

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME ALGORİTMALARI İLE PERSONEL GERİ
BİLDİRİMLERİNİN SINIFLANDIRILMASI VE ANALİZİ

YÜKSEK LİSANS TEZİ

Gökhan YİĞİDEFE

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Bilim Dalı

MAYIS 2025

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME ALGORİTMALARI İLE PERSONEL GERİ
BİLDİRİMLERİNİN SINIFLANDIRILMASI VE ANALİZİ

YÜKSEK LİSANS TEZİ

Gökhan YİĞİDEFE

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Bilim Dalı

Tez Danışmanı: Dr.Öğr.Üyesi Serap ÇAKAR KAMAN

MAYIS 2025

Gökhan Yiğidefe tarafından hazırlanan “DERİN ÖĞRENME ALGORİTMALARI İLE PERSONEL GERİ BİLDİRİMLERİNİN SINIFLANDIRILMASI VE ANALİZİ” adlı tez çalışması 14.05.2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Bilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı : **Doç.Dr. Zeynep GARİP**
Sakarya Uygulamalı Bilimler Üniversitesi

Jüri Üyesi : **Dr.Öğr.Üyesi Serap ÇAKAR KAMAN** (Danışman)
Sakarya Üniversitesi

Jüri Üyesi : **Dr.Öğr.Üyesi Gözde YOLCU ÖZTEL**
Sakarya Üniversitesi



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “DERİN ÖĞRENME ALGORİTMALARI İLE PERSONEL GERİ BİLDİRİMLERİNİN SINIFLANDIRILMASI VE ANALİZİ” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(14/05/2025).

Gökhan YİĞİDEFE





Kızım Masal Yiğidefe'ye



TEŐEKKÜR

Bu alıőmanın her aőamasında deęerli bilgi ve deneyimleriyle bana rehberlik eden, ynlendirmeleriyle araőtırmamın geliőimine byk katkı saęlayan Dr. ęr. yesi Serap akar Kaman hocama en iten teőekkrlerimi sunarım.

Kendilerinin akademik donanımı, zverili destekleri ve yol gsterici yaklaőımları sayesinde, alıőmamı daha saęlam temellere oturtma ve derinlemesine bir analiz yapma fırsatı buldum. Bilimsel bakıő aımı geliőtirmemde, problem özme yetkinlięimi artırmamda ve akademik disiplinimi oluőturmamda byk emekleri olan hocalarıma minnettarım.

Destekleri, anlayıőları ve sabırları iin kendilerine sonsuz teőekkr ederim.

Saygılarımla,

Gkhan YİęİDEFE



İÇİNDEKİLER

Sayfa

TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
TABLO LİSTESİ	xv
ŞEKİL LİSTESİ	xvii
ÖZET	xix
SUMMARY	xxi
1. GİRİŞ	1
1.1. Tezin Kapsamı	1
1.2. Tezin Amacı	1
1.3. Literatür Taraması	2
2. KULLANILAN YÖNTEMLER	5
2.1. TCN	5
2.2. CNN	8
2.3. LSTM	10
2.4. BERT	12
3. UYGULAMA ADIMLARI VE DENEYSEL SONUÇLAR	15
3.1. Veri Seti	16
3.2. Veri Ön İşleme	18
3.3. Modellerin Tanımlanması	18
3.4. Modellerin Eğitilmesi ve Parametre Ayarlamaları	20
3.5. Çapraz Doğrulama İşlemi	21
3.6. Modellerin Değerlendirilmesi	22
4. SONUÇLAR ve ÖNERİLER	29
KAYNAKLAR	31
ÖZGEÇMİŞ	35



KISALTMALAR

BERT	: Bidirectional Encoder Representations from Transformers (Çift Yönlü Transformer Kodlayıcı)
CLS	: Classification Token (Sınıflandırıcı Belirteç)
CNN	: Convolutional Neural Network (Evrşimsel Sinir Ağları)
LSTM	: Long Short Term Memory (Uzun Kısa-Vadeli Bellek)
mAP	: Mean Average Precision (Ortalama Ortalama Hassasiyet)
MLM	: Masked Language Modeling (Maskeli Dil Modellemesi)
NLP	: Natural Language Processing (Doğal Dil İşleme)
NSP	: Next Sentence Prediction (Sonraki Cümle Tahmini)
ReLU	: Rectified Linear Unit (Doğrultulmuş Doğrusal Birim)
RNN	: Recurrent Neural Network (Yinelemeli Sinir Ağları)
SEP	: Separator Token (Ayırıcı Belirteç)
TCN	: Temporal Convolutional Networks (Zamansal Evrşimsel Ağlar)



TABLO LİSTESİ

Sayfa

Tablo 3.1. Kategorilere göre gerçek ve sentetik cümleler.....	17
Tablo 3.2. Modellerde kullanılan parametre değerleri	21
Tablo 3.3. Modellerin performans değerleri.....	24





ŞEKİL LİSTESİ

Sayfa

Şekil 2.1. TCN'in çalışma mimarisi	6
Şekil 2.2. CNN'in çalışma mimarisi	9
Şekil 2.3. LSTM'in çalışma mimarisi	11
Şekil 2.4. BERT'in çalışma mimarisi	13
Şekil 3.1. Çalışmanın metodolojisi	16
Şekil 3.2. Çapraz doğrulama mantığı	22
Şekil 3.3. Modellerin mAP grafikleri	23
Şekil 3.4. Modellerin kayıp grafikleri	24
Şekil 3.5. TCN modeli ortalama karmaşıklık matrisi	25
Şekil 3.6. CNN modeli ortalama karmaşıklık matrisi	26
Şekil 3.7. LSTM modeli ortalama karmaşıklık matrisi	26
Şekil 3.8. BERT modeli ortalama karmaşıklık matrisi	27



DERİN ÖĞRENME ALGORİTMALARI İLE PERSONEL GERİ BİLDİRİMLERİNİN SINIFLANDIRILMASI VE ANALİZİ

ÖZET

Bu çalışma, kurumsal sürdürülebilirlik ve verimlilikte kritik rol oynayan personel memnuniyeti ve motivasyonunun, yapay zeka destekli analiz yöntemleriyle sistematik biçimde değerlendirilmesini amaçlamaktadır. Geri bildirimlerin manuel olarak analiz edilmesinin zorlukları, özellikle büyük veri kümeleri karşısında zaman ve kaynak açısından verimsiz hale gelmekte, bu da kurumların stratejik karar alma mekanizmalarını sekteye uğratmaktadır. Bu noktadan hareketle, çalışmada NLP ve derin öğrenme mimarileri kullanılarak personel geri bildirimlerinin sınıflandırılması hedeflenmiştir. Derin öğrenme tabanlı modeller olan Zamansal Evrişimsel Ağlar (TCN), Evrişimsel Sinir Ağları (CNN), Uzun Kısa Süreli Bellek (LSTM) ve çift yönlü bağlam anlayışı sunan BERT mimarileri kullanılmış; bu modellerin metin sınıflandırma performansları karşılaştırmalı olarak analiz edilmiştir.

Veri kümesi, Türkiye'de özel bir şirkette yürütülen toplantılar, anketler ve birebir görüşmeler sonucunda toplanan 386 özgün Türkçe geri bildirim cümlesi ve bunlara dayanarak oluşturulan 6.614 sentetik örnekten oluşan dengeli ve etiketlenmiş 7.000 cümlelik bir veri setinden oluşmaktadır. Veriler 14 farklı kategoriye ayrılarak etiketlenmiş, ardından veri temizleme, tokenizasyon, sayısallaştırma, padding ve encoding gibi ön işleme adımları gerçekleştirilmiştir. Model eğitim süreci 5 katlı çapraz doğrulama yöntemiyle yapılandırılmış ve doğruluk, kayıp, kesinlik, geri çağırma ve F1 puanı gibi performans metrikleri üzerinden değerlendirme yapılmıştır.

Analiz sonuçlarına göre, CNN modeli %96,40 doğruluk ve %96,41 F1 puanı ile en yüksek sınıflandırma performansını sergilemiştir. BERT modeli, %94,91 doğruluk oranı ile ikinci sırada yer almış ve bağlamsal anlayış gücü sayesinde güçlü sonuçlar üretmiştir. Ancak BERT'in eğitim süresi (245,56 sn) ve işlem maliyeti diğer modellere göre daha yüksektir. TCN modeli %94,36 doğruluk oranı ile tatmin edici bir performans göstermiş ve en kısa eğitim süresi (43,51 sn) ile dikkat çekmiştir. LSTM ise %93,70 doğruluk ile görece olarak daha düşük performans sergilemiştir. Bu bulgular, CNN'in personel geri bildirimlerini sınıflandırmada en etkili model olduğunu ortaya koymakta; BERT'in ise bağlamsal derinliği ile sınıflandırma kalitesini artırabileceğini göstermektedir.

Çalışma, yalnızca model karşılaştırması sunmakla kalmayıp, aynı zamanda Türkçe kurumsal veri seti üzerinde metin sınıflandırma uygulamalarının önemini ortaya koymaktadır. Elde edilen bulgular, insan kaynakları yönetimi, organizasyonel gelişim ve iç iletişim gibi alanlarda veri temelli yaklaşımların etkinliğini desteklemektedir. Ayrıca, veri ön işleme adımlarının metin sınıflandırmadaki etkisi ayrıntılı biçimde değerlendirilmiş, her modelin mimarisi ve avantajları derinlemesine ele alınmıştır.

Gelecek çalışmalar için öneriler arasında; CNN ve BERT mimarilerinin hibrit kullanımı ile daha yüksek doğruluk oranlarına ulaşılması, model sıkıştırma teknikleriyle eğitim süresinin azaltılması, farklı sektörlerden veri kullanımıyla

modellerin genellenebilirliđinin test edilmesi ve duygu analizi ile konu modelleme gibi ileri NLP görevlerinin entegre edilmesi yer almaktadır. Bu bağlamda çalışma, kurumsal ölçekte personel verilerinin anlamlandırılmasında etkili ve sürdürülebilir bir yöntem sunmaktadır.

Anahtar Kelimeler: Personel Geri Bildirim Sınıflandırması, TCN, CNN, LSTM, BERT, Derin Öğrenme ile Metin Analizi, Doğal Dil İşleme



CLASSIFICATION AND ANALYSIS OF EMPLOYEE FEEDBACK WITH DEEP LEARNING ALGORITHMS

SUMMARY

This study aims to analyze employee feedback using AI automatically supported deep learning methods, based on the critical influence of employee satisfaction and motivation on organizational success. The insufficiency of traditional analysis methods when faced with large datasets has highlighted the need for novel and scalable approaches. In this context, employee feedback is categorized through text classification algorithms, producing deep insights that contribute to managerial decision-making processes. This facilitates the development of data-driven strategies and supports institutions in achieving their sustainability and efficiency goals.

The study specifically focuses on analyzing Turkish language employee feedback to provide systematic and data-oriented contributions to organizational decision-making. Through the AI-based text classification approaches developed within the scope of the research, employee opinions are transformed into meaningful insights and strategic information, yielding outputs that support executive-level guidance. Machine learning and deep learning techniques are employed to effectively analyze large volumes of unstructured data and integrate the results into decision support systems. In doing so, the study supports a digital transformation process aligned with modern governance needs such as transparency and rapid decision-making.

Furthermore, the study goes beyond merely focusing on model accuracy; it also conducts a comprehensive evaluation of processing time, resource consumption, and the compatibility of model architectures with the task at hand. This multidimensional analysis provides a clearer picture of each model's advantages and disadvantages in practical applications.

In contrast to most existing research that focuses on customer reviews, this study seeks to fill a gap in the literature by concentrating directly on employee feedback. Real feedback data anonymized and collected from a private company in Turkey was supplemented with synthetically generated sentences via ChatGPT and categorized accordingly. Various deep learning models TCN, CNN, LSTM, and BERT were applied to these categories, and a comparative performance analysis was conducted. Additionally, the impact of NLP processes such as data cleaning and tokenization on model performance was evaluated. The thesis thus offers both a solid theoretical foundation and a practical AI-based model proposal.

Recent academic studies in the field of text classification aim to categorize data obtained from various sources into thematic classes. In studies involving Turkish content, customer reviews, news texts, social media posts, and product evaluations have been commonly used to achieve objectives such as sentiment analysis, topic classification, and user demand interpretation. Accordingly, both traditional machine learning methods and advanced deep learning models have been analyzed in detail.

Among the most frequently used algorithms in the literature are traditional machine learning techniques such as Naive Bayes, Decision Trees, Random Forest, CatBoost, XGBoost, Logistic Regression, and Support Vector Machines (SVM). Additionally, deep learning architectures like LSTM, CNN, GRU, BERT, and TCN have gained prominence. Word2Vec, TF-IDF, and FastText are commonly used for vector representation of texts, while techniques like SMOTE are applied to address data imbalance. Notably, BERT's contextual understanding and LSTM's success in time series data have been shown to significantly improve accuracy rates. Some studies have also reported that hybrid models like CNN LSTM yield superior performance.

The shared goal of these studies is to compare the accuracy, speed, and overall effectiveness of various classification algorithms to identify the most efficient model structures and to render text analytics faster, more accurate, and more automated. The results demonstrate that deep learning approaches outperform traditional methods, especially in processing large and complex datasets. This represents a significant advancement in the processing and classification of Turkish texts for both academic and industry applications.

In this context, modern deep learning models such as TCN, CNN, LSTM, and BERT are notable for their ability to provide tailored solutions for different data types and problem domains. Each model, with its unique structural features and learning capabilities, achieves significant success in natural language processing tasks. The choice of model depends on factors such as data type, processing time, contextual analysis needs, and computational resources.

TCN is a convolutional deep learning architecture designed to model sequential dependencies in time series data. Unlike traditional RNNs, TCN employs causal convolutions to process temporal information without feedback mechanisms. Dilated convolutions enable learning of long-term dependencies, while residual connections accelerate training by improving information flow. These properties make TCN an effective choice for large-scale data environments due to its parallelization capability and short training time.

While CNNs are primarily known for their performance on image data, they have also demonstrated success in text classification tasks. By leveraging convolution and pooling layers, CNNs capture local patterns in text which are then processed by fully connected layers for classification. Activation functions like ReLU and Softmax enhance the model's ability to learn non-linear relationships. With high accuracy, fast training, and stable outputs, CNN stands out as a powerful tool in text analytics.

LSTM is a recurrent neural network architecture well suited for sequential data due to its ability to learn long-term dependencies. Through forget, input, and output gates, it manages information flow effectively and can capture both short and long-range relationships. LSTM is widely used in domains such as NLP speech recognition, and financial forecasting. When paired with attention mechanisms, it demonstrates enhanced contextual interpretation in more complex tasks.

BERT is a modern language model based on the Transformer architecture, capable of learning contextual representations through bidirectional processing. Pretrained using Masked Language Modeling (MLM) and Next Sentence Prediction (NSP), BERT utilizes self-attention mechanisms to analyze relationships between all tokens in a sentence. These features allow it to achieve high accuracy in tasks such as classification, sentiment analysis, and information extraction. However, its high

computational cost and long training duration must be considered in practical applications.

All four models were implemented in Python using the Google Colab environment. To ensure class balance, each category was enriched with an equal number of synthetic and real sentences. The models were trained using Stratified 5-Fold Cross Validation and compared across several performance metrics. While CNN delivered the highest performance across all criteria, BERT stood out with its contextual analysis capabilities. TCN was notable for its low computational cost, and LSTM lagged in both accuracy and training efficiency.

In terms of comparative performance, CNN achieved the best results with 96.40% accuracy, an F1 score of 96.41%, and the lowest test loss at 14.74%. BERT followed closely with 94.91% accuracy and a 23.37% test loss but required a significantly longer training time of 245.56 seconds. TCN, with 94.36% accuracy and the fastest training time of 43.51 seconds, proved efficient but less accurate. LSTM, though structurally suited for sequential data, performed worst with 93.70% accuracy, a 38.92% test loss, and a relatively high training time of 98.84 seconds.

In conclusion, CNN emerged as the most reliable model for text classification due to its high accuracy, speed, and generalization capacity. BERT showed comparable performance in contextual understanding but was hindered by high computational demands. TCN offered a fast and practical solution but lacked classification precision, while LSTM fell short in both resource efficiency and accuracy despite its strength in sequential data processing.

Future research could explore hybrid models combining CNN's accuracy with BERT's contextual learning to further enhance classification performance. Model compression, transfer learning, and training optimization techniques may improve computational efficiency. Expanding datasets with feedback from various industries and integrating advanced NLP applications such as sentiment analysis and topic modeling could further amplify the strategic value of employee feedback in organizational decision-making.

Keywords: Employee Feedback Classification, TCN, CNN, LSTM, BERT, Text Analysis with Deep Learning, Natural Language Processing



1. GİRİŞ

Günümüz rekabetçi iş dünyasında, örgütlerin sürdürülebilir başarısı büyük ölçüde çalışan memnuniyeti ve motivasyonuna bağlıdır. Çalışanlardan düzenli olarak alınan geri bildirimler, kurumların iç dinamiklerini anlamasına, zayıf noktalarını tespit etmesine ve stratejik karar alma süreçlerini daha etkili yürütmesine olanak tanımaktadır. Ancak, bu tür geri bildirimlerin hacmi arttıkça, geleneksel analiz yöntemleri yetersiz kalmakta ve organizasyonlar daha hızlı, doğru ve ölçeklenebilir çözümler arayışına girmektedir. Bu bağlamda, yapay zeka destekli metin sınıflandırma algoritmaları, çalışan geri bildirimlerini anlamlı kategorilere ayırarak kurumsal içgörülerin oluşturulmasına katkı sunmaktadır. Bu tez, çalışan geri bildirimlerinin otomatik analizini derin öğrenme yöntemleriyle gerçekleştirerek, karar destek sistemlerine entegre edilebilir bilgi üretmeyi ve örgütsel gelişime veri temelli bir yaklaşım kazandırmayı amaçlamaktadır.

1.1. Tezin Kapsamı

Türkçe cümlelerden oluşan personel geri bildirimlerini analiz ederek, örgütsel karar alma süreçlerine katkı sağlamaktır. Çalışma, çalışanlardan gelen geri bildirimleri anlamlı içgörülere dönüştürmeyi, bu içgörülerini uygulanabilir stratejik bilgilere çevirmeyi ve nihayetinde personel memnuniyetini, motivasyonunu ve bağlılığını artırarak örgütsel verimliliği geliştirmeyi hedeflemektedir. Makine öğrenmesi ve derin öğrenme tabanlı metin sınıflandırma tekniklerinin kullanılmasıyla, büyük ölçekli yapılandırılmamış veriler sistematik şekilde analiz edilerek karar destek mekanizmalarına entegre edilmesi amaçlanmaktadır. Bu bağlamda, tez; şeffaflık, hızlı karar alma ve sürekli iyileştirme ilkeleri doğrultusunda iş süreçlerinin dijital dönüşümüne katkı sunmayı hedeflemektedir.

1.2. Tezin Amacı

Personel geri bildirimlerinin analizine yönelik mevcut literatürdeki boşlukları gidermek üzere kurgulanmıştır. İlk olarak, müşteri yorumları veya sosyal medya

içeriklerine odaklanan çalışmaların aksine, bu tez kuruma özgü, özellikle de çalışan geri bildirimlerine dayalı verilerin analizine odaklanmaktadır. Türkiye’de özel bir şirkette yapılan toplantılardan elde edilen ve anonimleştirilen gerçek geri bildirimler belirli kategorilere ayrılmış; bu veri kümesi sentetik cümlelerle desteklenerek genişletilmiştir. İkinci olarak, çalışma yalnızca tek bir modele değil, TCN, CNN, LSTM ve BERT gibi farklı derin öğrenme mimarilerine dayalı metin sınıflandırma algoritmalarının karşılaştırmalı performans analizine yer vermektedir. Son olarak, veri temizleme ve tokenizasyon gibi NLP süreçlerinin sınıflandırma başarısına etkisi ayrıntılı olarak ele alınmıştır. Tezin kapsamı, çalışan geri bildirimlerinin sistematik analizine dair teorik bilgiyle birlikte, uygulamalı bir derin öğrenme temelli model önerisi sunmaktadır.

1.3. Literatür Taraması

Literatürde, metin sınıflandırması için çeşitli makine öğrenmesi yöntemleri kullanılmıştır. Kayakuş ve arkadaşları tarafından yapılan çalışmada, Türkiye’deki beş haber sitesinden toplanan 10500 haber, Naive Bayes ve karar ağacı yöntemleri kullanılarak dünya, spor ve ekonomi olmak üzere üç sınıfa ayrılmıştır. Naive Bayes %88,66 doğruluk oranı ile daha iyi performans göstermiştir [1]. Bozkurt ve arkadaşları Amazon gıda incelemelerini Random Forest (RF), CatBoost ve XGBoost algoritmalarını kullanarak sınıflandırmış, RF %90,22 doğrulukla en yüksek performansı elde etmiştir [2]. Tuna ve arkadaşları Türkçe metinler için hedef kategorileri belirlemeye yönelik bir model önermişler ve FastText modelinin hedef terimleri belirlemede en iyi performansı gösterdiğini ortaya koymuşlardır [3]. Öge ve arkadaşları IMDB film incelemeleri üzerinde yaptıkları çalışmada, Lojistik Regresyon ve DVM algoritmalarının Word2Vec yöntemi ile birleştirildiğinde iyi performans gösterdiğini bulmuşlardır [4]. Metin ve arkadaşları tarafından yapılan bir başka çalışmada, jiroskop ve ivmeölçer verileri kullanılarak insan aktivitesi sınıflandırması yapılmış, TSA ve ESA yöntemleri ile sırasıyla %97 ve %99 doğruluk elde edilmiştir. Çalışmada ayrıca insan aktivitesi sınıflandırması için yeni bir veri kümesi ve yazılım araçları tanıtılmıştır [5]. Aydemir ve arkadaşları, Türkçe haber makalelerini sekiz farklı kategoriye ayırmış ve RF algoritması %99,86 doğrulukla en iyi performansı elde etmiştir [6]. Akgümüş ve arkadaşları, Multinomial Naive Bayes modelinin %99 doğruluk oranına ulaştığını ve bankacılık sektöründeki müşteri şikayetlerini sınıflandırmak için etkili bir araç olduğunu göstermiştir [7].

Son yıllarda, derin öğrenme yöntemleri literatürde metin sınıflandırması için giderek daha fazla kullanılmaktadır. Ertem ve arkadaşları tarafından yapılan çalışmada, COVID-19 aşı karışıklığını %99,23 doğrulukla tespit etmek için LSTM ve özellik seçimi teknikleri kullanılmıştır. Veri dengesizliği SMOTE yöntemi ve TF-IDF kullanılarak ele alınmıştır [8]. Demirbilek ve arkadaşları, LSTM ve makine öğrenimi yöntemlerini kullanarak Orta Anadolu'daki bir üniversitenin Google incelemeleri üzerinde duygu analizi gerçekleştirmiş ve Amazon Comprehend tüm metriklerde en iyi performansı göstermiştir [9]. Çataltaş ve arkadaşları Türkçe COVID-19 tweetlerini analiz etmiş ve bir CNN-LSTM modelinin duyarlılık sınıflandırması için %76 ve %84 doğruluk elde ettiğini göstermiştir [10]. Güler ve arkadaşları Türkçe haber makalelerini ve e-ticaret incelemelerini incelemiş, KSA tabanlı derin öğrenme modeli sırasıyla %91,7 ve %95,6 doğruluk elde etmiştir [11]. Yılmaz ve arkadaşları bir yardım masası sistemindeki 28.104 talebi sınıflandırmış ve LSTM modeli ile %97,60 doğruluk elde etmiştir [12]. Budak ve arkadaşları, derin öğrenme yöntemlerinin COVID-19 öncesi ve sonrası havayolu incelemelerini analiz etmede daha iyi performans gösterdiğini bulmuştur [13]. Sel ve arkadaşları çalışmalarında, Türkçe Twitter gönderilerinden cinsiyet tahmini yapmak için BERT, LSTM ve CNN modellerini kullanmış ve BERT %80,1 ile en yüksek doğruluğu elde etmiştir [14]. Acı ve arkadaşları Türkçe haber makaleleri için Word2Vec ve KSA yöntemlerini kullanmış ve KSA'nın klasik yöntemlere göre %93,3 daha yüksek doğruluk sağladığını göstermiştir [15]. Bişkin'in çalışması, Avrupa ülkelerindeki COVID-19 vakalarını tahmin etmek için TCN'yi uygulamış ve TCN'nin daha düşük hesaplama süresi ve daha yüksek tahmin doğruluğu açısından LSTM ve GRU modellerinden daha iyi performans gösterdiğini göstermiştir [16]. Kasapbaşı ve arkadaşları, CNN tabanlı derin öğrenme modellerini kullanarak Türk İşaret Dili (TİD) hareketlerini metne dönüştürmeyi amaçlamış ve %98 gibi yüksek bir doğruluk elde etmiştir [17]. Erol ve arkadaşları CNN, LSTM ve GRU gibi modeller kullanarak satış tahmini yapmış, özellikle mevsimsellik ve trendler içeren veri kümelerinde LSTM ve varyantlarının en iyi performansı gösterdiği sonucuna varmıştır [18]. Tuna ve arkadaşları, DeepCusComp-1 modelinin müşteri şikayetlerini sınıflandırmada %85,83 doğruluk elde ederek diğer yöntemlerden daha iyi performans gösterdiğini ortaya koymuştur [19]. Aydın'ın çalışması LSTM ve BERT tabanlı modelleri karşılaştırmış ve BERT'in LSTM'den daha iyi performans gösterdiğini ortaya koymuştur [20]. Arslan vd. sosyal medya verilerini kullanarak BERT tabanlı modellerin duruş tespitindeki başarısını

göstermiştir [21]. Gür, CNN, LSTM ve GRU modellerini karşılaştırmış ve hibrit bir CNN-LSTM-GRU modelinin en düşük hata oranlarını ve en iyi R^2 değerlerini elde ettiğini bulmuştur [22]. Demirbilek ve arkadaşları AWS Comprehend ile derin öğrenme yöntemlerini karşılaştırmış ve AWS Comprehend'in tüm metriklerde en yüksek performansı elde ettiğini belirtmiştir [23]. Kahraman ve arkadaşları BERT'i patent metinlerini sınıflandırmak için etkili bir araç olarak tanımlamıştır [24]. Aydın ve arkadaşları, BERT tabanlı modellerin işlem süresi ve doğruluk açısından LSTM modellerinden daha verimli olduğunu bulmuştur [25]. Sel ve arkadaşları, BERT'in kısa ve yapılandırılmamış metinlerde bile yüksek doğruluk elde ettiğini ve Twitter tabanlı analizler yoluyla cinsiyet tahmininde iyi performans gösterdiğini vurgulamıştır [26].



2. KULLANILAN YÖNTEMLER

TCN, CNN, LSTM ve BERT, modern derin öğrenme alanında temel mimariler arasında yer almaktadır. TCN ve LSTM zaman serisi analizinde üstün performans sergilerken, CNN görüntü işlemede baskın bir konuma sahiptir ve BERT, NLP görevlerinde yüksek başarı elde etmektedir. Bu modeller, kendine özgü mekanizmalar aracılığıyla veri özelliklerini çıkararak karmaşık problemlere etkili çözümler sunmaktadır. Özellikle BERT, çift yönlü bağlam anlayışı sayesinde NLP alanında öne çıkarken, TCN ve LSTM zamansal bağımlılıkları etkili bir şekilde modellemekte, CNN ise görsel özellikleri verimli bir biçimde yakalamaktadır.

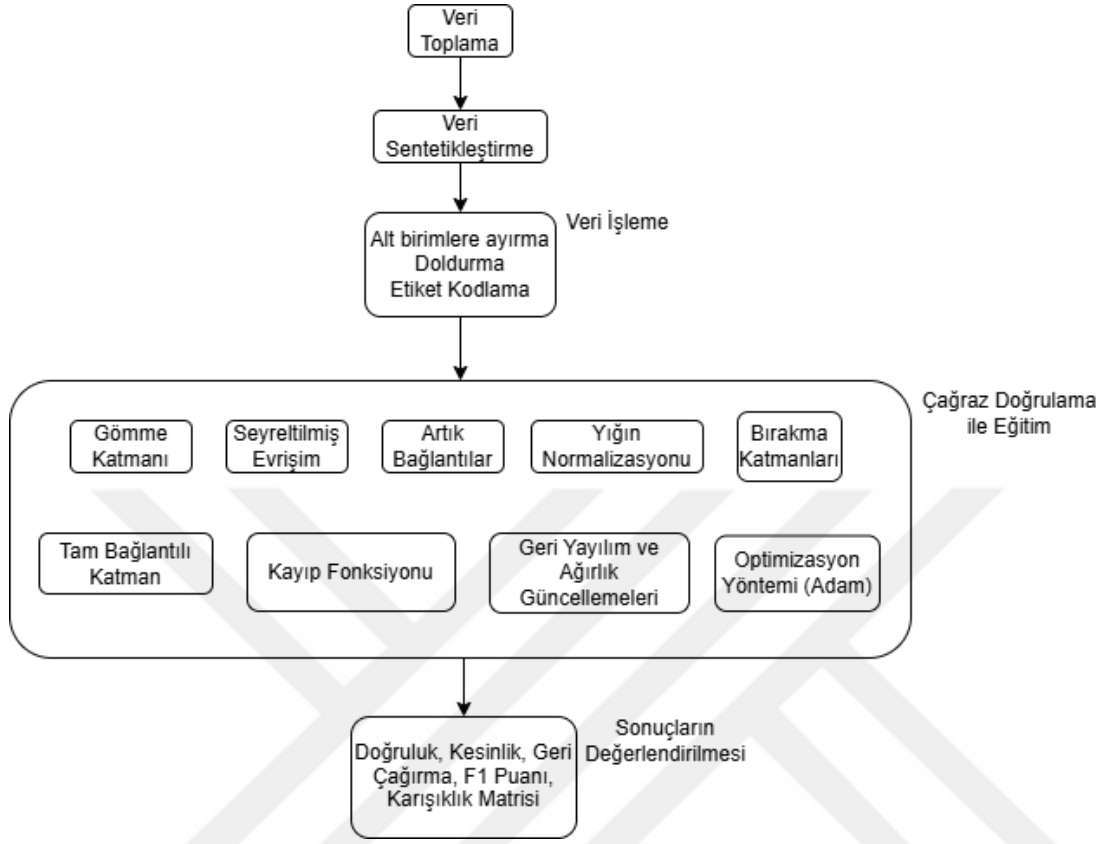
2.1. TCN

Zamansal Evrişimsel Ağlar (TCN), zaman serisi verilerini analiz etmek için geliştirilmiş bir yapay sinir ağı modelidir. Bu model, veriler arasındaki zamansal ilişkileri öğrenmek için geleneksel yöntemler yerine konvolüsyon (evrişim) katmanlarını kullanır. TCN'nin en önemli özelliklerinden biri, kauzal (nedensel) evrişim yapısıdır. Bu sayede model, yalnızca geçmiş verilere dayanarak tahmin yapar ve gelecekteki bilgilerin geçmişe sızmasını engeller. Böylece zaman sırasına uygun bir şekilde çalışır.

TCN, zaman serisi verilerini işlerken genişletilmiş evrişimler (dilated convolutions) kullanır. Bu yöntem, veriyi belirli aralıklarla analiz ederek modelin hem kısa hem de uzun vadeli ilişkileri öğrenmesini sağlar. Ayrıca, modelin içinde yer alan artık bağlantılar (residual connections), derin katmanlar arasında bilgi akışını güçlendirerek öğrenmeyi hızlandırır. Geleneksel RNN ve LSTM modellerine kıyasla TCN, eğitim sürecinde daha hızlı çalışır ve büyük veri setlerinde daha verimli olabilir [27].

TCN modeli, özellikle zaman serisi tahmini, anomali tespiti ve NLP gibi alanlarda kullanılır. 1D evrişim katmanları sayesinde verileri hiyerarşik olarak işler ve bilgiyi en verimli şekilde özetler. Ayrıca, kodlayıcı-çözücü (encoder-decoder) mimarisi sayesinde verileri sıkıştırarak öğrenmeyi daha etkili hale getirir. Daha kısa eğitim süresi ve paralelleştirme avantajı sayesinde, RNN ve LSTM gibi modellere göre daha

hızlı öğrenme kapasitesine sahiptir [27]. Şekil 2.1’de gösterilen diyagram TCN modelinin çalışma bloklarını vermektedir.



Şekil 2.1. TCN'in çalışma mimarisi

Bloklarda yapılan işlemlerin açıklamaları şu şekildedir:

- Veri Toplama (Data Collection): Verinin toplanması, modelin eğitilmesinde kullanılan ham veriyi ifade eder. Bu, metin, doküman, kullanıcı geri bildirim gibi farklı kaynaklardan olabilir.
- Veri Sentetikleştirme (Data Synthesizing): Yapay veri üretimi veya mevcut verinin zenginleştirilmesiyle, modelin daha çeşitlendirilmiş veriyle eğitilmesi sağlanır.
- Alt Birimlere Ayırma (Tokenization): Metni, anlamlı küçük parçalara ayırmak için kullanılan bir tekniktir. Örneğin, kelimelere veya alt kelimelere ayrılır (WordPiece, Byte Pair Encoding gibi).
- Doldurma (Padding): Farklı uzunluktaki dizileri, aynı boyuta getirmek için eklemeler yapılır. Bu, modelin veriyi işleyebilmesi için gereklidir.

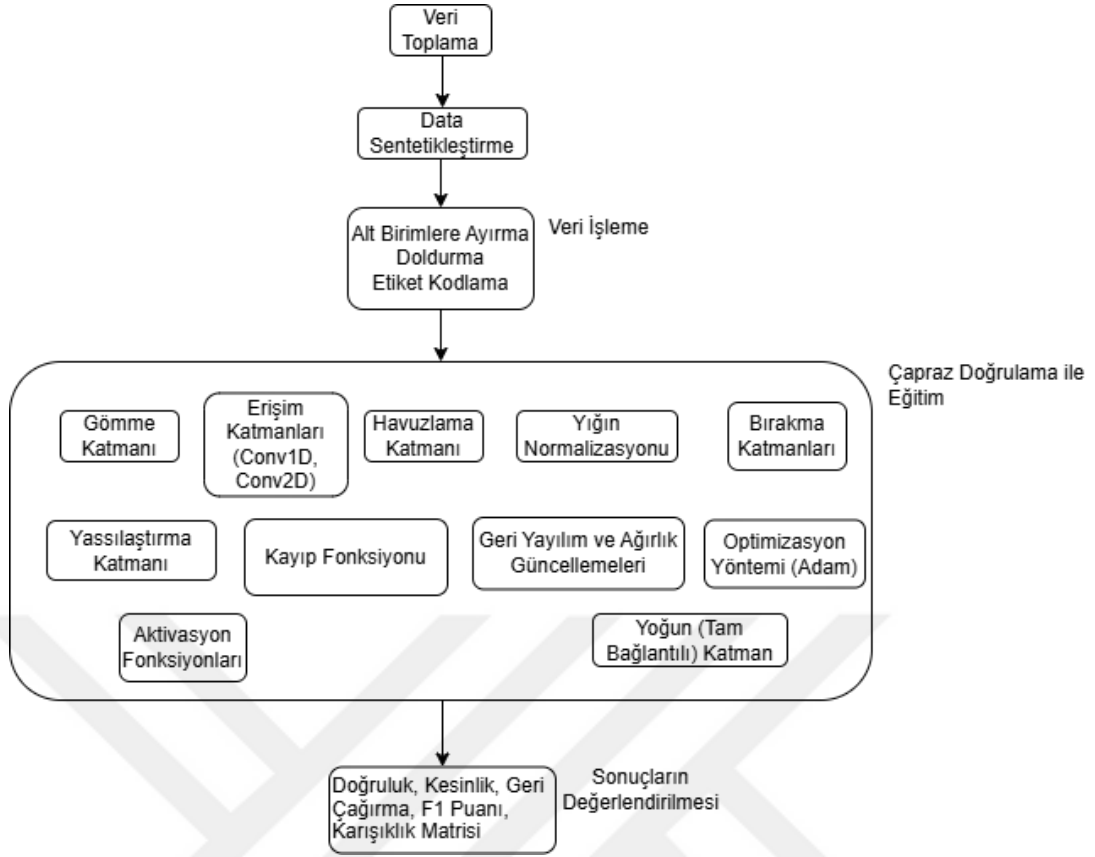
- Etiket Kodlama (Label Encoding): Metnin sayısal verilere dönüştürülmesidir. Genellikle One-Hot veya Label Encoding kullanılır; her kategoriye bir sayısal etiket atanır.
- Gömme Katmanı (Embedding Layer): Verinin sayısal hale getirilmesi sağlanır.
- Seyreltilmiş Evrişim (Dilated Convolution): Filtrelerin genişletilerek daha büyük bir bağlamdan bilgi almasını sağlar.
- Artık Bağlantılar (Residual Connections): Derin ağlarda bilgi kaybını önlemek için önceki katmanların çıktısı sonraki katmanlarla birleştirilir.
- Yığın Normalizasyonu (Batch Normalization): Ağın her katmanındaki verilerin normalizasyonunu sağlar ve öğrenme sürecini hızlandırır.
- Bırakma Katmanları (Dropout Layers): Ağı overfitting'den korumak için bazı nöronlar rastgele devre dışı bırakılır.
- Tam Bağlantılı Katman (Fully Connected Layer): Sonuçları çıkarmak için tamamen bağlı katman kullanılır.
- Kayıp Fonksiyonu (Loss Function): Modelin tahminlerinin ne kadar doğru olduğunu ölçen fonksiyondur. Örneğin, Cross-Entropy veya MSE.
- Optimizasyon Yöntemi (Optimizer): Modelin ağırlıklarını güncellemek için kullanılan algoritmadır. Adam, RMSprop ve SGD gibi popüler optimizatörler vardır.
- Geri Yayılım ve Ağırlık Güncellemeleri (Backpropagation & Weight Updates): Hata, ağın gerisinde yayılır ve ağırlıklar güncellenir.
- Doğruluk (Accuracy), Kesinlik (Precision), Geri Çağırma (Recall), F1 Puanı (F1-Score): Modelin başarısını ölçen metriklerdir. Doğruluk, kesinlik, hatırlama ve F1 skoru gibi çeşitli ölçümler kullanılır.
- Karışıklık Matrisi (Confusion Matrix): Modelin tahminlerini ve doğru/yanlış sınıflandırmaları görselleştiren bir matristir.
- Çapraz Doğrulama (Cross-Validation): Modelin genelleme yeteneğini artırmak için K-Fold gibi tekniklerle doğrulama yapılır.

2.2. CNN

Evrişimsel Sinir Ağları (CNN), özellikle görüntüleri işlemek ve analiz etmek için geliştirilen bir yapay zeka modelidir. Geleneksel yapay sinir ağlarının aksine, CNN'ler görüntüdeki temel özellikleri doğrudan öğrenebilir ve veriyi ham haliyle işler. Modelin en önemli bileşenleri arasında evrişim katmanları, havuzlama (pooling) katmanları ve tam bağlı katmanlar bulunur. Bu yapısı sayesinde, CNN modeli görüntülerdeki kenarlar, dokular ve şekiller gibi önemli detayları öğrenerek daha anlamlı bir temsil oluşturur.

CNN modeli, verileri katmanlar halinde işler ve her seviyede daha karmaşık özellikler öğrenir. İlk olarak, evrişim katmanları küçük filtreler kullanarak görüntüdeki belirli desenleri tanır. Daha sonra, havuzlama katmanları verinin boyutunu küçülterek gereksiz bilgileri atar ve modeli daha verimli hale getirir. ReLU aktivasyon fonksiyonu, modelin doğrusal olmayan ilişkileri öğrenmesine yardımcı olur. Son aşamada, tam bağlı katmanlar tüm öğrenilen bilgileri birleştirerek görüntünün hangi kategoriye ait olduğunu belirler [28].

CNN, özellikle görüntü işleme alanında oldukça başarılıdır. Nesne tanıma, yüz tanıma, tıbbi görüntü analizi gibi birçok alanda yaygın olarak kullanılır. Evrişim katmanları, görüntülerin farklı bölgelerindeki özellikleri çıkarırken, havuzlama işlemleri modelin aşırı öğrenmesini (overfitting) önler. Bu güçlü yapısı sayesinde, CNN modelleri yüksek doğruluk oranlarına sahip olup birçok yapay zeka uygulamasında tercih edilmektedir [28]. Şekil 2.2'de gösterilen diyagram CNN modelinin çalışma bloklarını vermektedir.



Şekil 2.2. CNN'in çalışma mimarisi

Bloklarda yapılan işlemlerin açıklamaları şu şekildedir:

Şekil 2.2'deki Veri Toplama, Veri Sentetikleştirme, Alt Birimlere Ayırma, Doldurma, Etiket Kodlama, Gömme Katmanı, Yığın Normalizasyonu, Bırakma Katmanı, Kayıt Fonksiyonu, Optimizasyon Yöntemi, Geri Yayılım ve Ağırlık Güncellemeleri, Doğruluk, Kesinlik, Geri Çağırma, F1 Puanı, Karışıklık Matrisi, Çapraz Doğrulama aşamaları Bölüm 2.1'de açıklandığı gibidir.

- Erişim Katmanları (Convolutional Layers - Conv1D, Conv2D): Veri içindeki önemli özellikleri yakalamak için filtreler uygular. Conv1D metin verisinde, Conv2D ise görüntü işlemede yaygındır.
- Havuzlama Katmanı (Pooling Layer - Max Pooling / Average Pooling): Özellik haritasının boyutunu küçülterek bilgi kaybını minimize eder ve modelin genelleştirme yeteneğini artırır.
- Yassılaştırma Katmanı (Flatten Layer): Çok boyutlu özellik haritalarını tek boyutlu vektöre dönüştürerek tam bağlantılı (Dense) katmana giriş hazırlar.

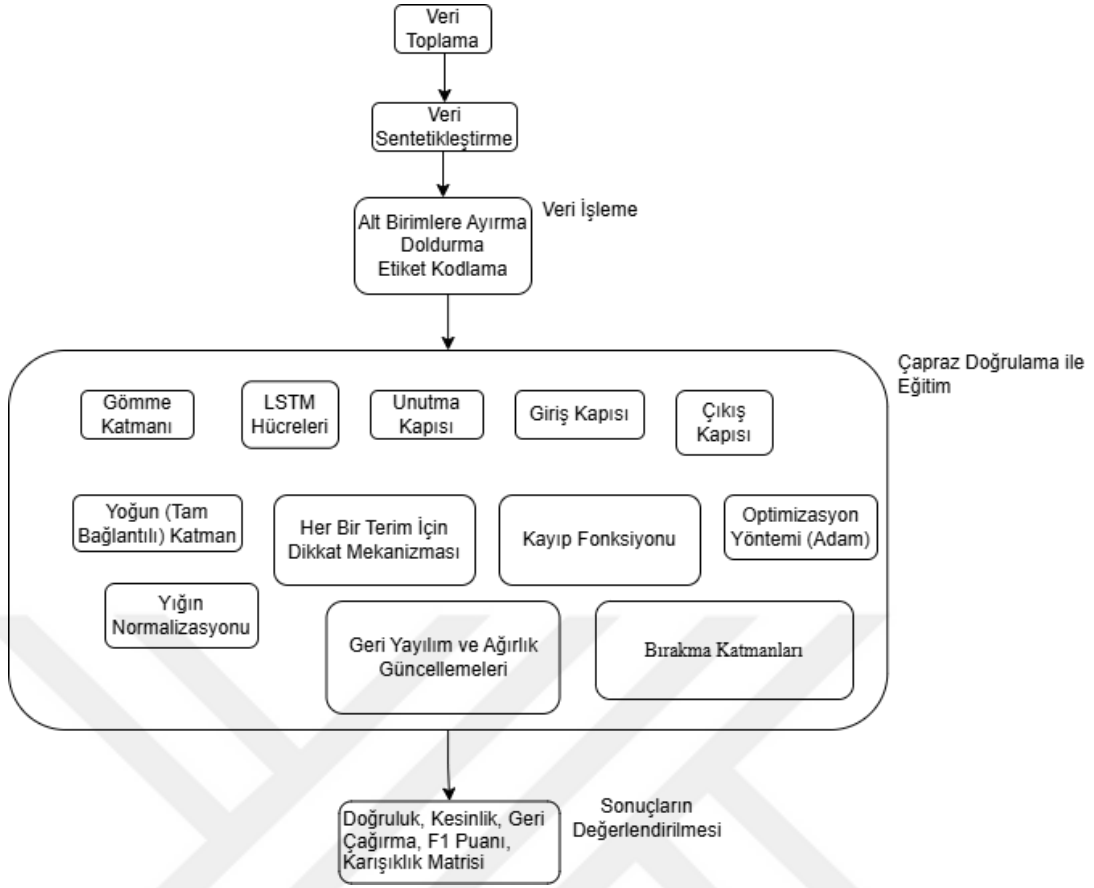
- Yoğun (Tam Bağlantılı) Katman (Dense Layer): Öğrenilen özellikleri işleyerek nihai sınıflandırma veya regresyon sonucunu üretir.
- Aktivasyon Fonksiyonları (Activation Functions - ReLU, Softmax, Sigmoid): Modelin nöronları etkinleştirmesini sağlar. ReLU derin ağlarda yaygın olup negatif değerleri sıfırlar, Softmax çok sınıflı sınıflandırmada, Sigmoid ise ikili sınıflandırmada kullanılır.

2.3. LSTM

Uzun Kısa Süreli Bellek (LSTM) ağı, zaman içindeki ilişkileri öğrenmede geleneksel Tekrarlayan Sinir Ağları'na (RNN) kıyasla daha başarılıdır. RNN'lerde, uzun veri dizileriyle çalışırken, model eski bilgileri hatırlamakta zorlanır ve gradyan kaybolması (vanishing gradient) problemi yaşanır. LSTM, bu sorunu çözmek için özel bir kapı yapısı kullanır. Bu yapılar, sadece önemli bilgileri saklayarak uzun vadeli ilişkileri etkili bir şekilde öğrenmesini sağlar. LSTM, NLP, konuşma tanıma ve finansal tahminler gibi sıralı veri gerektiren birçok alanda yaygın olarak kullanılır [29].

LSTM, klasik RNN'lerden farklı olarak, bilgi akışını kontrol eden üç kapıya sahiptir: unutma kapısı, giriş kapısı ve çıkış kapısı. Unutma kapısı, hangi geçmiş bilgilerin korunacağını veya silineceğini belirler. Giriş kapısı, yeni bilgilerin nasıl ekleneceğini düzenlerken, çıkış kapısı, hücredeki bilgilerin dışarıya aktarılmasını yönetir. Bu yapı sayesinde, LSTM uzun vadeli bağımlılıkları güçlü bir şekilde öğrenir ve gereksiz bilgileri filtreleyerek verimli bir şekilde çalışır. Bu özellik, LSTM'yi dil modelleri ve otonom sistemler gibi birçok alanda güçlü bir çözüm haline getirir.

LSTM, giriş, unutma ve çıkış kapıları sayesinde, seçici olarak bilgi işleyebilir ve vanishing gradient problemini engeller. Bu özellik, modelin hem kısa hem de uzun vadeli bağımlılıkları öğrenmesini sağlar. LSTM, bu nedenle NLP, konuşma tanıma ve zaman serisi tahminleri gibi alanlarda oldukça etkilidir ve geniş bir kullanım alanına sahiptir [29]. Şekil 2.3'te gösterilen diyagram LSTM modelinin çalışma bloklarını vermektedir.



Şekil 2.3. LSTM'in çalışma mimarisi

Bloklarda yapılan işlemlerin açıklamaları şu şekildedir:

Şekil 2.3'deki Veri Toplama, Veri Sentetikleştirme, Alt Birimlere Ayırma, Doldurma, Etiket Kodlama, Gömme Katmanı, Yığın Normalizasyonu, Bırakma Katmanı, Kayıt Fonksiyonu, Optimizasyon Yöntemi, Geri Yayılım ve Ağırlık Güncellemeleri, Doğruluk, Kesinlik, Geri Çağırma, F1 Puanı, Karışıklık Matrisi, Çapraz Doğrulama aşamaları Bölüm 2.1'de açıklandığı gibidir.

- LSTM Hücreleri (LSTM Cells): Uzun süreli bağımlılıkları öğrenen ve geçmiş bilgiyi taşıyan özel bir tekrar eden (RNN) hücre yapısıdır.
- Unutma Kapısı (Forget Gate): Önceki zaman adımındaki bilgilerin hangilerinin korunacağını ve hangilerinin unutulacağını belirler.
- Giriş Kapısı (Input Gate): Yeni gelen bilginin ne kadarının hücre durumuna ekleneceğini kontrol eder.
- Çıkış Kapısı (Output Gate): LSTM hücresinden çıkan çıktıyı belirleyerek bir sonraki katmana veya zaman adımına iletilmesini sağlar.

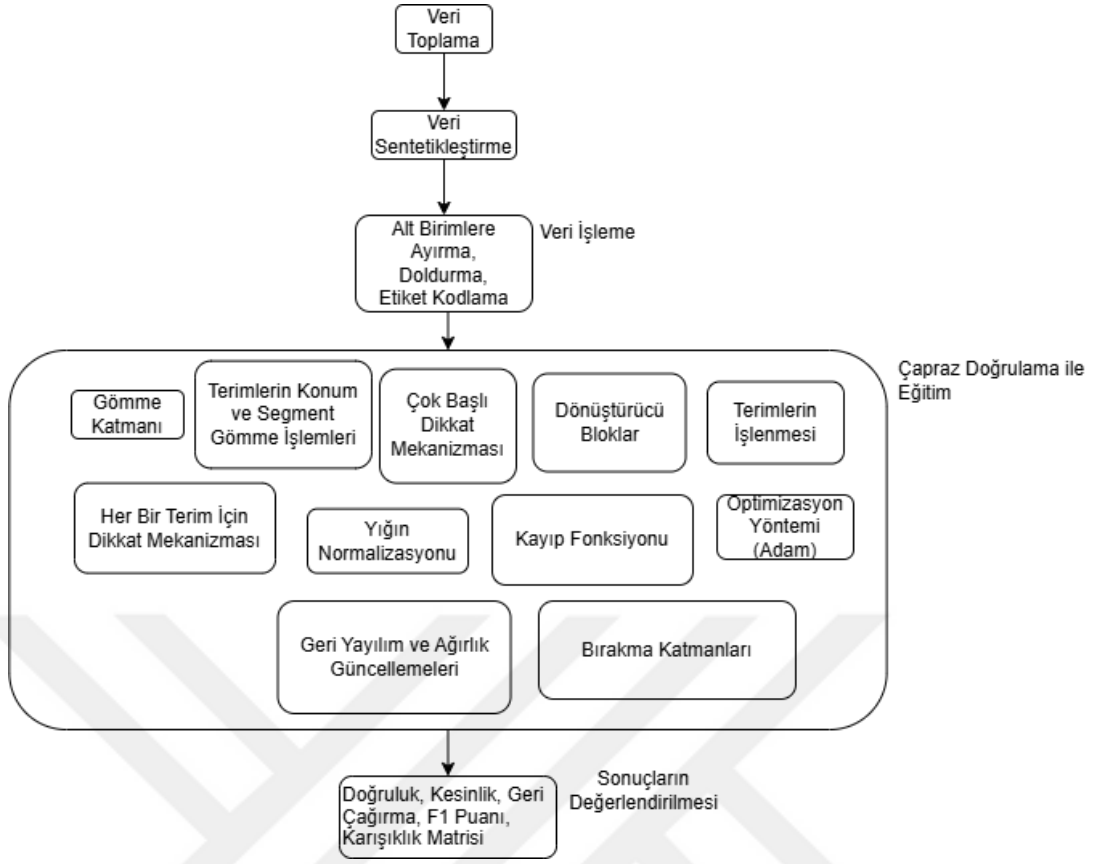
- Yoğun (Tam Bağlantılı) Katman (Dense Layer): Son katmandır ve LSTM'nin öğrendiği bilgileri kullanarak nihai tahmini (sınıflandırma veya regresyon) üretir.
- Her Bir Terim İçin Dikkat Mekanizması (Attention Mechanism for Each Token): LSTM modellerinde her kelimenin (token) önem derecesini belirleyerek modelin daha alakalı bilgilere odaklanmasını sağlar. Uzun dizilerde önceki kelimelerden gelen önemli bilgilerin kaybolmasını önleyerek bağlamın daha iyi anlaşılmasına yardımcı olur. Bu mekanizma, özellikle metin çeviri ve duygu analizi gibi NLP görevlerinde modelin performansını artırır.

2.4. BERT

Çift Yönlü Transformer Kodlayıcı (BERT), NLP alanında devrim yaratan bir modeldir. Çoğu geleneksel model yalnızca kelimeleri bir yönde işlerken, BERT kelimeleri hem önceki hem de sonraki kelimelerle aynı anda işler. Bu çift yönlü işlem, modelin bağlamı daha derinlemesine anlamasını sağlar. BERT, Transformer mimarisini kullanarak büyük metin verisi üzerinde eğitim alır ve ardından özelleştirilmiş görevler için ince ayar yapılır. Bu özellikleri sayesinde, metin sınıflandırma, duygu analizi ve soru-cevap gibi görevlerde yüksek doğruluk elde eder.

BERT, Transformer Encoder yapısına dayanır ve dilin bağlamını anlamada son derece etkilidir. Model, metnin her iki yönünü paralel olarak işler, yani her kelimeyi hem önceki hem de sonraki kelimelerle ilişkili olarak değerlendirir. BERT'in eğitiminde iki ana teknik kullanılır: Masked Language Model (MLM) ve Next Sentence Prediction (NSP). MLM, bazı kelimeleri gizleyerek modelin bu eksik kelimeleri tahmin etmesini sağlar, bu da bağlamı daha güçlü öğrenmesini sağlar. NSP ise, iki cümlenin ardışıklığını tahmin ederek metinler arasındaki ilişkiyi anlamasına yardımcı olur [30].

BERT, bağlam ilişkilerini öğrenmek için özel görevler olan Maskelenmiş Dil Modellemesi (MLM) ve Sonraki Cümle Tahmini (NSP) gibi teknikleri kullanır. Bu görevlerle, model dilin çeşitli nüanslarını daha iyi kavrayarak yüksek performans sergiler. Ayrıca, sınıflandırma ve cümle ilişkisi görevlerinde etkin olmak için özel belirteçler (CLS ve SEP) kullanılır. BERT, ince ayar (fine-tuning) yapılarak, duygu analizi, soru-cevap sistemleri gibi NLP görevlerinde güçlü sonuçlar elde eder [30]. Şekil 2.4'te gösterilen diyagram BERT modelinin çalışma bloklarını vermektedir.



Şekil 2.4. BERT'in çalışma mimarisini

Bloklarda yapılan işlemlerin açıklamaları şu şekildedir:

Şekil 2.4'teki Veri Toplama, Veri Sentetikleştirme, Alt Birimlere Ayırma, Doldurma, Etiket Kodlama, Gömme Katmanı, Yığın Normalizasyonu, Bırakma Katmanı, Kayıt Fonksiyonu, Optimizasyon Yöntemi, Geri Yayılım ve Ağırlık Güncellemeleri, Doğruluk, Kesinlik, Geri Çağırma, F1 Puanı, Karışıklık Matrisi, Çapraz Doğrulama aşamaları Bölüm 2.1'de açıklandığı gibidir.

- Terimlerin Konum ve Segment Gömme İşlemleri (Token + Position + Segment Embeddings): Token Embeddings, kelimeleri vektörlere dönüştürür. Position Embeddings, kelimelerin sırasını belirtir, çünkü Transformer'lar konum bilgisini doğrudan öğrenemez. Segment Embeddings, iki cümle arasında ayırım yaparak modelin bağlamı anlamasına yardımcı olur.
- Çok Başlı Dikkat Mekanizması (Self-Attention - Multi-Head Attention): Cümledeki her kelimenin diğer kelimelerle olan ilişkisini anlamasını sağlar. Multi-head yapısı, farklı kelime ilişkilerini paralel olarak öğrenmeyi mümkün kılar.

- Dönüştürücü Bloklar (Transformer Blocks - Feed Forward + Attention): Attention Katmanı, önemli kelimelere odaklanmayı sağlar. Feed Forward Katmanı, her kelimenin bağlam içindeki temsilini daha da güçlendirir.
- Terimlerin İşlenmesi – ([CLS] Token Handling): [CLS] (Classification) token'ı, girişin tamamını temsil eden özel bir token'dır. Özellikle sınıflandırma görevlerinde nihai tahmin için kullanılır.
- Her Bir Terim İçin Dikkat Mekanizması (Attention Mechanism for Each Token): LSTM modellerinde her kelimenin (token) önem derecesini belirleyerek modelin daha alakalı bilgilere odaklanmasını sağlar. Uzun dizilerde önceki kelimelerden gelen önemli bilgilerin kaybolmasını önleyerek bağlamın daha iyi anlaşılmasına yardımcı olur. Bu mekanizma, özellikle metin çeviri ve duygu analizi gibi NLP görevlerinde modelin performansını artırır.

Genel karşılaştırma yapıldığında, TCN ve CNN modelleri daha hızlı eğitilebilir ancak uzun vadeli bağımlılıkları yakalamada zorluk yaşayabilirler. LSTM, sıralı verilerde etkili olup özellikle dil işleme alanında güçlüdür. BERT ise derin bağlam öğrenmesi sağladığı için çok daha doğru sonuçlar verebilir, ancak eğitim süresi ve hesaplama maliyeti yüksektir. Her modelin avantajları, kullanım senaryolarına bağlı olarak değişir; TCN ve CNN genellikle hızlı eğitim süresi ve basit yapı sunarken, LSTM ve BERT daha karmaşık ilişkilere dair güçlü öğrenme yeteneklerine sahiptir.

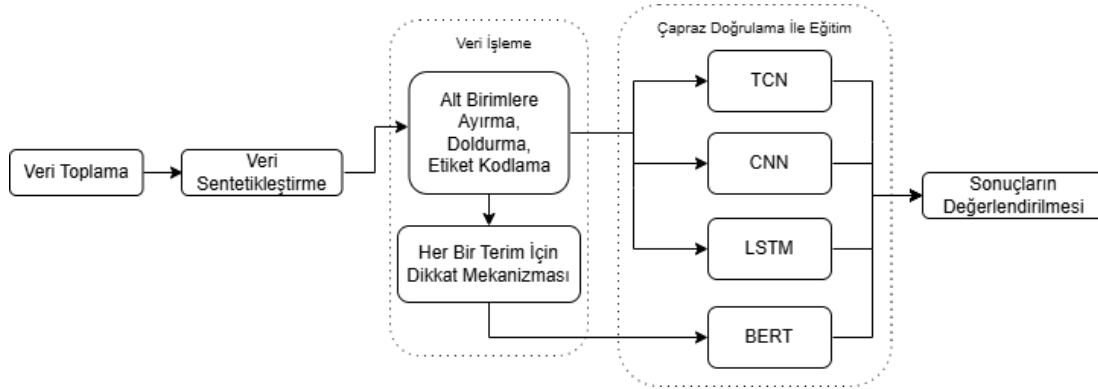
3. UYGULAMA ADIMLARI VE DENEYSEL SONUÇLAR

Bu çalışmada, modeller Google Colab aracılığıyla Python kullanılarak uygulanmıştır. Çalışmaya ve amacına uygun olarak, Türkiye'deki özel bir şirkete ait veriler ve bu verilerden türetilen sentetik veri seti kullanılarak modeller eğitilmiştir. Araştırma yöntemleri şu şekilde özetlenebilir:

1. Veri Seti Toplama: Gerçek verilerle sentetik veri üretimi yapılmış ve sentetik verilerle veri seti genişletilmiştir.
2. Veriler Üzerinde Ön İşleme: Veri temizleme, etiketleme ve kategorilerin sayısal işleme dönüştürülmesi, metinlerin tokenize işlemi ve uzunlukların eşitlenmesi işlemleri gerçekleştirilmiş, ayrıca eğitim ve test veri setlerinin çapraz doğrulama oranları belirlenmiştir.
3. Model Tanımlama: Kullanılacak tüm modellerin mimarileri tanımlanmıştır.
4. Modellerin Eğitilmesi: Optimizasyon algoritmaları kullanılarak model eğitimi gerçekleştirilmiş ve kayıp fonksiyonları hesaplanmıştır.
5. Çapraz Doğrulama İşlemi: Çapraz doğrulama yöntemiyle veri seti üzerinde eğitim ve test işlemleri yapılmıştır.
6. Modellerin Değerlendirilmesi: Kayıp, doğruluk, kesinlik, geri çağırma ve F1 skoru gibi metrikler elde edilmiş ve karmaşıklık matrisleri oluşturulmuştur.

Şekil 3.1'deki diyagram, bu çalışmada izlenen metodolojik süreci görsel olarak açıklamaktadır. Diyagram, veri seti toplama, veri ön işleme, model tanımlama, model eğitimi, çapraz doğrulama işlemi ve modellerin değerlendirilmesi aşamalarını sırasıyla göstermektedir. İlk adımda gerçek verilerle birlikte sentetik veri üretimi yapılmış ve veri seti genişletilmiştir. Sonrasında, veri temizleme, etiketleme ve kategorilerin sayısal hale dönüştürülmesi gibi ön işleme adımları gerçekleştirilmiştir. Ardından, metinler tokenize edilip uzunluklar eşitlenerek modellerin ihtiyacına uygun şekilde formatlanmıştır. Tüm modellerin mimarileri tanımlanmış, optimizasyon algoritmaları ile eğitim gerçekleştirilmiş ve kayıp fonksiyonları hesaplanmıştır. Çapraz doğrulama yöntemiyle veri seti üzerinde eğitim ve test işlemleri yapılmış, son olarak kayıp,

doğruluk, kesinlik, geri çağırma ve F1 skoru gibi metriklerle modeller değerlendirilmiştir.



Şekil 3.1. Çalışmanın metodolojisi

3.1. Veri Seti

Türkiye'deki özel bir şirkette toplantı notlarından, iç anketlerden ve yönetici-personel görüşmelerinden elde edilen 386 Türkçe cümle analiz edilmiş ve 14 kategori belirlenmiştir. Tüm cümleler anonimleştirilmiş ve ilgili kategorilerle eşleştirilmiştir. Model eğitimi için daha fazla veriye ihtiyaç duyulduğundan dolayı, mevcut veri seti ChatGPT'ye cümle-kategori eşleştirme sürecini öğretmek için kullanılmış ve ardından her kategori için 500 sentetik Türkçe cümle oluşturulmuştur. Öncelik gerçek cümleler olmak üzere oluşturulan sentetik verilerle birlikte toplamda 7.000 cümle elde edilmiştir. Bu sentetik cümlelerin uzunluğu en fazla 17 kelime olacak şekilde tasarlanmış ve ortalama 11 kelime uzunluğundadır. Belirlenen kategoriler, iş süreçleriyle ilgili personel geri bildirimlerinin yaygın türlerine dayanmaktadır ve her kategoriye bir etiket numarası atanmıştır. Tablo 3.1'de veri setindeki kategorileri, örnek cümlelerle birlikte sunmaktadır.

Tablo 3.1. Kategorilere göre gerçek ve sentetik cümleler

Etiket No	Kategori	Veri Sayısı	Gerçek Cümle	Sentetik Cümle
1	Bilgi Eksikliği	500	İş birimlerin iş bilgisi yetersizliği sebebi ile geliştirme aşamasında ara taleplerin gelmesi çalışma planını bozmaktadır	Yöneticilerden gerekli detayları zamanında alamadığımız için projelerimiz aksıyor.
2	Çalışma Ortamı	500	Zamanlama ve işlerin yoğunluğu sebebi ile ekipçe toplanamıyoruz	Çalışma alanlarının yetersizliği ekip içinde verimliliği olumsuz etkiliyor.
3	Değişiklik ve Planlama Yönetimi	500	Deployment süreçlerinde sürekli değişen zamanlamalar uzun form doldurmalar işimizi zorlaştırıyor ve vakit kaybına sebep oluyor	Planlamalar önceden paylaşılınca işler daha hızlı ilerliyor.
4	Eğitim	500	İş birimleri Jira kullanımı konusunda bilgilendirilmelidir	Eğitimlerin yetersiz olması, çalışanların gelişimini olumsuz etkiliyor.
5	Ekip Uyumu	500	Ekibimiz güzel ve uzaktan çalışmaktan çok memnunuz	Düzenli ekip toplantıları, iş birliğini artırıyor.
6	Etkinlik İhtiyaçları	500	Uzaktan çalıştığımız için periyodik olarak ekip olarak aktivite planlayamıyoruz	Şirket piknikleri, çalışanların iş dışında da bağ kurmasını sağlar.
7	Görev Tanımı ve Sorumluluklar	500	İş birimleri kullanıcı testleri yapmıyor aslında yapmalılar	Belirgin görev tanımları, çalışanların iş memnuniyetini artırır.
8	Hoş Geldin Kiti	500	Hoş geldin kiti verilmedi bizden hazırlıklı gelmemiz talep edildi	Hoşgeldin kitinin özenle hazırlanmış olması, yeni çalışanlara değer verildiğini hissettiriyor.
9	Kişisel İstekler	500	Kurum içerisindeki eski ve yeni personele yaklaşım eşit değil Adaletli ve eşit olunmalıdır	Yıllık izin günlerimizin artırılmasını isterim.
10	Onay Süreçleri	500	Deployment süreçlerindeki onaylar ilgili kişiler tarafından çok geç verilmektedir	Onay süreçlerinin dijitalleştirilmesi, zaman kazandırabilir.
11	Personel Eksikliği	500	Ekibe yeni personel katılması gücümüzü artırmaktadır	Personel eksikliği yüzünden zamanında sonuç alınamıyor.
12	Sağlık Sigortası	500	Sağlık sigortası eşi ve çocukları kapsamaması saçma Diğer bankalarda süreç bu şekilde yürütülmüyor	Çalışanlar için daha kapsamlı sağlık sigortası sunulmalı.
13	Ücret ve Yan Haklar	500	Maaş zam dönemlerinde bizlere zam oranı söyleniyor ama nasıl hesaplandığına dair bilgi verilmelidir	Çalışanlar için emeklilik fonları gibi yan haklar artırılmalıdır.
14	Verimli Çalışma	500	Hataların tespiti için kod inceleme yetkisini iş analistlerinede verilmesini bekliyorum	Verimli çalışabilmek için iş yükü dengeli bir şekilde dağıtılmalıdır.

3.2. Veri Ön İşleme

Metin verilerinin TCN, CNN ve LSTM modellerinde işlenmesi için benzer ön işleme adımları uygulanmıştır. Bu süreçte, metinler tokenizer aracılığıyla sayısal dizilere dönüştürülmüş ve pad işlemiyle her giriş 17 sabit uzunluğa tamamlanmıştır. Böylece modeller, tutarlı uzunlukta verilerle çalışarak daha sağlıklı öğrenme gerçekleştirebilmiştir. Ayrıca, metinlere ait kategorik etiketler LabelEncoder kullanılarak sayısal değerlere kodlanmıştır. Bu ortak ön işleme adımları, metinlerin doğru sınıflandırılması açısından temel bir gerekliliktir.

BERT modeli için ise farklı bir veri hazırlama süreci izlenmiştir. Metinler, BERT Tokenizer ile tokenize edilip 17 uzunluğunda sabitlenmiş, gerektiğinde kesilmiştir. Her belirteç için oluşturulan dikkat maskeleri, modelin anlamlı bilgilere odaklanmasını sağlamıştır.

Veriler, .xlsx formatında pandas kütüphanesiyle yüklenmiş; gerekli sütunlar seçilip eksik veriler temizlenmiştir. Etiketler sayısallaştırılırken yine LabelEncoder kullanılmıştır. Tokenizasyon işlemleri, TCN, CNN ve LSTM modelleri için sıralı dizi formatına uygun olarak padding ile desteklenmiş; LSTM'nin sıralı yapısıyla uyumluluğu sağlanmıştır. BERT ise kelime ve cümleleri daha anlamlı şekilde temsil etmek için gelişmiş tokenizasyon ve embedding teknikleri kullanmıştır.

3.3. Modellerin Tanımlanması

Model yapılandırma sürecinde, modelin yapısı genellikle Sequential veya Module sınıfları kullanılarak tanımlanır ve katmanlar sırasıyla eklenir. Modelin öğrenme süreci için uygun optimizör (örneğin, Adam) ve kayıp fonksiyonu (örneğin, CrossEntropyLoss) seçilir. TCN modeli, evrimsel katmanlar (Conv1D) ve dilatasyonlu konvolüsyon yöntemleriyle daha geniş kapsama alanı sağlar. CNN, metnin yerel özelliklerini çıkarmak için Conv1D katmanları ve MaxPooling1D havuzlama katmanları kullanır. LSTM, sıralı verilerde uzun bağımlılıkları modellemek için RNN yapıları ve LSTM katmanları kullanarak uzun vadeli ilişkiler oluşturur. BERT, transformer tabanlı bir model olup, dikkat mekanizmalarıyla kelimeleri derinlemesine analiz eder ve transformer encoder'ları içeren giriş katmanı ile metni hem sağdan sola hem de soldan sağa işler.

Model eğitim sürecinde, eğitim ve test verisi genellikle StratifiedKFold gibi yöntemlerle bölünerek sınıf dengesizliği engellenir. Model, 10 aşamalı epoch boyunca eğitilir ve her epoch sonunda kayıp ve doğruluk gibi metriklerle değerlendirilir. TCN ve CNN modelleri, evrimsel katmanlar sayesinde veriyi yerel özellikleri çıkararak işler ve dilatasyonlu konvolüsyonlar veya havuzlama gibi özel teknikler kullanabilir. LSTM, sıralı verilerle çalışırken, her adımda önceki çıktıyı kullanarak zamanla gelişen ilişkileri öğrenir. BERT modeli, her kelimenin bağlamını hem soldan sağa hem de sağdan sola işleyerek daha anlamlı öğrenimler sağlar, ancak eğitim süreci genellikle daha uzun ve maliyetlidir.

Değerlendirme ve metrikler sürecinde, her modelin doğruluğu ve kaybı test verileri üzerinde hesaplanarak genel başarısı ölçülür. Ayrıca, kesinlik, geri çağırma ve F1 score gibi metrikler, modelin başarısını daha ayrıntılı bir şekilde değerlendirmek için hesaplanır. TCN ve CNN modellerinde, karmaşıklık matrisi gibi araçlarla yerel doğruluklar incelenebilir; özellikle modelin yerel özellikleri ne kadar doğru öğrendiği önemli bir değerlendirme kriteridir. LSTM, zaman bağımlılığını iyi öğrendiği için, doğruluk ve kayıp dışında zaman içindeki verinin modelde nasıl yansıtıldığına bakılabilir. BERT ise bağlamı dikkate alarak derinlemesine analizler yapar ve genellikle daha yüksek doğruluk sağlar, bu nedenle diğer modellere göre daha iyi sonuçlar verebilir.

Sonuçlar ve görselleştirme sürecinde, modelin performansını değerlendirmek için karmaşıklık matrisi kullanılır, bu araç doğru ve yanlış sınıflandırmaların görselleştirilmesini sağlar. Ayrıca, modelin başarısı ve kayıp grafikleri, matplotlib kütüphanesi ile görselleştirilmiştir. TCN ve CNN modellerinde, yerel doğrulukları incelemek için karmaşıklık matrisi kullanılır ve evrimsel katmanların çıkardığı filtreler görselleştirilebilir. LSTM için zaman serisi grafikleri ile zaman içinde nasıl öğrendiği gösterilebilir. BERT modeli daha karmaşık olduğundan, modelin hangi kelimelere hangi bağlamlarla tepki verdiği üzerine daha derinlemesine görselleştirmeler yapılabilir.

Son modelin kaydedilmesi sürecinde, tüm modellerin eğitimi tamamlandıktan sonra, model genellikle `model.save()` gibi yöntemlerle kaydedilir. Ayrıca, kullanılan Tokenizer ve LabelEncoder gibi öğeler de kaydedilerek tekrar kullanılabilir. BERT gibi büyük modeller, çok büyük dosyalar oluşturabileceği için, model kaydedilmeden önce ek işlemler gerekebilir.

3.4. Modellerin Eğitilmesi ve Parametre Ayarlamaları

TCN, CNN, LSTM ve BERT modelleri için eğitim sürecinde, verilerin beş kat boyunca doğrulandığı katmanlı bir k-kat çapraz doğrulama yöntemi uygulanmıştır. Bu yaklaşım, modellerin genelleme yeteneklerini geliştirmiş ve daha tutarlı sonuçlar elde edilmesine katkıda bulunmuştur. Ayrıca, TCN, CNN ve LSTM modelleri kayıp fonksiyonu olarak kategorik çapraz entropi kullanırken, tüm modellerde optimizasyon için Adam optimizator kullanılmıştır.

TCN modeli çok sınıflı sınıflandırma problemleri için optimize edilmiş bir mimari sunmuş ve kategorik çapraz entropi kayıp fonksiyonu kullanılarak eğitilmiştir. Benzer şekilde, CNN modeli de benzer bir eğitim süreci izlemiş ancak uzamsal özellikleri çıkarmaya odaklanmıştır. Buna karşılık, LSTM modeli zaman serisi verileri ve sıralı bilgiler için uyarlanmış özel bir eğitim süreci kullanmıştır. Bu üç model, eğitim süreçleri sırasında genellikle benzer kayıp fonksiyonlarını ve optimizasyon yöntemlerini paylaşmıştır.

Diğer modellerden farklı olarak, BERT önceden eğitilmiş bir dil modelidir ve bu nedenle eğitimi sırasında daha küçük öğrenme oranları kullanılmıştır. BERT için bağlamsal dil anlamayı optimize etmek üzere tasarlanmış olan çapraz entropi kayıp fonksiyonu kullanılmıştır. Modellerde kullanılan ve veri kümesi boyutuna göre belirlenen parametre konfigürasyonları Tablo 3.2'de sunulmuştur.

Tablo 3.2. Modellerde kullanılan parametre değerleri

Parameter	TCN	CNN	LSTM	BERT
Embedding Dimension	128	128	128	128
Conv1D Filters (1st Layer)	64	128	-	-
Conv1D Filters (2nd Layer)	128	-	-	-
Kernel Size	3	3	-	-
Dropout Rate (1st Layer)	0.2	0.2	0.3	-
Dropout Rate (2nd Layer)	0.3	0.3	0.3	0.3
Dense Layer Units	128	128	128	-
Padding Sequences Max	17	17	17	17
Optimizer	Adam	Adam	Adam	Adam
Learning Rate	0.001	0.001	0.001	0.001
Loss Function	categorical_ crossentropy	categorical_ crossentropy	categorical_ crossentropy	CrossEntropyLoss
Batch Size	32	32	32	32
Epochs	10	10	10	10
Validation Splits	Stratified	Stratified	Stratified	-
Cross Validation Folds	5	5	5	5
Max Pooling Size	-	2	-	-
LSTM Units	-	-	128	-
Tokenizer	-	-	-	BertTokenizer (bert- base-uncased)
Pretrained Model	-	-	-	bert-base-uncased
Dropout Rate	-	-	-	0.3

3.5. Çapraz Doğrulama İşlemi

Çapraz doğrulama, modelin genellenebilirliğini ve performansını güvenilir bir şekilde değerlendirmek için yaygın olarak kullanılır. Bu çalışmada, 7000 örnekten oluşan ve 14 kategoriye ayrılmış veri seti üzerinde 5 katlı çapraz doğrulama uygulanmıştır. Her fold'da yaklaşık 1400 örnek ve her kategori için ortalama 100 cümle yer alarak dengeli bir dağılım sağlanmıştır. Bu yapı, modelin farklı veri alt kümelerinde nasıl performans gösterdiğini gözlemlememize olanak tanırken, overfitting'i de azaltır. Modelin her seferinde farklı bir test kümesiyle değerlendirilmesi, genel performans hakkında daha sağlıklı bir fikir verir.

Bununla birlikte, bazı kategorilerde veri dengesizliği yaşanma riski bulunur. Bu riski azaltmak için kategoriler eşit sayıda cümle içerecek şekilde düzenlenmiştir. BERT gibi büyük modellerle çalışıldığında her fold'un eğitilmesi ve test edilmesi zaman alabilir. Ancak, bu yöntemin sağladığı daha sağlam ve genellenebilir sonuçlar, modelin gerçek dünya verilerine uyumunu değerlendirme açısından büyük avantaj sunar. Şekil 3.2' de çapraz doğrulama yapısı ve kullanılan veri miktarları gösterilmektedir. Her fold sonunda elde edilen metriklerin ortalaması alınarak nihai sonuçlar hesaplanmıştır.

Parça 1	1400	5600		Sonuç 1	Ortalama Model Performansı	
Parça 2	1400	1400	4200	Sonuç 2		
Parça 3	2800		1400	2800		Sonuç 3
Parça 4	4200		1400	1400		Sonuç 4
Parça 5	5600			1400		Sonuç 5
Eğitim					5600	
Test					1400	

Şekil 3.2. Çapraz doğrulama mantığı

3.6. Modellerin Değerlendirilmesi

Doğruluk, modelin doğru sınıflandırdığı örneklerin toplam örneklere oranıdır (Denklem 3.1).

$$\text{Doğruluk} = \frac{\text{Doğru Tahminler}}{\text{Toplam Örnek Sayısı}} \quad (3.1)$$

Kayıp (Loss), modelin tahminlerinin doğruluğu ile gerçeği arasındaki farkı ölçer. Eğitim sürecinde minimize edilmeye çalışılır.

Kesinlik (Precision), modelin pozitif olarak tahmin ettiği örneklerin gerçekten pozitif olma oranıdır (Denklem 3.2).

$$\text{Kesinlik} = \frac{\text{Doğru Pozitifler}}{\text{Doğru Pozitifler} + \text{Yanlış Pozitifler}} \quad (3.2)$$

Geri Çağırma (Recall), gerçek pozitif örneklerin model tarafından doğru tahmin edilme oranıdır (Denklem 3.3).

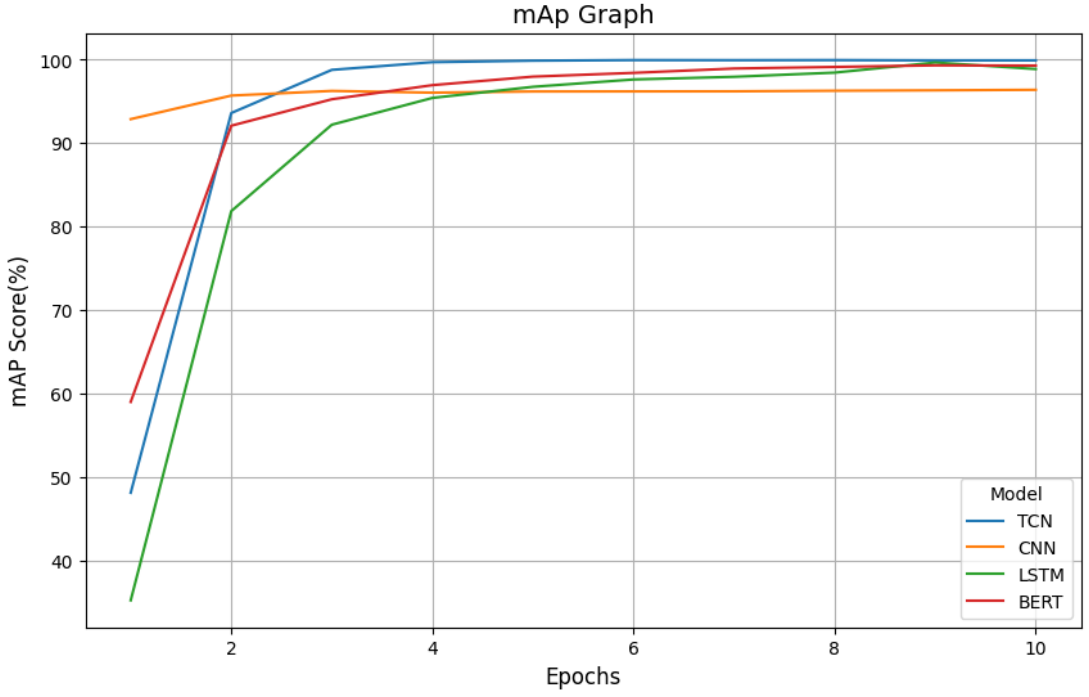
$$\text{Geri Çağırma} = \frac{\text{Doğru Pozitifler}}{\text{Doğru Pozitifler} + \text{Yanlış Negatifler}} \quad (3.3)$$

F1 Puanı (F1 Score), kesinlik ve geri çağırma arasındaki dengeyi ölçer. Yüksek kesinlik ve geri çağırma sağlamak önemlidir (Denklem 3.4).

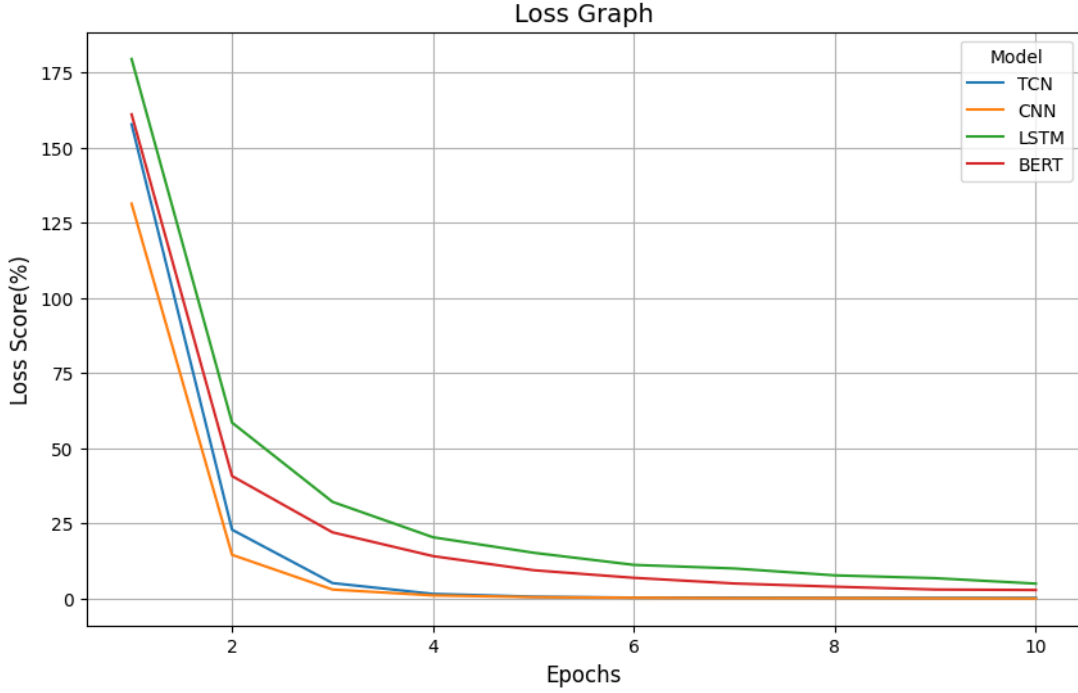
$$\text{F1 Puanı} = 2 \times \frac{\text{Kesinlik} \times \text{Geri Çağırma}}{\text{Kesinlik} + \text{Geri Çağırma}} \quad (3.4)$$

Modellerin performansı doğruluk, kesinlik, geri çağırma ve F1 puanı gibi çeşitli metrikler kullanılarak değerlendirilmiştir. Doğruluk, doğru sınıflandırılmış örneklerin toplam örnek sayısına oranını temsil eder. Kesinlik ve geri çağırma, sırasıyla, modelin belirli bir sınıfı ne kadar doğru tahmin ettiğini ve bu sınıfın gerçek örneklerini ne kadar etkili bir şekilde tanımladığını gösterir. Kesinlik ve geri çağırmanın dengeli bir ölçüsü

olan F1 puanı, modelin sınıflandırma performansını kapsamlı bir şekilde değerlendirir. Test kaybı, modelin test verileri üzerindeki performansını ölçer; burada daha düşük bir kayıp daha iyi genelleştirilebilirliği gösterir. Tüm modellerin eğitimi sırasında 5 kat çapraz doğrulama uygulanmış ve tablo ve matrislerde sunulan değerler bu katların ortalamaları alınarak hesaplanmıştır. Ayrıca, model eğitimi sürecinde her bir epoch için ortalama kayıp ve doğruluk değerleri hesaplanmış ve Şekil 3.3' te mAP, Şekil 3.4' te kayıp değerlerinden oluşan grafiklerde gösterilmiştir. Tüm modeller eğitildikten sonra elde edilen performans ölçütleri Tablo 3.3'te sunulmuştur.



Şekil 3.3. Modellerin mAP grafikleri



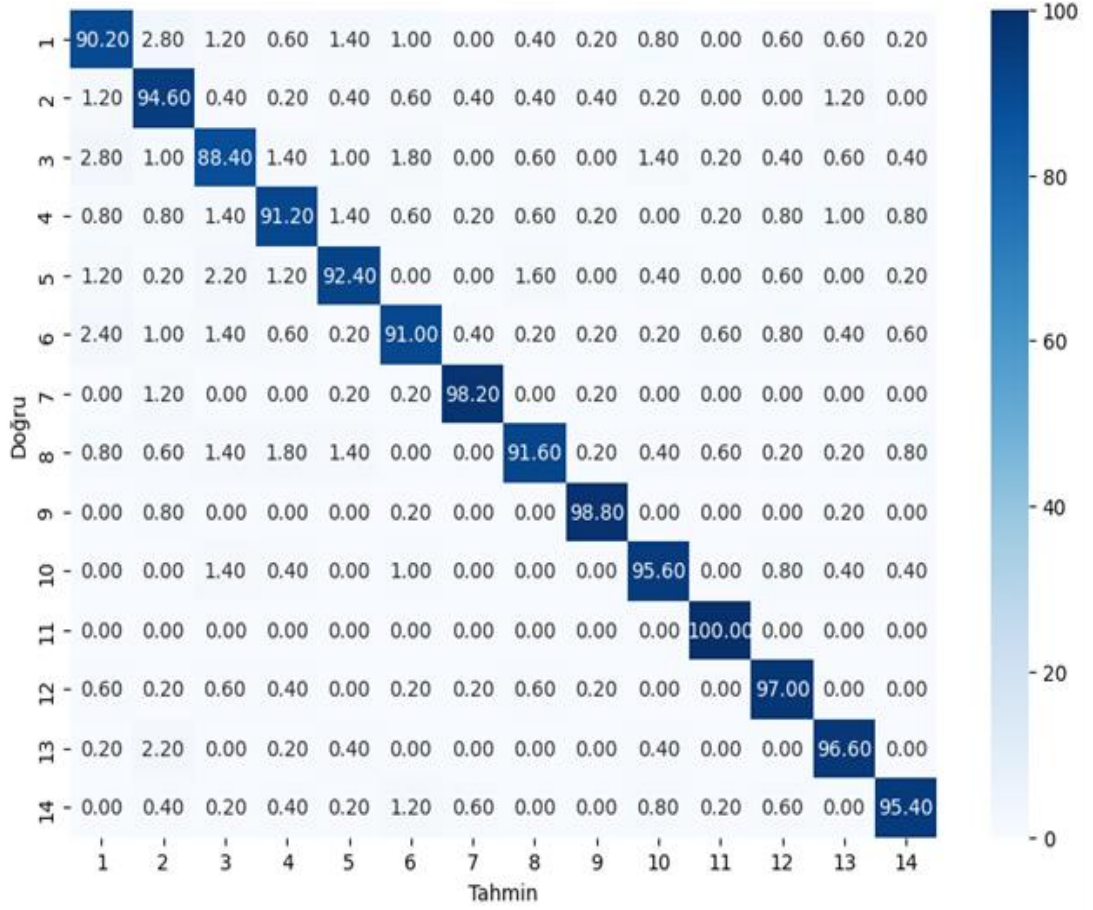
Şekil 3.4. Modellerin kayıp grafikleri

Tablo 3.3. Modellerin performans değerleri


Performans Ölçütleri	TCN	CNN	LSTM	BERT
Kayıp (%)	30.54	14.74	38.92	23.37
Doğruluk (%)	94.36	96.40	93.70	94.91
Kesinlik (%)	94.45	96.46	93.91	95.10
Geri Çağırma (%)	94.36	96.40	93.70	94.93
F1 Skoru (%)	94.36	96.41	93.73	94.92
Ortalama Eğitim Süresi (sn)	43.51	50.21	98.84	245.56

Tablo 4.3'teki sonuçlara göre, CNN modeli %14,74 ile en düşük test kaybı değerini elde ederek yüksek bir genelleme kabiliyetine işaret etmiştir. BERT de %23,37'lik test kaybıyla benzer bir performans göstermiştir. Buna karşılık, LSTM modeli %38,92'lik test kaybıyla geride kalmıştır. Doğruluk açısından CNN modeli %96,40 ile en yüksek değere ulaşmış, onu yine güçlü performans sergileyen BERT (%94,91) ve TCN (%94,36) izlemiştir. LSTM %93,70'lik doğruluk oranıyla en düşük sırada yer almıştır. Kesinlik ve geri çağırma metrikleri için CNN %96,40 ile en yüksek değerleri elde etmiş, onu BERT(%94,93) ve TCN(94,36) izlemiştir. Kesinlik ve geri çağırmanın dengeli bir ölçütü olan F1 puanı dikkate alındığında, CNN %96,41 ile yine lider olurken, BERT (%94,92) ve TCN (%94,36) onu yakından takip etmiştir. Eğitim süresi açısından TCN, eğitimi yalnızca 43,51 saniyede tamamlayarak en hızlısı olmuştur. CNN 50,21 saniye gibi daha uzun bir eğitim süresi gerektirmesine rağmen, üstün

doğruluğu ile bunu telafi etmiştir. Öte yandan, LSTM ve BERT sırasıyla 98,84 saniye ve 245,56 saniyelik eğitim süreleriyle önemli ölçüde daha fazla kaynak gerektirmiştir. Dört model için 5 katlı çapraz doğrulama sonuçlarının ortalama karmaşıklık matrisleri TCN modeli için Şekil 3.5’ te, CNN modeli için Şekil 3.6’ da, LSTM modeli için Şekil 3.7’ de ve BERT modeli için Şekil 3.8’ de ayrı ayrı gösterilmiştir.




Şekil 3.5. TCN modeli ortalama karmaşıklık matrisi



Şekil 3.6. CNN modeli ortalama karmaşıklık matrisi



Şekil 3.7. LSTM modeli ortalama karmaşıklık matrisi



Şekil 3.8. BERT modeli ortalama karmaşıklık matrisi



4. SONUÇLAR VE ÖNERİLER

Bu çalışmada, personel geri bildirim verileri dört farklı derin öğrenme modeli kullanılarak sınıflandırılmış ve modellerin performansları ve eğitim süreleri karşılaştırılmıştır. CNN modeli, test kaybı, doğruluk, kesinlik, geri çağırma ve F1 puanı dahil olmak üzere tüm performans ölçütlerinde en iyi sonuçları elde ederek en başarılı model olarak ortaya çıkmıştır. Yüksek doğruluğu ile CNN, sınıflandırma görevleri için etkili bir seçenek olduğunu kanıtlamıştır. Bağlamsal dil temsillerini öğrenme kabiliyetiyle bilinen BERT modeli, CNN'e yakın bir performans sergilemiştir. Bununla birlikte, daha uzun eğitim süreleri, bu yöntemi hesaplama açısından daha maliyetli hale getirmiştir. TCN modeli hızlı eğitim süresiyle öne çıkmış ancak performans ölçütlerinde diğer modellerin gerisinde kalmıştır. TCN zaman serisi analizi için avantajlar sunsa da bu çalışmanın sınıflandırma görevinde güçlü bir performans gösterememiştir. LSTM modeli, sıralı verileri işleme kabiliyetine rağmen, daha uzun eğitim süresi ve daha düşük doğruluk nedeniyle CNN'in gerisinde kalmıştır.

Gelecekte yapılacak çalışmalar kapsamında, farklı derin öğrenme modellerinin ve hibrid yaklaşımların incelenmesi, sınıflandırma performansını daha da artırabilir. Özellikle CNN'in yüksek doğruluğu ile BERT'in bağlamsal dil işleme yetenekleri birleştirilerek daha güçlü bir model oluşturulabilir. Bunun yanı sıra, eğitim sürelerini optimize etmek için model sıkıştırma teknikleri uygulanarak hesaplama verimliliği artırılabilir. Mevcut veri seti, farklı sektörlerden toplanan geri bildirimlerle genişletilerek modellerin genellenebilirliği test edilebilir. Ayrıca, duygu analizi ve konu modelleme teknikleri kullanılarak personel geri bildirimlerinin daha derinlemesine incelenmesi sağlanabilir.



KAYNAKLAR

- [1] KAYAKUŞ, M., AÇIKGÖZ, F. Y. (2022). Classification of News Texts by Categories Using Machine Learning Methods. *Alphanumeric Journal* , 10(2), 155 - 166. doi.org/10.17093/alphanumeric.1149753
- [2] BOZKURT, A. H., YALÇIN, N. (2024). Topluluk Öğrenmesi Algoritmaları Kullanarak Amazon Yemek Yorumları Üzerine Duygu Analizi. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi* , 11(1), 128 - 139. doi.org/10.35193/bseufbd.1300732
- [3] TUNA, M. F., POLATGİL, M., KAYNAR, O. (2023). Restoran Müşterilerinin Geri Bildirimleri Üzerinde Hedef Kategorinin Tespiti ve Hedef Tabanlı Duygu Analizi. *Süleyman Demirel Üniversitesi Vizyoner Dergisi* , 14(40), 1205 - 1221. doi.org/10.21076/vizyoner.1208355
- [4] ÖĞE, B. C., KAYAALP, F. (2021). Farklı Sınıflandırma Algoritmaları ve Metin Temsil Yöntemlerinin Duygu Analizinde Performans Karşılaştırılması. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi* , 9(6), 406 - 416. doi.org/10.29130/dubited.1015320
- [5] METİN, İ. A., KARASULU, B. (2021). İnsanın günlük aktivitelerinin yeni bir veri kümesi: Derin öğrenme tekniklerini kullanarak sınıflandırma performansı için kıyaslama sonuçları. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 36(2), 759 - 778. doi.org/10.17341/gazimmfd.772849
- [6] AYDEMİR, E., IŞIK, M., TUNCER, T. (2021). Türkçe Haber Metinlerinin Çok Terimli Naive Bayes Algoritması Kullanılarak Sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi* , 33(2), 519 - 526. doi.org/10.35234/fumbd.871986
- [7] AKGÜMÜŞ, M. M., BOYACI, A. (2023). Bankacılık sektörü için topluluk öğrenimini kullanan iki aşamalı bir müşteri şikayet yönetimi. *TBV Bilgisayar Bilimleri ve Mühendisliği Dergisi* , 16(1), 45 - 52. doi.org/10.54525/tbbmd.1163852
- [8] ERTEM, S., ÖZBAY, E. (2024). Detection of COVID-19 Anti-Vaccination from Twitter Data Using Deep Learning and Feature Selection Approaches. *Firat University journal of experimental and computational engineering (Online)*, 3(2), 116 - 133. doi.org/10.62520/fujece.1443753
- [9] DEMIRBILEK, M., DEMIRBILEK, S. Ö. (2023). Google Yorumları Üzerinden Makine Öğrenme Yöntemleri ve Amazon Comprehend ile Duygu Analizi: İç Anadolu'da Bir Üniversite Örneği. *Üniversite Araştırmaları Dergisi (Online)*, 6(4), 452 - 461. doi.org/10.32329/uad.1383794
- [10] ÇATALTAŞ, M., ÜSTÜNEL, B., BAYKAN, N. A. (2023). SENTIMENT CLASSIFICATION ON TURKISH TWEETS ABOUT COVID-19 USING LSTM NETWORK. *Konya mühendislik bilimleri dergisi (Online)* , 11(2), 341 - 353. doi.org/10.36306/konjes.1173939

- [11] ALPARSLAN, G., DURSUN, M. (2023). Konvolüsyonel Sinir Ağları Tabanlı Türkçe Metin Sınıflandırma. *Bilişim Teknolojileri Dergisi* , 16(1), 21 - 31. doi.org/10.17671/gazibtd.1165291
- [12] YILMAZ, M., GÜNAL, E. S. (2022). DERİN ÖĞRENME TEMELLİ OTOMATİK YARDIM MASASI SİSTEMİ. *Eskişehir Osmangazi Üniversitesi mühendislik ve mimarlık fakültesi dergisi (online)* , 30(3), 318 - 327. doi.org/10.31796/ogummf.1038486
- [13] BUDAK, İ., ORGAN, A. (2022). VERİ VE METİN MADENCİLİĞİ İLE HAVA YOLU İŞLETMELERİNİN COVID-19 ÖNCESİ VE SONRASI SOSYAL MEDYA YORUM VE SKORLARININ DEĞERLENDİRİLMESİ. *Ömer Halisdemir Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* , 15(4), 998 - 1022. doi.org/10.25287/ohuiibf.1149801
- [14] SEL, İ., HANBAY, D. (2021). Ön Eğitimli Dil Modelleri Kullanarak Türkçe Tweetlerden Cinsiyet Tespiti. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi* , 33(2), 675 - 684. doi.org/10.35234/fumbd.929133
- [15] ACI, Ç., ÇIRAK, A. (2019). Türkçe Haber Metinlerinin Konvolüsyonel Sinir Ağları ve Word2Vec Kullanılarak Sınıflandırılması. *Bilişim Teknolojileri Dergisi* , 12(3), 219 - 228. doi.org/10.17671/gazibtd.457917
- [16] BİŞKİN, O. T. (2021). MULTI-STEP FORECASTING OF COVID-19 CASES IN EUROPEAN COUNTRIES USING TEMPORAL CONVOLUTIONAL NETWORKS. *Mugla Journal of Science and Technology* , 7(1), 117 - 126. doi.org/10.22531/muglajsci.875414
- [17] KASAPBAŞI, A., CANBOLAT, H. (2024). İŞİTME ENGELLİ BİREYLERİN HAREKETLERİNİ SINIFLANDIRMAYA YÖNELİK YAPAY ZEKA MODELİNİN GELİŞTİRİLMESİ. *Black Sea Journal of Engineering and Science* , 7(5), 826 - 835. doi.org/10.34248/bsengineering.1477046
- [18] EROL, B., İNKAYA, T. (2024). SATIŞ TAHMİNİ İÇİN DERİN ÖĞRENME YÖNTEMLERİNİN KARŞILAŞTIRILMASI. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi* , 29(2), 535 - 554. doi.org/10.17482/uumfd.1382971
- [19] TUNA, M. F., GÖRMEZ, Y. (2024). Evrimsel Sinir Ağları Tabanlı Derin Öğrenme Yöntemiyle Müşteri Şikayetlerinin Sınıflandırılması. *Bingöl Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi (Online)* , 8(1), 31 - 46. doi.org/10.33399/biibfad.1362160
- [20] AYDIN, Ö., KANTARCI, H. (2024). Türkçe Anahtar Sözcük Çıkarımında LSTM ve BERT Tabanlı Modellerin Karşılaştırılması. *Bilgisayar bilimleri ve mühendisliği dergisi* , 17(1), 9 - 18. doi.org/10.54525/bbmd.1454220
- [21] ARSLAN, S., FIRAT, E. (2024). Stance Detection on Short Turkish Text: A Case Study of Russia-Ukraine War. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi* , 24(3), 602 - 619. doi.org/10.35414/akufemubid.1377465

- [22] GÜR, Y. E. (2024). Comparative Analysis of Deep Learning Models for Silver Price Prediction: CNN, LSTM, GRU and Hybrid Approach. *Akdeniz İİBF Dergisi* , 24(1), 1 - 13. doi.org/10.25294/aiiibfd.1404173
- [23] DEMIRBILEK, M., DEMIRBILEK, S. Ö. (2023). Google Yorumları Üzerinden Makine Öğrenme Yöntemleri ve Amazon Comprehend ile Duygu Analizi: İç Anadolu'da Bir Üniversite Örneği. *Üniversite Araştırmaları Dergisi (Online)* , 6(4), 452 - 461. doi.org/10.32329/uad.1383794
- [24] KAHRAMAN, S. Y., DURMUŞOĞLU, A., DERELİ, T. (2024). Ön eğitilmiş Bert modeli ile patent sınıflandırılması. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi* , 39(4), 2484 - 2496. doi.org/10.17341/gazimmfd.1292543
- [25] AYDIN, Ö., KANTARCI, H. (2024). Türkçe Anahtar Sözcük Çıkarımında LSTM ve BERT Tabanlı Modellerin Karşılaştırılması. *Bilgisayar bilimleri ve mühendisliği dergisi* , 17(1), 9 - 18. doi.org/10.54525/bbmd.1454220
- [26] SEL, İ., HANBAY, D. (2021). Ön Eğitilmiş Dil Modelleri Kullanarak Türkçe Tweetlerden Cinsiyet Tespiti. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi* , 33(2), 675 - 684. doi.org/10.35234/fumbd.929133
- [27] Lea, C., Vidal, R., Reiter, A., & D.Hager, G. (2016). *Temporal Convolutional Networks: A Unified Approach to Action Segmentation*. Lecture Notes in Computer Science. Springer International Publishing. https://doi.org/10.1007/978-3-319-49409-8_7
- [28] ÜLKER, E., & İNİK, Ö. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*. Retrieved from <https://dergipark.org.tr/tr/pub/gbad/issue/31228/330663>
- [29] Ghojogh, B., & Ghodsi, A. (2023). *Recurrent Neural Networks and Long Short-Term Memory Networks: Tutorial and Survey*. arXiv. Retrieved from <https://arxiv.org/abs/2304.11461>
- [30] Devlin, J., Chang, M.-W., Lee, K., & Kristina Toutanova, and. (2019). *BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding*. arXiv Preprint. arXiv. Retrieved from <https://arxiv.org/abs/1810.04805>



ÖZGEÇMİŞ

Ad-Soyad : Gökhan YİĞİDEFE

ÖĞRENİM DURUMU:

- Lisans : 2018, Erciyes Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- 06.2017-07.2017 tarihleri arasında TEMSA'da stajyer olarak çalıştı.
- 08.2017-09.2017 tarihleri arasında WIKI SOFTWARE'da stajyer olarak çalıştı.
- 10.2017-12.2017 tarihleri arasında İPEK BİLGİSAYAR'da gönüllü stajyer olarak çalıştı.
- 06.2018-12.2018 tarihleri arasında ERBE YAZILIM'da yazılım uzmanı olarak çalıştı.
- 01.2019-12.2019 tarihleri arasında ACERPRO BİLİŞİM'de yazılım uzmanı olarak çalıştı.
- 01.2020-11.2023 tarihleri arasında VAKIFBANK'ta kıdemli yazılım uzmanı olarak çalıştı.
- 11.2023 tarihinden itibaren TOMBANK'ta kıdemli yazılım uzmanı olarak çalışmaktadır.

TEZDEN TÜRETİLEN ESERLER:

- Yiğidefe, G., Çakar Kaman, S., & Eken, B. (2025). Classification and Analysis of Employee Feedback with Deep Learning Algorithms. Sakarya University Journal of Computer and Information Sciences, 8(1), 38-46. <https://doi.org/10.35377/saucis...1627619>