmak için bilgisayarları kullanarak fayda sağlar. Doğal dil işleme ile gerçekleştirilen uygulamalardan biri de duygu analizidir (Çelik vd.,2021). Duygu analizi, bir metni duygusal olarak sınıflandırmayı amaçlayan bir metin işleme aracıdır. Öncelikle, duygusal kutupsallık olarak bilinen bir yöntem kullanılarak metni olumlu, olumsuz veya nötr olarak sınıflandırmayı hedefler. Bu yöntem, kelimelerin olumlu veya olumsuz olarak ayrılması ve yorumlardaki kelimelerin sayısına göre yorumları sınıflandırmak gibi basit bir yaklaşım sunar. Ancak, bu yöntem alayıcı yorumlar gibi durumlarda başarılı olmayabilir ve nispeten düşük bir doğruluk oranına sahip olabilir. Bu nedenle, daha akıllı yöntemler geliştirilmiştir; bu yöntemler, kendi kendini yenileyen ve kelimelerin anlamlarını otomatik olarak tespit eden algoritmaları içerir (Seker, 2016).

Kullanılan metinlerde yapay zeka ve doğal dil işleme alanlarındaki hızlı gelişmeler, ChatGPT gibi dil tabanlı yapay zeka sistemlerinin ortaya çıkmasına yol açtı. Bu tür sistemler, metin tabanlı görevlerde çeşitli uygulamalarda kullanılabiliyor. Ancak, bu sistemlerin oluşturulması ve geliştirilmesi karışık aşamaları gerektirir. Önceden eğitilmiş bir dil modelinin belirli bir vazife veya kullanım için daha özgün hale getirilmesi anlamına gelir. Model, önceleri eğitim verilerinden edindiği genel dil yeteneklerini kullanarak, kendisini özel bir veri kümesine veya göreve uygun duruma getirecek şekilde özelleştirilir. Bu işlem, modelin daha özgün ve faydalı hale gelmesini sağlar (Altınbaş, 2023).

Bu çalışmada, beyazperde.com verileri üzerinde Naive Bayes (NB), Logistic Regression, Destek Vektör Makinesi (SVM) ve Uzun Kısa Süreli Bellek (LSTM) modelleri kullanılarak duygu analizi gerçekleştirilmiştir. Türkçe metinler üzerinde duygu analizi modellerinin performansını karşılaştırmayı ve chatbot uygulaması için bu modellerin uygunluğunun incelenmesi amaçlanmıştır. Burada duygu analizi yapabilen chatbotların kullanıcı ile etkileşimi sonrası kurumların ve hizmetlerinin iyileştirilmesi hedeflenmektedir.

1.1. Amaç

2013 yılı Türkiye duyarlılık analizi verilerine dayanarak beyazperde.com kullanıcı yorumları kullanılarak farklı makine öğrenimi modellerinin duygu analizi üzerindeki başarısı araştırılarak, hangi modellerin daha başarılı sonuçlar verdiğini belirlemek hedeflenmektedir. Ayrıca, elde edilen sonuçlara dayanarak chatbot uygulamasının gerçek zamanlı duygu analizi için ne kadar başarılı olduğu değerlendirilecektir. Bu çalışma, Türkçe metinlerde duygu analizi alanında daha iyi performans elde etmek ve chatbotların duygu analizi uygulamalarındaki rolünü belirlemek amaçlanmaktadır.

1.2. Kapsam

Duygu analizi, doğal dil işleme alanındaki en yaygın uygulama alanlarından biridir. Ancak, Türkçe gibi sınırlı kaynak içeren diller için uygun veri kümeleri bulmak bazen zor olabilir. Bu çalışmada, analiz modellerini eğitmek için 2013 yılı Türkiye duyarlılık analizi verilerine dayanarak beyazperde.com kullanıcı yorumları veri kaynağı olarak seçilmiştir.

Etkili sınıflandırma performansı, genelleme yeteneği ve aykırı değerlere karşı dirençlilik gösterdiği için SVM modelini, girdi özelliklerini kullanarak verilerin hangi sınıfa ait olma olasılığını tahminlenebilme yeteneği nedeniyle Logistic Regression modelini, basit ve hızlı çalışması ile bilinen Naive Bayes modelinin genellikle metin sınıflandırma gibi doğal dil işleme görevlerinde iyi performans göstermesi nedeniyle, LSTM modelini ise derin öğrenmedeki uzun vadeli bağımlılıkları yakalama özelliği ile duygu analizi gibi sıralı verilerin analizinde etkili olması sebebiyle seçilmişlerdir. Duygu analizi yapan chatbot uygulamasının ise Logistic Regression, SVM ve LSTM modellerine uygulanması tercih edilmiştir.

Bu çalışmanın odak noktası, Türkçe metinler üzerinde farklı duygu analizi modellerinin performansını değerlendirmek ve bu modellerin chatbot uygulamalarında kullanılabilirliğini araştırmaktır. Naive Bayes, Logistic Regression, SVM ve LSTM gibi çeşitli makine öğrenimi modelleri kullanılarak yapılan duygu analizi sonuçları incelenerek Türkçe metinlerde duygusal içeriklerin ne kadar doğru bir şekilde sınıflandırıldığını belirlemektir. Elde edilen bulgular sayesinde bu modellerin chatbot uygulamalarında duygusal içerikli yorumların işlenmesindeki etkinliği ve başarısını ortaya koymak amaçlanmaktadır.

1.3. Tezin Yapısı

Bu tez, beş ana bölümden oluşmaktadır. Giriş bölümünde, verinin önemi, doğal dil işlemede duygu analizinin yeri, sohbet robotlarının gelişimi, çalışmanın amacı ve kapsamı detaylı bir şekilde açıklanmıştır.

İkinci bölüm, doğal dil işlemeye dönemsel bir bakış sunmaktadır. Ardından, Türkçe metinler ve duygu analizi hakkında ayrıntılı bilgiler paylaşılmıştır. Ayrıca yapay zeka ile makine öğrenmesine odaklanılmıştır. Chatbot uygulaması hakkında bilgi verilmiştir.

Üçüncü bölüm, Türkiye duyarlılık analizi verileri ile ilgili bilgiler sunmaktadır. Projede kullanılan araçlar ve yöntemler ayrıntılı şekilde tanımlanmıştır.


Dördüncü bölüm, chatbot uygulamasının gerçekleştirilme yöntemi ve modellerin performans sonuçlarıyla görselleştirme teknikleri ile çalışmadaki bulguları içermektedir.

Son bölümde, bu çalışmayla elde edilen sonuçlara ve önerilere yer verilmiştir.

2. GENEL BİLGİLER

2.1. Yapay Zeka

Yapay zeka, teknolojik sistemlerin insanlara özgü niteliklerle donatılarak, çözüm yolları bulma, anlama, mana çıkartma, genelleme ve geçmiş deneyimlerden öğrenme gibi karmaşık mantıksal süreçleri yerine getirebilme yeteneği olarak tanımlanmıştır. Farklı uzmanlara göre yapay zeka, sezgisel programlama temelli bir yaklaşım, insanların yaptıklarını bilgisayarlara aktarabilme çalışması veya akıllı programların geliştirilmesi olarak da ifade edilmiştir (Öztürk ve Şahin, 2018). Yapay zeka, 1956' da matematik, elektronik ve psikoloji alanlarından araştırmacıların bir araya geldiği bir konferansta resmi olarak ilk kez bir terim olarak Dartmouth College' da yer almasına karşın, aslında kavram olarak 1950' de Alan Turing'in (1912-1954) bir çalışmasında görünür hale gelmiştir (Triantafyllou, 2024). Alan Mathison Turing, makine zekâsı hakkındaki tartışmanın fitilini, "Makineler düşünebilir mi?" sorusunu gündeme getirerek ateşlemiştir (Wikipedia, 2024). Daha sonra bu soruya cevaben Alan Turing, Turing testi olarak bilinen bir taklit oyununu önerdi. Bu oyun Şekil 1' de açıklanmıştır (Triantafyllou, 2024).



Şekil 1: Turing testi (Triantafyllou, 2024)

Turing Testi, bir grup insanın ve bir yapay zeka programının belirli bir zaman sadece yazılı iletişim yoluyla birbirleriyle sohbet ettiği bir testtir. Bu sohbet bitiminde, deneklere hangi kişinin insan, hangisinin yapay zeka olduğunu belirlemeleri için sorular sorulur. Şaşırtıcı bir şekilde, yapılan bazı testlerde, makine zekası insan olarak algılanırken gerçek insanlar makine olarak algılanmıştır (Wikipedia, 2024).

Yapay zeka, insan zekasına has görevleri yerine getirebilen bilgisayar sistemlerinin çalışmasını ve geliştirilmesini kapsar (Triantafyllou, 2024). McCulloch ve Pitts tarafından yapılan ilk yapay zekâ çalışmaları, sinir hücrelerini kullanan hesaplama modellerini ve mantıksal işlemlerin gerçekleştirilmesini kapsıyordu. Bu çalışmalar, önermeler mantığı, fizyoloji ve Turing'in hesaplama kuramına dayanmaktadır. McCulloch ve Pitts, sinir hücrelerinden oluşan ağlarla hesaplanabilir fonksiyonların gerçekleştirilebileceğini ve uygun şekilde tanımlandığında bu ağ yapılarının öğrenme becerisi kazanabileceği fikrindeydiler. Hebb'in sinir hücreleri arasındaki bağlantıları değiştirmek için önerdiği basit kural, öğrenebilen yapay sinir ağlarının ilerlemesine sağlamıştır (Wikipedia, 2024).


Yapay zeka alanındaki araştırmalar, modern dünyanın teknolojik değişimine rağmen, daha akıllı makineler yaratma hedefi etrafında hala araştırma zorluklarıyla karşılaşmaktadır. Yapay zeka altında ki temel araştırmaların katmanları Şekil 2' de gösterildiği gibidir (Triantafyllou, 2024).



Şekil 2: Yapay zekanın gelişiminin üç katmanı (Triantafyllou, 2024)

2.2. Makine Öğrenmesi

Makine öğrenimi, veri analizi ve bilgi çıkarmak için kullanılan geniş bir teori, yöntem, algoritma ve mimari yelpazesini kapsayan bir yapay zeka alt disiplini. Makine öğrenimi, dördüncü endüstri devriminin anahtarı olarak kabul edilir ve amacı bu veriden gizlenmiş bilgi ve ilgili bilgiyi çıkarmak, ardından harekete geçmek ve uygulamaya koymaktır (Chellappa, 2021). Özetle, makine öğrenmesi, verilerin kullanıldığı sistemlere, önceden programlanmamış deneyimlerden öğrenme yeteneği sağlayarak kendini geliştiren bir yapay zeka dalıdır (miesofficial.com, 2024). Bu alandaki araştırmalar, 1986 yılında makine öğreniminin bir varlık olarak tanınmasından sonra hızla gelişmiştir (Chellappa, 2021).



Şekil 3: Makine öğrenmesi (Miesofficial.com, 2024)

Makine öğrenimi, makinelerin verileri daha etkili bir şekilde işlemesini sağlamak için kullanılmaktadır. Verileri analiz ettiğimizde bazen elde edilen bilgileri yorumlamak güç olabilir. Bu durumda, makine öğrenimi teknikleri kullanılır. Zamanla artan miktarda veri, makine öğrenimi tekniklerine olan talebi de artırmaktadır. Birçok endüstri, önemli bilgileri elde etmek için makine öğrenimini kullanmaktadır. Makine öğreniminde amaç, verilerden öğrenen makinelerin açık programlanmadan kendi kendine öğrenmesini sağlamaktır. Bu nedenle, matematikçiler ve programcılar, büyük veri kümeleriyle başa

çıkarmak için çeşitli yöntemler geliştirmektedirler. Zamanla verilerin miktarındaki hızlı artış düşünüldüğünde, bu büyük veri kümesini karşılayabilecek bir sistem zorunluluk haline gelmiştir (medium.com, 2024). Makine öğrenimi, farklı problemleri çözmek için birçok algoritma kullanır. Veri bilimcileri, herhangi bir problemi çözmek için en uygun algoritmanın tek olmadığını belirtirler ve kullanılacak algoritmanın seçimi, çözülmek istenen problem ve mevcut veri seti gibi nedenlere bağlı olarak değişir (Mahesh, 2020).

Makine öğreniminin çalışma prensibi Şekil 4’te gösterildiği gibidir.



Şekil 4: Makine öğrenimi çalışma prensibi (Medium.com, 2024)

Makine öğrenmesi işlemleri için aşağıdaki adımlar sırasıyla gerçekleştirilir (miuul.com, 2024):


- 1) **Problem Tanımı:** Öncelikle hangi konuda tahmin yapılacağı belirlenir ve hangi tür gözlem verilerinin kullanılacağına karar verilir.
- 2) **Veri Toplama:** Probleme alakalı yapılandırılmış veya yapılandırılmamış veriler toplanarak bir veri seti hazırlanır.
- 3) **Veri Hazırlama:** Veriler makine öğrenimi için uygun hale getirilirken hatalı veya eksik veriler düzeltilir böylece tüm veriler aynı standart formata dönüştürülmüş olur.
- 4) **Model Seçimi:** Probleme en uygun model seçilir ve uygulanır.
- 5) **Veri Setinin Bölünmesi:** Veri seti eğitim, doğrulama ve test verileri olarak bölünür.
- 6) **Model Eğitimi:** Modelin öğrenmeye başladığı andır. Eğitim ve doğrulama verileriyle eğitilen model, test verileriyle doğrulanır.
- 7) **Değerlendirme:** Modelin performansı eğitim sonucunda değerlendirilir ve gerekli görülürse iyileştirmeler yapılır.

- 8) **Parametre Ayarlama:** Modelin performansının yükseltilmesine kanaat getirilmişse parametreler ayarlanır.
- 9) **Tahmin:** Model, eğitimde kullanılmayan farklı veri örnekleri üzerinde test edilir ve tahminler gerçekleştirilir.

Alanın uzmanları, makine öğrenimindeki son gelişmeler nedeniyle yeni öğrenme algoritmaların keşfine, teorilerin geliştirilmesine ve çevrimiçi verilerin kullanım artışı sebebiyle de düşük maliyetli hesaplamaya yönelmiştir (Jordan vd., 2015). Problem ve veri türü dikkate alındığında kullanılan makine öğrenimi teknikleri değişkenlik gösterebilir. Yaygın kullanılan makine öğrenimi tekniklerini şu başlıklar altında incelemek mümkündür (Wasnik ve Mankar, 2019):

- 1) **Denetimli veya Yönlendirilmiş Öğrenme:** Bu teknik, bilinen giriş verileri ile ilişkilendirilmiş çıktıları kullanarak bir modelin eğitildiği makine öğrenme tekniğidir. Bu teknik, sınıflandırma veya regresyon gibi belirli çıktıları tahmin etmek için kullanılır.
- 2) **Denetimsiz veya Yönlendirilmemiş Öğrenme:** Bu teknikte, eğitim verilerinde hedef çıktılar bulunmaz. Burada amaç, veriler arasındaki benzerlikleri bulmaktır. Bu tür öğrenme, örüntü tanıma veya kümeleme gibi görevlerde kullanılır.
- 3) **Yarı Denetimli Öğrenme:** Bu teknik hem denetimli hem de denetimsiz öğrenme yöntemlerini birleştirir. Etiketlenmemiş veri varsa ve etiketli veri elde etmek önemsizse kullanılır.
- 4) **Takviyeli Öğrenme:** Bu teknik, bir ajanın deneme-yanılma yoluyla öğrenme yeteneğine sahiptir. Öğrenme sistemi, geri bildirim şeklinde ödülleri veya cezaları alarak performansını geliştirir.
- 5) **Çoklu Görev Öğrenme:** Bu teknik, bir görevde elde edilen tecrübeyi diğer benzer görevlerin çözümünde kullanır.
- 6) **Topluluk Öğrenme:** Bu teknik, genellikle artan doğruluk ve güvenilirlikle sonuçlanan birden fazla model veya algoritmanın birleştirilmesiyle tahminler yapar. Bu yaklaşımla farklı hipotezlerin çıktıları birleştirilerek daha sağlam kararlar alınması mümkündür.
- 7) **Sinir Ağı:** Biyolojik sinir hücrelerinden esinlenen bu teknik, gerçek, ayrık veya vektör hedef fonksiyonlarını modellemek için kullanılır.


- 8) **Örnek Temelli Öğrenme:** Bu teknik, en yakın komşu ve yerel ağırlıklı regresyon gibi yöntemler için kullanılır. Öğrenme algoritması, örüntüleri tanımlar ve test verisiyle birlikte çalıştırır.



Şekil 5: Makine öğrenimi teknikleri (Mahesh, 2020)

2.2.1. Klasik makine öğrenmesi

Makine öğrenimi yöntemleri, çeşitli alanlardaki verilerden önemli bilgileri elde etmek için uygun bir yaklaşımdır (Maleki vd., 2020). Klasik makine öğrenimi, makine öğreniminin bir alt kümesidir. Klasik makine öğrenimi algoritmalarıysa istatistiksel teknikler kullanarak verilerdeki desenleri ve ilişkileri keşfeder. Bu algoritmalar belirli bir kapsam ve belirli bir özellik seti olan durumlarda iyi performans göstermek üzere tasarlanmıştır. Klasik makine öğrenimi, belirli bir kurala göre incelediği veri girdilerini alarak tahminler veya seçimler yapmak için kullanılabileceği desenleri ve ilişkileri oluşturur (geeksforgeeks.org, 2024). Ayrıca genelleştirilebilir ve yüksek performanslı uygulamaların geliştirilmesi de temel kavramları anlamakla ilgilidir. Klasik makine öğrenimi, denetimli ve denetimsiz öğrenme yöntemlerini içerir (Maleki vd., 2020). Denetimsiz makine öğrenimi, etiketsiz bilinmeyen giriş verilerinden sonuçlar çıkarmak için kullanılır. Bu durumda, istenen çıktı verilmez. Denetimli makine öğreniminde amaç etiketli yani tanımlanmış giriş verileriyle bir hedef özellik arasındaki ilişkiyi bulmaktır (Soofi ve Awan, 2017).



Şekil 6: Denetimli öğrenme sınıflandırma teknikleri (Soofi ve Awan, 2017)

Klasik makine öğrenimin bazı uygulamalarda kullanılan teknikleri şu şekildedir (Atalay ve Çelik, 2017):

- 1) **Görüntü ve Video Tanıma:** Karar ağaçları, rastgele ormanlar ve destek vektör makineleri gibi klasik makine öğrenme teknikleri, görüntü ve video uygulamalarında yüz tespiti, nesne tanıma gibi görevler için kullanılmıştır.
- 2) **Doğal Dil İşleme:** Duygu analizi, metin sınıflandırma ve spam filtreleme gibi doğal dil işleme uygulamalarında Naive Bayes, Logistic Regression ve Karar Ağaçları gibi klasik makine öğrenmesi yöntemleri kullanılmıştır.
- 3) **Veri Madenciliği:** Klasik makine öğrenmesi algoritmalarının birliktelik kuralları ve kümeleme gibi uygulamaları, büyük veri kümelerinde desenleri ve bağlantıları bulmak için kullanılmıştır.
- 4) **Sahtekarlık Tespiti:** Logistic Regression ve Karar Ağaçları gibi klasik makine öğrenme teknikleri, sahtekarlık tespiti uygulamalarında sahtekarlık faaliyetlerinin desenlerini tespit etmek ve kullanıcıları sahtekarlık içeren işlemler konusunda uyarmak için kullanılmıştır.
- 5) **Tıbbi Teşhis:** Karar Ağaçları ve SVM gibi klasik makine öğrenme teknikleri, tıbbi teşhis uygulamalarında birtakım hastalıkların olası durumunu belirlemek için semptom desenlerini tanımlamada kullanılmıştır.

2.2.1.1. Naive bayes

Naive Bayes sınıflandırıcısı, denetimli makine öğrenimi algoritmasıdır ve genellikle metin sınıflandırması gibi görevlerde kullanılır. Bu algoritma aynı zamanda üretken öğrenme algoritmaları grubundan olup belirli bir sınıf veya kategorideki girdilerin dağılımını modellemek üzerinedir (ibm.com, 2024). Bayes teoremine dayalı Naive Bayes sınıflandırıcısı olasılık sınıflayıcı olarak bilinir. Bu yaklaşımlar, bilinmeyen gözlemlerin sınıfını tahmin etmek için her çift özelliğe karşılık gelen sınıf etiketinden koşullu olarak bağımsız olduğunu varsayar. Yani, Naive Bayes sınıflandırıcısı, bir sınıfta tanımlı özelliklerin her birinin diğer özelliklerle ilişkili olmadığını kabul eder (Maleki vd., 2020). Naive Bayes, Bayes teoremine dayalı sınıflandırma tekniğinde tahmin ediciler arasında bağımsızlık varsayımını kullanır. Bu sınıflandırıcı, bir sınıftaki belirli bir özelliğin varlığının, diğer herhangi bir özelliğin varlığıyla ilişkili olmadığını varsayar. Naive Bayes çoğunlukla metin sınıflandırma endüstrisinde kullanılır ve şartlı olasılığa dayalı olarak kümeleme ve sınıflandırma amaçları için kullanışlıdır (Mahesh, 2020).

Naive Bayes teoremi matematiksel olarak verilmiştir (Bayes, 1968):

$$P(C|x) = \frac{P(x|C)P(C)}{P(x)} \quad (1)$$

$$P(C|x) = P(x_1|C) \times P(x_2|C) \times \dots \times P(x_n|C) \times P(C) \quad (2)$$

Naive Bayes Kod Örneği:

Giriş:

Eğitim veri seti T,

F = (f1, f2, f3..., fn) // test veri setindeki tahmin edici değişkenin değeri.

Çıktı: Test veri setinin sınıfı.

Adımlar:

- 1) Eğitim veri setini T olarak oku;
 - 2) Her sınıftaki tahmin edici değişkenlerin ortalamasını ve standart sapmasını hesapla;
 - 3) Her sınıftaki gauss yoğunluk denklemini kullanarak fi'nin olasılığını hesapla;
- Tüm tahmin edici değişkenlerin (f1, f2, f3..., fn) olasılığı hesaplanıncaya kadar bu işlemi tekrar et;

- 4) Her sınıf için olasılığı hesapla;
- 5) En büyük olasılığı al.

Naive Bayes sınıflandırıcı yöntemleri 3 farklı adımda gruplanmıştır. (scikit-learn.org, 2024):

- 1) **Gaussian Naive Bayes:** Devamlı değişkenlerle kullanılan ve Gauss dağılımlarını varsayan bir Naive Bayes sınıflandırıcı türüdür. Model, her sınıfın ortalama ve standart sapmasını hesaplayarak eğitilir.
- 2) **Multinomial Naive Bayes:** Özelliklerin çok terimli dağılımlara sahip olduğunu varsayan bir Naive Bayes sınıflandırıcı türüdür. Frekans sayıları gibi ayrık verilerle kullanılan bu sınıflandırıcı, genellikle doğal dil işlemede spam sınıflandırmasında tercih edilir.
- 3) **Bernoulli Naive Bayes:** Boole değişkenleriyle (doğru ve yanlış veya 1 ve 0 gibi iki değere sahip değişkenlerle) kullanılan bir Naive Bayes sınıflandırıcı türüdür. Bu sınıflandırıcı, özellikle metin sınıflandırması gibi belirli özelliklerin varlığını veya yokluğunu temsil etmek için tercih edilir.

Naive Bayes' in ikili ve çok sınıflı sınıflandırmalar için kullanılabilir olması, özellikle metin sınıflandırma problemlerinde (spam e-posta sınıflandırması gibi) yaygın olarak başarıyla kullanılması hem küçük hem de büyük veri kümeleri üzerinde kolay ve hızlı eğitilebilir olması avantajlarıdır. Ancak, Naive Bayes' in önemli dezavantajı, özelliklerin tümünü birbirinden bağımsız olarak farz etmesi, bu durumda özellikler aralarındaki ilişkiyi öğrenemez (medium.com, 2024). Naive Bayes sınıflandırıcısının çeşitli uygulamaları, spam filtreleme, belge sınıflandırması, duygu analizi ve zihinsel durum tahminleri gibi alanlarda mevcuttur. Bu uygulamalar, büyük hacimli verileri işleyerek kullanışlı bilgilere dönüştüren veri madenciliği algoritmalarının bir parçasıdır. Özellikle spam filtreleme ve belge sınıflandırması gibi alanlarda etkili olan Naive Bayes, metin sınıflandırması ve duygu analizi gibi işlemlerde yaygın kullanılmaktadır. Ayrıca, fMRI verileri gibi beyin aktivitesi verileriyle yapılan zihinsel durum tahminleri gibi araştırmalarda da bu algoritma etkili bir şekilde kullanıldığı görülmüştür (Mitchell vd., 2002).

2.2.1.2. Logistic regression

Analiz için en yaygın kullanılan doğrusal sınıflandırıcılardan Logistic Regressionun kullanımı basit ve açıktır. Verilerin işlenmesi amacıyla ikili sınıflandırma ve tahminlemede kullanımı yaygındır. Logistic Regression, doğrusal regressiona benzer olarak çoklu değişkenlerin arasındaki ilişki modellemek için kullanılır (Kanjanasurat vd., 2023). Bu istatistiksel model genellikle sınıflandırma ve tahmine dayalı analizler için kullanılır. Logistic Regression, bağımsız değişkenlerin belirli bir veri kümesine dayalı olarak belirli bir olayın gerçekleşme olasılığını tahmin eder. (Nick ve Campbell, 2007).

Logistic fonksiyonun tanımının matematiksel ifadesi (Kanjanasurat vd., 2023):

$$\rho(y) = \frac{1}{1+e^{-f(x)}} \quad (3)$$


$$\rho(y) = \frac{1}{1+e^{-(b_0+b_1x)}} \quad (4)$$

$$\rho(y) = \frac{e^{b_0+b_1x}}{1+e^{b_0+b_1x}} \quad (5)$$

$\rho(y)$, ilgili bir durumun olasılığını, $f(x)$ tahmin fonksiyonunu, x bağımsız bir değişkeni ifade ediyor. Trafik akış verilerinde 4 giriş bulunmaktadır. Bu bilgilerin, lojistik denklemin belirli bir durumun olasılığını tahmin etmek için kullanımı:

$$\rho(y) = \frac{e^{b_0+b_1x_1+b_2x_2+b_3x_3+b_4x_4}}{1+e^{b_0+b_1x_1+b_2x_2+b_3x_3+b_4x_4}} \quad (6)$$

Logistic fonksiyonunun eğri grafiği şekil 7’ de verilmiştir:



Şekil 7: Logistic fonksiyonun eğrisi (Kanjanasurat vd., 2023).

Sonuç olarak Logistic Regression, kategorik bir bağımlı değişkenin çıktısını tahmin etmek için kullanıldığından sonuç kategorik veya ayrık bir değeri olmalıdır, yani evet veya hayır, 0 veya 1, doğru veya yanlış gibi. Logistic Regression, tam değeri 0 ile 1 arasında kalan olasılık değeri tahminler. Bu yöntemde, regresyon çizgisi yerine "S" şeklinde bir lojistik fonksiyon ifade edilir. Bu, iki maksimum değeri (0 veya 1) tahmin eden bir eğri oluşturur (geeksforgeeks.org, 2024).

Kategorik olarak, Logistic Regressionun çeşitleri ise şu şekildedir (Nick ve Campbell, 2007):

1) **İkili Logistic Regression:** Bu yöntem, iki olasılıktan (örneğin, 0 veya 1) oluşan yanıt ve bağımlı değişkene dayanır. Logistic Regression, bu türde en çok kullanılan yaklaşımdır ve ikili sınıflandırma için temel bir yöntemdir.


2) **Çoklu Logistic Regression:** Bu tür bir modelde, bağımlı değişkenin belirli bir sıraya sahip olmayan üç veya daha fazla olasılık tahmini vardır.

3) **Sıralı Logistic Regression:** Bu model, yanıt değişkeninin tanımlanan sıraya sahip üç veya daha fazla olasılık tahmini vardır.

2.2.1.3. Destek vektör makinesi-svm


Makine öğrenimi, yapay zekânın bir alt disiplindir ve bilgisayarın öğrenmesini sağlayan tekniklerin geliştirilmesi üzerinedir. Destek Vektör Makinesi, 1992' de Boser, Guyon ve Vapnik tarafından açıklandı. Destek Vektör Makinesi, sınıflandırma ve regresyon için kullanılan bir grup ilişkili öğrenme tekniğidir (Boser vd., 1992). Destek Vektör Makinesi, tahminlemede doğruluğu maksimum seviyeye ulaştırmak ve verilere aşırı uyumu önlemek için makine öğreniminden yararlanır. Bu teknik, yüksek boyutlu özellik uzayında doğrusal fonksiyonlarla ilişkilendirilen sistemlerdir. Destek Vektör Makinesinin temelleri Vapnik tarafından atılmış ve kullanım alanları nedeniyle ünlüdür. Destek Vektör Makinesi, başlangıçta sınıflandırma problemlerini hedef alsa da daha yakın zamanlarda regresyon problemleri için de uyumlanmıştır. Destek Vektör Makinesi istatistiksel öğrenmede genelleme yeteneğiyle diğer yöntemlerden ayrılır (Jakkula, 2006). Destek Vektör Makinesi, karar sınırına en yakınında konumlanmış veri noktalarıdır. Destek Vektör Makinesi, geniş boyutlu bir uzaydaki hiper düzlemdeki veri vektörlerinin sınıflandırılması işlemini yapar. Yüksek marj sınıflandırıcısı, ikili sınıflandırmada doğrular şeklinde ayrılabilen eğitim verilerinin sınıflandırma problemini belirlemede

kullanılan Destek Vektör Makinesinin en basit şeklidir. Destek Vektör Makinesinin önemli avantajlarından biri, boyutu yüksek ve doğrular şeklinde ayrılamayan problemleri çözümlemedeki başarısıdır. Destek Vektör Makinesinin başlıca dezavantajıysa, kusursuz sınıflandırma sonuçlarını bulmak için bir dizi önemli parametreye uygun ayarlamalar yapmak gereksinimidir (Soofi ve Awan, 2017).



Şekil 8: Destek vektör makineleri (Mahesh, 2020).

Destek Vektör Makinesinin işleyişi, en iyi hiper düzlem olarak en büyük ayrımı veya marjı temsil eden seçimi yapmaktır. Birden fazla hiper düzlemin, verileri iki sınıfa bölmesi şekil 9’ da gösterilmiştir (Boser vd., 1992).




Şekil 9: Birden fazla hiper düzlemin verileri iki sınıfa bölmesi (Geeksforgeeks.org, 2024).

Destek Vektör Makineleri, veri sınıflandırma kullanılan bir yöntem olup nöral ağlara göre bazen daha başarılı sonuçlar verebilir. Bir sınıflandırmada, genellikle eğitim ve test verileri bulunur. Eğitim setindeki her örnek için, bir hedef değer ve birden fazla

öznitelikte mevcuttur. Destek Vektör Makinelerinin amacı, öznitelikleri verilen test setindeki veri örneklerindeki etiketi tahminleyen modeli oluşturmaktır. Özellik seçimi ve Destek Vektör Makinesi sınıflandırması, etiketlenmemiş örneklerin sınıflarını bulmada ve önemli özelliklerini belirlemekte uygulanabilir (Jakkula, 2006).

2.2.1.4. Yapay sinir ağları

Bilgisayar yazılımı olan yapay sinir ağları, insan beyninin öğrenme aşamalarını kopyalayarak öğrenme, hatırlama, genelleme gibi ana fonksiyonları yerine getirirler. İlk kez 1943 yılında Warren McCulloch ve Walter Pitts'ın birlikte tasarladığı bu yapay ağlar, biyolojik sinir ağlarını taklit eden sentetik yapılar olarak kabul edilirler. Ayrıca, bu ağlar paralel dağıtılmış ağlar, bağlantılı ağlar ve nöromorfik ağlar gibi farklı isimlerle de anılırlar (Öztürk ve Şahin, 2018). Yapay sinir ağlarında öğrenme aşamaları ara katmanlarda yer alır (smartmind.com.tr, 2024).



Şekil 10: Biyolojik sinir hücresi ve yapay sinir ağı (Maltarollo, 2013).V

Belli başlı fonksiyonlarının doğrusallıktan uzak olma, paralel çalışma, öğrenme, genelleme, hata toleransı ve esneklik, eksik verilerle çalışabilme, çok sayıda değişken ve parametre kullanabilme, uyarlanabilirlik özellikleridir. Yapay sinir ağları, tahmin, sınıflandırma, veri ilişkilendirme, veri yorumlama ve veri filtreleme gibi birçok alanda kullanılmaktadır, örneğin, altın ons fiyatının tahmini, veri filtreleme, sınıflandırma ve veri yorumlama gibi işlemlerde büyük öneme sahiptir (Öztürk ve Şahin, 2018). Yapay sinir

ağları, görüntü tanıma, doğal dil işleme ve karar verme gibi amaçlar için kullanılmaktadır (hosting.com.tr, 2024). Yapay sinir ağlarının eğitimi, sinir hücrelerini birbirine bağlayan sinapsislerin ağırlıklarının belirlendiği bir süreçtir. Ağırlıklar eğitim sırasında değiştirilerek ağı performansı yükseltilir. Eğitim genellikle gözetimli, gözetimsiz veya yarı gözetimli yöntemlerle gerçekleştirilir. Gözetimli eğitimde, insan müdahalesiyle ağırlıklar belirlenirken, gözetimsiz eğitimde ağırlıklar otomatik olarak belirlenir. Her iki durumda da sinir ağının doğruluğu sürekli olarak test edilir ve başarıya ulaşana kadar eğitim devam eder. Ancak bazı durumlarda, hatalı tasarlanmış bir yapay sinir ağı eğitimi başarıya ulaşmayabilir ve tasarımın yeniden gözden geçirilmesi gerekebilir. Eğitim süreci boyunca sinir ağının doğruluğunun sürekli olarak sınanması önemlidir ve başarıya ulaşıldığında eğitim tamamlanır (bilgisayarkavramlari.com, 2024). Yapay sinir ağları, öğrenme ve veri tabanlı tahmin yetenekleriyle, özellikle görüntü tanıma, örüntü tanıma ve sınıflandırma gibi görevler için elverişlidir. Bu ağların temel avantajlarından bazıları, verilere dayalı öğrenme yetenekleri ve tahminlerde bulunma yetenekleridir. Diğer yapay zeka türleriyle karşılaştırıldığında, yapay sinir ağları, geçmiş verilerden öğrenme yetenekleri nedeniyle daha kullanışlıdır. Dezavantajları ise gürültülü verilere duyarlı olmaları ve özellikle büyük veri kümeleriyle uğraşırken eğitimlerinin yavaş olmasıdır. Yine de yapay sinir ağları, birçok gerçek hayattaki problemleri çözmek için etkili bir araç olarak kabul görmektedir (clickworker.com, 2024).

Yapay sinir ağları, temelde beş ana kategoride incelenebilir (geeksforgeeks.org, 2024):


- 1) **İleri Beslemeli Sinir Ağı (İBSA):** Verilerin tek bir yönde hareket ettiği yapay sinir ağı türüdür. Giriş katmanından alınan veriler, gizli katmanlar aracılığıyla işlenir ve çıkış katmanından sonuç elde edilir. Geri yayılım mekanizması bulunmaz.
- 2) **Evrişimli Sinir Ağı (ESA):** Görüntü ve ses tanıma gibi görevler için kullanılan yapay sinir ağı türüdür. Evrişim işlemi kullanarak girdi verisinden özellikleri çıkarır ve ardından bu özellikleri işleyerek çıktı elde eder.
- 3) **Modüler Sinir Ağı:** Bağımsız çalışan farklı sinir ağlarının bir araya gelerek karmaşık hesaplamaları küçük bileşenlere ayırdığı bir yapay sinir ağı türüdür.
- 4) **Radyal Tabanlı Fonksiyon Sinir Ağı (RTFSA):** Bir noktanın merkezden olan mesafesine ilişkin fonksiyonları kullanır. Genellikle verilerdeki temel eğilimleri modellemek için kullanılır.

- 5) **Tekrarlayan Sinir Ağı (TSA):** Bir katmanın çıktısını hatırlayarak bir sonraki adımda uygulayan zaman serilerine benzer şekilde sürekli verileri işlemek için kullanılır.

2.2.2. Derin öğrenme

2006 yılında makine öğrenimi alanında desen tanıma gibi birçok araştırma konusuyla ilgili yeni bir kavram olan Derin öğrenme uygulaması kendinden söz ettirmiştir (Vargas vd., 2017). Derin öğrenme, insan beyninin korteksine benzerlikte işlevi olan modern bir sinir ağı tabanlı tekniktir. Yapay zekanın bir türü olan derin öğrenmenin amacı, bilgisayar programlarının veri analizi ve öğrenme süreçlerini geliştirmektir. Bu yöntem, çok katmanlı sinir ağlarını kullanarak verilerin içerdiği karmaşıklığı çözümlmek ve temsil ettiği anlamı öğrenmek üzerine programlanmıştır (Sunitha, 2021).

Yapay zeka alanındaki sinir ağı modellerinin işleyişi Şekil 11’ de verilmiştir.



Şekil 11: Yapay zeka alanındaki sinir ağı modellerinin işleyişi (Ncbi.nlm.nih.gov, 2024)

Sinir ağı modelleri, sinyalleri nöronlara benzer düğümler aracılığıyla ileterek çalışır. Bu sinyaller, sinaptik bağlantıların analogları olan bağlantılar boyunca düğümden düğüme geçer. Öğrenme, her bağlantının taşıdığı sinyalleri yükselten veya sönmöleyen ağırlıkları ayarlayarak sonucu iyileştirir. Düğümler genellikle kortekste farklı işlem

merkezlerine benzeyen bir dizi katman şeklinde sıralanır. Bugünün bilgisayarları, çok fazla katmana sahip Derin öğrenme ağlarını işleyebilecek kadar güçlüdür. Görselin sanatçısı Lucy Reading-Ikkanda' dır (ncbi.nlm.nih.gov, 2024).

Derin öğrenme çalışmaları genellikle üç kategoride incelenebilir (Deng ve Yu, 2014):

- 1) **Denetimsiz veya üretilen öğrenme için derin ağlar:** Bu tür derin ağlarda, hedef sınıf etiketleri hakkında bilgi olmadan gözlemlenen veya görülebilen verinin yüksek dereceli ilişkilerini bulmaya odaklanılır. Desen analizi veya sentez amacıyla görülebilir veri hakkındaki yüksek seviyedeki ilişkileri bulmada kullanılır.
- 2) **Denetimli öğrenme için derin ağlar:** Bu tür derin ağlar, desen sınıflandırması için doğrudan ayırt edicidir. Hedef etiket verileri vardır ve bu verilere dayanarak öğrenmeyi gerçekleştirir.
- 3) **Hibrit derin ağlar:** Bu yaklaşım, genellikle daha etkili sonuçlar elde etmek için, üretken veya denetimsiz derin ağların sonuçlarıyla önemli ölçüde desteklenen ayırt ediciliği hedeflemektedir. Bunun için denetimli öğrenme için tasarlanmış derin ağların en iyi optimizasyonunu veya düzenlenmesini gerçekleştirir.


Günümüzde derin öğrenme uygulamaları, ürün ve hizmetlerin içine öyle bir entegre edilmiştir ki, kullanıcılar genellikle bu karmaşık veri işleme aşamalarını bilmemektedir. Örneğin, kolluk kuvvetleri derin öğrenme algoritmalarını kullanarak dolandırıcılık veya suç faaliyetlerini belirleyebilir. Finans kurumları, hisse senetleri için algoritmik ticaret, kredi risklerini değerlendirme, dolandırıcılığı tespit etme ve müşteri portföylerini yönetme gibi birçok faaliyette derin öğrenme teknolojisinden faydalanırken, müşteri hizmetleri chatbotlar aracılığıyla müşteri etkileşimlerini özelleştirerek yönetebilir. Sağlık sektöründe tıbbi görüntüleme uzmanlarını desteklemek ve hastalıkları daha çabuk teşhis etmekte derin öğrenme uygulamalarını kullanmaktadır (ibm.com, 2024).

2.2.2.1. Tekrarlayan sinir ağları (recurrent neural network- rnn)

1990' dan günümüze RNN' ler, geleneksel sinir ağlarının kısıtlı bellek problemini çözmek için tasarlanmıştır (scholarpedia.org, 2024). RNN' ler geri bildirimli bir döngü içeren tipik bir ileri beslemeli sinir ağı sinir ağı olarak tanımlanabilir (Vennerød vd.,


2021). Bu döngüsel yapı sayesinde, özellikle zaman serileri gibi dinamik veri türlerinde daha verimli sonuçlar elde edebilirler (scholarpedia.org). RNN' ni farklı yapan, özel bir zaman diliminde belirli veri değerinin belirli bir süre önceki değerine bağlantılı olmasıdır. Bu nedenle, RNN' ler eski ve yeni arasındaki bağlantıyı kurarak gelecek öngörüsünde kullanılabilirler. Geri beslemeli sinir ağları (RNN 'ler), nöronların gizli değişkenler aracılığıyla eski verilerin kayıt altına almasını sağlayan mimarisi ile ön plana çıkar. RNN' ler, eski veriyle ilişkili envanteri koruyarak ve bu envanteri gelecek bağlantı noktalarında işleyerek zaman serilerinden elde edilen bilgileri öngöründe bulunmak için ortamı oluştururlar. Böylece zaman serileri gibi sabit olmayan değişkenli veri çeşitlerinde daha verimli bir şekilde çalışabilirler (Vennerød vd., 2021).

RNN, sıralı veriler için uygun olanıdır ve esneklikleri sayesinde farklı girdi/çıkış uzunluklarını uygulayabilir. Ana belleği sayesinde geçmiş verilerle güncel veriler bir arada geçmiş durumu kullanarak mevcut durumun işlemini gerçekleştirebilir. Bu özellikler RNN' lere, özellikle metin çevirisi gibi işlemlerde diğer algoritmalarla karşı üstünlük sağlayabilir (medium.com, 2024). RNN' nin açık hali aşağıdaki gibidir;



Şekil 12: Rnn açık gösterimi (Vennerød vd., 2021)

RNN' in çeşitleri One to One RNN, One to Many RNN, Many to One RNN ve Many to Many RNN Şekil 13' te gösterilmiştir.



Şekil 13: Rnn' in türleri (Medium.com, 2024)


RNN' lerde, kaybolan veya aşırı büyüyen gradyanlar önemli bir problem teşkil eder, matris çarpımı esnasında küçük değerlerin gradyanın küçülerek kaybolmasına yol açabilir. Bu engeli aşmak amacıyla LSTM birimleri geliştirilmiş ve geleneksel RNN' leri geçmek için kullanılmıştır. LSTM' ler, kaybolan gradyan sorununu ele almak üzere tasarlanmış ve genellikle daha iyi performans sergilemektedir. Bu yapılar özellikle uzun vadede bağımlılıkları koruduğu gerekçesiyle öncelik görülmüş ve RNN' lerin bütünsel verimliliğini pozitif etkilemiştir. Kaybolan veya aşırı büyüyen gradyanlar, LSTM' lerin ilgi çekerek derin öğrenme modellerinde istikrarlı eğitime olanak sağlamıştır (Schmidt, 2019).

2.2.2.2. Uzun kısa süreli bellek (long short-term memory- lstm)

Uzun Kısa Süreli Bellek (LSTM), RNN' lerdeki kaybolan gradyan problemini çözmeyi hedefleyen bir tekrarlayan sinir ağıdır. Diğer sıra öğrenme modelleriyle kıyaslandığında, aralık uzunluğuna etkisizliği avantajıdır. Konuşma tanıma, el yazısı tanıma, makine çevirisi, robot kontrolü, video oyunları ve sağlık hizmetleri gibi birçok uygulamada yüksek hassasiyetle zaman serilerine dayalı verilerin sınıflandırılması, işlenmesi ve tahmini için yöntem sunar (en.wikipedia.org, 2024).

RNN' e paralel olan LSTM mimarisi, yinelenen hücreler LSTM hücreleriyle değiştirilir ve uzun süreli bilgiyi korumak için yapılandırılmıştır. Her LSTM hücresi, bir önceki çıktıyı tekrarlayanın yanı sıra uzun vadeli belleği temsil eden bir hücre durumu (ct) da korur. Bu nedenle, LSTM' ler kısa vadeli (gizli durum ht) ve uzun vadeli belleğe (hücre durumu ct) erişim sağlarlar, böylece önemli bilgi ve gradyanların ilerleyişini sürdürürler (Vennerød vd., 2021).

LSTM, ardışık yapıların birleşimi olan ve üç temel kısımdan oluşan bu yapılar: unutmama, giriş ve çıkış tabakalarıdır. Unutmama tabakası, gelen bilginin hatırlanıp hatırlanmayacağını, giriş tabakası bellekte hangi bilgilerin saklanıp saklanmayacağını tespit ederken çıkış tabakası ise hangi bilgilerin çıktı olarak kullanılacağını tespitini yapar. Bu etkileyici birimler, sigmoid fonksiyonu ve bir nokta çarpım işlemiyle bilginin ilerleyişini belirler (Kara, 2019).



Şekil 14: Lstm mimari yapısı (Xiao ve Yin., 2019)

Şekil 14’ de verilen Uzun Kısa Süreli Bellek (LSTM) mimarisi temelde unutma, giriş ve çıkış olmak üzere 3 tabakasında meydana gelen süreç aşağıdaki gibi tanımlanmıştır (Yılmaz ve Orman, 2021).

LSTM algoritmasının ilk aşama giriş olarak X_t ve h_{t-1} değerlerini alır ve hangi bilgilerin silineceğini seçer. Bu işlemler unutma tabakasında (f_t) Eşitlik (7) ile gerçekleştirilir. Burada aktivasyon fonksiyonu, sigmoid fonksiyonudur.

$$f_t = (W_{f,x} * X_t + W_{f,h} * h_{t-1} + b_f) \quad (7)$$

İkinci aşamada güncel bilgilerin seçildiği giriş tabakası devrededir. Önce (i_t) Eşitlik (8) ile sigmoid fonksiyonu aracılığıyla bilgiler yenilenir. Sonrasında Eşitlik (9) ile güncel bilgiyi oluşturacak aday bilgiler tanh fonksiyonu aracılığıyla seçilir.

$$i_t = (W_{i,x} * X_t + W_{i,h} * h_{t-1} + b_i) \quad (8)$$

$$\tilde{C}_t = \tanh(W_{c,x} * X_t + W_{c,h} * h_{t-1} + b_c) \quad (9)$$

Eşitlik (10) ile güncel bilgiler hazırlanır.

$$C_t = C_{t-1} * f_t + i_t * \tilde{C}_t \quad (10)$$

Sonuç olarak çıkış tabakasında Eşitlik (11) ve (12) ile çıktı değerleri hesaplanır.

$$o_t = (W_{o,x} * X_t + W_{o,h} * h_{t-1} + b_o) \quad (11)$$


$$h_t = o_t * \tanh(C_t) \quad (12)$$

Yukarıda açıklanan bu süreç devam ederek tekrarlanırken, ağırlık parametreleri (W) ve bias parametreleri (b) gerçek eğitim verileri ile LSTM çıktıları arasındaki farkı en aza indirmek için öğrenir (Yılmaz ve Orman, 2021).

LSTM' lerin zamansal verilere hâkim olma becerisi, LSTM mimarisinin çeşitli varyasyonlarının farklı alanlarda ve çeşitli uygulamalarda kullanılmasının doğal bir sonucudur (Vennerød vd., 2021).

2.2.2.3. Geçitli tekrarlayan birimler (gated recurrent units- gru)

LSTM' nin bir varyantı olarak bilinen GRU (Gated Recurrent Unit), 2014' te Cho ve diğerleri tarafından sunulan bir tekrarlayan sinir ağı (RNN) türüdür. GRU, standart bir rekürrent sinir ağının karşılaştığı kaybolan gradyan sorununu çözmek için geliştirilmiştir (Cho vd., 2014). Bir GRU birimi, güncelleme kapısı, sıfırlama kapısı ve giriş kapısı olmak üzere üç ana bileşenden oluşur. Bu kapılar, geçmişten gelen bilgiyi seçerek güncellenmesine ve işlenmesine izin vererek, GRU' nun uzun vadeli bağımlılıkları yakalayabilmesini sağlar. Şekil 15' de bir GRU mimarisinin yapısı gösterilmiştir. (Shiri vd., 2023).



$$z_t = \sigma(W^z x_t + V^z h_{t-1} + b^z)$$

$$r_t = \sigma(W^r x_t + V^r h_{t-1} + b^r)$$

$$\bar{h}_t = \tanh(W^c x_t + V^c (r_t \cdot h_{t-1}))$$

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \bar{h}_t$$

Şekil 15: Gru mimarisi (Shiri vd., 2023)

Bu kapılar, eğitim verilerinde hangi bilgilerin saklanması veya atılması gerektiğini öğrenerek, ilgili bilgileri uzun zaman aralıklarında kullanarak tahminlerde bulunabilirler. Günümüzde, RNN tabanlı birçok ileri teknoloji sonuç, genellikle LSTM 'ler ve GRU' lar ile elde edilmektedir. Ayrıca, LSTM' ler ve GRU' lar konuşma tanıma,


metin oluřturma gibi eřitli uygulamalarda ve hatta videolar iin altyazı oluřturmakta bile kullanılabilmektedir (Demirci ve Karaatlı, 2023).

2.3. Doęal Dil İřleme (NLP)

Doęal dil iřleme (NLP), makine sistemlerinin insan dillerini analiz ettięi, anlamaya alıřtıęı veya rettięi bir disiplindir. NLP, İngilizce, Japonca, İtalyanca veya Rusa gibi birok insan dilini iřleme amacındadır. Girdi metni, konuřma veya klavye giriři ile gerekleřtirilirken NLP' nin grevleri arasında, metni bařka bir dile evirme, metin ierięini anlama, veri tabanı oluřturma veya zetleme, hatta kullanıcıyla etkileřim kurarak diyalog gerekleřtirme olabilir. NLP' nin asıl zorluęu, problem seviyelerinin her birinde yaygın olan belirsizliktir. Basit kelimelerdeki anlam belirsizlięi, yapısal veya sentaktik belirsizlik, anlamsal belirsizlik, sylem belirsizlięi ve referans belirsizlięi gibi farklı trlerde belirsizlikler mevcuttur. Tm bu belirsizlik trleri etkileřime girebilir ve son derece karmařık bir yorumlama sreci retebilir (Chopra vd., 2013). Doęal dil iřleme, genellikle sesli anlatımların yazılı metinlere dnřtrlmesiyle bařlar ve daha sonra bu metinler iřlenir. Bu alıřmalar, kelime bilimi, szdzimsel analiz, anlamsal analiz ve sylem analizi olmak zere drt temel seviyede incelenir. Kelime bilimi, kelimelerin manalarını arařtırarak bařlangı yapar; szdzimsel analiz, cmlelerdeki kelime dzenlerini dikkate alır; anlamsal analiz, kullanılan cmlelerin manalarını deęerlendirir ve sylem analizi, bir konuřma esnasında kullanılan kelimeler ve manalarıyla ilgilenir (Seker, 2015).

Doęal Dil İřleme (NLP), insanlar ve makineler arasındaki haberleřmeyi geliřtirerek iř performansını iyileřtirir ve bilginin etkileřimini kolaylařtırır. Bu alanda yapılan gncel ilerlemeler bu aıdan olduka nemlidir. NLP' nin kullanıldıęı eřitli alanlar arasında kiřisel asistanlar gibi uygulamalar yer alır. Bu uygulamalar, teknolojinin gnlk yařamımızdaki etkisini artırırken, iletiřimi ve bilgi akıřını daha verimli hale getirir. Sonu olarak, doęal dil iřleme (NLP), makinelerin insan dillerini anlamasına ve retmesine yardımcı olan bir disiplindir. Bu, insanlarla makineler arasındaki diyalogu ykseltirken iř verimlilięini ve bilgi alıřveriřini kolaylařtırır (geeksforgeeks.org, 2024).

NLP' nin bir metni veya konuşmayı anlamak ve cevaplamak için bilgisayar sistemleri kullanarak nasıl işlediğini gösteren diyagram Şekil 16' da gösterilmiştir (Chopra vd., 2013).



Şekil 16: Doğal dil işleme (Chopra vd., 2013)

Yukarıda NLP' nin temsili diyagram şeklinin Doğal Dil Anlama (Understanding), girişin doğal dil olduğu ve kavrandığı bölgeyi, NLP' nin bir alt disiplini olan Doğal Dil Üretimi (Generation) yazılı içerik oluşturmada kullanılan kısmı göstermektedir (Chopra vd., 2013).

NLP' nin beş adımı sırasıyla şöyledir (Totade vd., 2023):

- 1) **Leksikal veya Morfolojik Analiz:** NLP' nin başlangıcıdır. Kelimelerin yapısının incelendiği ve bir dildeki kelimelerin koleksiyonun analiz edildiği kısımdır. Analiz, kelimeleri paragraflara, ifadelere, kelimelere veya karakterlere ayırarak leksikona ayrılmasıdır.
- 2) **Sözdizimsel Analiz:** NLP' nin bu ikinci kısmında, dilbilgisi denetlenir, sözcüklerin düzeni ve bağlantıları belirlenir. Cümlede yer alan sözcükler ve anlatım biçimleri incelenir ve birbirleri arasındaki ilişki değerlendirilir.
- 3) **Anlamsal Analiz:** Anlamı çözmek için yapılan NLP' nin bu üçüncü aşamasında kelimelerin ve cümlelerin tanımları araştırılır. Kelimelerin organizasyonu ve cümlelerin anlamlı olup olmadığı belirlenir.
- 4) **Söylem Entegrasyonu:** Cümlelerin metinsel bütünlüğünün göz önüne alındığı NLP' nin bu dördüncü aşamasında, cümlelerin daha geniş bir bağlama yerleştirilmesi ve uygunluğunun sağlanması önemlidir.

- 5) **Pragmatik Analiz:** NLP' nin bu son aşamasında, diğer dört aşamalardan gelen bilgilerin entegrasyonunu gerçekleştirilir ve dilin nasıl uygulandığını anlamak için tercümesi yapılır.

Doğal Dil İşleme (NLP), bugün birçok alanda geniş kullanımı olan tekniktir. NLP' nin örnek kullanım alanları arasında aşağıda sunulanları içermektedir (Seker, 2015):

- Soru Cevaplama: Yazı analizi, metinleri derinlemesine inceleyerek anlamlı soruların ve cevapların çıkarılmasını sağlayan önemli bir yöntemdir.
- Otomatik Tercüme: Diller arası iletişimi kolaylaştıran teknolojik bir yöntemdir.
- Bilgi Getirme: Bilgi getirme, belirli bir konu hakkında istenen bilginin yazılı kaynaklardan araştırılarak bulunması ve edinilmesi sürecidir.
- Sözcük İşleme: Yazılı metinlerdeki yazım hatalarının kontrol edilmesi, düzeltilmesi ve belirli sözcüklerin bulunması gibi önemli faaliyetleri kapsayan bir süreçtir.
- Doğal Dil İşleme-Veri Tabanı Arayüzü: Geleneksel sorgulama yöntemlerinden farklı olarak, kullanıcıların doğal dilde sorular sormasına olanak tanıyan bir teknolojidir.
- İnternet Arama Motorları: Kullanıcıların internet üzerinde doğal dilde arama yapmalarını sağlayan ve istenilen bilgilere hızlı erişimi gerçekleştiren önemli bir teknolojidir.
- Yapay Zeka Botları: Kullanıcılarla sohbet ederken doğal dilde soruları cevaplayan ve bunun için arama yapabilen yapay zeka destekli sistemlerdir.
- Metin İşleme: Metinlerin kategorize edilmesi, bölünmesi ve kümeleme işlemlerinin gerçekleştirilmesi.
- Finansal Raporlama, Sohbet Odaları ve Telefon Cevaplama: Modern dünyada büyük miktarda metin verisinin analiz edilmesi ve anlamlı içgörüler elde edilmesi için kullanılan teknolojidir.
- İnternet Bilgi Deposu: Milyarlarca web sitesi, belge, veri tabanı ve diğer kaynakları içeren geniş bir bilgi ağıdır.
- Metin Özetleme: Büyük bilgi yığını içinde aradığımız bilgilere ulaşmak ve bunları etkili bir şekilde anlamak kullanılan bir tekniktir.

Bu alanlarda doğal dil işleme teknolojilerinin kullanımı, bilgiye erişimi ve işleme süreçlerini kolaylaştırmak için önemli bir rol oynamaktadır (Totade vd., 2023).


2.3.1. Duygu analizi (sentiment analysis)

Duygu analizi, kullanıcıların duygularını veya görüşlerini tespit etmek, açıklamak veya sınıflandırmak için kullanılmaktadır. Bu, filmler, ürün hataları, aktiviteler veya rastgele özelliklerden birinin olumlu, olumsuz veya nötr olduğunu belirlemeyi içermektedir. Bu tür analiz için kaynaklar, incelemeler, forum tartışmaları, bloglar, mikro bloglar, X gibi sosyal iletişim kanallarında bulunan web sitelerini kapsamaktadır. Popülerleşen bu alan araştırmacıların kullanıcıların günlük yaşamlarında faydalı olabilecek hizmetler hakkında incelemelerde bulunmasına sebep olmuştur (Mehta ve Pandya, 2020). Duygu analizi günümüzde araştırmacıların yanı sıra firmalar, devletler ve vakıflar tarafından yaygın kullanıma uygun görülmüştür (Sánchez-Rada ve Iglesias 2019). Yaygınlaşan internet ile web, küresel veri deposu olarak öne çıkmıştır. Kullanıcılar, düşüncelerini ve görüşlerini ifade etmek için farklı çevrimiçi bilgileri kullanmaktadır. Halkın fikirlerini düzenli olarak takip etmek ve karar verme süreçlerine katkıda bulunmak için kullanıcı üretimi verileri sistematik olarak değerlendirmek önemlidir. Bu nedenle, duygu analizi son yıllarda araştırma camiasında ün kazanmıştır. Duygu analizi ayrıca Görüş analizi veya Görüş madenciliği olarak da kabul edilir. Son zamanlarda bu alandaki ilerleme kayda değerdir. Duygu analizi konusundaki çeşitli araştırmalarda bu ilerlemeyi desteklemekte ve bu alandaki çalışmaların önemini vurgulamaktadır (Ligthart vd., 2021).

Sosyal ağ sitelerinin genişlemesi, bu platformları ve içeriklerini incelemek ve gerekli bilgileri çıkarmak için türlü alanlara yol açmıştır. Duygu analizi, bir metnin içeriğinden aktarılan duyguları tespit süreciyle ilgilidir. Duygu analizi, doğal dil işleme (NLP) alanının bir alt dalıdır ve uzun ve tanınmış bir halka açık görüş kararları ele alındığında, bu konuda yapılmış birçok temel çalışma vardır. Ancak, duygu analizi, yeni milenyum kadar gelişimini devam ettirmektedir (Wankhade vd., 2022).

Görüş madenciliğinin temeli olan duygu analizi, metinleri öznel ya da nesnel sınıflandırır. Güncel çalışmalar, amaca uygun yöntemleri bulmak için hem denetimli hem de denetimsiz öğrenme tekniklerini kullanmaktadır. İlk araştırmalar incelendiğinde denetimli öğrenme yöntemlerinden destek vektör makinesi, maksimum entropi, naive bayesin tek başına ya da bir arada kombine edilerek kullanıldığı, denetimsiz öğrenme yöntemlerinden ise duygu sözlüklerinden yararlanma, gramatik analiz, sözdizimsel kalıpların kullanıldığı görülmektedir. Sonuç olarak, Duygu Analizi, metinlerdeki

duyguları sınıflandırarak öznellik ya da nesnellik gibi farklı görevleri sebebiyle duygu eğilimini belirlerken cümlelerin nötr, negatif veya pozitif ayrımını da yapmaktadır (Mehta ve Pandya, 2020).



Şekil 17: Duygu analizinin genel işleyişi (Wankhade vd., 2022)

Duygu analizi bağlamında TF-IDF, terimlerin önemini anlamak için kullanılabilecek ve duygusal içeriğin belirlenmesine katkı sağlayabilecek bir tekniktir.

TF-IDF, metin verilerindeki her kelimenin önemini belirlemek için kullanılan bir yöntemdir ve kelimenin bir belgedeki frekansı ile tüm belgelerdeki frekansı arasındaki orantısızlığı ölçer. Bu şekilde, her kelimenin belirli bir belgedeki önemi vurgulanır ve metin verileri sayısal vektörlere dönüştürülür (Liu vd., 2018).

Duygu analizinde kullanılan TF- IDF (Term Frequency- Inverse Document Frequency) formülü şu şekildedir (Jones, 2004):

t: İlgilenilen kelime veya terim

d: Belge içindeki kelime veya terimin sıklığı

D: Tüm belgelerin toplamı

TF (Term Frequency- Terim Sıklığı), bir terimin belgede ne kadar sık geçtiğini ölçer ve şöyle hesaplanır:

$$TF(t,d) = \frac{\text{Belgedeki Terim } t' \text{ nin Sıklığı}}{\text{Belgedeki toplam Terim Sayısı}} \quad (13)$$

IDF (Inverse Document Frequency- Belge Frekansının Tersi), bir terimin belgede genel olarak ne kadar nadir bulunduğunu ölçer ve hesaplaması şu şekildedir:

$$IDF(t,D) = \log\left(\frac{\text{Toplam Belge Sayısı}}{\text{Belgede Terim } t' \text{ nin Bulunduğu Belge Sayısı}+1}\right) \quad (14)$$

TF-IDF değeri, TF ve IDF' nin çarpımı olup şu şekilde bulunur:

$$TF-IDF(t,d,D)=TF(t,d) \times IDF(t,D) \quad (15)$$

2.4. Chatbot

Günümüzde teknolojinin hızla ilerlemesiyle birlikte, iletişim ve kullanıcı deneyimi alanlarında önemli değişiklikler yaşanmaktadır. Yapay zeka (AI), akıllı ajanlar olarak adlandırılan yazılım ve donanımların inşası ve analiziyle günlük yaşantımızı etkilemektedir. Bu değişimlerden biri de chatbotlar olarak adlandırılan yapay zeka destekli iletişim araçlarıdır (Bansal ve Khan, 2018). Chatbotlar, yapay zeka sistemlerinin belirgin bir örneği olup, kullanıcıların metin veya ses yoluyla etkileşime geçebildiği ve Doğal Dil İşleme (NLP) teknikleriyle insan dillerini anlayabilen bilgisayar programlarıdır. Kısaca chatbotlar, insanlarla doğal dilde etkileşim kurabilen, soruları yanıtlayabilen ve çeşitli görevleri yerine getirebilen yazılımlardır (Khanna vd., 2015). Chatbotlar eğitim, bilgi edinme, işletme ve e-ticaret gibi farklı alanlarda kullanılmakta olup kullanıcılara birçok avantaj sunmaktadırlar (Shawar ve Atwell, 2007).

1950' de Alan Turing, Makinelerin düşünebilir olup olamayacağı sorusuyla Turing Testi' ni önererek chatbot fikrinin popüler hale gelmesine katkı sağladı (Turing, 2009). İlk bilinen chatbot olan Eliza, 1966' da geliştirildi ve kullanıcı ifadelerini sorularla yanıtlayarak bir psikoterapist gibi davranıyordu. Eliza, basit desen eşleştirme ve şablon tabanlı yanıtlar kullanarak konuşma yeteneği bakımından sınırlı olsa da chatbot geliştirmeye teşvik etti (Weizenbaum, 1966). 1972' de geliştirilen PARRY, kişilik sahibi bir chatbot olarak Eliza' nın bir ilerlemesiydi. Ardından, 1995 yılında ALICE isimli

chatbot, yıllık Turing Testi olan Loebner Ödülü' nü kazanarak "en insan bilgisayarı" unvanını aldı. ALICE, Yapay zeka İşaretleme Dili' ne (AIML) dayalı temel zeka ve örüntü eşleştirme algoritmalarını kullanarak başarılı oldu (Epstein vd., 2009). 2001'de SmarterChild gibi chatbotlar geliştirilerek mesajlaşma uygulamaları aracılığıyla popülerlik kazandı. Bu dönemde, Apple Siri, Microsoft Cortana, Amazon Alexa, Google Asistan ve IBM Watson gibi sanal kişisel asistanlar da ortaya çıktı. Son yıllarda chatbotlara olan ilgi hızla artmıştır, özellikle 2016' dan sonra endüstriyel çözümler ve çeşitli araştırma ve uygulamalara yönelik chatbotlar geliştirilmiştir (Adamopoulou ve Moussiades, 2020).

Chatbotların temel çalışma prensibi doğal dil işleme (NLP) ve makine öğrenimi tekniklerine dayanmaktadır. Kullanıcıdan gelen metin tabanlı soruları anlamak için NLP algoritmaları kullanılır ve ardından uygun yanıtlar üretmek için önceden eğitilmiş modeller devreye girer. Bu modeller, genellikle büyük veri setleri üzerinde eğitilir ve sürekli olarak güncellenerek daha iyi performans sağlarlar.

Chatbot teknolojisiyle ilgili temel kavramlar şunları içerir (Adamopoulou ve Moussiades, 2020):

Desen Eşleme: Bu metot, sembolik uyarıcı-yanıt modellerine dayanır. Kullanıcıdan gelen ifadeler belirli desenlere göre işlenir ve buna göre bir cevap üretilir (Marietto vd., 2018). Geçmişte Eliza ve ALICE gibi eski chatbotlar bu yöntemi kullanıyordu. Dezavantajı, yanıtların öngörülebilir ve tekrarlayıcı olma eğilimidir.

AIML (Artificial Intelligence Markup Language): AIML, eşleşme ve tanıma tekniklerine dayanır ve chatbotlarla insanlar arasındaki iletişimi modeller. XML tabanlı bir formata sahiptir ve konuşma kategorilerini belirleyen şablonlar içerir (Marietto vd., 2018).

Gizli Anlamsal Analiz (LSA): AIML ile kullanılan LSA, kelime vektörleri arasındaki ilişkileri keşfeder. Örüntü tabanlı soruların yanı sıra belirsiz veya cevaplanmamış sorulara da cevap üretebilir (Ahmad vd., 2018).

Chatscript: AIML' nin gelişmiş versiyonu olan Chatscript, açık kaynaklı bir betik dili ve uzman bir sistemdir. Kullanıcı girişlerini en uygun kurallara göre işler.

RiveScript: Metin tabanlı bir betik dili olan RiveScript, chatbotlar ve diğer konuşma araçları için kullanılır. Farklı programlama dillerine uyumlu olarak geliştirilmiştir (Ramesh vd., 2017).

Doğal Dil İşleme (NLP): Bilgisayarların insan dilini anlamasıyla ilgilenen NLP, chatbot geliştirme süreçlerinde kritik bir rol oynar (Jung, 2019). Genellikle makine öğrenimi teknikleriyle birlikte kullanılır.

Doğal Dil Anlama (NLU): NLU, kullanıcı girdilerinden anlam ve bağlam çıkararak chatbotların etkileşimini yönetir. Kullanıcı niyetlerini ve öznitelikleri belirlemede kullanılır (Jung, 2019).

Varlık Tanımlama: Kullanıcı girdilerinden bilgi çıkarma sürecini ifade eder. Örneğin, tarih, yer gibi belirli bilgileri belirleme yeteneği sağlar.

Bağlam Yönetimi: Kullanıcının önceki iletilerine dayalı olarak değişen anlamları işlemek için kullanılır. Önceden tanımlanmış bağlamları kullanarak daha anlamlı cevaplar üretir. Bu temel kavramlar, chatbot teknolojisinin evrimi ve doğal dil işleme alanındaki ilerlemelerin anlaşılmasında önemli bir rol oynamaktadır (Kucherbaev vd., 2018).

3. GEREÇ VE YÖNTEM

3.1. Veri Seti

Bu çalışma için Kaggle platformunda paylaşılan 2013 yılı Türkiye duyarlılık analizi verilerine dayanarak oluşturulan beyazperde.com kullanıcı yorumları adlı veri seti kullanılmıştır. Veri seti, kullanıcıların filmlerle ilgili yorumlarını içermekte olup her bir yorum olumlu veya olumsuz duygu etiketi ile etiketlenmiştir.

Türk film incelemeleri veri seti ilk olarak 2013 yılında Demirtaş ve Pechenizkiy tarafından tanıtılmıştır ve toplamda 10662 yoruma sahiptir. Yorumların sınıflandırılması 1 ile 5 arasında değişen yıldız derecelendirmeleri üzerinden yapılmıştır (Demirtaş ve Pechenizkiy, 2013). Bu çalışmada, yıldız derecelendirmeleri 2 sınıfa ayrılmıştır: 4 veya 5 yıldızlı yorumlar olumlu olarak kabul edilirken, 1 veya 2 yıldızlı yorumlar olumsuz olarak kabul edilmiştir. 3 yıldızlı yorumlar analiz dışı bırakılmıştır. Veri seti mükemmel bir şekilde dengelenmiştir. Eğitim verilerinde 3998 adet olumlu ve 3998 adet olumsuz etiketli yorum bulunmaktadır. Test verilerinde ise her sınıf için 1333 yorum bulunmaktadır. Veri setinin yapısı oldukça basittir; her bir yorum metni ile bu yoruma ait olumlu (1) veya olumsuz (0) etiketlerden oluşmaktadır (kaggle.com, 2023). Kaggle platformundan elde edilen bu veri seti üzerinde belirli ön işleme adımları gerçekleştirmeden önce veri seti incelenmiştir. Bu çalışma kapsamında kullanılan veri setine ait token sayıları toplamı Tablo 1’ de, kullanıcı yorumlarının ilk beş satırının incelemesi Tablo 2’ de aşağıdaki gibidir.

Tablo 1: Veri setine ait token sayıları toplamı

Train Veri Setindeki Toplam Token Sayısı	130368
Test Veri Setindeki Toplam Token Sayısı	43210
Toplam Token Sayısı	173578

Tablo 2: Kullanıcı yorumlarının ilk beş satırının incelemesi

	Unnamed: 0	Comment	Label
0	0	biri bana bu filmde benim anlamadığım bisey olduğunu söylesin lütfen.. uzun zamandır bilim kurgu vb tür filmleri izliyorum basit olanları,mantiksiz olanları,hatalı olanları gördüm ama böylesine rastlamadım saçma filmler kategorisinde kesin bi ödül alır film.kısaca:bu ne ya? diyorsunuz.. . \n	0
1	1	ya çocuklar ilk filmin sonunda büyüdüler ya bu filmde büyük mü kalcaklar dolaba girince gene büyücekler mi anlamadım ben o olayı oyuncular aynı ya. \n	1
2	2	film biraz daha uzun sürse harbi kıyameti görecektik.. \n	0
3	3	pek orjinal bi cinayet yok ama orjinal oyuncular var iki dev isim, ama artık oyunculuk yerine biri senarist biri yönetmen olsa daha iyi olacak gibi bi izlenim var, ya da godfatherda ki gibi olacak her filmleri, sonuç olarak izlenebilir bi film ama izlerken unutabilirsiniz. \n	0
4	4	film tek kelimeyle muhtesemdi heleki sonundaki sasirticiligi filmin ne kadar zekice ortaya kondugunu gösteriyodu oyunculuklar ztn ayrı bir harikaydı izledigim en ii filmlerden biriydi . \n	1

Kaggle platformunda paylaşılan Türkiye Duygu Analizi Verileri-beyazperde.com adlı veri setinin istatistikleri Tablo 3 ve Tablo 4’ de aşağıdaki gibidir.

Tablo 3: Veri seti istatistikleri-1

	Unnamed: 0	Label
count	7996	7996
mean	3997.5	0.5
std	2308.39	0.500031
min	0	0
%25	1998.75	0
%50	3997.5	0.5
%75	5996.25	1
max	7995	1

Tablo 4: Veri seti istatistikleri-2

	Sütun Adı	Veri Türü	Non-Null Sayısı	Açıklama
0	Unnamed :0	int64	7996	İndeks veya tanımlayıcı olarak kullanılabilir.
1	Comment	object	7996	Yorumları içerir.
2	Label	int64	7996	Etiketleri (0 veya 1) içerir.

Bu çalışma kapsamında "Unnamed :0" sütunu, veri setinde tanımlayıcı olan ancak analiz veya model eğitimi için anlamlı bir bilgi içermeyen sütun olması nedeniyle modelin eğitimini etkilemeyeceği için kaldırılmıştır. Train veri setinden "Unnamed: 0" sütunu, drop fonksiyonu kullanılarak çıkartılmış ve bu değişiklik orijinal train veri setine (inplace=True kullanılarak) uygulanmıştır. Bu işlem sonucunda veri setindeki gereksiz bir sütun temizlenmiş ve model için gerekli olan veri hazırlık aşaması tamamlanmıştır.

3.2. Yazılım

Bu çalışma kapsamında veri ön işleme adımları, modellerin eğitimi ve chatbot uygulamaları Google Colab ortamında Python programlama dili kullanılarak gerçekleştirilmiştir.

3.2.1. Google colab

Google Colab (Google Colaboratory), yapay zeka ve derin öğrenme projeleri için geliştirilmiş, bulut tabanlı bir Jupyter Notebook ortamıdır. Google Colab' ın belli başlı özellikleri (colab.research.google.com, 2024):

- 1) **Ücretsiz ve Bulut Tabanlı:** Google' un bulut altyapısı üzerinde çalışan Google Colab ücretsizdir ve kullanıcıların kendi bilgisayarlarına herhangi bir şey kurmadan tarayıcı üzerinden çalışmalarına olanak sağlar.
- 2) **Jupyter Notebook ile Uyumlu:** Google Colab, Jupyter Notebook formatını destekler. Kod, metin ve görselleri aynı belgede birleştirmeye imkân sağlar. Bu durum kod yazımını ve analizleri düzenlemeyi kolaylaştırır.
- 3) **GPU ve TPU Desteği:** Google Colab, kullanıcıların ücretsiz olarak GPU (Graphics Processing Unit) ve TPU (Tensor Processing Unit) gibi yüksek performanslı donanımları kullanmasının yolunu açar. Bu özellik derin öğrenme gibi maliyetli projeler için çok önemlidir.
- 4) **Paylaşım ve İş Birliği:** Colab projeleri Google Drive ile entegredir ve kolayca paylaşılabilir. Birden çok kullanıcı aynı anda Colab not defteri üzerinde çalışma ve değişiklikleri anlık olarak görebilme imkanına sahiptir.
- 5) **Kütüphane ve Paketlerin Kolay Kurulumu:** Colab' da yaygın olarak kullanılan kütüphaneler ve paketler önceden yüklenmiştir.
- 6) **Eğitim ve Dersler İçin İdeal:** Kodlama becerilerini geliştirmek, projeleri paylaşmak ve sunmak için kullanışlı bir ortamı vardır.

Google Colab, yapay zeka ve veri bilimi alanlarında çalışanlar için idealdir. Kullanıcılarına esneklik, yüksek hesaplama gücü ve kolay paylaşım imkânı sunar.

3.2.2. Python programlama dili

Python, 1991 yılında Guido van Rossum tarafından geliştirilen genel amaçlı, yüksek seviyeli ve açık kaynaklı bir programlama dilidir. Python' un dikkat çeken özelliklerinden biri, okunması ve anlaşılması kolay söz yapısıdır. Bu dil, çeşitli işletim sistemlerinde kullanılabilir ve geniş bir kullanıcı tabanına sahiptir. Nesne tabanlı programlamayı destekleyen Python, yorumlanabilen bir dil olma özelliği nedeniyle kullanıcıların kaynak kodlarını doğrudan çalıştırmalarına olanak sağladı. Ayrıca, geniş bir standart kütüphaneye sahip olması ve sürekli gelişen bir topluluk tarafından desteklenmesi, Python' u çeşitli uygulama alanlarında tercih edilen bir dil haline getirmiştir (Mingzhe, 2022).

Python' un bilimsel hesaplamalar için gereken veri yapısını oluşturmak amacıyla, Python topluluğu 1995 yılında matrix-sig adlı özel bir ilgi grubunu oluşturdu. Bu süreçte, Jim Hugunin tarafından geliştirilen Numeric, bu ihtiyacı karşılamak için önemli bir adım oldu. Ancak, Numeric' in geliştirme hızındaki yavaşlama ve genişletme sorunları, Perry Greenfield, Todd Miller ve Rick White tarafından geliştirilen numarray ile aşılmaya çalışıldı. Numeric ve numarray arasındaki ayrılık, Travis Oliphant' ın NumPy' yi piyasaya çıkarmasıyla son buldu. Bu süreçte, bilimsel Python topluluğu için oldukça önemli olan SciPy, IPython ve matplotlib gibi paketler geliştirdi. Bu gelişmeler, Python'un bilimsel hesaplama alanında kullanılabilirliği ve etkinliği açısından önemli bir adımdı (Millman ve Aivazis, 2011).

Bu gelişmeler Python' ı bilimsel hesaplamalar, veri analizi, yapay zeka, makine öğrenimi ve daha birçok alanda tercih edilen bir dil haline getirdi. Yapısı gereği esnek ve geniş kütüphanelerle desteklenen Python, araştırma ve endüstriyel projelerde yaygın bir şekilde kullanılmaktadır. Python' un bu geniş alanlarda kullanılabilmesi, özellikle veri bilimi ve yapay zeka gibi yüksek hesaplama gücü gerektiren alanlarda büyük bir avantaj sağlamaktadır (python.org, 2024).

3.3. Doğal Dil İşleme (NLP) İşlemleri

Doğal Dil İşleme (NLP) teknikleri, metin verilerinin analiz edilmesi ve işlenmesi için kullanılan önemli araçlardır. Bu çalışmada, NLP tekniklerinden biri olan NLTK (Natural Language Toolkit) kütüphanesinden yararlanılmıştır. NLTK, Python programlama dili üzerine kurulu bir platformdur ve doğal dil işleme (NLP) alanında öğrenim, araştırma ve uygulama yapmak isteyenler için temel bir kaynak olmuştur. NLTK'nın sunduğu avantajlar arasında çeşitli NLP veri türlerini, işleme görevlerini, korpus örneklerini ve okuyucularını içermesidir. NLTK, kullanıcılarına animasyonlu algoritmalar, öğreticiler ve problem setleri gibi zengin kaynaklar sunarak öğrenme deneyimini etkinleştirir. Bu özellikleriyle NLTK, öğrenciler, araştırmacılar ve öğretmenler için çok değerli bir kaynaktır (Bird, 2006). NLTK'nın açık kaynak yapısı ve Python ile uyumluluğu, geniş bir kullanıcı kitlesine hitap etmesini sağlar. Bu özellikleri sayesinde NLTK, NLP alanında çalışanların verimliliğini artırır ve karmaşık işlemleri basit çözümler sunar. NLTK etkin kullanımıyla, NLP konularında derinlemesine çalışma ve pratik deneyim kazanma imkânı sağlar. Öğrenciler için interaktif arayüzlerle desteklenen bu platform, teorik bilgilerin yanı sıra pratik becerilerin de geliştirilmesine imkân sağlar. Sonuç olarak, NLTK, hesaplamalı dilbilimi ve doğal dil işleme alanlarında çalışanlar için vazgeçilmez bir araç haline gelmiştir (Loper ve Bird, 2002). Bu çalışma kapsamında Türkçe metin verilerinin NLP işlemlerine tabi tutulması için izlenen adımlar şunlardır:

- 1) **Tokenizasyon (Tokenization):** Bu adım, metin verilerini anlamlı parçalara ayırarak daha detaylı analizlerin yapılmasını sağlar (Toraman vd., 2023). Bu çalışmada metin verilerindeki cümleleri ve kelimeleri anlamlandırmak için NLTK kütüphanesindeki `word_tokenize` fonksiyonu kullanılmıştır. Örneğin, "Bu film harika!" cümlesi "Bu", "film", "harika", "!" gibi ayrı parçalara ayrılır.
- 2) **Lemmatizasyon:** Bu işlem, kelime vektörlerinin temsil edilirken kök kelimelerin kullanılmasını sağlayarak veri boyutunu azaltır ve analiz doğruluğunu artırır (Ak ve Tosun, 2020). Bu çalışmada metin verilerindeki kelimelerin köklerini (lemma) bulmak için NLTK kütüphanesindeki `WordNetLemmatizer` kullanılmıştır. Örneğin, "oynuyor", "oynar", "oynuyordu" gibi farklı şekillerde kullanılan kelimeler "oyna" köküne indirgenir.

- 3) **TF-IDF Vektörleştirme:** Bu yöntemle kelimelerin belirleyiciliği hesaplanarak vektörler oluşturulur. Bu vektörler, metin verilerinin makine öğrenimi modelleri tarafından işlenebilir hale getirilmesini sağlar (Liu vd., 2018). Bu çalışmada metin verilerini sayısal vektör temsillerine dönüştürmek için TF-IDF (Term Frequency-Inverse Document Frequency) vektörleştirme yöntemi kullanılmıştır. Örneğin, "film" kelimesinin sıklığı belirlenirken belirli bir dokümanda ne kadar sık geçtiği ve genel koleksiyonda ne kadar sık geçtiği dikkate alınır.
- 4) **Word Embedding (Kelime Gömme):** Kelimelerin temsili, embedding boyutu ve belirlenen maksimum kelime uzunluğu dikkate alınarak oluşturulur. Kelime gömme, kelime vektörlerini oluştururken kelimeler arasındaki ilişkileri de dikkate alır (Li ve Yang, 2018). Bu çalışmada kelimelerin sayısal vektör temsillerine dönüştürülmesi için embedding katmanı kullanılmıştır. Örneğin, "king-man + woman = queen" gibi ilişkileri çıkarabilir ve kelimeler arasındaki anlamsal ilişkileri modelleyebilir.

Çalışma kapsamında yapılan bu NLP işlemleri, kullanılan LSTM, Naive Bayes (NB), Destek Vektör Makineleri (SVM) ve Logistic Regression modellerin eğitim ve test süreçlerinde kullanılmıştır. Bu sayede Türkçe metin verilerinin doğru bir şekilde işlenmesi ve duygusal analiz için uygun özelliklerin çıkarılması sağlanmıştır.

3.4. Model Eğitimi ve Test Süreci

3.4.1. Naive bayes modeli eğitim süreci

Veri Hazırlığı: Tokenize edilmiş, lemmatize edilmiş ve TF-IDF vektörleri oluşturulmuş metin verileri kullanılmıştır.

Model Seçimi: Bernoulli Naive Bayes modeli, duygusal analiz için uygun olduğu düşünülmüş seçilmiştir.

Eğitim: TF-IDF vektörleriyle eğitim verisi üzerinde model eğitilmiştir.

Test: Eğitilen model, ayrılmış test verisi üzerinde değerlendirilmiş ve duygusal analiz performansı ölçülmüştür.

3.4.2. Logistic regression modeli eğitim süreci

Veri Hazırlığı: Tokenize edilmiş, lemmatize edilmiş ve TF-IDF vektörleri oluşturulmuş metin verileri kullanılmıştır.

Model Seçimi: Duygu analizi için uygun olduğu düşünülen Logistic Regression modeli seçilmiştir.

Eğitim: TF-IDF vektörleriyle eğitim verisi üzerinde model eğitilmiştir.

Test: Eğitilen model, ayrılmış test verisi üzerinde değerlendirilmiş ve duygusal analiz performansı ölçülmüştür.

3.4.3. Svm Modeli Eğitim Süreci

Veri Hazırlığı: Tokenize edilmiş, lemmatize edilmiş ve TF-IDF vektörleri oluşturulmuş metin verileri kullanılmıştır.

Model Seçimi: Linear SVC (Destek Vektör Makineleri) algoritması, duygusal analiz için uygun bir sınıflandırıcı olduğu düşünülmüş ve seçilmiştir.

Eğitim: TF-IDF vektörleriyle eğitim verisi üzerinde model eğitilmiştir.

Test: Eğitilen model, ayrılmış test verisi üzerinde değerlendirilmiş ve duygusal analiz performansı ölçülmüştür.

3.4.4. Lstm modeli eğitim süreci

Veri Hazırlığı: Tokenize edilmiş, lemmatize edilmiş ve embedding işleminden geçirilmiş metin verileri kullanılmıştır.


Model Seçimi: Embedding katmanı, iki LSTM katmanı, bir çıkış katmanı ve üç Dropout katmanı içeren 7 katmanlı bir sinir ağı modeli, duygusal analiz için uygun bir sınıflandırıcı olduğu düşünülmüş ve seçilmiştir. Katmanlar arasında Dropout kullanılarak overfitting riski azaltılmaya çalışılmıştır.

Eğitim: Model, tokenizasyon ve ön işleme yapılmış metin verileri üzerinde “Adam” optimizasyonu ile derlenirken, eğitim sırasında da early stopping callback kullanılarak belirtilen metriğin gelişiminin izlenmesi ve gerektiğinde eğitimin durdurulması sağlanmıştır. Ayrıca model eğitimi sırasında kullanılan parametreler şu şekildedir: verbose (görüntüleme seviyesi) değeri 1 olarak belirlenmiş, epochs (iterasyon

sayısı) değeri 100 olarak ayarlanmış ve batch_size (toplu iş birimi boyutu) değeri 32 olarak seçilmiştir. Aktivasyon fonksiyonu olarak 'sigmoid' tercih edilmiştir.

Test: Eğitilen model, ayrılmış test verisi üzerinde değerlendirilmiş ve duygusal analiz performansı ölçülmüştür.

Bu çalışmaya ait kullanılan tüm modellerin genel eğitim ve uygulama iş akış şeması Şekil 18’ de verilmiştir.



Şekil 18: Model eğitim ve uygulama iş akışı

3.5. Duygu Analizi (Sentiment Analysis) İşlemleri

Bu çalışmada, duygu analizi için farklı makine öğrenimi modelleri ve yöntemleri detaylı bir şekilde incelenmiştir. beyazperde.com kullanıcı yorumları adlı veri setinde kelimelerin önemini ölçümlemek ve aykırı değerleri çıkarmak için TF-IDF (Term Frequency-Inverse Document Frequency) istatistiksel ölçüm tekniği kullanılmıştır. Veri hazırlığı aşamasında metin verileri öncelikle tokenize edilerek kelimelerine ayrılmış ve ardından TF-IDF (Term Frequency-Inverse Document Frequency) vektörleri oluşturulmuştur.

TF-IDF formülü, bir kelimenin belgedeki sıklığının (TF) tüm belgeler içinde ne kadar nadir olduğu (IDF) ile çarpılmasıyla kelimenin önemini belirler. Bu sayede sık geçen ancak genel koleksiyonda nadir olan kelimeler daha yüksek bir ağırlığa sahip olurken, genel olarak sık geçen ve her belgede bulunan kelimelerin önemi azalır (Jones, 2004).


Bu kapsamda her bir makine öğrenimi modeli için uygun özellikler belirlenirken, TF-IDF vektörleri kullanılarak elde edilen sayısal temsiller modele girdi olarak verilmiştir. Naive Bayes, Logistic Regression ve SVM modellerinde TF-IDF vektörleri kelime frekanslarına dayalı özelliklerdeki orantısızlığı belirlemek için kullanılmıştır. LSTM modelinde ise TF-IDF vektörleri yerine metin verileri üzerinde daha derin bir işlem olan tokenize, lemmatize ve embedding işlemleri uygulanmıştır. Model seçimi aşamasında, embedding, LSTM katmanları ve çıkış katmanı içeren 7 katmanlı bir sinir ağı modeli, duygusal analiz için uygun bir sınıflandırıcı olarak tercih edilmiştir. Eğitim ve test aşamalarında model, belirlenen epoch sayısı kadar eğitilerek ayrılmış test verisi üzerinde değerlendirilmiştir.

3.6. Chatbot İşlemleri

Bu çalışma kapsamında duygu analizi yapabilen chatbot uygulaması için Türkçe metinler üzerinde eğitimi gerçekleştirilen makine öğrenmesi modellerinden Logistic Regression, SVM ve LSTM kullanılmıştır. Kullanıcı tarafından girilen Türkçe metinlerin, duygu analizi modeli tarafından işlenerek metnin olumlu veya olumsuz olduğu sonucu çıkarılmıştır. Chatbot etkileşimleri, basit bir döngü içinde kullanıcıdan giriş alarak ve model çıktılarını değerlendirerek gerçekleştirilmiştir. Bu yöntemlerin kullanılmasıyla

chatbot, kullanıcıların Türkçe metin girişlerini anlayarak duygusal içeriklerine göre yanıtlar üretebilmektedir.

Chatbotun ismi Türkçe' de ki “nüsha” kelimesinden esinlenilerek NÜNÜ konmuştur. Genellikle bu ifade, bir şeyin tıpkısının başka bir tıpkısıyla aynı olduğunu ifade etmek için kullanılır. Aralarındaki benzerlik vurgulanırken "nüsha" kelimesi kullanılırken, "nüsha" kelimesi tekrar edilerek vurgu yapılır. Çalışma kapsamında Logistic Regression, SVM ve LSTM modellerine chatbot uygulaması uygun görülmüştür. Şekil 19’ da NÜNÜ’ ye ait duygu analizi modellerinde kullanılan tahmin yapma fonksiyonları ve NÜNÜ’ nün çalışma prensibi verilmiştir.



Şekil 19: Nünü çalışma prensibi

Bu çalışmada uygulaması yapılan chatbotun kullanıcıyla etkileşime geçme süreci ve modelin tahminlerini kullanıcıya geri bildirimi şu şekildedir:

- I. Kullanıcı Metin Girişi:** Kullanıcı, chatbotla etkileşime geçmek için bir Türkçe metin girişi yapar.

Merhaba, ben NÜNÜ. Sana bir yorumun olumlu mu yoksa olumsuz mu olduğunu söyleyebilirim.
Lütfen bir yorum girin:

- II. Chatbot İşlemi:** Chatbot aldığı Türkçe metni öncelikle ön işleme adımlarından geçirir. Bu adımlar, metnin küçük harflere dönüştürülmesi, gereksiz karakterlerin temizlenmesi, kelimelerin köklerinin bulunması şeklindedir. Daha sonra bu işlenmiş metin, model tarafından yorumlanabilir hale gelir.

- III. Model Tahmini:** İşlenmiş Türkçe metin, model tarafından duygusal bir etiketleme sürecinden geçirilir. Model, genellikle bu metnin olumlu mu yoksa olumsuz mu olduğunu tahmin eder.

- IV. Geri Bildirim:** Modelin tahminine göre chatbot, kullanıcıya Türkçe metnin olumlu mu yoksa olumsuz mu olduğunu bildiren bir yanıt verir. Örneğin, "Bu yorum olumlu bir duygu içeriyor." veya "Bu yorum olumsuz bir duygu içeriyor." şeklindedir.

Merhaba, ben NÜNÜ. Sana bir yorumun olumlu mu yoksa olumsuz mu olduğunu söyleyebilirim.
Lütfen bir yorum girin: film harikaydı
Bu yorum olumlu bir duygu içeriyor.
Lütfen bir yorum girin:

- V. Çıkış Kontrolü:** Kullanıcı, chatbotla etkileşimini sonlandırmak istediğinde 'q' tuşuna basarak çıkar. Bu durumda chatbot, "Rica ederim. İyi günler!" şeklinde bir veda mesajıyla etkileşimi sonlandırır.

Lütfen bir yorum girin: q
Rica ederim. İyi günler!

4. BULGULAR

Makine öğrenimi çalışmalarında modelin performansını değerlendirmek için kullanılan önemli araçlardan biri confusion matrix (karışıklık matrisi)' dir. Confusion matrix, modelin gerçek ve tahmini sınıflandırmalarını gösteren bir tablodur. Şekil 20' de confusion matrix gösterilmiştir.

		Predicted condition	
Total population = P + N		Positive (PP)	Negative (PN)
Actual condition	Positive (P)	True positive (TP)	False negative (FN)
	Negative (N)	False positive (FP)	True negative (TN)

Şekil 20: Confusion Matrix (en.wikipedia.org, 2024)

True Positive (TP): Gerçekte pozitif olan örneklerin doğru bir şekilde pozitif olarak tahmin edilen değerlerin sayısıdır.

True Negative (TN): Gerçekte negatif olan örneklerin doğru bir şekilde negatif olarak tahmin edilen değerlerin sayısıdır.

False Positive (FP): Gerçekte negatif olan örneklerin yanlışlıkla pozitif olarak tahmin edilen değerlerin sayısıdır.

False Negative (FN): Gerçekte pozitif olan örneklerin yanlışlıkla negatif olarak tahmin edilen değerlerin sayısıdır.

Confusion matrix modelin doğruluk (accuracy), hassasiyet (sensitivity), özgüllük (specificity), keskinlik (precision) gibi performans metriklerini değerlendirmede kullanılır.

Accuracy değeri, doğruluk değerini ifade eder ve aşağıdaki formül ile hesaplanır.

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \quad (16)$$

Precision değeri, pozitif olarak tahmin edilen örneklerin gerçekten pozitif olma olasılığıdır.

$$Precision = \frac{TP}{TP+FP} \quad (17)$$

Sensitivity değeri, gerçek pozitif örneklerin tüm pozitif örnekler içindeki oranıdır.

$$Sensitivity (Recall) = \frac{TP}{TP+FN} \quad (18)$$

Specificity değeri, Gerçek negatif örneklerin tüm negatif örnekler içindeki oranıdır.

$$Specificity = \frac{TN}{TN+FP} \quad (19)$$

Bu çalışma kapsamında oluşturulan dört modele ait Confusion Matrix bilgileri Tablo 5' de gösterilmiştir.

Tablo 5: Confusion matrix değerleri

SVM

	Tahmin (0)	Tahmin (1)
Gerçek (0)	TN (716)	FN (101)
Gerçek (1)	FP (110)	TP (673)

Logistic Regression

	Tahmin (0)	Tahmin (1)
Gerçek (0)	TN (742)	FN (75)
Gerçek (1)	FP (103)	TP (680)

Naive Bayes

	Tahmin (0)	Tahmin (1)
Gerçek (0)	TN (713)	FN (104)
Gerçek (1)	FP (82)	TP (701)

LSTM

	Gerçek (0)	Tahmin (1)
Gerçek (0)	TN (1146)	FN (187)
Gerçek (1)	FP (163)	TP (1170)

Modellerin karışıklık matrisleri incelendiğinde, her bir modelin sınıfları ne kadar doğru tahmin ettiğini ve hangi sınıflarda yanıltıcı sonuçlar verdiği görülmektedir.

Bu çalışma kapsamında, Türkçe metin verileri üzerinde duygusal analiz gerçekleştirmek için Naive Bayes (NB), Logistic Regression, Support Vector Machine (SVM) ve Long Short-Term Memory (LSTM) gibi farklı makine öğrenimi ve derin öğrenme modeli incelenmiştir. Eğitim süreci boyunca her bir modele ait eğitim çıktıları Tablo 6 ve Tablo 7’ de sunulmuştur.

Tablo 6: Model eğitim metrikleri-1

MODEL	accuracy	Label	precision	recall	f1-score	support
Naive Bayes	0.88	0	0.90	0.87	0.88	817
		1	0.87	0.90	0.88	783
Logistic Regression	0.89	0	0.88	0.91	0.89	817
		1	0.90	0.87	0.88	783
SVM	0.87	0	0.87	0.88	0.87	817
		1	0.87	0.86	0.86	783
LSTM	0.87	0	0.88	0.86	0.87	1333
		1	0.86	0.88	0.87	1333

Tablo 7: Model eğitim metrikleri-2

MODEL	Eğitim Süresi (saniye)	Tahmin Süresi (saniye)
Naive Bayes	0.5299	0.03534
Logistic Regression	0.330724	0.0597
SVM	1.60701	0.25425
LSTM	72.81	2.43

Bu bağlamda, modellerin sınıflandırma yetenekleri doğruluk oranları üzerinden değerlendirilirse en yüksek doğruluk oranından en düşüğüne doğru sıralandığında, Logistic Regression modeli %89 doğruluk oranıyla en iyi performansı sergilemiştir. Bu model eğitim süresi açısından da oldukça hızlıdır, yalnızca 0.330724 saniye sürerken, tahmin süresi ise 0.0597 saniyedir. Ardından Naive Bayes modeli gelir, %88 doğruluk oranıyla başarılı sonuçlar verirken, eğitim süresi 0.5299 saniye ve tahmin süresi 0.03534 saniyedir. SVM modeli %87 doğruluk oranıyla tatmin edici sonuçlar gösterir ancak eğitim ve tahmin süreleri biraz daha uzundur; eğitim süresi 1.60701 saniye, tahmin süresi ise 0.25425 saniyedir. Son olarak, derin öğrenme modeli olan LSTM %87 doğruluk oranıyla diğer modellere yakın bir başarı elde eder, ancak eğitim ve tahmin süreleri diğer modellere göre oldukça uzundur; eğitim süresi 72,81 saniye ve tahmin süresi ise 2,43 saniyedir.

Bu değerlendirme, modellerin hem doğruluk oranları hem de eğitim ve tahmin süreleri açısından karşılaştırılmasını içermektedir. Daha yüksek doğruluk oranları genellikle tercih edilirken, hızlı eğitim ve tahmin süreleri de gerçek zamanlı veya hızlı cevap gerektiren uygulamalarda önemli bir faktördür. Dolayısıyla, belirli bir uygulama için en uygun modeli seçerken bu faktörlerin dikkate alınması önemlidir. Bu bilgiler ile modellerin performansını daha detaylı bir şekilde değerlendirdiğimizde Logistic Regression modelinin en iyi performansı sergilediğini göstermektedir.

Bu çalışma kapsamında Logistic Regression, SVM ve LSTM makine öğrenimi modellerine ve derin öğrenme modeline uygulanan chatbotların Türkçe duygu analizi performanslarını değerlendirmek için chatbot gözlemci formu oluşturulmuştur. Bu form chatbotun doğruluğunu, yanıt kalitesini ve kullanıcı deneyimini değerlendirmek için belirli ölçütlere dayanmaktadır. Gözlemci doğruluk formu, kullanıcı tarafından chatbotla

gerçekleştirilen etkileşimlerde kullanmaya yönelik olup chatbotun duygu analizi değerlendirmesi için önceden belirlenmiş ölçütler içermektedir. Bu değerlendirmede duygu etiketleri sayısal formata dönüştürülerek olumlu ve olumsuz gibi duygu etiketlerine sayısal değerler verilmiştir. Olumlu için 1, olumsuz için -1 değerleri kullanılmıştır. Eğitim süreci sonunda her bir modelin chatbotunda kullanıcıya ait Türkçe yapılmış on metin için chatbot gözlemci formu performans başarıları değerleri yüzdesi Tablo 8’ de sunulmuştur.

Tablo 8: Chatbot gözlemci formu

Kullanıcı Metinleri	Beklenen Duygu Analizi Yorumu	Logistic Regression	SVM	LSTM
film harikaydı	1	1	1	1
film çok kötüydü, berbat	-1	-1	-1	-1
film çok güzeldi, tavsiye ederim	1	1	1	-1
film çöp, hiç tavsiye etmem, berbat	-1	-1	-1	-1
film nefes kesiciydi, harikaydı	1	1	1	-1
filmi öneririm, çok güzel oyunculuk, harika bir kurgu var	1	1	1	1
çok çok kötü, gitmeyin, tavsiye etmem	-1	-1	-1	-1
oyuncuların performansı göz alıcıydı	1	-1	1	-1
hikaye harika işlenmiş, oyuncular çok iyi	1	1	1	-1
oyunculuk harikaydı	1	1	1	1
Performans Başarı Değeri (%)	100	90	100	60

Gözlemci Formunda kullanıcının filmle ilgili Türkçe yorumları sonucunda duygusal tepki verilerinin farklı makine öğrenimi modelleri üzerinde gerçekleştirilen duygusal analiz sonuçlarına göre, SVM modeli %100 başarı oranıyla olumlu ve olumsuz yorumların tümünü doğru tahmin etmiştir. Benzer şekilde, Logistic Regression modeli de %90 başarı oranıyla tatmin edici sonuçlar vermiştir. LSTM modelinin %60 başarı oranına

baktığımızda olumsuz yorumlarda diğer modellere kıyasla daha düşük başarı gösterdiği görülmüştür. Bu sonuçlar, Türkçe yapılan kullanıcı yorumlarının duygusal analiz değerlerini belirleyen chatbot uygulamasında Logistic Regression ve SVM modellerinin daha başarılı olduğunu göstermektedir.



5. TARTIŞMA

Türkiye’de ve dünyada yapılan akademik çalışmalar incelendiğinde, Türkçe metinler üzerinde eğitilmiş duygu analizi yapabilen chatbot uygulaması bulunamamış olup, benzer akademik çalışma olarak 2022 yılında yayınlanan National Formosa Üniversitesinin, I-Ching Hsu ve An-Hung Liao’ nun yaptığı “Sentiment-based Chatbot using Machine Learning for Recommendation System” adlı çalışmayla kıyaslama gerçekleştirilmiştir.

Hsu ve Liao (2022), çalışmalarında duygu tahmini modelleri için farklı algoritmaların verimliliğini değerlendirmek amacıyla altı algoritma kullanmıştır. Dört tanesi makine öğrenmesi algoritması olup bunlar Karar Ağacı, Logistic Regression, Destek Vektör Makinesi (SVM) ve Gradyan Artırılmış Karar Ağacı' dır. Diğer ikisi ise derin öğrenme algoritmaları olup Basit-RNN ve LSTM'dir. Eğitim verisi, 6.000 iş, 6.000 duygu ve 6.000 COVID-19 olmak üzere toplam 18.000 makaleden oluşmaktadır. Her kategoriden rastgele seçilen 1.200 makale ise daha küçük bir eğitim veri seti olarak kullanılmıştır. Deney ortamı Spark on Yarn' dır. Yapılan çalışmanın makine öğrenmesi algoritmalarının performansı 6.000 makale ile Karar Ağacı eğitimi en kısa sürede tamamlayan algoritmadır. SVM ve Logistic Regression sırasıyla Karar Ağacını takip etmektedir. Gradyan Artırılmış Karar Ağacı ise en düşük verimliliğe sahip olup eğitimi tamamlaması en uzun süren algoritmadır. Derin öğrenme algoritmalarının performans değerlendirme sonuçları karşılaştırıldığında Basit-RNN' nin eğitim performansının LSTM 'den daha iyi olduğu görülmüştür. F1 skorları 6000 duygu makalesi datası için değerlendirildiğinde ise Karar Ağacı %99.31, Logistic Regression %58.624, SVM %73.625, Gradyan Artırılmış Karar Ağacı %99.624, Basit-RNN %80.125 ve LSTM %80.523 çıkmıştır. Bu çalışmaya ait sonuçlar Tablo 9’ da gösterilmiştir.

Tablo 9: Çalışmanın performans karşılaştırması

Çalışmayı Gerçekleştirenler	Yöntem	Veri Türü ve Sayısı	F1 Skor (%)	Eğitim ve Tahmin Süresi (saniye)	Chatbot Gözlemci Formu Performans Başarısı (%)
Hsu ve Liao, (2022)	Karar Ağacı	Duygu Makalesi-6000	99.31	2.35641	-
	Logistic Regression		58.624	4.05918	-
	SVM		73.625	2.85329	-
	Gradyan Arttırılmış Karar Ağacı		99.624	8.25821	-
	Basit-RNN		80.125	13.67182	-
	LSTM		80.523	19.92142	-
Çalışmada elde edilen sonuçlar	Naive Bayes	Türkiye Duygu Analizi Verileri- beyazperde.com kullanıcı yorumları-10662	88	0.5299	-
	Logistic Regression		89	0.330724	90
	SVM		87	1.60701	100
	LSTM		87	72.81	60

Çalışmada, toplamda 10662 yorum olup eğitim verilerinde 3998 adet olumlu ve 3998 adet olumsuz etiketli yorum bulunmaktadır. Test verilerinde ise her sınıf için 1333 yorum bulunmaktadır. Veri setinin sınıf dağılımı, Türkçe chatbot uygulamasına uygun olan modelin performansını değerlendirmede doğruluk (Accuracy) metriği tek başına yeterli olmadığı için F1 skoru gibi hassasiyet ve duyarlılığın birleşimini sağlayan metriklere, Chatbot Gözlemci Formu performans başarısı, eğitim ve tahmin sürelerine odaklanılmıştır. Naive Bayes modeli %88, Logistic Regression modeli %89, SVM modeli %87 ve LSTM modeli %87 F1 skorunda sınıflandırma işlemi gerçekleştirilmiştir. Naive Bayes modeli eğitim için 0.5299 saniye, tahmin için ise 0.03534 saniye; Logistic Regression modeli eğitim için 0.330724 saniye, tahmin için ise 0.0597 saniye, SVM modeli eğitim süresi 1.60701 saniye, tahmin için ise 0.25425 saniye; LSTM modeli eğitim süresi 72.81 saniye, tahmin için ise 2.43 saniyedir. Uygun görülen modellere uygulanan chatbotların Gözlemci Formu performans başarı değeri SVM modeli %100, Logistic Regression modeli %90, LSTM modeli %60 başarı oranlarıyla tahminleme gerçekleştirmiştir. Benzer çalışmada chatbotların Gözlemci Formu gibi performans başarısını belirleyen değerlendirmeleri olmadığı için kıyaslama yapılamamıştır.

6. SONUÇ VE ÖNERİLER

Türkçe dili, milyonlarca insanın ana dili ya da günlük yaşamında kullandığı bir dil olduğu için Türkçe chatbotlar geniş bir kullanıcı topluluğuna hitap eder. Ana diliyle iletişim kurulan chatbotlar, atasözleri, deyimleri ve duygusal ifadeleri daha iyi analiz eder. Böylece chatbotlar ile kullanıcılar arasında daha anlamlı bir etkileşim kurulabilir.

Doğal dil işlemede Türkçe metinler üzerinde eğitilerek oluşturulan bir chatbot, kullanıcıların Türkçe yorumlarından daha başarılı duygu analizi değerlendirmesi yapar. Bu da kullanıcıların ürün veya hizmetlerle ilgili memnuniyetini artırır. Türkçe chatbotlar, Türkçe konuşan kullanıcılara yönelik ürün veya hizmetlerin pazarlama ve iletişimde önemli bir rol oynar. Kullanıcılar kendilerini daha iyi anlaşılmış ve değerli hissederek, bu durum müşteri memnuniyetini artırır ve kullanıcıların markaya olan bağlılığını da pekiştirir. Ayrıca Türkçe dilinde oluşturulan chatbot kullanıcıların sorularını hızlı ve kolay bir şekilde yanıtlarken, işletmeye müşterilerin aldığı hizmetle ilgili olumlu/olumsuz memnuniyet bilgisinin dönütünü daha başarılı verir. Böylece işletmelerin daha fazla müşteri kazanmasına ve müşterisini elinde tutmasına yardımcı olur. Bu nedenlerle, Türkçe dilinde chatbot oluşturmak hem kullanıcı deneyimini iyileştirmek hem de işletmeler için daha etkili iletişim ve pazarlama stratejileri geliştirmek için önemlidir. Doğru dilde doğru iletişim, chatbot uygulamalarının başarısını belirleyen önemli bir faktördür. Bu sebepler çalışmanın amacını ve kapsamını belirlemiştir.

Bu çalışmada duygu analizi modellerinin Türkçe metinler üzerindeki performansı ve uygulanan chatbotların başarı kıyaslaması için modellerin doğruluk oranlarına, performans sürelerine ve gözlemci formu verilerine bakıldı. Yapılan eğitim sonucunda en yüksek doğruluk oranına sahip olan Logistic Regression modeli, aynı zamanda çok kısa eğitim ve tahmin sürelerine sahip olduğu için pratik uygulamalar için en uygun seçenek olarak öne çıktı. Naive Bayes modeli de başarılı sonuçlar verirken, makul seviyede eğitim ve tahmin süreleriyle dikkat çekti. SVM modeli tatmin edici sonuçlar göstermesine rağmen eğitim ve tahmin sürelerinin biraz daha uzun olması, maliyet unsuruna bakılmalıdır. LSTM modeli ise diğer modellere yakın doğruluk oranına sahip ancak daha uzun süren eğitim ve tahmin süreleriyle daha yüksek maliyetli bir seçenek olarak belirlendi.

Chatbot uygulaması, klasik makine öğrenmesi modellerinden SVM ve Logistic Regression' a, derin öğrenme modeli olan LSTM' ye entegrasyonu gerçekleştirildi. Chatbot gözlemci formu verileri dikkate alındığında SVM ve Logistic Regression modellerinin duygusal analiz yeteneklerinin diğer makine öğrenme modellerine göre daha üstün olduğu görüldü. SVM ve Logistic Regression modellerin özellikle olumlu ve olumsuz yorumları doğru tahmin etmedeki başarıları yüksek ve doğruluk oranlarına paraleldi. Ancak LSTM modelinin özellikle olumsuz yorumlarda başarısının diğer modellere göre düşük olduğu ve doğruluk oranıyla uyummadığı gözlemlendi.

Bu çalışmanın sonucunda chatbotun Türkçe metinlerdeki duygusal analiz yeteneklerini değerlendirme ve kullanma sürecinde Logistic Regression ve SVM modellerinin tercih edilmesi önerilir. Bu modellerin başarılı duygu analizi yapabilmeleri, hızlı eğitim ve tahmin süreleri, gerçek zamanlı chatbot uygulamalarına daha uygun görüldü. Çünkü model seçimi yapılırken performans ölçütlerinin yanı sıra maliyet unsurlarının da göz önünde bulundurulması chatbot uygulamasının verimli bir şekilde kullanılabilmesi açısından önemlidir. Gelecekte, doğal dil işleme tekniklerinin ve makine öğrenme tekniklerinin daha kapsamlı kullanımıyla duygusal analiz performansının artırılması amaçlanmalıdır. Bu şekilde, dil çevirisindeki hatalar ve yanlış değerlendirmeler olmadan kullanıcıların ana dilinde deneyimini geliştiren ve duygusal tepkileri doğru şekilde analiz edebilen, maliyeti düşük chatbotlar tasarlanabilir.

KAYNAKLAR

- Adamopoulou, E., & Moussiades, L. (2020). An overview of chatbot technology. In IFIP international conference on artificial intelligence applications and innovations (pp. 373-383). Springer, Cham.
https://doi.org/10.1007/978-3-030-49186-4_31
- Ahmad, N. A., Che, M. H., Zainal, A., Abd Rauf, M. F., & Adnan, Z. (2018). Review of chatbots design techniques. *International Journal of Computer Applications*, 181(8), 7-10.
<https://doi.org/10.5120/ijca2018917606>
- Ak, E., & Tosun, A. (2020, October). "Graph-Based and Personalized Content Recommendations for Software Developers." In 2020 28th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE. <https://doi.org/10.1109/SIU49456.2020.9302381>
- ALPKOÇAK, A., TOCOGLU, M. A., ÇELİKTEN, A., AYGÜN, İ. (2019), "Türkçe Metinlerde Duygu Analizi için Farklı Makine Öğrenmesi Yöntemlerinin Karşılaştırılması." *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen Ve Mühendislik Dergisi*, 21(63): 719-725. <https://doi.org/10.21205/deufmd.2019216303>
- Ahmet, K. A. R. A. (2019), "Uzun-Kısa Süreli Bellek Ağı Kullanarak Global Güneş Işınımı Zaman Serileri Tahmini." *Gazi University Journal of Science Part C: Design and Technology*, 7(4): 882-892. <https://doi.org/10.29109/gujsc.571831>
- ALTINBAŞ, Ş. (2023). *ChatGPT DİJİTAL DİLİN BÜYÜSÜ*. KODLAB YAYIN DAĞITIM YAZILIM LTD. ŞTİ. [ChatGPT DİJİTAL DİLİN BÜYÜSÜ - Şahap ALTINBAŞ - Google Kitaplar](#)
- Atalay, M., & Çelik, E. (2017). Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamaları-artificial intelligence and machine learning applications in big data analysis. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22), 155-172.
<https://doi.org/10.20875/makusobed.309727>
- Bansal, H., & Khan, R. (2018). A review paper on human computer interaction. *International Journals of Advanced Research in Computer Science and Software Engineering*, 8(4), 53-56.
<https://doi.org/10.23956/ijarcsse.v8i4.630>

Bayes, T. (1968). Naive bayes classifier. *Article Sources and Contributors*, 1-9. <https://biomisa.org/wp-content/uploads/2019/10/Lect-7-DM.pdf>

bilgisayarkavramlari.com, (2024), <https://bilgisayarkavramlari.com/2008/10/02/yapay-sinir-aglarinin-egitimi-training-neural-networks/>, (e.t. 27.02.2024)

Bird, S. (2006, July).” NLTK: the natural language toolkit.” In *Proceedings of the COLING/ACL 2006 Interactive Presentation Sessions* (pp. 69-72). <https://aclanthology.org/P06-4018.pdf>

Boser, B. E., Guyon, I. M., & Vapnik, V. N. (1992, July). A training algorithm for optimal margin classifiers. In *Proceedings of the fifth annual workshop on Computational learning theory* (pp. 144-152). <https://doi.org/10.1145/130385.130401>

Chellappa, R., Theodoridis, S., & van Schaik, A. (2021),” Advances in Machine Learning and Deep Neural Networks”, *Proceedings of the IEEE*, 109(5) : 607-611. <https://doi.org/10.1109/JPROC.2021.3072172>

Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014).” Learning phrase representations using RNN encoder-decoder for statistical machine translation.” *arXiv preprint arXiv:1406.1078*. DOI: [10.3115/v1/D14-1179](https://doi.org/10.3115/v1/D14-1179)

Chopra, A., Prashar, A., & Sain, C. (2013). Natural language processing. *International journal of technology enhancements and emerging engineering research*, 1(4), 131-134. <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=eace1d14e266a5cd44fe781a874c662928602fd>

clickworker.com, (2024), <https://www.clickworker.com/ai-glossary/artificial-neural-network-ann-and-how-it-works/>, (e.t. 27.02.2024)

colab.research.google.com, 2024, <https://colab.research.google.com/?hl=tr>, (e.t. 16.03.2024)

ÇELİK, E., DAL, D., & AYDİN, T. (2021),” Duygu Analizi İçin Veri Madenciliği Sınıflandırma Algoritmalarının Karşılaştırılması.” *Avrupa Bilim ve Teknoloji Dergisi* (27): 880-889. <https://doi.org/10.31590/ejosat.905259>

Deng, L., & Yu, D. (2014) "Deep Learning: Methods and Applications." Foundations and Trends® in Signal Processing, 7(3–4), 197-387. <http://dx.doi.org/10.1561/20000000039>

Demirci, E., & KARAATLI, M. (2023). "KRİPTO PARA FİYATLARININ LSTM VE GRU MODELLERİ İLE TAHMİNİ." Mehmet Akif Ersoy Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 10(1), 134-157. <https://doi.org/10.30798/makuiibf.1035314>

Demirtas, E., & Pechenizkiy, M. (2013, August). "Cross-lingual polarity detection with machine translation." In Proceedings of the Second International Workshop on Issues of Sentiment Discovery and Opinion Mining (pp. 1-8). <https://doi.org/10.1145/2502069.2502078>

Deng, L., & Yu, D. (2014) "Deep Learning: Methods and Applications." Foundations and Trends® in Signal Processing, 7(3–4), 197-387. <http://dx.doi.org/10.1561/20000000039>

Doğan, K. ve Arslantekin, S. (2016), "Büyük Veri: Önemi, Yapısı ve Günümüzdeki Durum." DTCF Dergisi, 56 (1):15-36. https://doi.org/10.1501/Dtcfder_0000001461

en.wikipedia.org (2024), https://en.wikipedia.org/wiki/Confusion_matrix, (e.t.25.03.2024)

en.wikipedia.org, (2024), https://en.wikipedia.org/wiki/Long_short-term_memory, (e.t.28.02.2024)

Epstein, R., Roberts, G., & Beber, G. (Eds.). (2009). Parsing the Turing test (pp. 978-1). Dordrecht: Springer Netherlands. <https://doi.org/10.1007/978-1-4020-6710-5>

geeksforgeeks.org, (2024), <https://www.geeksforgeeks.org/artificial-neural-networks-and-its-applications/>, (e.t. 27.02.2024)

geeksforgeeks.org, (2024), <https://www.geeksforgeeks.org/natural-language-processing-overview/>, (e.t.28.02.2024)

geeksforgeeks.org, (2024), <https://www.geeksforgeeks.org/support-vector-machine-algorithm/?ref=lbp>, (e.t. 22.02.2024)

geeksforgeeks.org, (2024), <https://www.geeksforgeeks.org/understanding-logistic-regression/>, (e.t. 20.02.2024)

hosting.com.tr, (2024), <https://www.hosting.com.tr/blog/neural-networks>, (e.t. 27.02.2024)

Hsu, I. C., & Liao, A. H., (2022), “Sentiment-based chatbot using machine learning for recommendation system.”, DOI: <https://doi.org/10.21203/rs.3.rs-1468604/v1>

ibm.com, (2024), <https://www.ibm.com/topics/deep-learning>, (e.t. 26.02.2024)

Jakkula, V. (2006),” Tutorial on support vector machine (svm).” School of EECS, Washington State University, 37(2.5): 3. Corpus ID: 15115403

Jung, S. (2019). Semantic vector learning for natural language understanding. Computer Speech & Language, 56, 130-145. <https://doi.org/10.1016/j.csl.2018.12.008>

kaggle.com, 2023, <https://www.kaggle.com/datasets/ozcan15/turkish-sentiment-analysis-data-beyazperdecom>, (e.t. 02.09.2023)

Kanjanasurat, I., Jungsuwadee, W., Lasakul, A., & Benjangkaprasert, C. (2023),” Comparison of logistic regression and random forest algorithms for airport’s runway assignment.” In Journal of Physics: Conference Series (Vol. 2497, No. 1, p. 012016). IOP Publishing.
<https://doi.org/10.1088/1742-6596/2497/1/012016>

Khanna, A., Pandey, B., Vashishta, K., Kalia, K., Pradeepkumar, B., & Das, T. (2015). A study of today’s AI through chatbots and rediscovery of machine intelligence. International Journal of u-and e-Service, Science and Technology, 8(7), 277-284. <https://doi.org/10.14257/ijunesst.2015.8.7.28>

Kucherbaev, P., Bozzon, A., & Houben, G. J. (2018). Human-aided bots. IEEE Internet Computing, 22(6), 36-43. <https://doi.org/10.1109/MIC.2018.252095348>

Li, Y., & Yang, T. (2018). Word embedding for understanding natural language: a survey. Guide to big data applications, 83-104.https://doi.org/10.1007/978-3-319-53817-4_4

- Ligthart, A., Catal, C., & Tekinerdogan, B. (2021).” Systematic reviews in sentiment analysis: a tertiary study.” *Artificial Intelligence Review*, 1-57. <https://doi.org/10.1007/s10462-021-09973-3>
- Liu, C. Z., Sheng, Y. X., Wei, Z. Q., & Yang, Y. Q. (2018, August).” Research of text classification based on improved TF-IDF algorithm.” In 2018 IEEE International Conference of Intelligent Robotic and Control Engineering (IRCE) (pp. 218-222). IEEE.
<https://doi.org/10.1109/IRCE.2018.8492945>
- Loper, E., & Bird, S. (2002). “Nltk: The natural language toolkit.” arXiv preprint cs/0205028.
<https://doi.org/10.48550/arXiv.cs/02028>
- Maresh, B. (2020). “Machine Learning Algorithms- A Review.” *International Journal of Science and Research (IJSR)*, 9(1): 10-15. doi: 10.21275/ART20203995
- Maleki, F., Ovens, K., Najafian, K., Forghani, B., Reinhold, C., & Forghani, R. (2020). Overview of machine learning part 1: fundamentals and classic approaches. *Neuroimaging Clinics*, 30(4), e17-e32. <https://doi.org/10.1016/j.nic.2020.08.007>
- Maltarollo, V. G., Honório, K. M., & da Silva, A. B. F. (2013). Applications of artificial neural networks in chemical problems. *Artificial neural networks-architectures and applications*, 203-223.
[Artificial Neural Networks: Architectures and Applications - Google Kitaplar](#)
- Marietto, M. G. B., Aguiar, R. V., Barbosa, G. O., Botelho, W. T., Pimentel, E., França, R. S., & Silva, V. L. (2013). ARTIFICIAL INTELLIGENCE MARKUP LANGUAGE: A BRIEF TUTORIAL. *International Journal of Computer Science & Engineering Survey (IJCSES)*, 4(3).
<https://doi.org/10.5121/ijcses.2013.4301>
- medium.com, (2024), <https://medium.com/analytics-vidhya/understanding-recurrent-neural-network-rnn-and-long-short-term-memory-lstm-30bc1221e80d> (e.t. 28.02.2024)
- medium.com, (2024), <https://medium.com/machine-learning-community/chapter-2-naive-bayesclassification-supervised-machine-learning-algorithm-62f916708206>, (e.t. 20.02.2024)

medium.com, 2024, [Makine Öğrenimi — Temel Kavram | tarafından Datamir | Orta \(medium.com\)](#)
, (e.t. 18.02.2024)

Mehta, P., & Pandya, S. (2020).” A review on sentiment analysis methodologies, practices and applications.” International Journal of Scientific and Technology Research, 9(2), 601-609.
https://www.researchgate.net/profile/Pooja-Mehta-26/publication/344487215_A_Review_On_Sentiment_Analysis_Methodologies_Practices_And_Applications/links/5f7bfb2992851c14bcb16528/A-Review-On-Sentiment-Analysis-Methodologies-Practices-And-Applications.pdf

miesofficial.com, 2024, <https://miesofficial.com/blog/makine-ogrenmesi-nedir/> , (e.t. 18.02.2024)

Millman, K. J., & Aivazis, M. (2011). “Python for scientists and engineers”. Computing in science & engineering, 13(2), 9-12. DOI: [10.1109/MCSE.2011.36](https://doi.org/10.1109/MCSE.2011.36)

Mingzhe, Hu., Yu, Zhang. (2022). An empirical study of the Python/C API on evolution and bug patterns. Journal of Software: Evolution and Process, 35(2) doi: 10.1002/smr.2507

Mitchell, T., Hutchinson, R., Just, M., Newman, S., Niculescu, R., Periera, F., & Wang, X. (2002, December). Machine learning of fMRI virtual sensors of cognitive states. In *The 16th Annual Conference on Neural Information Processing Systems, Computational Neuroimaging: Foundations, Concepts and Method Workshop*
https://www.researchgate.net/publication/228714347_Machine_learning_of_fMRI_virtual_sensors_of_cognitive_states

miuul.com, (2024), <https://miuul.com/not-defteri/ml101-makine-ogrenmesi-nedir>, (e.t. 18.02.2024)

ncbi.nlm.nih.gov, (2024), <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6347705/>, (e.t. 26.02.2024)

Nick, T. G., & Campbell, K. M. (2007). Logistic regression. *Topics in biostatistics*, 273-301.
https://doi.org/10.1007/978-1-59745-530-5_14

ÖZTÜRK, K., & ŞAHİN, M. E. (2018),” Yapay Sinir Ağları ve Yapay Zekâ’ya Genel Bir Bakış.” Takvim-I Vekayi, 6(2): 25-36. <https://dergipark.org.tr/en/download/article-file/596690>

python.org, 2024, <https://www.python.org/about/>, (e.t. 16.03.2024)

Ramesh, K., Ravishankaran, S., Joshi, A., & Chandrasekaran, K. (2017, May). A survey of design techniques for conversational agents. In International conference on information, communication and computing technology (pp. 336-350). Singapore: Springer Singapore. https://doi.org/10.1007/978-981-10-6544-6_31

Sánchez-Rada, J. F., & Iglesias, C. A. (2019).” Social context in sentiment analysis: Formal definition, overview of current trends and framework for comparison.” Information Fusion, 52, 344-356. <https://doi.org/10.1016/j.inffus.2019.05.003>

Schmidt, R. M. (2019).” Recurrent neural networks (rnns): A gentle introduction and overview.” arXiv preprint arXiv:1912.05911. <https://doi.org/10.48550/arXiv.1912.05911>

scholarpedia.org, (2024), http://www.scholarpedia.org/article/Deep_Learning (e.t. 28.02.2024)

scikit-learn.org, (2024), https://scikit-learn.org/stable/modules/naive_bayes.html, (e.t. 20.02.2024)

Seker, S. E. (2015). Doğal Dil İşleme (Natural Language Processing). YBS Ansiklopedi, 2(4). Retrieved from <https://ybsansiklopedi.com/wp-content/uploads/2015/09/ybsddi.pdf>

Seker, S. E. (2016).” Duygu Analizi (Sentimental Analysis).” YBS Ansiklopedi, 3(3): 21-36.

Shawar, B. A., & Atwell, E. (2007). Chatbots: are they really useful?. Journal for Language Technology and Computational Linguistics, 22(1), 29-49. DOI:10.21248/jlcl.22.2007.88

Shiri, F. M., Perumal, T., Mustapha, N., & Mohamed, R. (2023).” A comprehensive overview and comparative analysis on deep learning models: CNN, RNN, LSTM, GRU. “arXiv preprint arXiv:2305.17473. <https://doi.org/10.48550/arXiv.2305.17473>

smartmind.com.tr, (2024), <https://www.smartmind.com.tr/yapay-sinir-agi-nedir-i-965>, (e.t. 27.02.2024)

- Soofi, A. A., & Awan, A. (2017),” Classification techniques in machine learning: applications and issues.” *Journal of Basic & Applied Sciences*, 13(1): 459-465. <https://doi.org/10.6000/1927-5129.2017.13.76>
- Spärck Jones, K. (2004). IDF term weighting and IR research lessons. *Journal of documentation*, 60(5), 521-523. <https://doi.org/10.1108/00220410410560591>
- Sunitha, S. (2021),” An Overview of Deep Learning.” *International Journal of Engineering Research & Technology (IJERT) ICRADL – 2021 (Volume 09 – Issue 05)*. DOI: 10.17577/IJERTCONV9IS05064
- Toraman, C., Yılmaz, E. H., Şahinuç, F., & Özçelik, O. (2023).” Tokenizasyonun dil modelleri üzerindeki etkisi: Türkçe için bir analiz.” *Asya ve Düşük Kaynaklı Dil Bilgi İşlemede ACM İşlemleri*, 22(4), 1-21. <https://doi.org/10.1145/3578707>
- Totade, S. K., Bhombre, P., & Bagde, M. (2023),” Natural Language Processing (NLP): A Review.” *International Research Journal of Innovations in Engineering and Technology (IRJIET)*, 7(10):589-593. <https://doi.org/10.47001/IRJIET/2023.710078>
- Triantafyllou, S. A. (2024),” Artificial Intelligence: An Overview. Concept Paper.” Retrieved from <https://doi.org/10.20944/preprints202401.1634.v1>
- Turing, A. M. (2009). *Computing machinery and intelligence* (pp. 23-65). Springer Netherlands. <https://doi.org/10.1093/mind/LIX.236.433>
- Vargas, R., Mosavi, A., & Ruiz, R. (2017),” Deep learning: a review.” [Working Paper]. Retrieved from <https://eprints.qut.edu.au/127354/>
- Vennerød, C. B., Kjærran, A., & Bugge, E. S. (2021),” Long short-term memory RNN.” *arXiv preprint arXiv:2105.06756*. <https://doi.org/10.48550/arXiv.2105.06756>
- YILMAZ, M. C., & ORMAN, Z. (2021),” LSTM Derin Öğrenme Yaklaşımı ile Covid-19 Pandemi Sürecinde Twitter Verilerinden Duygu Analizi.” *Acta Infologica*, 5(2): 359-372. <https://doi.org/10.26650/acin.947747>

Wasnik, C. T., & Mankar, K. (2019),” Machine learning techniques: A review.” *International Journal for Research in Applied Science & Engineering Technology (IJRASET)*, 7.

Wankhade, M., Rao, A. C. S., & Kulkarni, C. (2022).” A survey on sentiment analysis methods, applications, and challenges.” *Artificial Intelligence Review*, 55(7), 5731-5780.<https://doi.org/10.1007/s10462-022-10144-1>

Weizenbaum, J. (1966). ELIZA—a computer program for the study of natural language communication between man and machine. *Communications of the ACM*, 9(1), 36-45.
<https://doi.org/10.1145/365153.365168>

Wikipedia, (2024), [Yapay zekâ - Vikipedi \(wikipedia.org\)](https://pt.wikipedia.org/wiki/Yapay_zekâ), (e.t. 06.02.2024).

Xiao, Y., & Yin, Y. (2019),” Hybrid LSTM neural network for short-term traffic flow prediction.” *Information*, 10(3): 105. DOI:[10.3390/info10030105](https://doi.org/10.3390/info10030105)