



AKSARAY ÜNİVERSİTESİ

SOSYAL BİLİMLER ENSTİTÜSÜ

YÖNETİM BİLİŞİM SİSTEMLERİ ANABİLİM DALI

**OTEL FİRMALARINA YAPILAN YORUMLARIN METİN
MADENCİLİĞİ VE DERİN ÖĞRENME YÖNTEMLERİ İLE
ANALİZİ**

YÜKSEK LİSANS TEZİ

MUHAMMED KAAAN AKGÜN

DANIŞMAN

DOÇ. DR. KEMAL ADEM

AKSARAY-2025

AKSARAY ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
YÖNETİM BİLİŞİM SİSTEMLERİ ANABİLİM DALI

OTEL FİRMALARINA YAPILAN YORUMLARIN METİN
MADENCİLİĞİ VE DERİN ÖĞRENME YÖNTEMLERİ İLE
ANALİZİ
YÜKSEK LİSANS TEZİ

MUHAMMED KAAAN AKGÜN

DANIŞMAN : DOÇ. DR. KEMAL ADEM

İKİNCİ DANIŞMAN : DR. ÖĞR. ÜYESİ UĞUR DEMİROĞLU

JÜRİ ÜYESİ : DOÇ. DR. RAHMİ BAKİ

JÜRİ ÜYESİ : DR. ÖĞR. ÜYESİ ŞÜKRÜ ÜNVER

AKSARAY-2025

TELİF HAKLARI VE TEZ FOTOKOPİ İZİN FORMU

Bu tezin tüm hakları saklıdır. Kaynak göstermek koşuluyla tezin teslim tarihinden itibaren (....) ay sonra tezden fotokopi çekilebilir.

YAZARIN

Adı : Muhammed Kaan

Soyadı : AKGÜN

Bölümü : Yönetim Bilişim Sistemleri

İmza :

Teslim Tarihi :

TEZİN

Türkçe Adı : Otel Firmalarına Yapılan Yorumların Metin Madenciliği ve Derin Öğrenme Yöntemleri ile Analizi

İngilizce Adı : Analysis of Reviews Made to Hotel Companies Using Text Mining and Deep Learning Methods

ETİK İLKELERE UYGUNLUK BEYANI

Tez yazma sürecinde bilimsel ve etik ilkelere uyduğumu, yararlandığım tüm kaynakları kaynak gösterme ilkelerine uygun olarak kaynakçada belirttiğimi ve bu bölümler dışındaki tüm ifadelerin şahsıma ait olduğunu beyan ederim.

Yazar Adı Soyadı

Muhammed Kaan AKGÜN

İmza

T.C.
AKSARAY ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
JÜRİ ONAY SAYFASI

Muhammed Kaan AKGÜN tarafından hazırlanan “Otel Firmalarına Yapılan Yorumların Metin Madenciliği ve Derin Öğrenme Yöntemleri ile Analizi” başlıklı tez çalışması aşağıdaki jüri tarafından oy birliği ile Aksaray Üniversitesi Sosyal Bilimler Enstitüsü Yönetim Bilişim Sistemleri Anabilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

	<u>Kabul</u>	<u>Ret</u>	<u>İmza</u>
Danışman: (Doç.Dr. Kemal ADEM) (Bilgisayar Mühendisliği, Sivas Cumhuriyet Üniversitesi)	☐	☐	
Üye: (Doç. Dr. Rahmi BAKİ) (Yönetim Bilişim Sistemleri, Aksaray Üniversitesi)	☐	☐	
Üye: (Dr. Öğr. Üyesi Şükrü ÜNVER) (Bilgisayar Mühendisliği, Sivas Bilim ve Teknoloji Üniversitesi)	☐	☐	

Tez Savunma Tarihi: 23/01/2025

Sosyal Bilimler Enstitüsü Yönetim Kurulu’nun tarih ve sayılı kararı ile onaylanmıştır.

Sosyal Bilimler Enstitüsü Müdürü

Prof. Dr. Aybala ÇAYIR

İmza

TEŞEKKÜR SAYFASI

Bu çalışmanın gerçekleştirilmesinde desteklerini esirgemeyen ve bana yol gösteren danışman hocam Sayın Doç. Dr. Kemal ADEM'e, ikinci danışman hocam Sayın Dr. Öğr. Üyesi Uğur DEMİROĞLU'na, arkadaşım Buse SAÇIKARALI'ya ve aileme teşekkür ederim.

ÖZET

Günümüzde yaygınlaşan internet kullanımının olanaklarından bazıları da sosyal ağların kullanımının, ürün ve hizmetlerin ticari faaliyetleri ile ilgili yorumların oldukça önemli hale gelmesine zemin hazırlamıştır. Sanal ortamlardaki yorumların, metinlerin üzerinde duygu analizi yapılması birçok alanda faydalı amaçlar doğrultusunda kullanım sahası oluşturabilmektedir. Bu çalışmada, müşterilerin otellerle ilgili yorumları okumadan, olumlu, nötr veya olumsuz olarak değerlendirme yapabilmesi amaçlanmıştır. Bu doğrultuda, otel rezervasyon sitelerinden biri olan Etstur'daki müşteri yorumları kullanılarak, derin öğrenme yöntemleriyle otellerin değerlendirilmesi gerçekleştirilmiştir. Veri kümesine Random, Word2Vec, FastText, GloVe ve BERT kelime gömme teknikleri uygulandıktan sonra, derin öğrenme tekniklerinden CNN-LSTM karma modeli, GRU modeli ve DENSE katmanı kullanılarak analiz gerçekleştirilmiş ve en yüksek başarı, GloVe kelime gömme tekniği sonrası uygulanan CNN-LSTM derin öğrenme modeli ile elde edilmiştir.

Anahtar Kelimeler : Makine Öğrenmesi, Derin Öğrenme, Metin Madenciliği, Duygu Analizi, GloVe, BERT

Bilim Kodu : 92432, 92416

Sayfa Adedi : 107

Yazar : Muhammed Kaan AKGÜN

Danışman : Doç. Dr. Kemal ADEM

İkinci Danışman : Dr. Öğr. Üyesi Uğur DEMİROĞLU

ABSTRACT

With the increasing use of the internet today, the utilization of social networks and the importance of comments on products and services in commercial activities have gained significant attention. Sentiment analysis of comments and texts in virtual environments can be applied in various fields for beneficial purposes. This study aims to enable customers to evaluate hotel reviews as positive, neutral, or negative without having to read them. In this context, customer reviews from Etstur, a hotel reservation platform, were analyzed using deep learning methods. After applying word embedding techniques such as Random, Word2Vec, FastText, GloVe, and BERT to the dataset, deep learning techniques, including the CNN-LSTM hybrid model, GRU model, and DENSE layer, were employed for analysis. The highest accuracy was achieved using the CNN-LSTM deep learning model following the application of the GloVe word embedding technique.

Keywords : Machine Learning, Deep Learning, Text Mining, Sentiment Analysis, Glove, BERT

Science Code : 92432, 92416

Number of Pages : 107

Author : Muhammed Kaan AKGÜN

Supervisor : Assoc. Prof. Dr. Kemal ADEM

Co-Supervisor : Assist. Prof. Dr. Uğur DEMİROĞLU

İÇİNDEKİLER

TELİF HAKLARI VE TEZ FOTOKOPİ İZİN FORMU	i
ETİK İLKELERE UYGUNLUK BEYANI	ii
TEŞEKKÜR SAYFASI	iv
ÖZET.....	v
ABSTRACT	vi
İÇİNDEKİLER	vii
TABLolar LİSTESİ.....	ix
ŞEKİLLER LİSTESİ.....	x
KISALTMALAR.....	xii
GİRİŞ	1
BİRİNCİ BÖLÜM.....	4
KURAMSAL TEMELLER.....	4
1.1. İletişim	4
1.2. Ağızdan Ağıza iletişim.....	4
1.3. Elektronik Ağızdan Ağıza İletişim.....	6
1.3.1. Turizm Sektöründe Dijital Ağızdan Ağıza İletişim (E-Turizm)	7
1.3.2. Çevrimiçi Otel Platformları	9
1.4. Temel Literatür Bilgisi	12
İKİNCİ BÖLÜM	21
MATERYAL VE YÖNTEM.....	21
2.1. Verilerin Elde Edilmesi.....	21
2.2. Zekâ ve Yapay Zekâ.....	22
2.2.1. Yapay Zekâ.....	23
2.3. Metin Madenciliği.....	26
2.4. Duygu Analizi	28
2.5. Tokenleştirme.....	29
2.6. Kelime Gömme Teknikleri	30
2.6.1. Word2Vec.....	31

2.6.2. GloVe	35
2.6.3. FastText	37
2.6.4. Bert Modeli.....	38
2.7. Makine Öğrenmesi	39
2.7.1. Öğrenme Yöntemleri	40
2.8. Derin Öğrenme.....	41
2.8.1. Derin Öğrenme Modelleri	42
ÜÇÜNCÜ BÖLÜM	53
BULGULAR	53
3.1. Derin Öğrenme Yöntemlerinden Sonra Elde Edilen Sonuçlar	54
SONUÇ.....	73
KAYNAKÇA	80
EKLER.....	90
AKSARAY ÜNİVERSİTESİ TEZ DEĞERLENDİRME FORMU	92

TABLÖLAR LİSTESİ

Tablo 1. Olumlu-Olumsuz-Nötr Veri Örneği	21
Tablo 2. GRU Modelinin Sonuçları.....	55
Tablo 3. Random Kelime Gömmesi CNN-LSTM Model Sonucu	57
Tablo 4. GloVe Kelime Gömme Tekniği CNN-LSTM Model Sonucu.....	60
Tablo 5. Word2Vec Kelime Gömmesi CNN-LSTM Modeli	62
Tablo 6. BERT Kelime Gömmesi CNN-LSTM Modeli.....	64
Tablo 7. FastText Kelime Gömmesi CNN-LSTM Modeli.....	67
Tablo 8. Dense Modeli sonuçları	69
Tablo 9. Derin Öğrenme Modellerinin Analiz Sonuçları	71

ŞEKİLLER LİSTESİ

Şekil 1. Zekâ Kavramı (Gümüş, 2019)	23
Şekil 2. Yapay Zekanın Tarihsel Gelişimi (Daşgın, 2023)	25
Şekil 3. Yapay zekâ, Makine Öğrenimi ve Derin Öğrenme İlişkisi (Ucuza, 2020)	26
Şekil 4. Metin Madenciliği Süreci	27
Şekil 5. Metin Ön İşleme Süreçleri	27
Şekil 6. Duygu Analizi Yöntemleri (Kılıçer, 2024)	29
Şekil 7. Word2Vec Mimarisi (Keskin, 2018)	31
Şekil 8. Cbow ve Skip-Gram Mimarisi (Polat, 2021)	32
Şekil 9. Cbow Modeli Mimarisi (Polat, 2021)	34
Şekil 10. Skip-Gram Model Mimarisi (Çelenli, 2020)	35
Şekil 11. Glove Mimarisi (Venugopal, 2021)	36
Şekil 12. FastText Kelime Gömme Modeli	37
Şekil 13. Bert Model Mimarisi (Bhakta, 2024)	39
Şekil 14. Klasik Derin öğrenme Yapısı (Gündüz, 2019)	42
Şekil 15. Yapay Sinir Ağı Modeli	44
Şekil 16. ReLU Fonksiyonu Grafiği (Dikici, 2024)	45
Şekil 17. CNN Model Yapısı (Bardız, 2019)	46
Şekil 18. Geleneksel RNN Mimarisi (Amidi ve Amidi, 2018)	49
Şekil 19. LSTM Mimarisi (Gürbüz, 2020)	49
Şekil 20. GRU Mimarisi (Canlı, 2022)	51
Şekil 21. FastText-GRU Modeli Loss Grafiği	56
Şekil 22. FastText-GRU Modeli Accuracy Grafiği	56

Şekil 23. Random CNN-LSTM Modeli Loss Grafiği.....	58
Şekil 24. Random CNN-LSTM Modeli Accuracy Grafiği.....	58
Şekil 25. GloVe CNN-LSTM Modeli Loss Grafiği.....	61
Şekil 26. GloVe CNN-LSTM Modeli Accuracy Grafiği.....	61
Şekil 27. Word2Vec CNN-LSTM Modeli Loss Grafiği.....	63
Şekil 28. Word2Vec CNN-LSTM Modeli Accuracy Grafiği.....	63
Şekil 29. Bert CNN-LSTM Modeli Loss Grafiği	65
Şekil 30. Bert CNN-LSTM Modeli Accuracy Grafiği.....	65
Şekil 31. FastText CNN-LSTM Modeli Loss Grafiği	68
Şekil 32. FastText CNN-LSTM Modeli Accuracy Grafiği	68
Şekil 33. Dense CNN-LSTM Modeli Loss Grafiği	70
Şekil 34. Dense CNN-LSTM Modeli Accuracy Grafiği	70

KISALTMALAR

DOI	:	Digital Object Identifier
TDK	:	Türk Dil Kurumu
TTK	:	Türk Tarih Kurumu
URL	:	Uniform Resource Loader
YÖK	:	Yükseköğretim Kurulu
CNN	:	Convolutional Neural Network
LSTM	:	Long Short-Term Memory
GRU	:	Gated Recurrent Unit
YSA	:	Yapay Sinir Ağı
TF	:	Term Frequency
IDF	:	Inverse Document Frequency
NLP	:	Natural Language Processing
RNN	:	Recurrent Neural Network
WOM	:	Ağızdan Ağıza İletişim
e-WOM	:	Elektronik Ağızdan Ağıza İletişim
e-AAİ	:	Elektronik Ağızdan Ağıza İletişim
IDE	:	Integrated Development Environment

GİRİŞ

Günümüzde yaygınlaşan internet kullanımının, olanaklarından bazıları da sosyal ağların kullanımının ürün ve hizmetlerin ticari faaliyetleri ile ilgili yorumların oldukça önemli hale gelmesine zemin hazırlamıştır. Birçok insan yorumlarını internet ortamında, e-ticaret veya sosyal medya gibi sanal platformlarda yazıya dökerek belirtmektedirler. Bu gibi durumlar sanal ortamlarda, web sitelerinde yaygınlaşarak, insanların hislerini ve fikirlerini metinlerle ortaya çıkartmasının önemini arttırmıştır. Sanal ortamlardaki yorumların, metinlerin üzerinde duygu analizi yapılması birçok alanda faydalı amaçlar doğrultusunda kullanım sahası oluşturabilir. Satıcılar için müşteri memnuniyeti geri dönüşü ve iyileştirmesi için pazarlama üzerinde yapmış oldukları politikaları belirleme veya değiştirmede belirleyici olabilir (Önal, 2017). Ürün ve hizmetleri satın alacaklar için de hangi ürün veya hizmeti satın alacakları yahut almayacaklarını belirlemeye ve işlerini kolaylaştırma açısından belirleyici olabilir. Bu çalışmada ise otellerin tercih edilmesi, başkalarının deneyimlerinin yararlanılması oteller hakkında olumlu, olumsuz veya nötr gibi sonuçlar elde edilebilecek, tüm müşteri yorumlarını tek tek incelemek ve karar vermek zorlayıcı olacağından, müşterilerin zaman tasarrufu yapmasını sağlayacak bir sistem geliştirilmesi amaçlanmaktadır. Müşterilerin otellere yapılan tüm yorumları incelemesi ve karara varması zamansal yönden çok zaman kaybedici olduğundan bu sorunun metin madenciliğinin alt işlevlerinden biri olan duygu analiziyle aşılacak bir sistem üzerinde çalışılmıştır. Bu çalışma ile Etstur platformu üzerinden çekilecek olan yorumlar üzerinde metin madenciliği ve derin öğrenme yöntemleri kullanılarak ortaya çıkacak olan sınıflar sayesinde müşterilerin daha kolay otel seçimi ve oteller arasında kıyaslama yapabilmesi amaçlanmaktadır.

Araştırmanın amacı, Sürekli gelişen ve değişen teknoloji ile birlikte günümüz tüketici ihtiyaç ve alışkanlıkları da değişmiştir. Günümüz teknolojisiyle insanlar bir hizmet veya ürün satın alacakları zamanlarda birçok farklı satın alma kararları yanına online platformları da tercih etmektedirler. Yapacakları satın alma işleminde online platformlarda yer alan yorum kısmında müşteri deneyimleri ile karşılaşmaktadırlar ve bu durum onların satın alma kararlarını etkilemektedir. Otellerde konaklamak isteyen müşteriler de otel tercihi yapmadan

önce o otellere ait yorumları incelemektedir. Buradan hareketle Etstur platformu üzerinden çekilecek olan yorumlar üzerinde metin madenciliği ve derin öğrenme yöntemleri kullanılarak ortaya çıkacak olan sınıflar sayesinde müşterilerin daha kolay otel seçimi ve oteller arasında kıyaslama yapılabilmesi amaçlanmaktadır.

Araştırmanın önemi, Oteller üzerinde yapılmış çalışmalara bakıldığında daha çok olumlu-olumsuz olarak iki sınıfta verileri topladıklarını, bazı çalışmalarda ise konu modelleme ve derecelendirme işlemi uygulandığı görülmektedir. Bu çalışmada güncel metin madenciliği ve derin öğrenme yöntemleri kullanılacaktır. Kullanılacak olan bu yeni yöntemler sonucunda müşterilerin daha kolay satın alma işlemi ve kıyaslama yapabilmeleri açısından bu çalışma önemlidir.

Araştırmanın yöntemi, Platform içerisinden, belirlenmiş oteller hakkında yazılmış materyaller platformdan çekilerek, bir veri kümesi oluşturulmuş ve bu veriler sayısallaştırılmıştır. Bu sayısallaştırma işleminde veri kümesine Random, Word2Vec, GloVe, FastText, BERT kelime gömme teknikleri kullanılmıştır. Kullanılan bu teknikler sonucu oluşturulan sayısallaştırılmış veri kümesine, derin öğrenme yöntemleri kullanarak bu kelime gömme teknikleri ile derin öğrenme yöntemlerini karşılaştırıp en başarılı yöntem karar destek sistemi olarak sunulmuştur.

Araştırmanın kapsamı, otel arama platformu olan Etstur'da yer alan otellere yönelik puanlama ve yorumların, duygu analizi ve derin öğrenme yöntemleri kullanılarak değerlendirilmesini içermektedir. Python programlama dili ile geliştirilen bir kodlama süreciyle Etstur'daki otel yorumları toplanmış, veriler temizlenmiş ve derin öğrenme ile kelime gömme tekniklerinin uygulanmasına uygun hale getirilmiştir.

Bu çalışma, literatürdeki eksiklikleri ele alarak duygu analizi ve metin madenciliği alanına çeşitli katkılar sunmaktadır. Çalışmanın öne çıkan katkıları şu şekilde sıralanabilir:

- Derin öğrenme tabanlı modellerin duygu analizi üzerindeki etkisini değerlendirmek: Literatürde genellikle geleneksel makine öğrenmesi yöntemleri kullanılmaktadır. Bu çalışma, CNN-LSTM ve GRU gibi gelişmiş derin öğrenme modellerini kullanarak duygu analizi performansını artırmayı hedeflemektedir.
- Farklı kelime gömme tekniklerinin karşılaştırılması: Literatürde yaygın olarak kullanılan Word2Vec ve GloVe yöntemlerinin yanı sıra, BERT ve FastText gibi modern teknikler kullanılmış ve duygu analizi üzerindeki etkileri detaylı bir şekilde

incelenmiştir.

- Büyük ölçekli veri kümesiyle çalışma yapılması: Çalışmada 200.001 otel yorumu içeren geniş bir veri kümesi kullanılarak modelin genelleme yeteneği artırılmıştır. Önceki çalışmalar genellikle daha küçük veri setleriyle sınırlıyken, bu çalışma büyük veri kullanımıyla fark yaratmaktadır.
- Bağlamsal kelime gömme tekniklerinin donanımsal gereksinimlerinin değerlendirilmesi: Özellikle BERT gibi güçlü modellerin eğitim süreçlerinde yüksek donanım gerektirdiği tespit edilmiş ve bu sınırlamalar çalışmada ele alınmıştır.
- Otelcilik sektörü için uygulanabilir bir duygu analizi modeli geliştirilmesi: Çalışmada geliştirilen model, yalnızca akademik bir katkı sunmakla kalmayıp, otel işletmecileri için müşteri yorumlarını otomatik olarak analiz edebilecek pratik bir araç olarak da kullanılabilir.
- Geleneksel ve derin öğrenme yöntemlerinin karşılaştırmalı analizi: Çalışmada derin öğrenme tabanlı yaklaşımlar kıyaslanarak, hangi yöntemin daha iyi sonuçlar verdiği detaylı olarak ortaya konmuştur.

Sonuç olarak, bu tez çalışması duygu analizi alanında literatüre hem teorik hem de pratik katkılar sunarak, metin madenciliği ve doğal dil işleme tekniklerinin geliştirilmesine önemli bir katkı sağlamaktadır.

BİRİNCİ BÖLÜM

KURAMSAL TEMELLER

1.1. İletişim

Bu bölümde, iletişim kavramı, süreci ve temel unsurlarının tanımları incelenmektedir. Ardından, ağızdan ağıza iletişim ve elektronik ağızdan ağıza iletişim kavramları detaylandırılarak, bu iletişim türlerinin özellikleri ve önemi açıklanmaktadır.

İletişim, bir göndericinin iletmek istediği bilgiyi bir alıcıya aktardığı süreç olarak tanımlanabilir. Bu süreçte en temel unsurlar; kaynak, alıcı ve kanal olarak sıralanabilir. Kanal, mesajın iletilmesini sağlayan araçtır. Genel olarak, iletişim kavramı bir kaynak ile bir alıcı arasındaki bilgi paylaşımını içerir ve bu paylaşımın bir kanal aracılığıyla anlam kazandığı bir süreçtir. Kökeni Latince "communis" kelimesine dayanan iletişim, insanların bilgi alışverişi yapma süreci olarak da ifade edilebilir (Türk Dil Kurumu, 2025).

1.2. Ağızdan Ağıza iletişim

Ağızdan ağıza iletişim, pazarlama kaynaklarından bağımsız olarak kişiler arasında gerçekleşen, ticari motivasyona dayanmayan doğal bir iletişim biçimidir. Bu kavram, ürünler ve markalar hakkındaki kişisel görüşlerin güvenilir ve etkili bir şekilde paylaşılmasını ifade eder. Tüketiciler, çevrelerindeki kişilere reklamlardan daha fazla güvenme eğilimindedir, çünkü bu tür iletişim, tarafsız ve dürüst bir bilgi kaynağı olarak algılanır. Ağızdan ağıza iletişim, güvenilirlik, deneyim, uzmanlık ve kanıt gibi özellikleri olan kaynakların etkisiyle şekillenir ve bireylerin tutumlarını, davranışlarını ve algılarını güçlü bir şekilde etkileyebilir (Aksoy, 2024).

Ağızdan ağıza iletişim (WOM), bireylerin fikir, tutum ve satın alma davranışlarını

şekillendiren etkili bir süreçtir ve araştırmacılar tarafından uzun yıllardır incelenmektedir. İlk çalışmalar, WOM'un ürün, mesaj ve bireyin kendi ihtiyaçlarına olan ilgisiyle ilişkilendirilen bir süreç olduğunu ortaya koymuştur. WOM, bireylerin ürünler ve hizmetler hakkındaki deneyimlerini, bilgilerini ve görüşlerini paylaşımlarını sağlayarak güçlü bir etki yaratır. Araştırmalar, WOM'un geleneksel pazarlama yöntemlerine kıyasla daha etkili olduğunu ve özellikle yeni veya belirsizlik riski yüksek ürün/hizmetler hakkında bilgi sağlama konusunda öne çıktığını göstermektedir.

Bu kategorileri genişleterek WOM'un pozitif ve negatif etkilerini detaylandırmıştır. Örneğin, olumlu turizm diğerlerine fayda sağlarken, intikam ve negatif turizm olumsuz deneyimlerden kaynaklanır. Olumsuz WOM'un daha hızlı yayıldığı ve daha geniş kitlelere ulaştığı tespit edilmiştir (Sundaram vd., 1998, s. 527).

Berger ise WOM'un tüketici davranışlarını iki temel şekilde etkilediğini belirtmiştir: Farkındalık yaratma, yeni ürün veya hizmetler hakkında bilgi sağlayarak tüketicileri bilinçlendirir. Tutumları etkileme, tüketicilerin fikirlerini ve sosyal davranışlarını değiştirebilir. WOM, güvenilir bir bilgi kaynağı olması nedeniyle, tüketiciler için geleneksel pazarlama yöntemlerinden daha etkili kabul edilmektedir. Özellikle belirsiz durumlarda WOM, tüketicilerin kararlarını destekleyen değerli bir rehber rolü oynar (Berger, 2014).

WOM, ürün veya hizmet hakkında ticari olmayan, bireyler arası bilgi paylaşımıdır. Başlangıçta yalnızca yüz yüze iletişim olarak tanımlanmış olsa da internetin yaygınlaşmasıyla elektronik iletişimle sanal ortamlarda da gerçekleşebilir hale gelmiştir.

Olumlu WOM, memnun müşterilerin deneyimlerini paylaşarak diğer tüketicilerin kararlarını olumlu etkiler. Olumsuz WOM ise tatminsiz tüketicilerin deneyimlerini paylaşmasıyla oluşur ve işletmeler için tehdit oluşturabilir. Araştırmalara göre tatminsiz müşteriler yorumlarını daha geniş kitlelere ulaştırırken, memnun müşteriler genellikle daha sınırlı bir çevrede paylaşım yapar.

Olumsuz WOM, tüketicilerin diğerlerini uyarması, hayal kırıklıklarını azaltması, intikam amacı gütmesi ya da çözüm yolları araması gibi dört ana boyutta incelenir. Günümüzde WOM, telefon ve internet aracılığıyla da gerçekleşerek tüketici davranışlarında etkili bir rol oynamaktadır (Ertürk, 2024).

1.3. Elektronik Ağızdan Ağıza İletişim

Teknolojik gelişim ve internetin icadıyla iletişim biçimleri değişmiş, Elektronik Ağızdan Ağıza iletişim (e-WOM) bireyler arasındaki iletişimi kolaylaştırmıştır. e-WOM, bireylerin ürün ve hizmetler hakkındaki görüşlerini geniş kitlelere zaman ve maliyet avantajıyla ulaştırmasına olanak tanır. Bu iletişim, tüketiciler ve üreticiler arasında bilgi alışverişini kapsar ve internetin küresel yapısından faydalanarak ürün ve hizmetlere dair etkilerin analiz edilmesini sağlar. Tüketiciler hem olumlu hem de olumsuz geri bildirimlerini paylaşmak için interneti aktif şekilde kullanır; bunun için forumlar, uzman onayları ve özel web siteleri yaygın olarak tercih edilir.

e-WOM, geleneksel ağızdan ağıza iletişime kıyasla daha etkili ve güvenilir bir iletişim yöntemi olarak değerlendirilmektedir. Kullanıcı yorumlarının imzasız niteliği, güveni artırırken üreticiler için müşteri beklentilerini anlamak, güven oluşturmak ve rekabette kalmak adına önemli bir platform sunar. İşletmeler, ağızdan ağıza iletişim yoluyla tüketicilerin satın alma kararlarını etkileyebilir ve bunu teşvik etmek için sosyal ağ platformlarını geliştirir.

Bu platformlar, tüketicilere deneyimlerini paylaşma imkânı sunarak bilgiye erişimi kolaylaştırır. Örneğin, Deloitte'un seyahat anketi, bireylerin %83'ünün seyahat planlamasında interneti kullandığını, %77'sinin ise diğer tüketicilerin yorumlarına dayanarak karar verdiğini göstermektedir. İnternet platformlarının, e-WOM'un yayılmasında ve etkili bir pazarlama aracı olmasında büyük rol oynadığı anlaşılmaktadır. Özellikle turizm sektöründe, turist yorumlarının pazarlama potansiyeli, blogların etkisi, çevrimiçi topluluklardaki deneyimli kişilerin görüşleri ve otel işletmelerinin pazarlama performansı gibi konular e-WOM'un önemini ortaya koymaktadır (Ertürk, 2024).

e-WOM, tüketicilerin internet aracılığıyla bir ürün veya işletme hakkında olumlu ya da olumsuz yorumlarını paylaşmasını ifade eder. Geleneksel ağızdan ağıza iletişimden farklı olarak e-WOM, daha geniş kitlelere hızlı ve kolay bir şekilde ulaşabilmeyi mümkün kılar ve içeriklerin sıradan insanlar tarafından oluşturulmasıyla daha da yaygınlaşmıştır. e-WOM'un etkisi, müşterilerin satın alma kararlarını yönlendirme ve satışları artırma açısından oldukça büyüktür. Ayrıca, geleneksel yöntemlere kıyasla e-WOM, daha organize edilmiş ve kapsamlı bilgi kaynakları sunar, bu da tüketiciler için daha elverişli bir seçenek oluşturur. e-WOM, hacim, değer ve içerik kalitesi olmak üzere üç temel boyuttan oluşur.

Hacim: Bir ürün hakkında çevrimiçi yapılan yorumların sayısını ifade eder. Yorum sayısı ne

kadar yüksekse, bilinirlik ve dolayısıyla satış potansiyeli de o kadar artar.

Değer: Yorumların olumlu ya da olumsuz oluşunu belirtir. Olumlu yorumlar, ürünün tercih edilmesini teşvik ederken, olumsuz yorumlar ürünle ilgili beklentileri düşürebilir.

İçerik Kalitesi: Yorumların müşterilere ne derece yardımcı olduğunu (yardımlaşma), yorumlardaki olumlu ya da olumsuz tonun yoğunluğunu (varyans) ve yorumların metin şeklindeki sunumunu (sözel boyut) kapsar.

Özellikle olumlu e-WOM, ürün kalitesine olan güveni artırırken, olumsuz e-WOM bu güveni azaltabilir. Tüketiciler tarafından oluşturulan içeriklerin yardımlaşma boyutu, diğer müşterilere sağladığı faydayla değerlendirilir. Varyans boyutu ise yorumların tonunun şiddet dağılımını ifade eder; aşırı olumlu ya da olumsuz yorumlar bu kategoride değerlendirilir.

e-WOM'un sağladığı avantajlar, tüketicilerin satın alma kararlarını etkilemek isteyen işletmeler için önemli bir pazarlama aracı oluştururken, aynı zamanda tüketicilerin bilgiye kolay erişimini de destekler (Tufan, 2022).

1.3.1. Turizm Sektöründe Dijital Ağızdan Ağıza İletişim (E-Turizm)

Son yıllarda, web teknolojilerinin gelişmesiyle birlikte tüketiciler, otellerle ilgili deneyimlerini çevrimiçi platformlarda paylaşmaya başlamıştır. Bu durum hem tüketiciler hem de turizm işletmeleri için önemli yönetimsel çıkarımlar yaratmıştır. Elektronik ağızdan ağıza iletişim (e-AAİ), bireylerin bilgilere hızlı ve güvenilir şekilde erişmesini sağlayarak, turizm sektöründe turistlerin karar alma süreçlerinde önemli bir rol oynamaktadır. Turistler, özellikle otel rezervasyonları sırasında, çevrimiçi yorumları güvenilir bir bilgi kaynağı olarak görmekte ve kararlarını bu yorumlara göre şekillendirmektedir. Araştırmalar, turistlerin büyük bir kısmının otel seçimlerinde diğer kullanıcıların yorumlarına öncelik verdiğini göstermektedir. Örneğin, bir çalışma, turistlerin %84'ünün otel rezervasyonu sırasında çevrimiçi yorumlardan etkilendiğini ortaya koymuştur. Çevrimiçi yorumlar, otel işletmelerinin reklam ve pazarlama çalışmalarına kıyasla daha ikna edici olarak algılanmaktadır.

Turizm sektöründe elektronik ağızdan ağıza iletişim, yalnızca turistlerin kararlarını etkilemekle kalmamış, aynı zamanda işletmelere müşteri ilişkileri yönetimi ve hizmet iyileştirme konularında önemli fırsatlar sunmuştur. Önde gelen platformlar, tüketicilerle otel işletmeleri arasında etkili bir iletişim kanalı haline gelmiştir. Örneğin, Tripadvisor gibi

platformlar, her ay milyonlarca kullanıcı tarafından ziyaret edilmekte ve turistler için değerli bir bilgi kaynağı sunmaktadır (Tufan, 2022).

e-Turizm, seyahat ve konaklama başta olmak üzere sektöre ait ticari ve işleyiş süreçlerinin çevrim içi platformlara entegrasyonunu ifade etmektedir. Bu yaklaşım, sektör paydaşlarının etkinliğini ve verimliliğini artırırken, e-ticaretin yaygınlaşmasıyla turizm endüstrisinde ürün ve hizmet pazarını, dağıtım kanallarını ve müşteri memnuniyeti anlayışını kökten değiştirmiştir.

e-Turizm, turizm sektörünü daha dinamik hale getirerek, uluslararası dağıtım şirketlerini aradan çıkarıp, tüketicilere esnek ve kişiselleştirilmiş ürünler sunmayı mümkün kılar. Tur operatörleri ve seyahat acenteleri, müşteri tabanlarını genişletmek için çeşitli bilgi ve iletişim teknolojileri ile e-ticaret uygulamalarından yararlanmaktadır. e-Turizm, ticarete olduğu gibi B2B (işletmeler arası) ve B2C (işletmeden tüketiciye) olarak iki ana kategoride incelenebilir. Örneğin, B2B sistemlerinde turizm hizmet sağlayıcıları arasında rezervasyon yapılabilirken, B2C örneklerinde havayolları kendi web sitelerinden uçak bileti satışı yapabilir. Her iki modelde de web siteleri hayati önem taşır. Turizm sektöründeki işletmeler, tüketici davranışlarına uyum sağlayarak süreçlerini hızlandırmayı ve ürünlerini daha verimli bir şekilde sunmayı hedefler (Tunçalp, 2018).

Sonuç olarak, çevrimiçi otel yorumları hem turistler hem de turizm işletmeleri için vazgeçilmez bir araç haline gelmiştir. Bu yorumlar, işletmelerin stratejik kararlar almasına yardımcı olurken, tüketicilere güvenilir bir bilgi kaynağı sunarak satın alma süreçlerinde önemli bir rol oynamaktadır (Tufan, 2022).

1.3.1.1. E-Turizm'in İşletmelere ve Potansiyel Müşterilere Etkisi

e-Turizm, teknolojinin gelişimiyle birlikte turizm sektöründe hem firmalar hem de gezginler için çeşitli olanaklar sunmaktadır. İşletmeler açısından, dijital turizm uygulamaları sayesinde maliyetler azalmakta, müşteri ilişkileri güçlenmekte ve uluslararası pazarlara erişim daha kolay hale gelmektedir. Ayrıca, 7/24 hizmet sunumu, tanıtım olanaklarının artması ve müşteri bilgilerine hızlı erişim gibi avantajlar işletmelerin rekabet gücünü artırmaktadır. e-Turizm, aracılara olan bağımlılığı azaltarak kârlılığını artırırken, daha iyi üretim ve satış koşulları sunmaktadır.

Turistler için e-Turizm, seyahat ve tatil planlamasını kolaylaştırır ve bilgiye her an erişim

imkânı sağlar. Yerel ve uluslararası işletmelerin sunduğu hizmetleri karşılaştırma şansı tanırken, ülkeler hakkında detaylı bilgi edinmelerini de mümkün kılar. İnternet üzerinden araştırma yaparak tatil seçeneklerini evden çıkmadan değerlendirme olanağı sunar (Tunçalp, 2018).

Tüketiciler, yüksek düzeyde dikkat gerektiren satın alma kararlarında daha doğru ve bilinçli tercihler yapabilmek için mümkün olduğunca fazla bilgi edinmeye çabalarlar. Daha fazla bilginin, daha etkili kararlar alınmasına yardımcı olacağına dair yaygın bir görüş bulunmaktadır. Bilginin tüketicilere sunduğu temel avantajlar şunlardır:

- Karar verme sürecini kolaylaştırma ve iyileştirme,
- Seçim yaparken algılanan riski azaltma,
- Alınan kararlarda güven hissini artırma,
- Doğru alternatifleri belirleme ve değerlendirme,
- Davranışlarını haklı çıkararak ego koruma isteğini tatmin etme.

Bu faktörler, tüketicilerin bilgiye erişim konusundaki çabalarını açıklamaktadır.

Sonuç olarak, e-Turizm hem işletmeler hem de turistler için önemli kolaylıklar ve fırsatlar yaratarak turizm sektöründe vazgeçilmez bir konuma sahiptir (Tunçalp, 2018).

1.3.2. Çevrimiçi Otel Platformları

İnternet teknolojilerinin gelişimiyle birlikte çevrimiçi otel değerlendirme ve yorum sitelerinin önemi giderek artmıştır. Bu platformlar, bireylerin veya toplulukların çevrimiçi ortamda iletişim kurabildiği ve karşılıklı etkileşimler sayesinde interaktif bir yapı oluşturduğu hizmet sağlayıcılarıdır.

Bu siteler, kullanıcıların konakladıkları işletmeler hakkında yorum ve değerlendirmeler yapmalarına, bu yorumların diğer turistler tarafından görülmesine, işletmelerle ilgili fotoğraf ve video paylaşımlarına olanak tanır. Günümüzde turistler tarafından yaygın olarak kullanılan birçok değerlendirme ve yorum platformu bulunmaktadır. Bu bölümde, bu sitelerden bazılarına dair bilgiler sunulacaktır (Tufan, 2022).

TripAdvisor: Tripadvisor, her ay 463 milyon gezgine hizmet sunarak dünyanın en büyük seyahat platformlarından biri olarak öne çıkmaktadır. Platform, kullanıcılarına otel, deneyim, hava yolu şirketi ve gemi seyahati gibi 8,6 milyon farklı seçenek hakkında 859 milyondan fazla yorum ve değerlendirme sunar. Gezinler, Tripadvisor'ı kullanarak otel,

uak bileti ve gemi seyahatleri iin fiyat karşılařtırması yapabilir, popler etkinliklere rezervasyon yaptırabilir ve restoranlarda masa ayırabilir. 49 lkede ve 28 dilde hizmet veren Tripadvisor, seyahat planlamadan deneyimlemeye kadar vazgeilmez bir yol arkadaşıdır (TripAdvisor, 2025).

Trivago: Trivago, 2005 yılında Almanya'nın Dsseldorf řhrinde  üniversite arkadaşı tarafından kurulmuř ve o zamandan beri kresel bir konaklama arama platformu olarak ne ıkmıřtır. řirket, milyonlarca gezginin otel ve diğerkonaklama seeneklerini arama ve karşılařtırma biimini dnřtrmeyi hedeflemektedir. Expedia Group'un bir parası olan Trivago, gezginlerin otel arayıřlarında ilk tercihleri olmayı misyon edinmiřtir (Trivago, 2025).

Google Travel: Google Travel, Mayıs 2019'da Google tarafından kullanıma sunulan bir web sitesidir. Seyahat planlaması yapmak isteyen kullanıcılar iin, gitmek istedikleri destinasyonlarla ilgili ayrıntılı bilgiler saėlar. Turistler, oteller ve destinasyonlar hakkında yorumları, fotoğrafları ve videoları inceleyebilir. Konakladıkları iřletmelerde aldıkları hizmetleri 1 ile 5 arasında puanlayarak deėerlendirme yapabilirler. Ayrıca, uak biletleri iin detaylı arama ve fiyat karşılařtırması imkanı sunan bir platform olarak da hizmet vermektedir (Google Travel, 2025).

Hotels.com: Hotels.com, 1991 yılında "Hotel Reservations Network" adıyla kurulmuř ve 2001 yılında Expedia tarafından satın alınarak bugnk adını almıřtır. Kullanıcılar, konakladıkları iřletmelerde aldıkları hizmetleri 1 ile 10 arasında puanlayarak deėerlendirebilir. Dnya genelinde 34 dilde hizmet veren Hotels.com, turistlere otel rezervasyonu yapma imkanı sunmanın yanı sıra binlerce otel hakkında yorum ve deėerlendirmeleri de bnyesinde barındırmaktadır (Hotels.com, 2025).

Otelpuan: Otelpuan, ETS Group bnyesinde 14 řubat 2008'de Trkiye'de kurulmuřtur. Platform, turistlere konakladıkları otelleri deėerlendirme, puanlama ve fotoğraf paylařma imkanı sunar. Kullanıcılar, 1 ile 10 arasında puanlama yaparak yorumlarını web sitesinde herkese aık řekilde yayınlr. İřletme yneticileri ise bu deėerlendirmelere cevap yazarak kullanıcılarla etkileřim kurabilir.

Otelpuan, yorumların tarafsız bir řekilde yayınlanmasını saėlayarak turistlerin beklentilerine uygun tesisleri semesine ve iřletmelerin kendilerini tketiciler gzyle deėerlendirmelerine olanak tanır. Platform, yalnızca Trkiye pazarına ynelik hizmet vermektedir (Otelpuan, 2025).

Etstur: Etstur, 1991 yılında misafirlerine en iyi hizmeti ve fiyatı sunma hedefiyle kurulmuş, turizm sektörünün yenilikçi temsilcilerinden biridir. Yurt içi ve yurt dışında paket tur ve otel konaklama hizmetleri sunan marka, Turizm endüstrisindeki yenilikçi yaklaşım sayesinde, birçok ilke öncülük ederek hızlı bir şekilde gelişim göstermiştir. Türkiye'nin önde gelen turizm ve seyahat şirketlerinden biri olan Etstur, ülke genelinde binlerce otelin satış ve pazarlama süreçlerini yönetmekte, Türkiye'de 60, yurt dışında ise yaklaşık 40 destinasyonu kapsayan yüzlerce tur paketi sunmaktadır. Ayrıca, çeşitli markaları bünyesinde barındırmaktadır. Etstur'un çatısı altında:

- Didimtur: Geniş bir müşteri kitlesine hizmet veren seyahat acentesi,
- Jetset: Kişiyi özel lüks seyahat programları oluşturan marka,
- Ucuzabilet.com: Ekonomik fiyatlarla uçak bileti sunan platform,
- Otel puan.com: Misafirlerin tarafsız yorumlarını paylaşan platform,
- Odamax.com: Online konaklama hizmeti sunan platform,
- Lets Go Dergi: Seyahat trendlerini paylaşan yayın, gibi markalar bulunmaktadır.

Etstur, geniş hizmet yelpazesiyle turizm ve seyahat alanında tüketicilere yenilikçi çözümler sunmaya devam etmektedir (Etstur, 2025).

1.3.2.1. Çevrimiçi Yorumların Tüketiciler ve İşletmeler Üzerindeki Etkisi

Elektronik ticaretin hızla gelişmesi, tüketicilerin ürün veya hizmetlerle ilgili bilgi edinme, seçim yapma ve satın alma süreçlerini büyük ölçüde değiştirmiştir. Tüketiciler, “en iyi oteli nasıl seçebilirim?” veya “seçtiğim ürün verilen paraya değer mi?” gibi sorularla çevrimiçi yorumlara yönelmektedir. Bu yorumlar, yalnızca tüketiciler için değil, işletmeler açısından da oldukça kritiktir (Schuckert vd., 2015, s. 608).

Olumlu veya olumsuz yorumların, potansiyel müşterilerin satın alma kararları üzerinde doğrudan etkisi bulunmaktadır. Çevrimiçi yorumların miktarı ve içeriği, otellerin satışları, fiyatları ve imajları üzerinde büyük bir etki yaratabilir. Öğüt ve Onur Taş, müşteri puanlarındaki %1’lik artışın oda satışlarını yaklaşık %2,6 oranında artırdığını belirtmiştir. Yapılan bir araştırmada, turist yorumlarındaki %10’luk bir artışın çevrimiçi rezervasyonları %5’ten fazla artırdığı tespit edilmiştir (Öğüt ve Onur Taş, 2011, s. 197).

Çevrimiçi yorumlar, elektronik ağızdan ağıza iletişimin en yaygın biçimlerinden biridir. İnternet kullanıcılarının yaklaşık %30’u deneyimlerini paylaşırken, %70’i satın alma

kararlarında bu yorumlardan faydalanmaktadır. Bu değerlendirmeler hem ürün ve hizmetler hakkında bilgi sağlar hem de tüketicilere tavsiye niteliği taşır (Gretzel ve Yoo, 2008, s. 35).

Tüketici yorumları, doğrudan kullanıcı deneyimlerini yansıttığı için pazarlama faaliyetlerine göre daha güvenilir olarak algılanmaktadır. İnternet üzerinden alışveriş yapan kişilerin %80'inden fazlasının diğer tüketicilerin görüşlerini dikkate alması, bu yorumların bilgi kaynağı olarak önemini vurgulamaktadır (Tufan, 2022). Sonuç olarak, çevrimiçi yorumlar ve değerlendirmeler, tüketiciler ve işletmeler için kritik bir enformasyon aracı haline gelmiştir.

1.4. Temel Literatür Bilgisi

İşletme analitiği, işletmelerin iç ve dış kaynaklardan topladığı verileri düzenleyerek analiz etmeyi ve bu verilerden anlamlı bilgiler üretmeyi amaçlamaktadır. Günümüzde gelişen teknoloji sayesinde sosyal medya platformları, geniş çapta kullanıcı görüşlerine ulaşmayı akabinde duygu analizi yöntemleri aracılığıyla bu ifadeleri yapılandırılmış bir şekle dönüştürmeyi mümkün hale getirmektedir. Bu çalışma kapsamında, bir işletmenin ürünleri hakkında sosyal medyada paylaşılan veriler toplanarak, kullanıcı yorumlarının olumlu, olumsuz veya nötr olup olmadığını belirlemek için bir duygu analizi algoritması geliştirilmiştir. Ayrıca, bu yorumların işletmenin gerçek değerleriyle ilişkisini incelemek amacıyla kümeleme analizi uygulanmıştır. Yorum sayısı, duygusal eğilimler ve ürünlerin özellikleri kullanılarak tahmin modeli oluşturulmuş ve işletmelerin ürün geliştirme, pazarlama stratejileri belirleme ve karar alma süreçlerinde kullanabilecekleri bir sistem tasarlanmıştır. Analiz sürecinde karar ağacı, dvm ve ysa yöntemleri kullanılmış, karşılaştırmalar sonucunda ysa'nın en başarılı tahmin performansını sağladığı görülmüştür. Böylece, sosyal medya verilerinin analitik yöntemlerle değerlendirilmesinin işletmelere önemli stratejik avantajlar sunduğu ve geleceğe yönelik karar alma süreçlerinde etkin şekilde kullanılabileceği ortaya konulmuştur (Karaöz, 2018).

Bu çalışmada, Tripadvisor.com platformundan alınan İstanbul, Roma, Barselona, New York, Atina, Berlin ve Paris'teki 142 otele ait 36.241 yorum analiz edilmiştir. Bu yorumlardan 15.250 cümle çıkarılmış ve değerlendirmeye tabi tutulmuştur. Otel müşterilerinin yorumlarını kapsayan özel bir sözlük oluşturulmuş; ardından n-gram, TF-IDF matrisi, duygu analizi ve LDA konu modelleme yöntemleri kullanılmıştır. Analiz sürecinde, duygu analizi ve konu modelleme sonuçları birlikte ele alınarak yorumlanmıştır. Tüm veri

işleme ve analiz aşamaları R programlama dili kullanılarak gerçekleştirilmiş olup, müşteri yorumlarında ağırlıklı olarak personel, konum ve temizlik unsurlarının öne çıktığı tespit edilmiştir. Duygu analizinde, müşterilerin çoğunlukla pozitif duygular sergilediği; bununla birlikte, negatif yorum yapma eğiliminde olanların sıklıkla nötr ifadeler kullandığı gözlemlenmiştir. Çalışmanın başarısının, meta veriye ek bilgiler dahil edilerek artırılabilceği değerlendirilmiş ve metin madenciliği yöntemlerinin pazarlama alanında uygulanabilir değerli sonuçlar sunabileceği sonucuna ulaşılmıştır (Caner, 2019).

Metin madenciliği kullanılarak müşteri yorumlarında gizli kalmış yapılar, desenler ve duygular ortaya çıkarılmıştır. Araştırma, Antalya'daki otellere ait çevrimiçi yorumlar, otel hizmetlerine yönelik müşteri algılarını belirleyen derecelendirmeler ve müşteri bilgilerini kapsamaktadır. Uygulama aşamasında, yedi farklı makine öğrenmesi algoritmasıyla (Bu çalışmada, Lojistik Regresyon, Rastgele Orman (Random Forest), CART Sınıflandırıcı, k-En Yakın Komşu (k-NN), Destek Vektör Makineleri (SVM), Doğrusal Diskriminant Analizi (LDA) ve Naïve Bayes gibi çeşitli makine öğrenimi algoritmaları kullanılmıştır.) müşteri yorumları analiz edilmiştir. Algoritmaların ortalama başarısı %81,3 olarak hesaplanmış ve Lojistik Regresyon yöntemi %87,9 ile en başarılı sonuçları vermiştir. Ayrıca, müşteri memnuniyetine ilişkin farklı kriterler incelenmiş ve bu analizler, otel hizmet kalitesine dair önemli bilgiler sunmuştur. Örneğin, yurtdışından gelen müşterilerin genellikle daha memnun olduğu, tatil amaçlı konaklayanların memnuniyet düzeylerinin daha yüksek olduğu belirlenmiştir. Memnuniyet düzeyleri aylara göre analiz edildiğinde, Nisan ayında genel memnuniyetin, Aralık ayında uyku memnuniyetinin ve Haziran ayında konum memnuniyetinin en yüksek olduğu görülmüştür. Sonuç olarak, bu modelin, otel yöneticilerinin pazarlama süreçlerinde hızlı, tutarlı ve maliyet açısından verimli kararlar almalarına yardımcı olduğu belirtilmiştir. Ayrıca, duygu analizinin, kısa sürede ve uzman personel ihtiyacı olmadan metinsel verilerden değerli bilgiler elde edilmesini mümkün kıldığı ifade edilmiştir. Çalışmanın hem otel işletmeleri hem de bu alanda araştırma yapan akademisyenler için faydalı olacağı düşünülmektedir (Tuna, 2019).

Bu çalışma, içerik analizi yöntemine dayalı olarak tasarlanmış olup, büyük ölçekli veri setlerinin işlenmesi ve analiz edilmesi amacıyla veri madenciliği tekniklerinden faydalanmıştır. Araştırma kapsamında, turistler tarafından en çok beğenilen ilk üç otelin İngilizce olarak yazılmış toplam 3.588 kullanıcı yorumu incelenmiştir. Veri analizi sürecinde, R programlama dilinin veri madenciliği ile ilgili kütüphaneleri kullanılmıştır. Her

şey dahil konseptiyle hizmet veren otellerin değerlendirildiği bu araştırmada, kullanıcı yorumları doğrultusunda belirlenen tema ve duygular genel olarak benzerlik göstermektedir. Ancak, Antalya ve Mayorka'ya ilişkin verilerin birbiriyle daha fazla örtüştüğü, Şarm El Şeyh'in ise bu iki bölgeden olumlu yönde farklılaştığı tespit edilmiştir. Çalışmanın, turizm sektörü paydaşları, destinasyon yöneticileri ve akademik araştırmacılar için önemli bilgiler ve veri işleme yaklaşımları sunduğu değerlendirilmektedir. Araştırma bulguları, Antalya, Mayorka ve Şarm El Şeyh'teki otellere dair kullanıcı yorumlarının düşük maliyetle analiz edilebileceğini ve seyahat platformlarındaki yorumlarda ortaya çıkan örüntülere hızlı bir şekilde ulaşılabileceğini ortaya koymaktadır. Ayrıca, gezginlerin en yüksek puan verdikleri otellere ilişkin paylaşımlarından elde edilen anlamlı verilerden faydalanmak için gerekli yöntemler ve bilgiler sağlanmıştır (Atabay, 2020).

Küreselleşme ile beraber gelen sıkı rekabet ortamında işletmelerin kullanmış oldukları sosyal medya platformlarına yapılan yorumları bazı yöntemler ve araçlar kullanarak işletmelere rekabetçi zekâ kazandırılmasını amaçlayan çalışmada makine öğrenmesi yöntemleri ve metin madenciliği ile konu modelleme analizi ve duygu analizi gerçekleştirmiştir. Yapılan yorumların %81'i olumlu, %19'u ise olumsuz bulunmuştur. Konu olarak ise çoğunlukla Değer-Eğlence ile Deneyim konularının konuşulduğu gözlemlenmiştir. Bir diğer baskın olan konu ise %20 ile Şikâyet konusudur (Büyükeke, 2020).

Farklı normalizasyon tekniklerinin sınıflandırma üzerindeki başarısının etkisi gösterilmek amacıyla, belirlenmiş bir otel sitesinden ülkemizdeki otellere yönelik yapılmış olan yorumlar üzerinde duygu analizi gerçekleştirmiştir. En yüksek oran için k değerini 5 alarak 3400 test verisinden 2812 adet veriyi doğru sınıflandırmıştır. En düşük oran için ise karekök normalizasyon yönteminde k değerini 5 alarak 3400 test verisinden 2783 adet veriyi doğru sınıflandırdığını gözlemlemiştir (Mengutaycı, 2020).

Seyahat türlerinden biri olan kruvaziyer seyahat süreçlerinin ve firmaları değerlendirmedeki süreçlerin etkisini belirlemek amacıyla yapılan Bu araştırmada, CruiseCritic adlı internet platformunda yayımlanan Royal Caribbean International firmasına ait içerikler ele alınmıştır. Gemilerinde seyahat eden müşterilerin yorumlarından hareketle firmaya olan genel yıldız derecelendirme değerleri makine öğrenmesi yöntemi olan denetimli öğrenme ile tahmin edilmiştir. Müşterilerin vermiş oldukları derece ile tahmin edilen derece karşılaştırılmış ve sonucunda en yoğun olarak Olumlu-Olumsuz duygulara göre

değerlendirdiklerini görmüştür. Ayrıca %80 olasılıkla genel bir yıldız derecelendirmesi olan firmayı değerlendirirken 11 farklı özellik bulunmaktadır (Öztürk, 2020).

Müşteri eğilimlerinin değişmesini dinamik bir biçimde analiz edebilmeyi amaçlamış ve bu amaç doğrultusunda karar destek sistemi uygulamış ve geliştirmiştir. Yapay zekâ ile otomatik olarak tespit etmeye çalışılan bu sistemle duygu, konu ve trend analizi yapılarak otellere gelen müşterilerin duygu durumları ve bu durumların zamana göre değişimlerini ele almıştır. Geliştirilen bu KDS'nin uygulanması sonucunda; gelen müşterilerin duygu durum skorlarında 2019 yılının ağustos ayına kadar artış görüldüğü, ağustos ayından sonra ise düşüş yaşandığı görülmüştür (Aksu, 2021).

Müşteri yorumlarının yanıltıcı olma durumunu tespit etmek amacıyla yapmış olduğu bu çalışmada ülkemizdeki oteller ile bu otellere yapılan yorumları Python programlama dili ile otomatik bir şekilde toplayarak veri setini oluşturmuştur. Metin kümeleme yöntemi kullanarak verileri sınıflandırmıştır. Sınıflanan veriyi 3 aşamada incelemiştir. İlk aşamada veriyi oteller bazında kümelemiş, daha sonra veriyi beş parçaya ayırarak bütün yorumların üzerinden tekrar gerçekleştirmiş ancak yeterli sonuç vermemiştir. Son aşamada verilerin tamamını kümelemiştir. Bu sayede benzer yorumları tespit etmiştir. Çalışmada 0.6 ile 0.7 Epsilon değerleri diğer değerlere göre daha fazla benzer yazılmış yorumları ortaya çıkartmıştır (Ay, 2021).

Veri ve metin madenciliği, büyük veri kümelerinden anlamlı ilişkiler ve eğilimler çıkarmak için kullanılan analiz süreçleridir. İşletmeler, bu teknikleri kullanarak rekabet avantajı elde edebilir ve müşteri beklentilerine uygun stratejiler geliştirebilir. Bu çalışmada, veri ve metin madenciliği tekniklerinden faydalanarak hava yolu şirketlerinin güçlü ve zayıf yönleri, müşteri yorumları ışığında değerlendirilmeye çalışılmıştır. Çalışma kapsamında, TripAdvisor üzerindeki çevrimiçi seyahat değerlendirmeleri analiz edilerek, Star Alliance üyesi 26 hava yolu şirketi incelenmiştir. Kullanıcı yorumları ve değerlendirme skorları üzerinden duygu analizi gerçekleştirilmiş, polarite ve polarite değerleri hesaplanmıştır. Sınıflandırma ve tahminleme sürecinde Destek Vektör Makineleri, Naive Bayes ve Derin Öğrenme algoritmalarından faydalanılmış, yapılan karşılaştırmalar sonucunda Derin Öğrenme yönteminin daha etkili olduğu belirlenmiştir. Ayrıca, Karar Ağaçları yöntemiyle güzergâh, uçuş yapılan yer, kabin sınıfı ve polarite etiketlerine göre kriterlerin önem dereceleri hesaplanarak analiz edilmiştir. Araştırma sonuçlarına göre, müşteri yorumları ve değerlendirme skorları dikkate alındığında, en yüksek puanı alan hava yolu şirketi EVA

olarak tespit edilmiştir (Budak, 2021).

Otel ziyaretçilerinin memnuniyeti ve müşteriler tarafından otel özelliklerini belirlemeyi amaçlayan çalışmada kullanmış olduğu yöntem tasarımı sıralı keşifsel yöntemdir. Çalışmanın ilk kısmında dünyaca ünlü TripAdvisor adlı otel ve konaklama araştırma platformundan 1.132 adet otelden 710.450 adet yorum elde ederek metin madenciliği yöntemleri ile analizini yapmıştır. Çalışma ve analiz sonunda müşterileri en fazla etkileyen faktörlerin otel çalışanlarının iyi hizmet sunmaları, yardımseverliği ve güler yüzlülükleri, temizlikleri ile oda temizliği konuları olduğu sonucuna varılmıştır (Elsadig, 2021).

Duygu analizi için metin madenciliği, doğal dil işleme ve hesaplamalı dilbilim yöntemlerinden faydalanılır. Çoğu zaman, örneğin pazarlama şirketleri tarafından ürün veya hizmetlerle ilgili değerlendirmelerden görüşleri anlamak için kullanılırken, medya tarafından siyasetteki konuşmalardaki duyguları analiz etmek amacıyla da kullanılmaktadır. Bu çalışmanın önemi, turizm ve otelcilik sektörünün duygu analizi ve metin madenciliğini nasıl kullandığı düşünülerek anlaşılabilir. Bu çalışmanın amacı, TripAdvisor ve Booking gibi rezervasyon platformlarında müşteriler tarafından yapılan yorumların duygu analizi için yapay sinir ağı algoritmalarını kullanarak bu algoritmaların etkinliğini incelemektir (Shwaish, 2022).

Turizmin küresel ölçekte büyümesiyle birlikte havayolu taşımacılığı da gelişmiş, serbestleşme hareketleri rekabeti artırarak farklı iş modellerinin ortaya çıkmasına neden olmuştur. Havayolu işletmeleri genel olarak geleneksel, düşük maliyetli, tarifesiz ve bölgesel havayolu modellerini benimsemektedir. Bu çalışmada, düşük maliyetli havayolu işletmelerinin maliyet liderliği stratejisini ne ölçüde uyguladığı, farklılık ve benzerlik gösterdikleri noktalar ile bu stratejinin sosyal medyadaki algıya etkisi incelenmiştir. Karma yöntem kullanılan çalışmada, havayolu işletmelerinin yayınladığı raporlar doküman analizi ile değerlendirilmiş, ayrıca maliyet liderliği stratejisine yönelik sosyal medya algısını belirlemek için duygu analizi gerçekleştirilmiştir. Bu analizlerin doğruluğunu test etmek amacıyla derin öğrenme algoritmalarından RNN, LSTM, BiLSTM ve GRU kullanılmıştır. Araştırma bulgularına göre, Ryanair'in maliyet liderliği stratejisini büyük ölçüde doğru uyguladığı ancak sosyal medyada düşük memnuniyet oranına sahip olduğu belirlenmiştir. Pegasus'un ise yüksek müşteri memnuniyeti sağladığı ancak maliyet liderliği stratejisini tam anlamıyla uygulamadığı sonucuna ulaşılmıştır (Yardı, 2022).

İki farklı bölgedeki konaklama işletmelerine ait 2015-2022 yılları arasındaki 197 binden

fazla müşteri yorumu analiz edilmiştir. Ön işleme sonrası 173 binden fazla yorum, yedi ana kategoriyle 26 alt dala ayrılmıştır. Veri seti, makine öğrenimi ve istatistiksel olarak incelenmiş, en yüksek başarı oranı %75 ile KNN yöntemi tarafından sağlanmıştır. Çoklu doğrusal regresyon analizleri sonucunda, duygu puanlarının müşteri değerlendirme puanlarını açıklama yüzdesi kategorik olarak %37,6; alt boyutsal olarak %37,9 olarak hesaplanmıştır. Bölgesel karşılaştırmalarda, rekreasyon ve belirli yiyecek-içecek alt boyutlarında Kemer bölgesindeki müşterilerin duygu puanlarının daha yüksek olduğu, diğer tüm kategorilerde ise Hanya bölgesindeki duygu puanlarının daha yüksek olduğu belirlenmiştir. Sezon bazında düşük sezonda duygu puanlarının daha yüksek olduğu görülmüştür. Zaman serisi analizlerinde ise genel müşteri duygu puanlarının yıllar içinde arttığı, ancak pandemi sürecinde bazı kategorilerde düşüş yaşandığı ve 2022’de tekrar 2019 seviyelerine ulaştığı tespit edilmiştir. Son olarak, müşterilerin sözel ifadeleri NVivo programı ve MAXQDA programları ile detaylı incelenerek, bulgular kavramsal temellere dayandırılarak yorumlanmıştır (Aktaş, 2023).

COVID-19 pandemisinin getirdiği sosyal mesafe, bireysellik ve teması azaltma gibi faktörler, konaklama tercihlerini de önemli ölçüde etkilemiştir. Günümüzde internetin yaygın kullanımı sayesinde, bireyler konaklama seçeneklerini değerlendirirken çevrimiçi müşteri yorumları ve puanlamalarını dikkate almaktadır. Bu geri bildirimler, işletmelerin müşteri memnuniyetini anlaması, hizmetlerini geliştirmesi ve rekabet avantajı sağlaması açısından kritik bir öneme sahiptir. Çevrimiçi yorumların içerdikleri duyguların analiz edilmesi, müşteri değerlendirmelerinin puanlamalarla ne kadar örtüştüğünü belirlemek için önemlidir. Duygu analizi, internet siteleri ve sosyal medya platformlarındaki yorumların duygu durumunu anlamak için sıkça kullanılan bir yöntemdir. Bu kapsamda gerçekleştirilen çalışmada, Sapanca bölgesindeki bungalov işletmelerine yönelik Google Places yorumları analiz edilerek, en çok olumlu ve olumsuz geri bildirim alan konular belirlenmiştir. Duygu yoğunluğunu ölçmek için makine öğrenmesi yöntemlerinden Naive Bayes, Destek Vektör Makineleri ve Rastgele Orman algoritmalarının yanı sıra, derin öğrenme yöntemlerinden BERT modeli kullanılmıştır. Bu algoritmaların başarı oranları karşılaştırılmış ve elde edilen sonuçlar değerlendirilmiştir. Ayrıca, COVID-19’un turizm tercihlerine etkisini incelemek amacıyla yorumlar 2020 öncesi ve sonrası olarak ayrılmış, tüketici eğilimlerindeki değişimler analiz edilmiştir (Çelik, 2023).

Bu araştırmada, Türkiye'nin önde gelen turizm merkezlerinden biri olan Alanya'daki otellere

ilişkin çevrimiçi kullanıcı yorumları incelenmiştir. Konaklayan bireylerin en sık dile getirdiği konular ve bu unsurların tüketici memnuniyeti üzerindeki etkileri, konu modelleme ve duygu analizi yöntemleri aracılığıyla analiz edilmiştir. Otellerin sunduğu olanaklar, animasyon ve personel konuları, tüketici memnuniyetine en olumlu katkıyı sağlayan unsurlar olarak belirlenmiştir. Buna karşılık, ön büro ve oda konuları memnuniyeti olumsuz etkileyen faktörler arasında yer almıştır. Özellikle, personel konusu, pozitif yorumların en önemli kaynağı olurken, ön büro ile ilgili sorunlar tüketicilerin en fazla negatif yorum yapmasına neden olan alan olarak öne çıkmıştır. Ayrıca, araştırmada ele alınan konulara duyulan memnuniyet seviyesinin otel sınıfına ve seyahat türlerine göre farklılık gösterdiği tespit edilmiştir (Tükenmez, 2023).

Bu çalışmada, müşteri yorumlarındaki karmaşıklıkları ve bağlamsal farklılıkları anlamak için BERT, DistilBERT, RoBERTa, Electra ve GPT-2 gibi gelişmiş transformatör modelleri kullanılmıştır. Transformatör tabanlı yaklaşımın etkinliği, TripAdvisor'dan toplanan özel bir yorum veri kümesi üzerinde kapsamlı deneylerle test edilmiştir. Bunun yanı sıra, önerilen çerçevenin üstün performansını göstermek amacıyla IMDb, SST-1, SST-2 ve MR gibi yaygın olarak kullanılan veri kümeleri de değerlendirilmiştir. Deneysel bulgular, transformatör modellerinin, özellikle sınıflar arasında denge sağlandığında, olumlu ve olumsuz yorumları %98'in üzerinde bir doğruluk oranıyla başarılı bir şekilde tanımlayabildiğini ortaya koymaktadır (Amalı, 2024).

Bu araştırmada, karma bir yöntem benimsenerek nitel ve nicel yaklaşımlar birlikte kullanılmıştır. Analizlere, akıllı otellere ait toplam 33.395 yorum dahil edilmiştir. Duygu analizi R ve Python ile, ilişki ve farklılık analizleri ise SPSS kullanılarak gerçekleştirilmiştir. Yorum analizlerinde en sık kullanılan kelimeler “oda”, “otel”, “mükemmel”, “kalış-geceleme”, “personel”, “hizmet”, “iyi”, “zaman” ve “konum” olarak belirlenmiştir. Yorumlarda hâkim olan duygular sırasıyla “güven”, “neşe”, “beklenti”, “şaşınlık”, “kızgınlık”, “üzgünlük”, “korku” ve “iğrenme” şeklinde tespit edilmiştir. Olumlu duygular arasında temizlik, yiyecekler ve havuz gibi hizmetlere yönelik memnuniyet dikkat çekerken, dost canlısı ve yardımsever personel de memnuniyet yaratan unsurlar arasında yer almıştır. Olumsuz yorumlarda ise bekleme sıraları, büfe hizmetleri, ücretler ve lobi alanlarına yönelik memnuniyetsizlik öne çıkmıştır. Seyahat türlerine göre yapılan analizde, iş amaçlı seyahat edenler ile çiftler, aileler, arkadaş grupları ve yalnız seyahat edenler arasında farklılıklar gözlemlenmiştir. Örneğin, yiyecekler, temizlik ve yardımseverlik olumlu duygular

yaratırken, büfe hizmetleri, ücretler ve tuvaletler gibi konular olumsuz duygulara yol açmıştır. Korelasyon analizi, pozitif duygular ile genel değerlendirme skorları arasında zayıf pozitif, negatif duygular ile zayıf negatif bir ilişki olduğunu göstermiştir. ANOVA analizi ise iş amaçlı seyahat edenlerle diğer gruplar arasında anlamlı farklar olduğunu ortaya koymuştur. Bu çalışma, akıllı otellere yönelik büyük veri ve duygu analizi sonuçlarının, otel yöneticilerine, turistlere ve turizm sektörüne çeşitli çıkarımlar sunduğunu göstermekte ve bu alanda yeni bir bakış açısı sunmaktadır (Çiğdemli, 2024).

Bu çalışmaların ortak noktası, metin madenciliği ve duygu analizi yöntemlerini kullanarak müşteri yorumlarını değerlendirmeye odaklanmalarıdır. Ancak, bu çalışmaların geneli geleneksel makine öğrenmesi yöntemleri ile gerçekleştirilmiş olup, derin öğrenme modelleriyle yapılan karşılaştırmalar sınırlı kalmıştır. Ayrıca, kelime gömme teknikleri açısından genellikle Word2Vec ve GloVe gibi yöntemler tercih edilmiş, ancak BERT gibi bağlamsal kelime gömme tekniklerinin etkisi detaylı bir şekilde ele alınmamıştır. Bu noktada, çalışmamız literatüre iki önemli katkı sağlamaktadır. Birincisi, derin öğrenme tabanlı CNN-LSTM ve GRU modelleri kullanılarak farklı duygu analizi modellerinin karşılaştırılması sağlanmıştır. İkincisi, geleneksel kelime gömme tekniklerinin yanı sıra, BERT gibi bağlamsal bilgi içeren modern kelime gömme teknikleri de kullanılarak, daha anlamlı kelime temsil kümeleri oluşturulmuştur. Bu sayede, literatürde eksik kalan noktalar ele alınarak daha kapsamlı bir analiz gerçekleştirilmiştir.

Literatürde otel yorumlarının duygu analizi ve metin madenciliği üzerine birçok çalışma yapılmıştır. Ancak, bu çalışmaların çoğu geleneksel makine öğrenmesi yöntemlerine odaklanmış olup, derin öğrenme tabanlı modellerle yapılan karşılaştırmalar sınırlı kalmıştır. Ayrıca, BERT ve FastText gibi modern kelime gömme teknikleri yeterince incelenmemiştir.

Bu bağlamda, çalışmamızın ele aldığı temel literatür boşlukları şunlardır:

Derin öğrenme modellerinin kapsamlı şekilde incelenmemesi: Literatürde genellikle geleneksel yöntemler kullanılmış, CNN-LSTM ve GRU gibi gelişmiş modellerle yapılan analizler sınırlı kalmıştır.

Farklı kelime gömme tekniklerinin performans kıyaslamalarının eksikliği: Çoğu çalışmada Word2Vec ve GloVe tercih edilirken, BERT ve FastText gibi tekniklerin duygu analizine etkisi yeterince araştırılmamıştır.

Büyük veri kümelerinin kullanımının sınırlılığı: Çoğu çalışma küçük ölçekli veri setleriyle

yapılırken, bu çalışmada 200.001 otel yorumu kullanılarak modelin genelleme yeteneği artırılmıştır.

Sonuç olarak bu çalışma, gelişmiş kelime gömme teknikleriyle donatılmış derin öğrenme modellerinin duygu analizine etkisini değerlendirerek literatürdeki eksiklikleri gidermeyi amaçlamaktadır.

Yapılan literatür taramaları, otel yorumlarının duygu analizi ve konu modelleme yöntemleriyle incelenmesine yönelik birçok çalışma olduğunu göstermektedir. Ancak, bu çalışmaların çoğunda geleneksel makine öğrenmesi yöntemleri (Naïve Bayes, Destek Vektör Makineleri, Lojistik Regresyon vb.) kullanılmış ve derin öğrenme teknikleriyle kapsamlı karşılaştırmalar yapılmamıştır. Ayrıca, kelime gömme teknikleri açısından genellikle Word2Vec ve GloVe gibi geleneksel yöntemler tercih edilmiş, ancak bağlamsal anlamı daha iyi yakalayabilen BERT gibi ileri düzey tekniklerin etkisi sınırlı olarak ele alınmıştır. Bu noktada, çalışmamızın motivasyonu, literatürde eksik kalan bu yönleri ele alarak daha kapsamlı bir duygu analizi modeli oluşturma ihtiyacıdır. Geleneksel yöntemlerin ötesine geçerek derin öğrenme tabanlı CNN-LSTM ve GRU modelleriyle duygu analizi yapılması ve farklı kelime gömme tekniklerinin etkilerinin incelenmesi çalışmamızın temel motivasyon kaynaklarıdır.

Yapılan literatür taramalarında, farklı çevrimiçi otel platformlarında yer alan müşteri yorumları ve şikayetlerin metin madenciliği teknikleriyle analiz edildiği görülmüştür. Bu doğrultuda, literatürde giderek artan uygulama alanına sahip olan otel işletmeleri üzerine odaklanılmış ve bu çalışmanın, otel yorumlarını içeren veri kaynaklarından biri olan Etstur üzerinden gerçekleştirilmesinin uygun olacağı düşünülmüştür.

İKİNCİ BÖLÜM

MATERYAL VE YÖNTEM

2.1. Verilerin Elde Edilmesi

Bu araştırmanın veri setini, Etstur platformundaki otellere yapılan müşteri yorumları oluşturmaktadır. Yorumlar Python programlama dili kullanılarak, tümleşik geliştirme ortamı (IDE) olan PyCharm ile çekilmiştir. Otel yorumlarında yer alan otellere yapılan puanlandırma ile veriler olumlu, olumsuz ve nötr olacak şekilde sınıflandırılmıştır. Bu sınıflandırma işlemi yapılırken yorumlara yapılan 1 ve 4 arası puanlama olumsuz, 5 ve 6 puanları nötr, 7 ve 10 arası puanlarda olumlu olarak sınıflandırılmıştır. Yorumlar arasında sadece puanlama, emoji ile yorum bırakma gibi durumlardan dolayı verilerde temizleme işlemi uygulanmıştır. Bu işlemlerden sonra 66.667 olumlu, 66.667 adet olumsuz, 66.667 adet nötr yorum olmak üzere 200.001 veri elde edilmiştir. Tablo 1’de verilen örnekler veri setindeki olumlu, olumsuz ve nötr ifadeleri göstermektedir.

Tablo 1. Olumlu-Olumsuz-Nötr Veri Örneği

Olumlu (1)	Gayet iyiydi, normal bir oteldi. Hemen hemen hepsi güzeldi. Fiyat performans olarak ortalamaydı. Aslında fiyat bu otele göre fazlaydı. Çok başarılı bir otel çok beğendim.
Olumsuz (0)	Yemekleri berbat yılbaşı balosu çok kötüydü ana yemeği olsun. Yemekleri kötüydü. Etlerinde koku vardı daha sonrasında garsonları iyiydi çok güler yüzlü insanlardı. Yemek, ilgi alakala, kontrol mekanizması zayıf.
Nötr (2)	Otel de yemekler çok kötüydü. Yemekler aşırı kötüydü. Yemekte elimizi ağzımızı silmek için kâğıt peçete yoktu. Otel, fiyat performans olarak ortalamaydı. Otel genel anlamda orta konserler iyi.

2.2. Zekâ ve Yapay Zekâ

Terminolojik yaklaşımda inceleyeceğimiz zekâ, Arapça kökenli bir sözcük olarak dilimize yerleşmiştir. Türk Dil Kurumu, zekâyı bireyin kavrama, mantık yürütme, gerçekleri değerlendirme ve sonuç çıkarma gibi yetilerinin bir bütünü olarak ifade etmekte ve bu nitelikleri anlak, dirayet, zeyreklik ve feraset kavramlarıyla ilişkilendirmektedir. Bu sebeple zekâ, bir durumu değerlendirme ve bunun durumun sonucunda karar verme yetisi, nesneler ile arasındaki bağı kurarak, kurduğu bağı kelimeler aracılığıyla anlatıma dönüştürme yetisi, düşünce kabiliyetidir (Balta, 2020).

Zekâ kavramının doğru tanımı yapay zekâyı doğru anlamamızı sağlayacaktır. Geçmişten bugüne bilimsel çalışmaların odak noktasında zekâ vardır. Fakat zekâ kavramı yıllarca konuşulup tartışılmış bir kavram olmasına rağmen hala standart bir tanımı yoktur. Zekâ kavramı için bilim insanlarından tanım yapılması istense birçok tanım çıkacaktır. Yıllar boyunca zekâ kavramını bilim insanları çok çeşitli disiplinlerden çok farklı tanımlar çıkartmıştır. Bu tanımlar şu şekildedir (Kınalıoğlu, 2019).


- Zekâ, soyut fikirleri sürdürebilmektir.
- Zekâyı akliselim, muhakeme, üstünlük, kolay düşünme ve bulunduğu ortama uyum sağlama yeteneği olarak tanımlar.
- Bireyin reel düşünebilmesi, akıllı davranması ve etkili biçimde etrafı ile başa çıkması için kendisinde bulunan kapasitedir.
- Zekâ en az bir kültürel alanda ürün oluşturma ya da sorun çözme yeteneğidir.
- Bireyin zihni bir özelliği olarak bilinen zekâ, dürtülere yoğunlaşma ve soyutlama kapasitesidir.
- Akıllı kullanabilme yeteneğidir.

Zekâ kavramı ile karıştırılan diğer bir kavram ise akıldır. Akıl kalıtsal olarak alınan özelliklere ek olarak toplum faktörleri ve şartları ile beraber etkileşimiyle ortaya çıkan bir olgudur. Bu sebepten dolayı sabit bir durumda olmayan akıl, insan yaşamı süresince değişiklik gösteren bir yetenektir. Akıl bu nedenle örnekleme için taklit edilemez. Bu sebeplerden dolayı bilgisayarlar, makineler veya yazılımların herhangi bir problemi tanımlayabilme, öğrenerek çözümler geliştirebilme kabiliyetleri kazandırılabilmesi için modellemelerde akıl değil zekâ modellenmiştir (Yılmaz, 2019).

2.2.1. Yapay Zekâ

Yapay zekâ kavramı, 1956 yılında Dartmouth konferansında bilgisayar bilimcisi John McCarthy tarafından ortaya atılarak bilimsel literatürde yer edinmiştir. McCarthy, insanlara özgü olduğu düşünülen zeka temelli hareket ve davranışların makineler tarafından gerçekleştirilmesi fikrini, yapay zekâ kavramı çerçevesinde açıklamıştır (Balta, 2020).

Literatürde çeşitli yapay zekâ tanımları bulunmaktadır. Nabiye, yapay zekâ kavramını bilgisayar kontrolündeki bir makinenin ya da bilgisayarın insana ait nitelikler olduğu düşünülen akıllı davranma, anlamlandırma, deneyimsel öğrenme ve genelleme gibi sadece insana ait olan üst kademe olan zihinsel süreçlere ait sorumluluk ve görevlerini yerine getirebilme yeteneğinin ifade edilmesi olarak tanımlamıştır (Gümüş, 2019).



Şekil 1. Zekâ Kavramı (Gümüş, 2019)

Yapay zekâ, insanın zihni faaliyetlerini ve hareketlerini sergileyebilecek makineleri oluşturma ve geliştirme teknolojisini adır. Yapay zekâ, insan beyninin yapabileceği bütün işlemlerini yapabilecek bilgisayarlar ve makineler yaratma peşindedir. Bir insanın düşünebilmesi zekâ gerektirirken, görme eylemi gerektirmemektedir (Paksın, 2020).

Bir başka tanımda ise yapay zekâ, ilk günden bugüne kadar olan bilimsel araştırmalarda iki boyutta incelenmiş ve tanımlanmıştır. İlki, davranışsal merkez ile düşünme ve muhakemeye önem veren yaklaşımı birbirlerinden ayırmasıdır. İkincisi, rasyonelliği ifade eden yaklaşım ile insanı baz alan yaklaşımı birbirinden ayırmasıdır. Merkeze insanı koyan

yaklaşım, insan davranışları üzerinde gözlem ve teorileri içeren deneyler bilimin bölümü iken; akılcı yani rasyonel yaklaşımlar mühendislik ve matematik alanının birleşimidir (Çoban, 2018).

Uygulama kapsamı geniş olan yapay zekâ için pek çok tanım yapılabilir. İnsan zekasına ihtiyaç duyan eylemleri yapabilecek makineler yaratmak yapay zekanın amaçlarındandır. Natürel zekâ gerektiren olaylara çözüm getirebilecek sistemlerin oluşturulması ise yapay zekâ araştırmalarının amacıdır. Sistemlere zekâ ekleyerek çözülmesi gereken problemlerde bu zekadan faydalanmak ise doğal zekanın amaçlarındandır (Yılmaz, 2019).


Bu tanımlardan yola çıkarak, yapay zekanın iki yapı ile alakalı olduğu söylenebilir. Bu yapılardan birincisi, insan muhakeme sürecinin araştırması iken; ikincisi ise insan düşünce sürecinin makineler vasıtasıyla gösterilmesidir. Genellikle yapay zekanın amacı, makineleri daha yaralı, akıllı hale getirmek ve zekayı anlamlandırmak gibi şekillerde gruplanabilir. Bu tanımlamalardan hareketle akıllı davranım üzerinde durduğumuzda pek çok davranım türleri, zekanın göstergesi olarak kabul edilebilir (Yılmaz, 2019). Bu davranışlar:

- Deneyimsel tecrübe ile anlama ve öğrenim,
- İlk kez karşılaşılan durumlarda başarılı ve çabuk adapte olma,
- Karmaşık ve karışık mesajları anlamlandırma
- Bilgiyi anlamlandırmak ve kullanabilmek,
- Çeşitli durumlarla başa çıkmak

2.2.1.1. Yapay Zekânın Tarihçesi


Yapay zeka, insana özgü düşünme yeteneğini makinelerin gerçekleştirmesi üzerine yapılan çalışmalar sonucu ortaya çıkmıştır. Alan Turing, evrensel bilgisayar fikriyle yapay zekanın temelini atmış ve programlanabilir bilgisayarların insan zekasını analiz edebilme ve taklit edebilme kapasitesini ilk fark eden kişi olmuştur. İlk yapay zeka kavramı, 1956'da Dartmouth Konferansı'nda John McCarthy tarafından isimlendirilmiştir. II. Dünya Savaşı sonrası elektronik ve bilgisayar teknolojilerindeki gelişmeler, özellikle Alan Turing'in laboratuvarı gibi öncü merkezlerde, yapay zeka alanının ilerlemesine zemin hazırlamıştır. Başlangıçta, yapay zekanın amacı insan davranışlarını kopyalamaktı; ancak bu çabalar 1960'lar ve 1970'lerde felsefi tartışmalara yol açtı ve klasik yapay zeka dönemi olarak bilinen bu süreç, yapay zekanın potansiyeli açısından sınırlı olarak değerlendirildi. 1970'lerden

itibaren yapay zeka, bilgi analizi, karar destek sistemleri ve iş süreçlerini iyileştirme alanlarında büyük bir potansiyel sergilemiştir. 1980’ler ve 1990’larda, sorunları çözmeye yönelik daha yenilikçi yaklaşımlar geliştirildi ve yapay zekanın sadece insan zekasını taklit etmekle kalmayıp, bağımsız bir zekâ tarzına sahip olabileceği kabul edildi (Atun, 2024).



Şekil 2. Yapay Zekanın Tarihsel Gelişimi (Daşgın, 2023)

Bu zamana kadar yapılmış çalışmalar sonucunda yapay zekâ üç kısma ayrılmıştır. İlki, belirli bir bölüme ayrılan ve sadece o alana çözüm üreten dar yapay zekadır. İkincisi, insana benzer özellikler göstermesi istenilen robotlara uygulanır. Yapay zekanın alt disiplinleri olan görüntü ve ses tanıma, doğal dil işleme, tahminleme, muhakeme, öğrenme, hareket etme gibi disiplinleri başarılı bir şekilde entegre eden çalışmaları içerir. Üçüncüsü ise gelecekteki insanların sahip olacağı bütün yeteneklere hatta daha fazla yeteneğe sahip olacağı düşünülen süper yapay zekadır. (Ucuzal, 2020)




Şekil 3. Yapay zekâ, Makine Öğrenimi ve Derin Öğrenme İlişkisi (Ucuza, 2020)


Yapay zekâ yöntemlerinden olan makine öğrenmesi ve derin öğrenme birbirleri ile ilişkili disiplinlerdir. Bundan dolayı aralarındaki ilişkinin iyi anlaşılması gerekir. Yapay zekâ oluşturma'nın bir yolu da makine öğrenmesidir. Makine öğrenmesinin alt disiplinlerinden olan derin öğrenme ise, yapay sinir ağını örnekleyerek oluşturulur. Veriler üzerinde tahminleme ve çıkarımsal sonuçlar üreten sistem ve uygulamaları makine öğrenmesi ve derin öğrenme yöntemleri ile oluşturabiliriz.

2.3. Metin Madenciliği

Temellerini, bilgisayarın dili işleme yeteneklerinin artmaya başladığı 1950'li yıllara dayandırmaktadır (Boztürk Kılınç, 2024). Ancak metin madenciliği kavramının ilk olarak 1995 yılında Feldman ve Dagan'ın çalışmasında geçtiği bilinmektedir (Akay, 2024). Devamlı olarak gelişen ve alan olarak günden güne önemi artan metin madenciliği, yapılandırılmayan veri kümelerini önemli, anlamlı çıktılar elde etmek amacıyla dönüştüren bir araç olarak ortaya çıkmıştır. İşlenmemiş haldeki metinlerin analizi, yorumlanması, anlamlı hale getirilmesi amacıyla belirli teknik ve algoritmalar kullanılması ile oluşan süreçtir (Ergöktaş, 2024).



Şekil 4’te başlangıç kısmında bahsedilen yapılanmamış ham veriyi toplayarak veri toplama safhası başlatılır. Bu aşama için işlenmesi istenen veriler, internet ortamında elde edilen metin veya çevrimdışı oluşturulabilen, veri tabanlarından çekilebilen metinlerdir. (Gürbüz 2022) veri toplama safhasındaki toplanan verilerin doğal dil ile yazılmış olduğu göz önünde bulundurulduğunda bir sonraki evre olan veri ön işlem aşamasına geçilmesi gerekmektedir. Veri ön işlem adımında gereksiz bilgilerin, sözcüklerin çıkarılmasını amaçlayan bu adım, sonuç için yani bilginin keşfi için oldukça önemlidir. Bu aşamada veriler üzerinde bazı işlemler uygulanmaktadır. Noktalama işaretlerini ve sayıları çıkarma işleminin ardından veriler küçük harflere çevrilir. Daha sonra tokenleştirme, metin içerisinden durak kelimeleri diye adlandırılan bağlaçları çıkarma, kökleri çözümleme yapıp ardından TF-IDF değerinin belirlenmesi ve metinleri sınıflandırma aşaması bulunmaktadır.




Şekil 5'teki tüm süreçlerden geçen metin verileri uygun olan veya belirlenen bir teknik kullanılarak analize hazır hale getirilmektedir.

2.4. Duygu Analizi

Sentiment Analysis olarak adlandırılan duygu analizi, çalışmalarına her ne kadar son 10 yılda yoğunlaşmış olsa da alanın ilk temel makalesi Pang vd. tarafından bu alanda yapılan temel çalışma olarak görülebilir (Tuna, 2019).

Doğal dil işleme (NLP) alanının yazılı metinlerdeki öznelleştirilmiş içeriğin incelenme ve çıkarımına odaklanan, fikir madenciliği yani opinion mining olarak da adlandırılan bir disiplin olarak ortaya çıkmıştır. Metinsel belgelerin içerisinde bulunan nesne, ürün, servis veya organizasyona ilişkin fikir, duygu, davranış gibi öznelleşmiş bilgilerin, makine öğrenmesi ve doğal dil işleme aracılığıyla anlamlı veriler çıkarılmasını hedefleyen bir araştırma disiplindir (Ergöktaş, 2024). En geniş tanımıyla duygu analizi, insanların yazılı olarak ifade etikleri metinler aracılığıyla duygu, düşünce ve görüşlerini, hislerini analiz etmeyi mümkün kılan tekniktir (Tuna, 2019). Metinlerde yer alan ifadelerin, görüşlerin olumlu, olumsuz, nötr gibi duygu sınıflarının hangisine ait olduğunu belirlemek amacıyla yapılmaktadır. Bu duyguları belirleyebilmek için yapay zekâ yöntemleri, doğal dil işleme gibi teknikler kullanılır (Ergöktaş, 2024). Bu teknikler sonrasında metinlerin içerisindeki kelimeler sayısallaştırılıp sınıflandırma yapılarak yığılmış metinler üzerinde çalışmalar yaparak somut olarak yargılara varma, karar verme mümkün hale gelmiştir (Tuna, 2019).

Duygu analizi yöntemleri için 3 farklı yaklaşım vardır. Bu yaklaşımlar Sözlük Tabanlı Yaklaşım, Makine Öğrenmesi Yaklaşımı ve de bu iki yaklaşımın karışımı olan hibrit yaklaşımdır (Kılıçer, 2024). Duygu analizi yöntemleri şekil 6 'da gösterilmiştir.



Şekil 6. Duygu Analizi Yöntemleri (Kılıçer, 2024)

Duygu analizinin makine öğrenmesi yaklaşımı, bu çalışmada otellere yapılan yorumları değerlendirmede kullanılacaktır.

2.5. Tokenleştirme

Doğal diller, bir karakter alfabesi ve kelimelerden oluşan bir kelime dağarcığına sahiptir. Dijital ortamlarda ise metin verisi, karakter dizileri olarak saklanır. Doğal dil işleme metin temsillerinde, metnin birimi "token" olarak adlandırılır ve token elde etme sürecine "tokenleştirme" denir. Metnin ana tokenleştirme yaklaşımı, karakter dizilerinden kelimeleri tespit etmektir çünkü kelime, insan dillerinin birimi olup, karakter dizilerine kıyasla belirgin semantik bilgilere sahiptir. Kelimeler karakterleriyle saklandığı için bilgisayarlar, kelimeler hakkında semantik bir bilgiye sahip değildir. Semantik bilgiyi elde etmek ve metin belgelerini analiz etmek amacıyla, NLP'nin tarihçesinde farklı yaklaşımlar geliştirilmiştir. Tokenleştirme, üç farklı seviyede yapılabilir: karakter, kelime ve alt kelime. Tokenleştirme işlemi sonucunda elde edilen tokenler ile veri, modeller için işlenmeye hazır hale gelir (Batmaz, 2017). Tokenizasyon, bir cümledeki kelimeler gibi küçük dil birimlerini ayıklayan bir süreçtir. Bu işlem, dilin makineler tarafından anlaşılabilmesi için önemli bir adımdır, çünkü tokenizasyon cümleyi daha küçük ve yönetilebilir parçalara ayırarak analiz edilebilir hale getirir. Bu sayede, metnin anlamı ve yapısı daha kolay bir şekilde incelenebilir. Teknik olarak, bir tokenleştirici aracı, cümledeki kelimeleri veya alt birimleri çıkartarak metnin yapı

taşlarını oluşturur. Tokenizasyon, büyük metinlerin daha küçük bileşenlere ayrılması sayesinde metnin anlamsal ve semantik özelliklerinin doğru bir şekilde analiz edilmesini sağlar. Bu da dilin anlam derinliğinin daha verimli bir şekilde ortaya konmasına olanak tanır. Sonuç olarak, tokenizasyon, doğal dilin makine tarafından anlaşılabilmesi için cümleyi analiz edilebilir parçalara ayırarak dilin her bir parçasının doğru şekilde işlenmesini sağlar (Ak, 2021).

2.6. Kelime Gömme Teknikleri

Duygu analizi araştırmalarında, metinleri sınıflandırabilmek için onların sayısal bir biçime dönüştürülmesi gerekmektedir. Bu süreçte, kelime temsilleri kullanılarak metindeki sözcükler, sayısal verilerle ifade edilen vektörlere aktarılmaktadır (Polat, 2021).


Kelime gömme, kelimelerin anlamlarını vektörlerle temsil eden bir tekniktir. Benzer anlamlara sahip kelimeler, koordinat sisteminde birbirine yakın konumlanır. Basit bir kelime gömme yöntemi olan one-hot encoding, kelime dağarcığındaki her kelimeyi uzun bir vektörle temsil eder ve yalnızca ilgili kelimenin bulunduğu konuma "1" atar. Ancak bu yöntem, kelimeler arasındaki anlam ilişkilerini ifade edemez ve genellikle kategorik verilerde kullanılır. Modern kelime gömme yöntemleri, one-hot encoding'den farklı olarak, dilin istatistiksel yapısını daha kompakt vektörlerle ifade eder. Bu sayede kelime anlamları, geometrik bir uzayda temsil edilerek benzer kelimeler yakın konumlanır. Örneğin, kelime vektörleriyle yapılan matematiksel işlemler "Kral - Erkek + Kadın = Kraliçe" gibi anlamlı sonuçlar üretir (Elverişli, 2024).

Doğal dil işleme projelerinde kelime gömme, model tasarımından önce önemli bir adımdır. Son yıllarda, kelimeleri vektörlere dönüştürme yöntemlerinde önemli ilerlemeler kaydedilmiştir. Başlangıçta TF-IDF gibi frekans tabanlı yöntemler kullanılırken, Word2Vec ve GloVe gibi öngörücü gömme yöntemleri geliştirilmiş ve metin sınıflandırma, duygu analizi gibi NLP görevlerinde yaygınlaşmıştır. Son dönemde, bağlam odaklı kelime gömme yöntemleri (contextualized embeddings) olan ELMo ve BERT, kelimelerin bağlama göre farklı temsillere sahip olmasını sağlamış ve birçok NLP görevinde etkili performans sergilemiştir. Ayrıca, metin sınıflandırma çalışmaları, farklı gömme yöntemlerinin model başarısına olan etkisini araştırmıştır. Kelime gömme yöntemleri arasında en bilinen modeller Word2Vec, GloVe ve FastText'tir. Bu modeller, kelimelerin anlamlarını daha etkili bir şekilde yakalayarak dil işleme görevlerinde sıkça kullanılır (Karagöl, 2024).

2.6.1. Word2Vec

Bir kelimeyi sabit boyutlu bir sayısal vektöre dönüştürmek amacıyla kullanılan en temel yöntemlerden biri olan one-hot kodlama, bazı sınırlamalara sahiptir. Öncelikle, bu yöntem büyük miktarda bellek gerektirir, çünkü vektör boyutu genellikle yüz binlere ulaşan benzersiz kelime sayısına eşit olur. Ayrıca, one-hot kodlama, iki kelimenin iç çarpımının sıfır olması ve tüm kelimelerin tamamen bağımsız kabul edilmesi nedeniyle, kelimeler arasındaki anlamsal ilişkileri yansıtamaz. Bu sorunlara çözüm bulmak amacıyla Mikolov ve ekibi (2013), kelimelerin anlamsal temsillerini üreten sinir ağı tabanlı bir model geliştirmiştir (Kuş, 2023).

Word2Vec, 2013 yılında Mikolov ve ekibi tarafından Google arama motorunun performansını artırmak amacıyla geliştirilen bir metin temsil yöntemidir. Bu yöntem, sığ yapay sinir ağlarını tahmin temelli bir yaklaşımla kullanarak kelime vektörleri oluşturur. Word2Vec'in sığ sinir ağı yapısı, anlamsal benzerlikleri hızlı bir şekilde tanıyabilir ve lojistik regresyon teknikleri ile eşanlamlı kelimeleri belirleyebilir. Bu özellik, Word2Vec'i derin sinir ağlarına kıyasla daha hızlı bir çözüm haline getirir.




Şekil 7. Word2Vec Mimarisi (Keskin, 2018)

TF-IDF gibi metni yüksek boyutlu ve seyrek matrislerle kodlama yöntemlerinin aksine, Word2Vec her kelime için yoğun vektörlerden oluşan kelime gömmeleri üretir. Ayrıca,

vektör uzayında benzer anlam taşıyan kelimeleri birbirine yakın konumlandırır. Bu gömmeler, vektör uzayında anlamca yakın kelimeleri bir araya getirerek doğal dil işleme uygulamalarında daha iyi performans ve daha düşük hesaplama maliyeti sağlar (Özdemir, 2024). Word2Vec yöntemi, sinir ağları tabanlı bir kelime gömme tekniğidir. Bu yöntemde, girdiler benzersiz kelimelerden oluşur ve bu kelimeler kullanılarak bir temsil matrisi oluşturulur. Word2Vec yönteminde kelimeler teker teker bir yapı içerisine eklenir ve bu kelimeler kaydırma işlemiyle taranır. Tarama sonucunda, kelimeler çok boyutlu bir çıktı vektörüne dönüştürülür. Bu yöntem, kelimelerin harflere ayrılması ve bu harflerin sayısal birer değer haline getirilmesi esasına dayanır. Word2Vec modelleri, girdiyi metin olarak alır, bunu gizli katmanlardan geçirir ve çıktı katmanına aktarır (Yalçın, 2023).

Word2Vec, kelimelerin metin içerisindeki bağlamlarını dikkate alarak kelime gömmeleri oluşturur. Bu amaçla iki farklı sinir ağı modeli kullanır: Continuous Bag of Words (CBOW) ve Skip-gram modelleri (Özdemir, 2024). Şekil 8’de model mimarileri gösterilmiştir.



Şekil 8. Cbow ve Skip-Gram Mimarisi (Polat, 2021)

2.6.1.1.CBOW (Sürekli Kelime Çantası) Modeli

CBOW modeli, bir bağlam kullanarak hedefteki kelimenin tahmin edilmesine odaklanır. Örneğin, "Senin evin bahçesi çok güzel" cümlesinde, 'senin', 'evin', 'çok' ve 'güzel' kelimeleri modele giriş olarak verilir. Model, bu bağlam kelimelerine dayanarak araya hangi kelimenin en yüksek olasılıkla geleceğini tahmin etmeye çalışır.

CBOW modeli, hedef kelimeyi (w_j) tahmin etmek için bağlam kelimelerini kullanır. Bu bağlam, hedef kelimenin önünde ve arkasında yer alan c sayıda kelimeden oluşur.

Burada c , pencere boyutunu ifade eder ve Eşitlik 1'deki gibi matematiksel olarak tanımlanır:


$$C(w_j) = \{w_j - c, w_j - c + 1, \dots, w_j - 1, w_j + 1, w_j + 2, \dots, w_j + c\} \quad (1)$$

Bir doküman D içinde K kelimenin yer aldığını varsayalım. Bu durumda, aşağıdaki Eşitlik 2 ve 3'te dokümanın ortalama log olasılığını maksimuma çıkarmak hedeflenir: Bu ifadelerde, c pencere boyutunu, w_j ise hedef kelimeyi temsil etmektedir (Çelenli, 2020).

$$D = \{w_1, w_2, \dots, w_K\} \quad (2)$$

$$L(D) = \frac{1}{K} \sum \log p(w_j | w_j - c, \dots, w_j + c) \quad (3)$$

CBOW modeli, merkezi kelimeyi tahmin etmek için hedef kelimenin çevresindeki birkaç bağlam kelimesini kullanır. Bu model, komşu kelimelerin sayısını belirlemek amacıyla sabit bir pencere boyutuna sahiptir. Pencere içindeki kelimeler, tahmin edilecek kelimeye eşit katkıda bulunur. Şekil 9'da CBOW modelinin yapısını görselleştirmektedir; burada $w(j)$ merkez kelimeyi temsil ederken, $w(j-2)$ ile $w(j+2)$ arasındaki kelimeler, bağlam kelimeleri olarak pencere boyutu içinde yer alır. Bu modelin sinir ağı yapısında, gizli katman tam bağlı bir yoğun katmandır. Çıktı katmanı ise kelime dağarcığında yer alan hedef kelime için olasılıkları hesaplar (Polat, 2021).



Şekil 9. Cbow Modeli Mimarisi (Polat, 2021)

2.6.1.2. Skip-Gram Modeli

İkinci yaklaşımda, Skip-gram modeli, merkez kelime verildiğinde çevresindeki kelimeleri tahmin eder veya üretir. Eşitlik 4'teki gibi hesaplanır.


$$P(w_t - m, \dots, w_t - 1, w_t + 1, \dots, w_t + m | w_t) \quad (4)$$

Bu model, olasılığını hesaplar; burada pencere boyutu m 'dir. Bu olasılık, Naive Bayes varsayımına dayanarak ayrıştırılır. Yani, merkez kelime verildiğinde çevresindeki kelimelerin birbirinden bağımsız olduğu kabul edilir. Bunun anlamı, Skip-gram modelinin her bir bağlam kelimesinin olasılığını hedef kelimeye olan uzaklığından bağımsız olarak ayrı ayrı hesaplamasıdır. Bu nedenle, olasılık aşağıdaki Eşitlik 5 ve 6 kullanılarak hesaplanır (Naderalvojoud, 2020).

$$P(w_t - m, \dots, w_t - 1, w_t + 1, \dots, w_t + m | w_t) = \prod_{j=0, j \neq m}^{2m} P(w_t - m + j | w_t) \quad (5)$$

$$P(w_t - m + j | w_t) = \frac{\exp(u_{t-m+j}^T u_t)}{\sum_{k=1}^{|V|} \exp(u_k^T u_t)} \quad (6)$$

Skip-gram modeli, bir kelimeyi pencere boyutunun merkezine yerleştirerek, bu pencere içinde bulunan diğer kelimeleri tahmin etmeye odaklanır. Orta kelime $w(j)$ olarak ifade edilirken, çevresindeki kelimeler $w(j-2)$ ile $w(j+2)$ arasındaki bir aralıkta yer alır. Bu ilişki Şekil 10'da görselleştirilmiştir.




Şekil 10. Skip-Gram Model Mimarisi (Çelenli, 2020)

Model, tek bir kelimenin bağlamına dayanarak yakınındaki kelimeleri öngörme yeteneğine sahiptir. Bu özellik, Skip-gram'ın, CBOW'dan farklı olarak seyrek veya nadir kelimeleri daha iyi temsil edebilmesini sağlar. Ayrıca, Skip-gram büyük veri setlerini işlerken CBOW'dan daha verimli çalışır. Daha önceki araştırmalarda da Skip-gram modelinin CBOW'ya kıyasla daha hızlı ve etkili sonuçlar verdiği görülmüştür (Özdemir, 2024). Bu nedenlerle, bu çalışmada Skip-gram modeli tercih edilmiştir.

2.6.2. GloVe

Pennington ve ekibi tarafından geliştirilen GloVe yöntemi, Word2Vec ile birlikte en yaygın kullanılan kelime temsil yöntemlerinden biridir. Bu yöntem, kelimeler ve kelime sıklıkları arasındaki ilişkileri değerlendirerek istatistiksel verilere dayalı tahminler yapar (Venugopal, 2021)



Şekil 11. GloVe Mimarisi (Venugopal, 2021)

GloVe, Word2Vec ile benzer şekilde kosinüs uzaklıklarını kullanarak anlamsal benzerlikleri analiz eder ve ilişkili kelimeleri tanır. Ancak GloVe'nin çalışma prensibi Word2Vec'ten farklıdır. Word2Vec, yerel bağlama dayalı bir yaklaşım benimserken, GloVe tüm veri kümesini dikkate alır, kelimeleri detaylı bir şekilde inceler ve bu kelimelerin birlikte kullanım desenlerini analiz eder. Bu yöntemin genel formülü Eşitlik 7'de gösterilmektedir (Yalçın, 2023).

$$J = \frac{1}{2} \sum_{i,j=1}^w f(P_{ij}) (u_i^T v_j - \log P_{ij})^2 \quad (7)$$

GloVe, kelime temsilleri için küresel vektörler kullanan ve Stanford tarafından geliştirilen denetimsiz bir öğrenme algoritmasıdır. Bu model, doğal dil işleme alanında, kelimelerin küresel birlikte oluşum istatistiklerini vektör uzayı temsilleriyle birleştirerek kelimeleri sayısal bir uzayda konumlandırır. GloVe, geniş ölçekli metin veri kümeleri üzerinde kelimeler arasındaki anlamsal benzerlikleri ve ilişkileri modellemeye yönelik geliştirilmiş bir yöntemdir. Bu yaklaşım, kelime vektörlerini oluştururken, bir kelimenin bağlamını ve diğer kelimelerle olan etkileşimini göz önünde bulundurur. GloVe'yi diğer kelime gömme yöntemlerinden ayıran en önemli özellik, istatistiksel verilere dayalı bir modelleme stratejisi kullanmasıdır. Metindeki kelime çiftleri arasındaki istatistiksel bağıntıları analiz ederek kelime vektörlerini üretir ve bu vektörler, kelimenin anlamını ve kullanım alanını etkili bir biçimde temsil eder (Şahin S. , 2024).


GloVe ve Word2Vec arasındaki temel fark, Word2Vec'in ileri beslemeli bir sinir ağı kullanarak çalışması, GloVe'nin ise matris çarpanlarına ayırma tekniği ile işleyişini sürdürmesidir (Yalçın, 2023).

2.6.3. FastText

FastText, doğal dil işleme görevlerinde kullanılan bir kelime gömme modelidir. Kelimeleri sürekli değerli vektörlerle temsil eder ve hem anlamsal hem de dilbilgisel bilgiyi yakalar. FastText, giriş metin verilerini denetimsiz bir şekilde işler ve kelime gömme öğrenimini verimli bir şekilde gerçekleştirebilmek için çok katmanlı bir sinir ağı kullanır. Model, kelimeleri karakter n-gramlarına ayırarak kelime gömülerini öğrenir, bu sayede zengin morfolojik yapıya sahip dillerde daha verimli çalışır. Bu, FastText'in, kelime düzeyindeki yaklaşımlar için uygun olmayan kelimelerle başa çıkmasını sağlar.

FastText, bir giriş katmanı, gizli katman ve çıkış katmanından oluşur. Girişte metin verileri, n-gram karakter dizilerine dönüştürülür ve subword bilgisini içerir. Gizli katman, doğrusal olmayan bir dönüşüm uygular ve çıkış katmanı kelimenin bağlamını tahmin eder. FastText, morfolojik varyasyonları daha iyi yakalayarak, geleneksel yöntemlerden daha etkili çalışır.

Modelin performansı, kelime vektörlerinin boyutunu, öğrenme hızını, eğitim dönemlerini ve bağlam penceresinin boyutunu belirleyen parametrelerle ayarlanabilir. Şekil 12 FastText eğitim modelinin mimarisini göstermektedir (Karakaya, 2024).



Şekil 12. FastText Kelime Gömme Modeli

Kelime yapıları ve eklerden türeyen ilişkiler, farklı dillerde önemli bir rol oynar. Örneğin, “dog” ve “dogs” kelimeleri aynı köke dayanırken farklı eklerle anlam değiştirir. Ancak, Word2Vec morfolojik bilgileri kullanmaz ve farklı biçimlere sahip kelimeleri ayrı vektörlerle temsil eder. Bu durum, kelimeler arasındaki ilişkileri modelde doğrudan ifade etmez.

FastText, bu eksikliği gidermek için alt birim gömme (subword embedding) yöntemini önerir. Bu yöntem, bir kelimenin vektörünü, alt birim vektörlerinin toplamı olarak ifade eder. Böylece, özellikle nadir kullanılan kelimelerin temsil kalitesini artırır ve morfolojik özelliklerden faydalanır (Memiş, 2024).


2.6.4. Bert Modeli

Son çalışmalar, büyük veri kümesi üzerinde önceden eğitilmiş modellerin metin sınıflandırması ve diğer doğal dil işleme uygulamalarındaki değerini göstermektedir. Bu modeller, büyük miktarda etiketlenmemiş veriyi entegre ederek yeni modelleri sıfırdan eğitime ihtiyacını ortadan kaldırmakta ve dünya dillerini temsil etmede son derece etkili olmaktadır. Bert tabanlı model, en iyi önceden eğitilmiş model türlerinden biridir (Alfigi, 2023).

BERT, çift yönlü kodlayıcı temsilleriyle çalışan, önceden eğitilmiş ve açık kaynak olarak sunulan bir derin öğrenme modeli olup, dil işleme alanında kullanılan etkili bir araçtır. BERT, arama sorgularındaki eksik kelimeleri bulmak için cümlelerin tamamını analiz eder, bu özelliği onu diğer algoritmalarından farklı kılar. Makine öğrenimi yöntemlerinden faydalanarak kelimeler arasındaki ilişkileri çözmeyi amaçlar ve bu nedenle çift yönlü dil işleme yeteneğine sahiptir. Geleneksel çift yönlü dil işleme tekniklerinden farklı olarak, BERT, sağdan sola ve soldan sağa doğru çalışan daha karmaşık bir maskelenmiş dil modeli kullanır (Saraçoğlu, 2024).

Bert yapısı iki aşamaya ayrılır: ön eğitim ve ince ayar. Ön eğitim aşamasında, model denetimsiz metin verileri üzerinde çeşitli ön eğitim görevleri kullanılarak eğitilir. Bu görevler arasında maskelenmiş dil modeli ve bir sonraki cümle tahmin edilmesi bulunur. İnce ayar aşamasında ise Bert modeli, ön eğitim parametreleriyle başlatılır ve bu parametreler, sınıflandırılmış verilerle ayarlanır. Bert-base modelinin mimarisi, 768 gizli boyut, 12 kendi kendine dikkat başlığı ve 12 transformer bloğundan oluşan bir encoder içerir.

Bert, 512 token'a kadar olan giriş dizisinden bir dizi temsili üretir. Dizi, ilk olarak [CLS] özel sınıflandırma gömme sembolünü ve ardından segmentleri ayırmak için kullanılan [SEP] sembolünü içeren birden fazla segmentten oluşur.



Şekil 13. Bert Model Mimarisi (Bhakta, 2024)

Bert, metin sınıflandırma görevlerinde, ilk token olan [CLS]'nin son gizli durumunu, tüm dizinin temsili olarak kullanır. Etiket c'nin olasılığını tahmin etmek için ise basit bir SoftMax sınıflandırıcı, Bert'in üzerine uygulanır (Alfigi, 2023).

2.7. Makine Öğrenmesi

Yapay zekanın araştırma, uygulama alanı çok büyük olan dallarından birisi de makine öğrenmesidir. Amerikalı bilgisayar bilimcisi Arthur Samuel, 1959 yılında ortaya çıkarttığı makine öğrenmesi kavramı, bilgisayarların programlama yapılmadan öğrenebileceğinin tanımı olarak kullanılır. Yüksek boyutlardaki verilerin el ile analiz edilmesi zaman alıcı ve zor bir süreçtir. Makine öğrenmesinin yöntemleri ile bu zor olan süreç geçmişteki verilerden faydalanarak çözülmesi mümkündür. Bilgisayarlar ve matematiksel işlemler aracılığıyla verilerden çıkarım yaparak tahminlenmesi sürecine makine öğrenmesi denir (Bağdatoğlu, 2020).

Bir başka tanıma göre, olaylar ile ilgili özellikleri bilgisayarların deneyimsel yollar ile öğrenerek önceden karşılaşılmamış benzer olaylara karar vererek çözüm üretmesidir. Bilgisayarın öğrenebilmesi ancak problem hakkında veriler sunulması ile mümkündür

(Yılmaz, 2019). Makine öğrenmesi, problemleri ve çözüm süreçlerini oldukça karmaşık bir şekilde ele alırken, model genellikle basit bir biçimde ifade edilir. Doğrudan bir çözüm elde etmek zorluğu nedeniyle, modele veri girilir ve çıkan sonuçların doğru hesaplanması sağlanır. Eğer çıktılar yanlış hesaplanır ise doğru sonuç alınana kadar parametreler belirli ölçülerde değiştirilebilir. Bu işlemler defalarca tekrarlanabilir. Bu süreçlerin ardından makine öğrenmesi modeli eğitilmiş olur. Makine öğrenmesinin temel özelliği, problemler ne kadar karmaşık olursa olsun, çözüm için veriler üzerinden doğru sınıflandırmalar ve çıkarımlar yapmayı, tıpkı bir insanın deneyim kazanarak olayları zaman içinde öğrenmesi gibi başarabilmesidir (Bağdatoğlu, 2020).

2.7.1. Öğrenme Yöntemleri

Makine öğrenmesinde, verilerin türüne ve karşılaşılan problemlere bağlı olarak farklı öğrenme yöntemleri bulunmaktadır. En yaygın kullanılan yöntemler ise gözetimli, yarı kontrollü ve gözetimsiz öğrenme yöntemleridir. Bu yöntemler aşağıda sırasıyla açıklanmıştır.

2.7.1.1. Gözetimli Öğrenme

Gözetimli öğrenme, makine öğrenmesinde çok sık kullanılan öğrenme yöntemidir. Bir gözetimli öğrenme probleminde girdilere x , çıktılarına y dediğimizde o problemde bir $f(x) = y$ fonksiyonunu bulma yöntemi olarak düşünebiliriz. Bu noktada x 'ler için verilerden elde edilen değer, y 'ler için ise çıktı sürecinde eşleştirebileceğimiz ya da elde edebileceğimiz değerler olarak düşünülür. Bu işlemdeki amaç, $f(x) = y$ fonksiyonunu olabilecek en iyi eşitlikte bulmaktır. Bu durum her an mümkün olamayacağı için çoğunlukla hata payı oluşmaktadır (Bağdatoğlu, 2020).

2.7.1.2. Gözetimsiz Öğrenme

Gözetimsiz öğrenme yönteminde ise öğrenim gerçekleşebilmesi için sadece sisteme problem ile ilgili giriş örnekleri verilir. Dolayısıyla danışman ya da öğretmen bu sistemde bulunmamaktadır. Eğitim sürecinde sisteme giriş örneklerine karşılık gelen çıkış verilmediği için sistemin veriler için bulunan parametrelerin arasındaki ilişkiyi kendi kendine öğrenmesi

beklenir. Sistem bu ilişkiyi belirledikten sonra giriş verilerine ait olan çıkışları hesaplar. Bu durumda tek yapılması gereken sistemin hesapladığı çıkış verilerinin ne anlama geldiğini etiketlendirmektir (Bağdatoğlu, 2020).


2.7.1.3. Yarı Gözetimli Öğrenme

Yarı kontrollü öğrenmede, denetimli ve denetimsiz öğrenme yöntemlerine benzer özellikler bulunmaktadır. Sisteme aynı gözetimsiz öğrenme yöntemindeki gibi sadece probleme ait giriş bilgileri verilir. Fakat sistem için kontrol eden bir danışman bulundurularak sistem çıkışının doğru veya yanlış olduğunu denetler. Bundan dolayı çıkış verileri verilmese bile doğru hesaplama için danışman gözüyle takviye alınmış olur. Danışman öğrenen sisteme yardımcı olmaktadır.

Sisteme sunulmuş olan giriş verileri için hesaplanması gereken çıktıları vermesi yerine sistemin o çıktıları hesaplaması beklenir. Hesaplama işleminden sonra çıktıların doğru veya yanlış olduğunu belirtecek olan sinyali danışman üretir. Bu durum neticesinde, danışmandan gelen sinyaller sayesinde sistemi doğruya yönlendirecek olan öğrenme işlemini devam ettirir (Bağdatoğlu, 2020).

2.8. Derin Öğrenme

Makine öğrenmesinin bir dalı olan derin öğrenme, insan aklının işleyişinden esinlenerek geliştirilen bir öğrenme yöntemidir. Derin öğrenmenin en önemli özelliği ise ham, işlenmemiş verilerden otomatik olarak özellik çıkartabilmesidir. (Önün, 2019) Bir uygulayıcı eğer derin öğrenme işlemi yapmak istiyorsa mutlaka sinir ağları ile karşılaşmış olmalıdır. İnsan beyninin sinir yapısından örnek alınarak tasarlanan sinir ağları, çok kademeli ve karmaşık hesaplama işlemlerini çözme konusunda faydalıdır. (Gündüz, 2019)



Şekil 14. Klasik Derin öğrenme Yapısı (Gündüz, 2019)

Derin öğrenme, bir bilgisayar modelinin doğrudan görüntü, metin veya ses gibi ham veriler üzerinden sınıflandırma görevlerini yerine getirmeyi öğrenmesini sağlar. Bu modeller, bazen insan performansını aşarak daha yüksek doğruluk oranlarına ulaşabilir. Eğitim süreçlerinde, çok katmanlı sinir ağı mimarileri ve geniş ölçekli etiketlenmiş veri setleri kullanılır. Derin öğrenmenin en önemli avantajlarından biri, önceki yöntemlere kıyasla daha yüksek doğrulukta tanıma ve analiz yapabilmesidir (Keskenler, 2024).

2.8.1. Derin Öğrenme Modelleri

Derin öğrenme algoritmaları ve yöntemleri, yapay zekâ ve makine öğrenimi alanlarında son yıllarda önemli gelişmeler arasında yer almaktadır. Bu teknoloji, özellikle büyük ve karmaşık veri setlerini işleyerek, gizli desenleri ve özellikleri otomatik olarak çıkarma yeteneğiyle öne çıkmaktadır. Sürecin temelini oluşturan yapay sinir ağları, çok sayıda katmandan oluşur ve girdi verisini çeşitli işleme aşamalarından geçirerek nihai çıktıyı üretir (Yıldırım, 2024). Aşağıdaki alt başlıklarda derin öğrenme modelleri verilmiştir.

2.8.1.1. Yapay Sinir Ağları(ANN)

İnsan beyninin, birleştirme, genelleştirme, öğrenme ve uyum sağlama gibi özelliklere sahip, doğrusal olmayan, karmaşık ve paralel çalışan bir sistem olduğu belirtilmektedir. Beyindeki nöronlar, elektriksel sinyaller aracılığıyla iletişim kurar ve bu özelliklerinden dolayı beyin genellikle elektriksel bir ağ yapısı olarak kabul edilir. Merkezi sinir sistemi tarafından üretilen komutlar motor organlara iletilir ve geri bildirim mekanizmaları, motor organlardan


gelen uyarıları doğrulayarak merkezi sinir sistemini düzenler ve kontrol eder.

Araştırmacılar, insan beyninde ortalama 10 milyar sinir hücresinin bulunduğunu ve bu hücrelerin yaklaşık 60 trilyon bağlantıyla iletişim kurduğunu ifade etmektedir. Nöronlar, duyular aracılığıyla gelen bilgiyi işler ve bu bilgiyi bir sonraki nörona iletir. İşlenen bilgi, sinir sistemine ulaştığında yorumlanarak tepki sinyallerine dönüştürülür.

Nöronlar, akson, bağlantılar, çekirdek ve dendrit gibi dört ana yapıdan meydana gelir. Dendritler, duyular tarafından alınan sinyalleri çekirdeğe taşıırken, çekirdek bu sinyalleri toplayarak aksone aktarır. Akson, gelen sinyalleri işleyerek nöronun diğer ucundaki bağlantılara iletir. Bu süreçte, sinaps adı verilen yapılar, sinyalleri diğer hücrelerin dendritlerine aktarır. Gelen sinyaller, belirli bir eşik değerine ulaştığında işleme alınır ve bağlantılar aracılığıyla diğer nöronlara iletilir. Dendritlerden gelen sinyalleri toplayan hücre çekirdeği ise soma olarak adlandırılır.

Bu yapı, insan beyninin bilgi işleme sürecini modellemek için bilim insanlarına önemli bir örnek teşkil etmiştir. İnsan beynini oluşturan sinir sisteminin modellenmesi, biyolojik sinir hücrelerinden alınan sınıflandırılmış veya öğrenilmiş verilerle yeni sonuçlar üretebilen yapay sinir ağlarının geliştirilmesine olanak sağlamıştır (Demirbaş, 2024).

Yapay sinir ağları, insan beynindeki nöronların ve bu nöronlar arasındaki bağlantıların matematiksel olarak modellenmesiyle oluşturulan bir sistemdir. Bu sistemdeki en küçük yapı taşı 'sinir' olarak adlandırılır ve her bir katman, sistemin işlevine bağlı olarak değişen sayıda sinir içerir. Şekil 15'te, yapay sinir ağlarının katmanlı yapısı ve bilgi akış yönü detaylı bir şekilde gösterilmektedir.




Şekil 15. Yapay Sinir Ağı Modeli

Yapay sinir ağları, insan beynindeki gibi nöronlardan oluşur ve bu nöronlar, 'ağırlık' olarak isimlendirilen parametreler aracılığıyla birbirine bağlanır. Ağı doğrusal bir yapıda olmaması için her nöron, aktivasyon fonksiyonu adı verilen bir işlem gerçekleştirecek şekilde tasarlanmıştır. Aktivasyon fonksiyonları, girdileri alır, işler ve bir çıktı oluşturur. Bu fonksiyonlar arasında yaygın olarak kullanılanlar Sigmoid, ReLU (Rectified Linear Unit) ve Tanh'dır. Hangi aktivasyon fonksiyonunun kullanılacağı, sisteme ve veri setine göre belirlenir.

Bir yapay sinir ağının temel birimi olan sinir, aldığı girdileri işler ve sonuçları iletir. Şekil 12'de, bu süreçte gerçekleştirilen matematiksel işlemleri ve sinir yapısını görselleştirmektedir (Özçelik, 2021).

ReLU, yapay sinir ağlarında sıkça tercih edilen bir aktivasyon fonksiyonudur. Bu fonksiyon, giriş değeri sıfırdan büyük olduğunda aynı değeri doğrudan çıktı olarak verir. Giriş değeri sıfır ya da daha küçük olduğunda ise çıktı olarak sıfır döndürür. ReLU'nun matematiksel ifadesi aşağıdaki Eşitlik 8'de sunulmaktadır.

$$f'(x) = \{ x, x > 0 \quad 0, x \leq 0 \} \quad (8)$$



Şekil 16. ReLU Fonksiyonu Grafiği (Dikici, 2024)

Şekil 16’da ReLU aktivasyon fonksiyonunun grafiği gösterilmektedir. Grafikte, x ekseninde yer alan negatif değerler için fonksiyonun çıktısının sıfır olduğu görülmektedir. Pozitif x değerlerinde ise fonksiyonun çıktısı, x ile doğru orantılı bir şekilde artmaktadır. Bu durum, ReLU'nun parçalı doğrusal yapısını ortaya koymaktadır. Negatif girişlerde sıfır değerini döndürürken, pozitif girişlerde çıktı ile giriş değeri eşit olmaktadır. ReLU, derin öğrenme modellerinde sıkça tercih edilmektedir çünkü hem hesaplama açısından yüksek verimlilik sağlar hem de gradyan kaybı sorununu azaltmada etkili bir rol oynar (Dikici, 2024).

Softmax fonksiyonu, genellikle çoklu sınıflandırma problemlerinde kullanılan bir aktivasyon fonksiyonudur. Bu fonksiyon, bir vektördeki her değeri 0 ile 1 arasında normalize eder ve toplamalarının 1 olmasını sağlar, böylece bir olasılık dağılımı elde edilir (Dikici, 2024).


$$\sigma_i(z) = \frac{\exp(\lambda z_i)}{\sum \exp(\lambda z_j)}, 1 \leq i \leq n \quad (9)$$

Softmax fonksiyonunun matematiksel formülü yukarıdaki Eşitlik 9’da gösterilmiştir. Bu ifade, fonksiyonun i’inci çıktısını, z vektörünü ve n değerini, yani vektördeki eleman sayısını temsil etmektedir. Ayrıca, λ parametresi fonksiyonun keskinliğini kontrol eden bir ayar mekanizması olarak görev yapmaktadır. (Dikici, 2024)

2.8.1.2. Evrişimsel Sinir Ağları (CNN)

Derin öğrenme yöntemleri arasında en sık kullanılanlardan biri olan Evrişimsel Sinir Ağları (CNN), 1989 yılında LeCun tarafından tanımlanmıştır. Ancak, bu yöntemlerin yüksek donanım gereksinimleri nedeniyle başlangıçta gelişim süreci yavaş ilerlemiştir. Donanım teknolojilerindeki ilerlemeler sayesinde, 2010'lu yıllarda CNN'ler yeterli hızda çalışabilecek hale gelmiş ve yaygın bir şekilde kullanılmaya başlanmıştır (Daşgın, 2023).

Evrişimsel Sinir Ağları, genellikle görüntü sınıflandırma gibi senaryolarda kullanılan bir yaklaşımdır. CNN mimarisinde, evrişim işlemleri her katmanda bir tür filtre görevi görerek görüntülerdeki köşe, gölge ve kenar gibi temel özellikleri çıkarmak için özelleştirilmiştir. Bu sayede bir görüntünün karakteristik öğeleri evrişim katmanları yardımıyla analiz edilebilir. Günümüzde CNN, yalnızca görüntü işlemede değil, aynı zamanda duygu analizi, soru-cevap sistemleri ve makine çevirisi gibi doğal dil işleme alanlarındaki uygulamalarda da yaygın bir şekilde kullanılmaktadır (Bardız, 2019)



Şekil 17. CNN Model Yapısı (Bardız, 2019)

Evrişimsel Sinir Ağları, hayvanların görme merkezlerinden ilham alınarak geliştirilmiş, çok katmanlı ileri beslemeli yapay sinir ağlarıdır. CNN'ler, ham veriyi giriş olarak alarak evrişim ve havuzlama katmanlarından geçirip özellik çıkarımı işlemini otomatik bir şekilde gerçekleştirmektedir.

Ağ derinliği, katman sayısı ile ifade edilirken; ağ genişliği, evrişim işlemlerinde kullanılan filtre sayısı ile belirlenir. CNN yapısı, giriş katmanını takiben özellik çıkarımı için evrişim ve havuzlama katmanlarını, sınıflandırma aşamasında ise tam bağlantılı ve softmax katmanlarını içerir. Şekil 17'de, CNN mimarisinin genel yapısı görsel olarak sunulmuştur (Tolan, 2024). Evrişim katmanı, Evrişimsel Sinir Ağlarının en temel bileşenlerinden biridir.

Matematiksel olarak evriřim, iki fonksiyonun birleřimiyle yeni bir fonksiyon oluřturma iřlemidir. Bu katmanda, bir giriř vektörüne filtre (kernel) uygulanarak öznitelik haritası (feature map) oluřturulur. Filtre, kayan bir pencere gibi giriř vektörü üzerinde hareket eder ve her konumda matris çarpımı iřlemi gerekleřtirilir. Bu iřlem sonucunda, her pikseli bir anlam taşıyan yeni bir matris elde edilir ve bu matris öznitelik haritasını temsil eder (Pervan, 2019).

Havuzlama katmanı, Evriřimsel Sinir Ağlarında önemli bir yapı taşıdır. Bu katman, evriřimsel katmanlar arasındaki baęlantı sayısını azaltarak hem hesaplama yükünü hafifletir hem de daha verimli bir iřlem süreci saęlar. Havuzlama katmanının temel amacı, benzer anlam taşıyan özellikleri bir araya getirerek özet bir temsil oluřturmaaktır. Bu süreçte, atlama miktarı genellikle birden büyük bir deęer seilir. Bu sayede, evriřim katmanından elde edilen temsilin boyutu küülür ve iřlem maliyeti düşer(Arslan, 2021).

Genellikle, havuzlama filtrelerinin boyutu ile atlama miktarı eřit seilir. Bu tercih, havuzlama sırasında farklı blokların birbiriyle akıřmasını engeller ve daha düzenli bir özellik ıkarımı saęlar (Arslan, 2021). Bu katman, aęın hesaplama yükünü ve parametre sayısını azaltmak amacıyla birçok filtre uygulandıktan sonra, modelin boyutunu küültür. Bu sadeleřtirme iřlemi, eęitim süresini kısaltırken aynı zamanda sinir aęının ezberleme eęilimini de azaltır. Havuzlama iin en yaygın kullanılan yöntem ise maksimum havuzlamadır (max pooling) (Pervan, 2019).

Mimarinin sonunda tam baęlantılı katmanlar (Fully Connected Layers) bulunur. Bu katmanlar, daha önce ıkarılan özniteliklerin yüksek seviyelerdeki kombinasyonlarını ve etkileřimlerini öęrenerek, farklı aktivasyon fonksiyonları kullanarak sınıflandırma ya da regresyon iřlemlerini gerekleřtirir. Ayrıca, aęın daha hızlı ve kararlı bir řekilde alıřabilmesi iin yığın normalizasyonu (Batch Normalization) katmanları ve aşırı öęrenme (overfitting) sorununu engellemek amacıyla sönümleme (Dropout) katmanları da modele dahil edilebilir (Saltürk, 2024). Yoęun katman veya tam baęlantılı katman (Fully Connected Layers), yapay sinir aęlarının temel bileřenlerinden biridir. Bu katman, bir önceki katmandaki tüm nöronlardan girdi alır ve her nörona özgü aęırlıklar ve sapmalar ile bu girdileri iřleyerek ıktı üretir. Bu katmandaki her nöron, önceki katmandaki tüm nöronlarla baęlantılıdır, bu yüzden "yoęun" olarak adlandırılır. Bu katmanlar, girdi özelliklerini alır ve belirli bir aktivasyon fonksiyonu (örneęin, ReLU, Sigmoid) kullanarak dönüřtürür ve ıktıyı bir sonraki katmana iletir. Matematiksel olarak, bir tam baęlantılı katmanın ıktısı, uygun

Eşitlikle hesaplanabilir (Kaya, 2024). Bir dense katmanı, düzenli bir tam bağlı katmanı temsil eder. Bu katmanın temel fikri, ağdaki her nöronu, komşu katmanlardaki her nörona bağlamaktır (Alkhasawe, 2018). Sınıflandırma Katmanı , Softmax sınıflandırıcısı, ağı tahmin ettiği nesnenin hangi sınıfa daha yakın olduğunu belirlemek için 0 ile 1 arasında bir olasılık değeri sunar. Bu olasılık değerleri, her bir sınıf için tahmin edilen olasılıkları temsil eder ve böylece ağı girdi için her sınıfla ilgili olasılıkları hesaplamasına olanak tanır. Genellikle, en yüksek olasılığa sahip sınıf, ağ tarafından tahmin edilen sınıf olarak seçilir (Talo, 2024).

Tahmin işlemi, softmax fonksiyonu aracılığıyla gerçekleştirilir. Derin öğrenme uygulamalarında sıkça kullanılan bu aktivasyon fonksiyonu, yapay sinir ağlarından elde edilen değerleri işleyerek olasılıklara dayalı bir kayıp (loss) değeri hesaplar. Bu fonksiyonun hesaplanması aşağıdaki Eşitlik 10 ile ifade edilmektedir.

$$\log p(w_j | w_j - c, \dots, w_t + c) = \frac{e^{y w_j}}{\sum_i e^{y_i}} \quad (10)$$


Her çıktı kelimesi için normalize edilmemiş log olasılık değerleri üzerinden yapılan hesaplamalar ise aşağıdaki Eşitlik 11 ile gösterilir.

$$y = b + U h(w_j - c, \dots, w_j + c; W) \quad (11)$$

Yukarıda belirtilen U ve b parametreleri, softmax fonksiyonuna özgü özelliklerdir. Bunun yanında, h parametresi, kelime vektörlerinin birleştirilmesi ya da ortalamasının alınmasıyla elde edilmiştir (Çelenli, 2020).

2.8.1.3. Tekrarlayan Sinir Ağları (RNN)

Tekrarlayan sinir ağları, doğal dil işleme için kullanılan yapay sinir ağı türlerinden biridir. Sıralı verilerle çalışır ve bu süreçte verilerin sırasına dikkat ederek bir önceki verinin girdilerini saklar ve gelecekte tahminde bulunabilmek için verileri hafızada tutar. Bu yeteneğinden dolayı tekrarlayan sinir ağları konuşma verilerini ve metindeki verileri çalışırken başarılıdır (Özdemir Tekir, 2023).




Şekil 18. Geleneksel RNN Mimarisi (Amidi ve Amidi, 2018)

Tekrarlayan sinir ağları da öğrenmek amacıyla eğitim verilerini kullanarak geleneksel sinir ağlarından farklı olarak önceki girdilerden etkilenir. Bundan dolayı çıktılar bir önceki hesaplamağa bağlı olarak etkilenir. Bir başka özelliği ise her bir katmanının parametrelerini paylaşmasıdır (Aksu S. , 2024). Tekrarlayan sinir ağları, uzun süreli verileri saklamada sorun yaşayabildiği için, bu zorlukları aşmak amacıyla Uzun-Kısa Süreli Bellek (LSTM) ve GRU gibi daha ileri düzey ağ modelleri tasarlanmıştır (Özdemir Tekir, 2023).

2.8.1.3.1. LSTM

Uzun-Kısa Süreli Bellek ağ modeli Hochreiter ve Schmidhuber 1997’de geliştirilmiştir. Geliştirilme amacı Tekrarlayan Sinir Ağları yapısındaki uzun zaman aralıklarıyla verileri saklayamaması sonucunda oluşan eksiklikleri gidermektir (Emekli, 2024). LSTM uzun süreli bellekleme ile uzun veri girdilerini uzun süreli işleyebilen Tekrarlayan sinir ağının bir alt türüdür (Sungur, 2024).



Şekil 19. LSTM Mimarisi (Gürbüz, 2020)

Uzun-Kısa Süreli bellek ağının bellek birimlerine hücre denilmektedir. Bu hücreler bir

önceki ve o anki veriyi girdi olarak alır. LSTM hücresinin giriş, çıkış ve unut kapısı şeklinde üç kapısı vardır. Hücre durumu ağın hafızasını temsil eder. Giriş, çıkış ve unut kapısı modelin en önemli yeniliğidir. Giriş kapısı, yeni bilgiler ile hücre durumunu yeniler. Hangi değerlerin güncelleneceğine Sigmoid fonksiyonu kullanarak karar verir. Ardından, yeni aday değerleri vektörleştirip tanh katmanının vektör oluşturmasını sağlar. Eşitlik 12 ve 13'teki gibi hesaplanır.

$$i_t = \sigma(w_i \cdot [h_{t-1}, x_t] + b_i) \quad (12)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (13)$$

Unut kapısı ise hücre kısmından ne tür bir bilginin atılması gerektiğine karar veren kapıdır. C_{t-1} Hücre durumu her bir sayı değeri için 0-1 arasında bir sayısallaştırma yapar. Bunu yaparken önceki gizli katmandan h_{t-1} ve mevcut girdi olan x_t 'ye bakar. “0”, “kurtul” anlamına gelirken “1”, “tut” anlamına gelir. Eşitlik 14'teki gibi hesaplanır.

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (14)$$


Hücre durumunda ise eski hücre olan C_{t-1} yeni hücre durumunda olan C_t arasında şekildeki gibi güncelleme işlemi olur. Unutma kapısında unutma kararı alınan bilgileri silmesi için, önceki hücre, unutma kapısından gelen çıktı ile çarpılarak bu işlemi yapar. Yeni bilgiler oluştururken giriş kapısının çıktı değeriyle aday değer çarpılarak bu işlemi gerçekleştirir (Asutay, 2024). Eşitlik 15'teki gibi hesaplanır.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (15)$$

2.8.1.3.2. GRU

Çevirisi Geçitli Tekrarlayan birim anlamına gelir. LSTM'e göre yapısı daha az karmaşıktır. Kapı sayısı olarak sadece iki kapısı vardır. LSTM modelinin iç yapısı ile GRU modelinin iç yapısı benzerlik göstermektedir (Şahin, 2024). Bu kapılar güncelleme ve sıfırlama olarak ikiye ayrılır. Güncelleme kapısı, verilerin ne kadarını gizli bölüme dahil edip ne kadarını dahil etmeyeceğine karar verirken, sıfırlama kapısı kendinden bir önceki gizli bölümün ne

kadarının tutulacağı konusunda karar verir. Bu gizli bölümler aynı zamanda hücre durumu ve çıkış kapısı olarak da işlem yapar. Bundan dolayı çıkış kapısı bölümü yoktur. Bu sebeple LSTM'e göre daha az parametre kullanarak uygulanması kolaylaştırılmıştır. Performans kıyaslaması yapıldığında GRU modeli LSTM'e göre daha hızlı ve verimli olmasına karşın uzun süreli bağımlılıkları LSTM kadar tutamayabilir. Genelleme yapılacak olursa LSTM daha güçlüdür ancak overfitting denilen eğitimi ezberleme eğilimi yüksektir (Tunç, 2024).



Şekil 20. GRU Mimarisi (Canlı, 2022)

Şekilde gösterilen veriler, x_t girdi verisi, h_{t-1} önceki katmanın çıkış verisi, r_t unutma kapısını, h_t çıktıları, z_t giriş kapısı $\tilde{h}_t$ güncelleme kapısını ifade etmektedir. Reset kapısı ise önceki bilgilerin ne kadarının unutulacağını göstermektedir.

$$r_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) \quad (16)$$

Eşitlik 16'da b_f unutma katmanının sapma değerini, w_f unutma katmanının ağırlık matrisini göstermektedir. Burada bellekteki verilerin h_{t-1}, x_t ne kadarının güncellenmesi gerektiğinin kararını veriyor. Güncelleme kapısı olarak da isimlendiriliyor.

$$z_t = \sigma(w_i \cdot [h_{t-1}, x_t] + b_i) \quad (17)$$

Eşitlik 17'de w_i giriş katmanının ağırlık matrisi ve b_i giriş katmanının sapma değerini belirtmektedir. Güncelleme ve resetleme kapısında gerçekleştirilen işlemler, LSTM modelinde gerçekleştirilen işlemler ile aynıdır. GRU modelinde ise bellek durumunu, belleğin unutma kapısından bilgileri alması ile önceden aldığı bilgilerin ne kadarını

kullanacağını hesapladığı parametresi de $\tilde{h}_t$ parametresidir. Bu $\tilde{h}_t$ parametresi hücrelerin çıkışını belirlemek için kullanılmaktadır.

$$\tilde{h}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (18)$$

Eşitlik 18’de W_C ağırlık matrisi b_C ise sapma değerini gösterir. GRU modelinin en önemli kısmı hücre çıkış kısmıdır. Bu kısımda bir sonraki kısma aktarılması gereken hücre çıkış verisi hesaplanır. GRU modelinin LSTM modelinden farkı bu kısımda yani çıkış kapısındadır. Eşitlik 19’de çıkış kapısı için çıkış değeri nasıl hesaplanır gösterilmiştir.

$$h_t = h_{t-1} * (1 - z_t) + z_t * \tilde{h}_t \quad (19)$$

Eşitlik 19’da $*$ işleminin anlamı eşit boyuttaki matrislerin çarpımı anlamına gelmektedir. Hücre giriş kapısının taşıdığı veri yani z_t verisi 1’e yaklaştığında GRU’nun hücresi kendinden önceki hücrenin çıktılarından daha az bilgi alması gerektiğini, eğer 0’a yaklaşıyor ise de kendinden önceki hücrenin yapısını benimseyerek fazla güncelleme işlemi yapmadan önceki verileri kullanıp kendi verisini çıktı olarak sunacaktır.

ÜÇÜNCÜ BÖLÜM

BULGULAR

Makine öğrenmesi ve derin öğrenme çalışmasında verilerin boyut ve türüne göre ihtiyaç duyulacak bilgisayar gereksinimleri de değişmektedir. Derin öğrenme yöntemlerinin çalışmasında, metin sayısının fazla olması ve bu yöntemlerin bellek kapasitesiyle doğrudan bağlantılı olması nedeniyle, bellek üzerinden analiz yapılırken güçlü ve donanımlı bilgisayarlara ihtiyaç duyulmaktadır. Bu çalışmada otel yorumlarının PyCharm programı ile Python kodlarıyla çekilmesinde 12 GB DDR3 Ram, 2 GB paylaşımlı NVIDIA ekran kartı, 1 TB Harddisk donanım gücüne sahip dizüstü bilgisayar kullanılmıştır. Ancak kelime gömme teknikleri ve derin öğrenme analizleri esnasında bellek yetersizliği sonucunda Google Colab üzerinden A100 makinesi ile 50 GB Ram, 40 GB NVIDIA A100 Tensor Core ekran kartı, 235 GB SSD donanım gücüne sahip sanal bilgisayar kullanılmıştır.

Bu araştırmada, Etstur otel rezervasyon platformundaki müşterilerin otellere yönelik yorumlarının olumlu, olumsuz veya nötr olup olmadığını belirlemek için derin öğrenme yöntemlerinden faydalanılmıştır. Derin öğrenme yöntemlerini uygularken Python programlama dili kullanılarak PyCharm tümleşik geliştirme ortamı (IDE) ile kodlama yapılmıştır.

Bu çalışmada öncelikle Etstur sitesinde bulunan otellere yapılan yorumları ve bu yorumlara müşteriler tarafından yapılan puanlamalar PyCharm 'da Python programlama dili kullanılarak kodlama ile çekilmiştir. Yorumlar .xlsx dosyası halinde çekilerek analizde sorun teşkil edebilecek boş hücreler yani yorum ve metin içermeyen veriler temizlenmiştir. Temizlenen veriler puanlama aralıklarına göre olumlu, olumsuz ve nötr olacak şekilde etiketlenmiştir. Etiketlendirme işleminden sonra sadece yorum ve puanlama içeren tüm satır ve sütunlar .csv uzantılı başka bir dosyaya kaydedilmiştir. Bu dosya daha sonra yine Python kodlamaları ile kelime gömme işlemleri uygulanabilmesi için tokenleştirme ve ardından derin öğrenme yöntemlerini uygulayabilmek için padding işlemi uygulanmıştır. Bu işlemler

sonucunda temizlenmiş veri seti kodlama ile eğitim, doğrulama ve test olmak üzere 3'e bölünmüştür. Verilerin %70'i train(eğitim), %10'u Validation(doğrulama) ve %20'si test verisi olarak bölünmüştür. Veri bölümlenmesi işlemlerinden sonra kelime gömme tekniklerinden olan Word2Vec, Glove, Random, BERT, FastText yöntemleri tek tek uygulanıp ardından GRU,CNN-LSTM ve DENSE derin öğrenme modelleri uygulanarak analizler gerçekleştirilmiştir. Analiz sonuçlarında, makine öğrenimi ve derin öğrenme modellerinin performansını değerlendirmek için kayıp (loss) ve doğruluk (accuracy) değerleri sıklıkla kullanılmaktadır. Bu grafikler, modelin eğitim aşamasında belirtilen epoch (dönem) boyunca elde edilecek olan kayıp ve doğruluk değerlerinin değişimini görselleştirmek amacıyla oluşturulmaktadır. Kayıp grafiği, modelin her epoch'ta yaptığı hatanın (loss) azalma eğilimini gözlemlemeyi sağlamaktadır. Kayıp, modelin tahmin ettiği sonuçlar ile gerçek sonuçlar arasındaki farkı ölçen bir metrik olarak kullanılmaktadır. Bu grafikte eğitim, doğrulama ve test kayıpları ayrı ayrı gösterilmektedir. Doğruluk grafiği ise modelin her epoch boyunca doğru tahmin ettiği örneklerin oranını göstermektedir. Modelin başarısını, eğitimi boyunca öğrenme sürecinin etkinliğini ve genel performansını değerlendirmek için kullanılmaktadır. Bu grafiklerin amacı, modelin aşırı öğrenme ya da eksik öğrenme (underfitting) sorunlarını tespit etmek, eğitimin dengeli bir şekilde ilerleyip ilerlemediğini analiz etmek ve modelin performansını görselleştirerek kıyaslama yapmaktır.


3.1. Derin Öğrenme Yöntemlerinden Sonra Elde Edilen Sonuçlar

Bu araştırmada; Word2Vec, GloVe, Random, BERT, FastText kelime gömme teknikleri ile bu tekniklerden sonra derin öğrenme yöntemlerinden olan GRU, CNN-LSTM ve DENSE modelleri kullanılarak yapılan analizler sonucunda olumlu, olumsuz ve nötr ifadelerle yapılan yorumların tahmininin başarıları sonuçlandırılmıştır. Bu analizde kullanılan modelleri Random, GloVe, Word2vec, BERT, FastText teknikleri ayrı ayrı çalıştırılarak daha sonra derin öğrenme yöntemleri uygulanmıştır. Uygulanan derin öğrenme yönteminin öğrenme oranı(Learning rate) 0,001 değeri ile, embedding uzunluğu 300 değeri ile, çıkış katmanında ise softmax fonksiyonu kullanılarak yapılan analizlerden olan GRU model sonuçları Tablo 2'de gösterilmiştir.


Tablo 2. GRU Modelinin Sonuçları

Kelime Gömmesi	Doğruluk (Accuracy)	Geri Çağırma (Recall)	Kesinlik (Precision)	Kayıp (Loss)
Random	0,8322	0,8317	0,8327	1,1394
GloVe	0,8399	0,8315	0,8478	0,3882
Word2Vec	0,8274	0,8176	0,8365	0,4110
BERT	0,8226	0,8051	0,8377	0,4008
FastText	0,8432	0,8314	0,8530	0,3561

Tablo 2’de yer alan analiz sonuçları için Random, GloVe, Word2vec, BERT ve FastText kelime gömmelerinden sonra GRU modeli uygulanmış olup çıkan sonuç doğruluk, kesinlik, geri çağırma ve kayıp değerlerini içermektedir. Analizler incelendiğinde ilk sırada yer alan Random kelime gömmesi için doğruluk değeri %83,22; %83,99 geri çağırma, %83,17 kesinlik ve %113,94 kayıp değerlerine ulaşılmıştır. İkinci sırada yer alan Glove kelime gömmesi için doğruluk değeri %83,99; %83,15 geri çağırma, %84,78 kesinlik ve %38,82 kayıp değerlerine ulaşılmıştır. Üçüncü sırada yer alan Word2Vec kelime gömmesi için doğruluk değeri %82,74; %81,76 geri çağırma, %83,65 kesinlik ve %41,10 kayıp değerlerine ulaşılmıştır. Dördüncü sırada yer alan BERT kelime gömmesi için doğruluk değeri %82,26; %80,51 geri çağırma, %83,77 kesinlik ve %40,08 kayıp değerlerine ulaşılmıştır. Beşinci sırada yer alan FastText kelime gömmesi için doğruluk değeri %84,32; %83,14 geri çağırma, %85,30 kesinlik ve %35,61 kayıp değerlerine ulaşılmıştır. Bu analiz sonucundaki karşılaştırmada en yüksek değerlere FastText kelime gömmesinden sonra uygulanan GRU modeli olmuştur. Şekil 21 ve 22’de bu modelin en başarılı sonucunun loss ve accuracy grafikleri verilmiştir.



Şekil 21. FastText-GRU Modeli Loss Grafiği



Şekil 22. FastText-GRU Modeli Accuracy Grafiği

Şekil 21'de, modelin eğitim kaybı (Train Loss), doğrulama kaybı (Validation Loss) ve test kaybı (Test Loss) değerlerinin epoch boyunca azalma eğilimi gözlemlenmektedir. Aşağıdaki yorumlar yapılabilir:

Eğitim Kayıp Değeri: Modelin her epoch'ta eğitim verileri üzerindeki hatasını göstermektedir. Grafikte eğitim kaybının hızlı bir şekilde azaldığı ve daha sonra belirli bir noktada sabit kaldığı görülmektedir. Bu durum, modelin eğitim verilerindeki örüntüleri başarıyla öğrenmiş olduğunu göstermektedir.

Doğrulama ve Test Kayıp Değerleri: Doğrulama ve test kaybı, modelin eğitim sırasında görmediği veriler üzerindeki performansın ölçülmesi için kullanılmaktadır. Grafikte doğrulama ve test kaybı değerlerinin eğitim kaybına paralel şekilde azaldığı görülmektedir. Ancak epoch sayısı arttıkça test ve doğrulama kayıplarının belirli bir noktada sabitlenip küçük dalgalanmalar gösterdiği dikkat çekmektedir. Bu durum, modelin genel performansında dengenin sağlandığını göstermektedir.

Overfitting veya Underfitting Durumu: Eğitim kaybı ile doğrulama/test kaybı arasında büyük bir fark bulunmamaktadır. Bu durum, modelin ne aşırı öğrenme ne de eksik öğrenme (underfitting) yapmadığını, iyi bir genel performans sergilediğini ifade etmektedir.

Şekil 22'de, modelin eğitim, doğrulama ve test doğruluk değerlerinin epoch boyunca artış eğilimi gözlemlenmektedir. Aşağıdaki yorumlar yapılabilir:

Eğitim Doğruluk Değeri: Modelin eğitim verileri üzerindeki doğruluğu her epoch'ta artarak 0,86 seviyelerine ulaşmıştır. Bu durum, modelin eğitim verilerinde yer alan bilgiyi etkili bir şekilde öğrenebildiğini göstermektedir.

Doğrulama ve Test Doğruluk Değerleri: Doğrulama ve test doğruluk değerlerinin eğitim doğruluğuna yakın bir eğilim sergilediği ve benzer seviyelere ulaştığı görülmektedir. Bu, modelin genelleme yeteneğinin güçlü olduğunu, yani yalnızca eğitim verileri üzerinde değil, görmediği veriler üzerinde de iyi bir performans sergilediğini göstermektedir.

Stabilizasyon ve Performans Düzeyi: Epoch sayısı arttıkça doğruluk değerleri sabitlenmiş ve küçük dalgalanmalar göstermiştir. Bu, modelin belirli bir noktada öğrenme sürecini tamamlayarak stabil bir performans seviyesine ulaştığını ifade etmektedir.

Sonuç Değerlendirmesi: Modelin hem doğruluk hem de kayıp grafiklerine bakıldığında, eğitim, doğrulama ve test verileri arasında tutarlı bir performans sergilendiği görülmektedir. Bu durum, modelin öğrenme sürecinin etkili bir şekilde gerçekleştirildiğini ve genelleme kabiliyetinin yeterli olduğunu ortaya koymaktadır.


CNN ve LSTM derin öğrenme modelleri için sırasıyla Random, GloVe, Word2Vec, BERT ve FastText kelime gömme teknikleri kullanılmıştır. Daha sonra, evrişim katmanında 3 ve 4 filtre boyutu, dropout katmanında 0.1 ve 0.2 değerleri, havuzlama katmanında ise 1, 2 ve 4 değerleri denenmiş ve elde edilen doğruluk, geri çağırma, kesinlik ve kayıp değerleri tabloya yansıtılmıştır. Aşağıda yer alan Tablo 3, 4, 5, 6 ve 7’de ortaya çıkan bu sonuçlar, tablodaki tüm kelime gömmeleri için CNN parametrelerinden olan filtre, dropout ve pool size değerleri ve üç farklı değerler ile elde edilen doğruluk, geri çağırma, kesinlik ve kayıp değerleri gösterilmektedir. Şekil 23 ve 24’te bu modelin en başarılı sonucunun loss ve accuracy grafikleri verilmiştir.

Tablo 3. Random Kelime Gömmesi CNN-LSTM Model Sonucu


CNN-LSTM Parametreleri						
Filtre Boyutu	Dropout	Pool size	Doğruluk (Accuracy)	Geri Çağırma (Recall)	Kesinlik (Precision)	Kayıp (Loss)
3	0,2	1	0,8412	0,8408	0,8419	1,3418
3	0,2	4	0,8442	0,8437	0,8449	1,2981
4	0,1	2	0,8439	0,8431	0,8447	1,2574

Tablo 3’te yer alan analiz sonuçları için Random kelime gömmesinden sonra CNN-LSTM modeli uygulanmış olup çıkan sonuçlarda doğruluk, kesinlik, geri çağırma ve kayıp değerleri yer almaktadır. Analizler incelendiğinde ilk sırada yer alan Random kelime gömmesi için

filtre boyutu 3, dropout 0,2; pool size 1 değerleri ile yapılan analizde doğruluk değeri %84,12; %84,08 geri çağırma, %84,19 kesinlik ve %134,18 kayıp değerlerine ulaşılmıştır. İkinci sırada yer alan Random kelime gömmesi için filtre boyutu 3, dropout 0,2; pool size 4 değerleri ile yapılan analizde doğruluk değeri %84,42; %84,37 geri çağırma, %84,49 kesinlik ve %129,81 kayıp değerlerine ulaşılmıştır. Üçüncü sırada yer alan Random kelime gömmesi için filtre boyutu 4, dropout 0,1; pool size 2 değerleri ile yapılan analizde doğruluk değeri %84,39; %84,31 geri çağırma, %84,47 kesinlik ve %125,74 kayıp değerlerine ulaşılmıştır. Bu analiz sonucundaki karşılaştırmada en yüksek değerlere Random kelime gömmesinin tabloda yer alan ikinci sıradaki filtre boyutu 3, dropout 0,2 ve pool size 4 olan değerler ile elde edildiği görülmektedir.



Şekil 23. Random CNN-LSTM Modeli Loss Grafiği



Şekil 24. Random CNN-LSTM Modeli Accuracy Grafiği

Şekil 23'te, modelin eğitim kaybı (Train Loss), doğrulama kaybı (Validation Loss) ve test kaybı (Test Loss) değerlerinin epoch boyunca farklı eğilimler sergilediği gözlemlenmektedir. Aşağıdaki yorumlar yapılabilir:

Eğitim Kayıp Değeri: Modelin her epoch'ta eğitim verileri üzerindeki hatasını göstermektedir. Grafikte eğitim kaybının hızlı bir şekilde azaldığı ve yaklaşık 10. epoch'tan itibaren neredeyse sıfır seviyesine ulaştığı görülmektedir. Bu durum, modelin eğitim verilerindeki örüntüleri başarıyla öğrenmiş olduğunu göstermektedir. Ancak eğitim kaybının sıfıra yakın olması, modelin eğitim verisi üzerinde aşırı öğrenme riski taşıdığını da ifade edebilir.

Doğrulama ve Test Kayıp Değerleri: Doğrulama ve test kayıpları, modelin eğitim sırasında görmediği veriler üzerindeki performansını değerlendirmek için kullanılmaktadır. Grafikte

doğrulama ve test kaybı değerlerinin, eğitim kaybına kıyasla artış eğilimi gösterdiği görülmektedir. Özellikle epoch sayısı arttıkça doğrulama ve test kayıplarının düzenli olarak yükseldiği ve dalgalanmalar sergilediği dikkat çekmektedir. Bu durum, modelin eğitim verisi dışındaki verilere genelleme yapmakta zorlandığını ve aşırı öğrenme probleminin ortaya çıktığını göstermektedir.

Overfitting veya Underfitting Durumu: Eğitim kaybının sıfıra yaklaşmasına rağmen doğrulama ve test kayıplarının artış göstermesi, modelin aşırı öğrenme yaptığına işaret etmektedir. Bu, modelin yalnızca eğitim verilerine odaklandığını, fakat doğrulama ve test verilerindeki örüntüleri yeterince öğrenemediğini ifade etmektedir.

Şekil 24'te, modelin eğitim, doğrulama ve test doğruluk değerlerinin epoch boyunca farklı eğilimler sergilediği gözlemlenmektedir. Aşağıdaki yorumlar yapılabilir:

Eğitim Doğruluk Değeri: Modelin eğitim verileri üzerindeki doğruluğu her epoch'ta hızla artarak yaklaşık %100 seviyesine ulaşmıştır. Bu durum, modelin eğitim verisinde bulunan bilgiyi neredeyse hatasız bir şekilde öğrendiğini göstermektedir. Ancak bu doğruluk seviyesi, eğitim verisinin ezberlenmiş olabileceğini (overfitting) işaret etmektedir.

Doğrulama ve Test Doğruluk Değerleri: Doğrulama ve test doğruluk değerlerinin eğitim doğruluğuna kıyasla oldukça düşük kaldığı ve yaklaşık %82-%85 aralığında sabitlendiği gözlemlenmektedir. Epoch sayısındaki artışa rağmen bu doğruluk değerlerinde önemli bir iyileşme olmamıştır. Bu durum, modelin genelleme yeteneğinin sınırlı olduğunu ve eğitim verisi dışında yeterli performans gösteremediğini ifade etmektedir.


Stabilizasyon ve Performans Düzeyi: Epoch sayısı arttıkça doğrulama ve test doğruluk değerleri sabitlenmiş ve küçük dalgalanmalar göstermiştir. Ancak bu değerlerin eğitim doğruluğuna kıyasla çok düşük kalması, modelin genelleme kapasitesinin yetersiz olduğunu ortaya koymaktadır. Bu nedenle, modelin hem veri işleme hem de mimari düzeyinde iyileştirilmesi gerektiği söylenebilir.

Sonuç Değerlendirmesi: Modelin loss ve accuracy grafiklerine birlikte bakıldığında, eğitim doğruluğunun aşırı yüksek ve doğrulama/test doğruluğunun düşük olması, modelin aşırı öğrenme problemi yaşadığını açıkça göstermektedir. Bu durum, modelin yalnızca eğitim verisi üzerinde başarılı olduğunu, ancak eğitim sırasında görmediği verilere genelleme yapamadığını ortaya koymaktadır.


Tablo 4. GloVe Kelime Gömme Tekniđi CNN-LSTM Model Sonucu

CNN-LSTM Parametreleri						
Filtre Boyutu	Dropout	Pool size	Doğruluk (Accuracy)	Geri Çağırma (Recall)	Kesinlik (Precision)	Kayıp (Loss)
3	0,2	1	0,8594	0,8574	0,8620	0,5610
3	0,2	4	0,8572	0,8548	0,8594	0,5797
4	0,1	2	0,8555	0,8542	0,8571	0,7446

Tablo 4’te yer alan analiz sonuçları için GloVe kelime gömmesinden sonra CNN-LSTM modeli uygulanmış olup çıkan sonuçlarda doğruluk, kesinlik, geri çağırma ve kayıp değerleri yer almaktadır. Analizler incelendiğinde ilk sırada yer alan GloVe kelime gömmesi için filtre boyutu 3, dropout 0,2; pool size 1 değerleri ile yapılan analizde doğruluk değeri %85,94; %85,74 geri çağırma, %86,20 kesinlik ve %56,10 kayıp değerlerine ulaşılmıştır. İkinci sırada yer alan GloVe kelime gömmesi için filtre boyutu 3, dropout 0,2; pool size 4 değerleri ile yapılan analizde doğruluk değeri %85,72; %85,48 geri çağırma, %85,94 kesinlik ve %57,97 kayıp değerlerine ulaşılmıştır. Üçüncü sırada yer alan GloVe kelime gömmesi için filtre boyutu 4, dropout 0,1; pool size 2 değerleri ile yapılan analizde doğruluk değeri %85,55; %85,42 geri çağırma, %85,71 kesinlik ve %74,46 kayıp değerlerine ulaşılmıştır. Bu analiz sonucundaki karşılaştırmada en yüksek değerlere GloVe kelime gömmesinin tabloda yer alan birinci sıradaki filtre boyutu 3, dropout 0,2 ve pool size 1 olan değerler ile elde edildiđi görölmektedir. Şekil 25 ve 26’da bu modelin en başarılı sonucunun loss ve accuracy grafikleri verilmiştir.



Şekil 25. GloVe CNN-LSTM Modeli Loss Grafiği



Şekil 26. GloVe CNN-LSTM Modeli Accuracy Grafiği

Şekil 25'te, modelin eğitim kaybı (Train Loss), doğrulama kaybı (Validation Loss) ve test kaybı (Test Loss) değerlerinin epoch boyunca nasıl değiştiği gözlemlenmektedir. Aşağıdaki yorumlar yapılabilir:

Eğitim Kayıp Değeri: Modelin her epoch'ta eğitim verileri üzerindeki hatasını göstermektedir. Grafikte eğitim kaybının hızlı bir şekilde azaldığı ve ilerleyen epoch'larda daha yavaş bir azalma eğilimi gösterdiği görülmektedir. Bu durum, modelin eğitim verilerindeki örüntüleri başarılı bir şekilde öğrendiğini ve hata oranını minimize ettiğini göstermektedir.

Doğrulama ve Test Kayıp Değerleri: Doğrulama ve test kayıpları, modelin eğitim sırasında görmediği verilerin performansının ölçülmesi için kullanılmaktadır. Grafikte doğrulama ve test kayıplarının başlangıçta eğitim kaybına benzer bir şekilde azaldığı ancak belirli bir epoch sonrasında artış eğilimi gösterdiği dikkat çekmektedir. Bu durum, modelin başlarda genelleme kapasitesinin iyi olduğunu ancak epoch sayısı arttıkça aşırı öğrenme probleminin ortaya çıkabileceğini düşündürmektedir.

Overfitting veya Underfitting Durumu: Eğitim kaybı ile doğrulama/test kayıpları arasındaki fark epoch sayısı arttıkça belirginleşmektedir. Eğitim kaybı sürekli azalırken, doğrulama ve test kayıplarının artış göstermesi, modelin aşırı öğrenme yaptığını ve yeni veriler üzerindeki başarısının azalmaya başladığını göstermektedir.

Şekil 26'da modelin eğitim, doğrulama ve test doğruluk değerlerinin epoch boyunca nasıl değiştiği gözlemlenmektedir. Aşağıdaki yorumlar yapılabilir:

Eğitim Doğruluk Değeri: Modelin eğitim verileri üzerindeki doğruluğu her epoch'ta artarak

yaklaşık %96 seviyelerine ulaşmıştır. Bu durum, modelin eğitim verilerindeki bilgiyi etkili bir şekilde öğrendiğini ve eğitim verileri üzerinde yüksek bir başarı elde ettiğini göstermektedir.

Doğrulama ve Test Doğruluk Değerleri: Doğrulama ve test doğruluk değerlerinin başlangıçta eğitim doğruluğu ile paralel olarak arttığı ancak belirli bir epoch sonrasında sabitlenip dalgalanmalar gösterdiği gözlemlenmektedir. Bu durum, modelin erken epoch'larda hem eğitim hem de test verileri için başarılı bir performans sergilediğini ancak epoch sayısı arttıkça öğrenme sürecinin doyuma ulaştığını göstermektedir. Ayrıca doğrulama ve test doğruluğu değerleri eğitim doğruluğunun oldukça altında kalmaktadır, bu da aşırı öğrenmenin etkisini destekleyen bir bulgudur.


Stabilizasyon ve Performans Düzeyi: Epoch sayısı arttıkça doğruluk değerleri belirli bir seviyede sabitlenmiştir. Ancak eğitim doğruluğunun sürekli artmaya devam etmesi, modelin eğitim verilerine fazla odaklandığını ve doğrulama/test verilerinde aynı oranda başarı gösteremediğini düşündürmektedir.

Tablo 5. Word2Vec Kelime Gömmesi CNN-LSTM Modeli


CNN-LSTM Parametreleri						
Filtre Boyutu	Dropout	Pool size	Doğruluk (Accuracy)	Geri Çağırma (Recall)	Kesinlik (Precision)	Kayıp (Loss)
3	0,2	1	0,8467	0,8422	0,8512	0,4724
3	0,2	4	0,8451	0,8408	0,8502	0,4933
4	0,1	2	0,8414	0,8389	0,8452	0,6391

Tablo 5'te yer alan analiz sonuçları için Word2Vec kelime gömmesinden sonra CNN-LSTM modeli uygulanmış olup çıkan sonuçlar doğruluk, kesinlik, geri çağırma ve kayıp değerlerini içermektedir. Analizler incelendiğinde ilk sırada yer alan Word2Vec kelime gömmesi için filtre boyutu 3, dropout 0,2; pool size 1 değerleri ile yapılan analizde doğruluk değeri %84,67; %84,22 geri çağırma, %85,12 kesinlik ve %47,24 kayıp değerlerine ulaşılmıştır. İkinci sırada yer alan Word2Vec kelime gömmesi için filtre boyutu 3, dropout 0,2; pool size 4 değerleri ile yapılan analizde doğruluk değeri %84,51; %84,08 geri çağırma, %85,02 kesinlik ve %49,33 kayıp değerlerine ulaşılmıştır. Üçüncü sırada yer alan Word2Vec kelime gömmesi için filtre boyutu 4, dropout 0,1; pool size 2 değerleri ile yapılan analizde doğruluk

değeri %84,14; %83,89 geri çağırma, %84,52 kesinlik ve %63,91 kayıp değerlerine ulaşılmıştır. Bu analiz sonucundaki karşılaştırmada en yüksek değerlere Word2Vec kelime gömmesinin tabloda yer alan birinci sıradaki filtre boyutunu 3, pool size 1 ve dropout 0,2 olan değerler ile elde edildiği görülmektedir. Şekil 27 ve 28’de bu modelin en başarılı sonucunun loss ve accuracy grafikleri verilmiştir.



Şekil 27. Word2Vec CNN-LSTM Modeli Loss Grafiği



Şekil 28. Word2Vec CNN-LSTM Modeli Accuracy Grafiği

Şekil 27’de modelin eğitim kaybı (Train Loss), doğrulama kaybı (Validation Loss) ve test kaybı (Test Loss) değerlerinin epoch boyunca nasıl değiştiği gözlemlenmektedir. Aşağıdaki yorumlar yapılabilir:

Eğitim Kayıp Değeri: Eğitim kaybı, modelin eğitim verileri üzerindeki hata oranını göstermektedir. Grafikte, eğitim kaybının hızla azaldığı ve epoch ilerledikçe düşüş eğilimini sürdürdüğü görülmektedir. Bu durum, modelin eğitim verileri üzerinde daha iyi bir performans sergilediğini ve eğitim sürecinin başarılı bir şekilde ilerlediğini göstermektedir.

Doğrulama ve Test Kayıp Değerleri: Doğrulama ve test kayıpları, modelin eğitim sırasında görmediği verilerin performansının ölçülmesi için kullanılmaktadır. Başlangıçta eğitim kaybına benzer bir azalma eğilimi gözlemlenmekte, ancak epoch sayısı arttıkça doğrulama ve test kaybı değerlerinin dalgalanmalar gösterdiği ve belirli bir noktadan sonra artış eğilimine girdiği görülmektedir. Bu durum, modelin erken epoch'larda genelleme açısından iyi performans gösterdiğini ancak ilerleyen epoch'larda aşırı öğrenme problemine maruz kaldığını düşündürmektedir.

Overfitting veya Underfitting Durumu: Eğitim kaybının sürekli olarak azalmasına karşın doğrulama ve test kayıplarının artış göstermesi, modelin eğitim verilerine aşırı uyum

sağladığını ve yeni veriler üzerindeki başarısının azaldığını göstermektedir. Bu, aşırı öğrenme probleminin varlığını işaret etmektedir. Modelin genelleme yeteneğini artırmak için erken durdurma (early stopping), düzenlileştirme (regularization) veya veri artırma (data augmentation) gibi stratejilerin uygulanması faydalı olabilir.

Şekil 28’de modelin eğitim, doğrulama ve test doğruluk değerlerinin epoch boyunca nasıl değiştiği gözlemlenmektedir. Aşağıdaki yorumlar yapılabilir:

Eğitim Doğruluk Değeri: Modelin eğitim doğruluğu her epoch'ta artış göstermekte ve yaklaşık %94 seviyelerine ulaşmaktadır. Bu durum, modelin eğitim verileri üzerindeki örüntüleri etkin bir şekilde öğrendiğini ve eğitim sürecinin başarılı ilerlediğini göstermektedir.

Doğrulama ve Test Doğruluk Değerleri: Doğrulama ve test doğruluk değerleri başlangıçta eğitim doğruluğuyla paralel şekilde artış göstermekte, ancak belirli bir epoch sonrasında sabitlenerek küçük dalgalanmalar sergilemektedir. Bu durum, modelin erken epoch’larda hem eğitim hem de doğrulama/test verileri üzerinde iyi bir performans sergilediğini, ancak belirli bir noktadan sonra öğrenme sürecinin doyuma ulaştığını göstermektedir. Ayrıca, doğrulama ve test doğruluklarının eğitim doğruluğunun oldukça altında kalması, aşırı öğrenmenin varlığını destekleyen bir göstergedir.


Stabilizasyon ve Performans Düzeyi: Epoch sayısı arttıkça doğruluk değerleri belirli bir seviyede sabitlenmiştir. Eğitim doğruluğunun sürekli artmasına karşın doğrulama ve test doğruluklarının bu seviyeye ulaşamaması, modelin eğitim verilerine fazla odaklandığını ve genelleme performansının yeterince güçlü olmadığını düşündürmektedir.

Tablo 6. BERT Kelime Gömmesi CNN-LSTM Modeli


CNN-LSTM Parametreleri						
Filtre Boyutu	Dropout	Pool size	Doğruluk (Accuracy)	Geri Çağırma (Recall)	Kesinlik (Precision)	Kayıp (Loss)
3	0,2	1	0,8249	0,8091	0,8377	0,4011
3	0,2	4	0,8221	0,8026	0,8367	0,3986
4	0,1	2	0,8241	0,8076	0,8388	0,4112

Tablo 6’da yer alan analiz sonuçları için BERT kelime gömmesinden sonra CNN-LSTM modeli uygulanmış olup çıkan sonuçlarda doğruluk, kesinlik, geri çağırma(recall) ve kayıp

değerleri yer almaktadır. Analizler incelendiğinde ilk sırada yer alan BERT kelime gömmesi için filtre boyutu 3, dropout 0,2; pool size 1 değerleri ile yapılan analizde doğruluk değeri %82,49; %80,91 geri çağırma, %83,77 kesinlik ve %40,11 kayıp değerlerine ulaşılmıştır. İkinci sırada yer alan BERT kelime gömmesi için filtre boyutu 3, dropout 0,2; pool size 4 değerleri ile yapılan analizde doğruluk değeri %82,21; %80,26 geri çağırma, %83,67 kesinlik ve %39,86 kayıp değerlerine ulaşılmıştır. Üçüncü sırada yer alan BERT kelime gömmesi için filtre boyutu 4, dropout 0,1; pool size 2 değerleri ile yapılan analizde doğruluk değeri %82,41; %80,76 geri çağırma, %83,88 kesinlik ve %41,12 kayıp değerlerine ulaşılmıştır. Bu analiz sonucundaki karşılaştırmada en yüksek değerlere BERT kelime gömmesinin tabloda yer alan birinci sıradaki filtre boyutunu 3, pool size 1 ve dropout 0,2 olan değerler ile elde edildiği görülmektedir. Şekil 29 ve 30'da bu modelin en başarılı sonucunun loss ve accuracy grafikleri verilmiştir.



Şekil 29. Bert CNN-LSTM Modeli Loss Grafiği



Şekil 30. Bert CNN-LSTM Modeli Accuracy Grafiği

Şekil 29'da modelin eğitim kaybı (Train Loss), doğrulama kaybı (Validation Loss) ve test kaybı (Test Loss) değerlerinin epoch boyunca nasıl değiştiği gözlemlenmektedir.

Eğitim Kayıp Değeri: Modelin eğitim kaybı başta hızlı bir şekilde düşmekte, ardından daha yavaş bir şekilde azalmaya devam etmektedir. 50 epoch sonunda eğitim kaybı yaklaşık 0,265 seviyelerine ulaşmış ve stabil hale gelmiştir. Bu durum, modelin eğitim verilerindeki örüntüleri iyi öğrendiğini ve kaybın minimize edildiğini göstermektedir.

Doğrulama ve Test Kayıp Değerleri: Doğrulama kaybı belirli bir seviyede dalgalanmalar gösterirken, test kaybı genellikle daha düşük seviyede seyretmektedir. 30. epoch'tan sonra doğrulama kaybındaki artış ve dalgalanmalar dikkat çekicidir. Özellikle 40. epoch

sonrasında keskin artışlar gözlemlenmektedir. Test kaybı, doğrulama kaybına göre daha düşük seviyede ilerlese de dalgalanmalar göstermektedir. Bu durum, modelin aşırı öğrenmeye (overfitting) başladığını ve doğrulama performansında istikrarsızlık yaşadığını göstermektedir.

Overfitting veya Underfitting Durumu: Eğitim kaybı sürekli azalırken, doğrulama ve test kayıplarındaki dalgalanmalar dikkat çekicidir. Özellikle doğrulama kaybının eğitim kaybına göre belirgin şekilde yüksek olması ve belirli epoch'lardan sonra artış göstermesi, modelin eğitim verilerine fazla uyum sağladığını ve genelleme yeteneğinin azaldığını düşündürmektedir. Şekil 30'da modelin eğitim, doğrulama ve test doğruluk değerlerinin epoch boyunca nasıl değiştiği görülmektedir.

Eğitim Doğruluk Değeri: Modelin eğitim doğruluğu düzenli bir şekilde artarak %89,5 seviyelerine ulaşmıştır. Eğitimin başında hızlı bir yükselme gerçekleşmiş, daha sonra artış hızı azalarak sabitlenmiştir. Bu, modelin eğitim verileri üzerindeki öğrenme sürecini başarılı bir şekilde tamamladığını göstermektedir.


Doğrulama ve Test Doğruluk Değerleri: Doğrulama doğruluğu %88 civarında bir seviyeye ulaşmış ancak belirli epoch'lardan sonra dalgalanmalar görülmektedir. Test doğruluğu da benzer şekilde %88,5 civarında ilerlemekte, ancak doğrulama doğruluğuna kıyasla daha stabil bir görünüm sergilemektedir. Doğrulama doğruluğundaki belirgin dalgalanmalar, modelin genelleme yeteneğinin tam olarak stabil hale gelmediğini göstermektedir.

Stabilizasyon ve Performans Düzeyi: Eğitim doğruluğu sürekli artarken, doğrulama ve test doğruluk değerleri belirli bir seviyeye ulaştıktan sonra değişkenlik göstermektedir. Doğrulama doğruluğundaki ani düşüşler, modelin belirli epoch'larda doğrulama verileri üzerinde tutarlı bir performans sergileyemediğini göstermektedir. Model, eğitim verilerinde çok iyi bir performans gösterirken, doğrulama ve test setlerinde belirli epoch'larda sapmalar olması aşırı öğrenmeye işaret etmektedir.


Tablo 7. FastText Kelime Gömmesi CNN-LSTM Modeli

CNN-LSTM Parametreleri						
Filtre Boyutu	Dropout	Pool size	Doğruluk (Accuracy)	Geri Çağırma(Recall)	Kesinlik (Precision)	Kayıp (Loss)
3	0,2	1	0,8590	0,8559	0,8624	0,4518
3	0,2	4	0,8540	0,8503	0,8572	0,5012
4	0,1	2	0,8537	0,8517	0,8561	0,6601

Tablo 7’de yer alan analiz sonuçları için FastText kelime gömmesinden sonra CNN-LSTM modeli uygulanmış olup çıkan sonuçlar doğruluk, kesinlik, geri çağırma(recall) ve kayıp değerlerini içermektedir. Analizler incelendiğinde ilk sırada yer alan FastText kelime gömmesi için filtre boyutu 3, dropout 0,2; pool size 1 değerleri ile yapılan analizde doğruluk değeri %85,90; %85,59 geri çağırma, %86,24 kesinlik ve %45,18 kayıp değerlerine ulaşılmıştır. İkinci sırada yer alan FastText kelime gömmesi için filtre boyutu 3, dropout 0,2; pool size 4 değerleri ile yapılan analizde doğruluk değeri %85,40; %85,03 geri çağırma, %85,72 kesinlik ve %50,12 kayıp değerlerine ulaşılmıştır. Üçüncü sırada yer alan FastText kelime gömmesi için filtre boyutu 4, dropout 0,1; pool size 2 değerleri ile yapılan analizde doğruluk değeri %85,37; %85,17 geri çağırma, %85,61 kesinlik ve %66,01 kayıp değerlerine ulaşılmıştır. Bu analiz sonucundaki karşılaştırmada en yüksek değerlere FastText kelime gömmesinin tabloda yer alan birinci sıradaki filtre boyutunu 3, pool size 1 ve dropout 0,2 olan değerler ile elde edildiği görülmektedir. Şekil 31 ve 32’de bu modelin en başarılı sonucunun loss ve accuracy grafikleri verilmiştir.



Şekil 31. FastText CNN-LSTM Modeli Loss Grafiği



Şekil 32. FastText CNN-LSTM Modeli Accuracy Grafiği

Şekil 31’de modelin eğitim (Train Loss), doğrulama (Validation Loss) ve test (Test Loss) kayıp değerlerinin epoch sayısına bağlı olarak nasıl değiştiği gözlemlenmektedir.

Eğitim Kaybı (Train Loss): Modelin eğitim kaybı başlangıçta yüksek bir değere sahipken, epoch ilerledikçe düzenli bir şekilde azalmaktadır. Bu durum, modelin eğitim verisindeki örüntüleri öğrendiğini ve giderek daha düşük hata ile tahminler yaptığını göstermektedir.

Doğrulama ve Test Kaybı (Validation and Test Loss): Doğrulama ve test kayıplarının başlangıçta eğitim kaybına paralel olarak düştüğü, ancak belirli bir noktadan sonra dalgalanmaya başladığı ve hatta artış gösterdiği görülmektedir. Özellikle 20. epoch sonrası doğrulama ve test kaybında belirgin bir yükseliş eğilimi vardır. Bu, modelin eğitim verisine fazla uyum sağlayarak aşırı öğrenme eğiliminde olduğunu göstermektedir. Model eğitim verisini iyi öğrenirken, doğrulama ve test setlerinde daha yüksek kayıplar vermektedir.

Genel Değerlendirme: Modelin başlangıçta başarılı bir şekilde öğrenme gerçekleştirdiği, ancak belirli bir epoch sonrasında genelleme performansının düşmeye başladığı söylenebilir.

Şekil 32’de modelin eğitim, doğrulama ve test doğruluk değerlerinin epoch boyunca nasıl değiştiği gözlemlenmektedir.

Eğitim Doğruluğu (Train Accuracy): Modelin eğitim doğruluğu her epoch ile birlikte düzenli olarak artmakta ve 50. epoch sonunda %94 seviyelerine ulaşmaktadır. Bu, modelin eğitim verisini oldukça iyi öğrendiğini ve eğitim verisinde yüksek başarı sağladığını göstermektedir.

Doğrulama ve Test Doğruluğu (Validation and Test Accuracy): Doğrulama ve test doğruluk

değerleri başlarda artış gösterse de belirli bir noktadan sonra dalgalanarak sabit bir seviyede kalmıştır. Eğitim doğruluğu ile doğrulama/test doğruluğu arasındaki fark giderek açılmıştır. Modelin doğrulama ve test doğruluğu %85 civarında kalırken, eğitim doğruluğunun çok daha yüksek seviyelere çıkması, modelin aşırı öğrenme yaptığına dair güçlü bir gösterge olabilir.


Genel Değerlendirme: Model eğitim verisinde yüksek doğruluğa ulaşırken, doğrulama ve test setlerinde belirli bir seviyede kalmaktadır. Eğitim doğruluğunun çok yüksek olup, doğrulama/test doğruluğunun aynı ölçüde artmaması, modelin genelleme performansında sıkıntılar olduğunu ve overfitting etkisi görüldüğünü düşündürmektedir.

Tablo 8. Dense Modeli sonuçları


Kelime Gömmesi	Doğruluk (Accuracy)	Geri Çağırma (Recall)	Kesinlik (Precision)	Kayıp (Loss)
Random	0,8119	0,8089	0,8151	2,7478
GloVe	0,8275	0,8263	0,8290	1,2802
Word2Vec	0,8018	0,7976	0,8066	1,2236
BERT	0,8096	0,7858	0,8293	0,4340
FastText	0,8202	0,8180	0,8220	1,2872

Tablo 8’de yer alan analiz sonuçları için Random, GloVe, Word2vec, BERT ve FastText kelime gömmelerinden sonra DENSE modeli uygulanmış olup çıkan sonuçlar doğruluk, kesinlik, geri çağırma ve kayıp değerlerini içermektedir. Analizler incelendiğinde ilk sırada yer alan Random kelime gömmesi için doğruluk değeri %81,19; %80,89 geri çağırma, %81,51 kesinlik ve %274,78 kayıp değerlerine ulaşılmıştır. İkinci sırada yer alan Glove kelime gömmesi için doğruluk değeri %82,75; %82,63 geri çağırma, %82,90 kesinlik ve %128,02 kayıp değerlerine ulaşılmıştır. Üçüncü sırada yer alan Word2Vec kelime gömmesi için doğruluk değeri %80,18; %79,76 geri çağırma, %80,66 kesinlik ve %122,36 kayıp değerlerine ulaşılmıştır. Dördüncü sırada yer alan BERT kelime gömmesi için doğruluk değeri %80,96; %78,58 geri çağırma, %82,93 kesinlik ve %43,40 kayıp değerlerine ulaşılmıştır. Beşinci sırada yer alan FastText kelime gömmesi için doğruluk değeri %82,02; %81,80 geri çağırma, %82,20 kesinlik ve %128,72 kayıp değerlerine ulaşılmıştır. Bu analiz sonucundaki karşılaştırmada en yüksek değerlere GloVe kelime gömmesinden sonra

uygulan DENSE modeli olmuştur. Şekil 33 ve 34'te bu modelin en başarılı sonucunun loss ve accuracy grafikleri verilmiştir.



Şekil 33. Dense CNN-LSTM Modeli Loss Grafiği



Şekil 34. Dense CNN-LSTM Modeli Accuracy Grafiği

Şekil 33'te modelin eğitim kaybı (Train Loss), doğrulama kaybı (Validation Loss) ve test kaybı (Test Loss) değerlerinin epoch'lar boyunca nasıl değiştiği gözlemlenmektedir.

Eğitim Kayıp Değeri: Modelin eğitim verileri üzerindeki hata oranını göstermektedir. Eğitim kaybının hızla düştüğü ve 10. epoch civarında oldukça düşük değerlere ulaştığı görülmektedir. Bu durum, modelin eğitim verilerindeki örüntüleri hızla öğrendiğini göstermektedir. 10. epoch'tan sonra eğitim kaybı neredeyse sıfıra yaklaşmıştır.

Doğrulama ve Test Kayıp Değerleri: Modelin görmediği verilere karşı nasıl bir performans sergilediğini anlamak için incelenir. Başlangıçta eğitim kaybına paralel bir azalma gösterse de 10. epoch'tan sonra doğrulama ve test kaybı değerlerinin artış eğiliminde olduğu dikkat çekmektedir. Özellikle 20. epoch'tan itibaren doğrulama ve test kaybında belirgin bir artış gözlemlenmektedir. Bu, modelin eğitim verilerine fazla uyum sağladığını (overfitting) ve yeni verilere karşı genelleme yeteneğini kaybetmeye başladığını göstermektedir.

Overfitting Durumu: Eğitim kaybının sürekli azalırken doğrulama ve test kaybının belirgin bir şekilde arttığı göz önüne alındığında, modelin aşırı öğrenme yaptığı söylenebilir. Model, eğitim verilerini çok iyi öğrenmiş ancak doğrulama ve test verilerinde başarısı düşmüştür. Bu, modelin eğitim setine fazla ezberci yaklaştığını gösterir.

Şekil 34'te modelin eğitim doğruluğu (Train Accuracy), doğrulama doğruluğu (Validation Accuracy) ve test doğruluğu (Test Accuracy) epoch'lar boyunca gözlemlenmektedir.

Eğitim Doğruluk Değeri: Eğitim doğruluk oranı oldukça hızlı bir artış göstermekte ve 10.

epoch civarında neredeyse %100 seviyelerine ulaşmaktadır. Bu, modelin eğitim verisini neredeyse hatasız öğrendiğini göstermektedir.

Doğrulama ve Test Doğruluk Değerleri: Doğrulama ve test doğruluk oranları başlangıçta artış göstermekte ancak belirli bir seviyede sabitlenmektedir. Modelin eğitim doğruluğuna kıyasla doğrulama ve test doğruluk oranları çok daha düşük kalmaktadır. Bu durum, modelin eğitim verisine aşırı uyum sağladığını ancak yeni verilerde performansının sınırlı kaldığını göstermektedir.

Genelleme Yeteneği ve Performans Değerlendirmesi: Modelin eğitim doğruluğunun çok yüksek olması, ancak doğrulama ve test doğruluğunun belirli bir noktadan sonra artmaması genelleme problemi yaşandığını göstermektedir. Eğitim doğruluğunun %100'e yaklaşması, modelin ezberleme yaptığını ve overfitting sorununun bulunduğunu düşündürmektedir.

Tablo 9. Derin Öğrenme Modellerinin Analiz Sonuçları

	Doğruluk (Accuracy)	Geri Çağırma(Recall)	Kesinlik (Precision)	Kayıp (Loss)
GRU(FastText)	0,8432	0,8314	0,8530	0,3561
CNN-LSTM (Random)	0,8442	0,8437	0,8449	1,2981
CNN-LSTM (GloVe)	0,8594	0,8574	0,8620	0,5610
CNN-LSTM (Word2Vec)	0,8467	0,8422	0,8512	0,4724
CNN-LSTM(BERT)	0,8249	0,8091	0,8377	0,4011
CNN-LSTM(FastText)	0,8590	0,8559	0,8624	0,4518
DENSE(GloVe)	0,8275	0,8263	0,8290	1,2802

Tablo 9’da yer alan sonuçlarda ise derin öğrenme modelinden birisi olan GRU, CNN-LSTM ve DENSE modelinin doğruluk, geri çağırma, kesinlik ve kayıp değerleri yer almaktadır. FastText kelime gömmesinin ardından uygulanan GRU modeli ile yapılan analiz sonucunda doğruluk değeri %84,32; %83,14 geri çağırma, %85,30 kesinlik ve %35,61 kayıp değerlerine ulaşılmıştır. Random kelime gömmesinin ardından uygulanan CNN-LSTM hibrit modelinin sonuçlarında ise doğruluk değeri %84,42; %84,37 geri çağırma, %84,49 kesinlik ve %129,81 kayıp değerlerine ulaşılmıştır. GloVe kelime gömmesinin ardından uygulanan CNN-LSTM karma modelinin sonuçlarında ise doğruluk değeri %85,94; %85,74 geri çağırma, %86,20 kesinlik ve %56,10 kayıp değerlerine ulaşılmıştır. Word2Vec kelime

gömmesinin ardından uygulanan CNN-LSTM modelinin sonuçlarında ise doğruluk değeri %84,67; %84,22 geri çağırma, %85,12 kesinlik ve %47,24 kayıp değerlerine ulaşılmıştır. BERT kelime gömmesinin ardından uygulanan CNN-LSTM modelinin sonuçlarında ise doğruluk değeri %82,49; %80,91 geri çağırma, %83,77 kesinlik ve %40,11 kayıp değerlerine ulaşılmıştır. FastText kelime gömmesinin ardından uygulanan CNN-LSTM modelinin sonuçlarında ise doğruluk değeri %85,90; %85,59 geri çağırma, %86,24 kesinlik ve %45,18 kayıp değerlerine ulaşılmıştır. GloVe kelime gömmesinin ardından uygulanan DENSE modelinin sonuçlarında ise doğruluk değeri %82,75; %82,63 geri çağırma, %82,90 kesinlik ve %128,02 kayıp değerlerine ulaşılmıştır. Sonuçlar incelendiğinde GloVe kelime gömmesinin ardından uygulanan CNN-LSTM derin öğrenme yöntemi en yüksek başarı gösteren yöntem ve model olmuştur.

SONUÇ

Günümüzde teknolojinin gelişmesi ve değişmesiyle birlikte, konaklama hizmetinin alınış biçimi de dönüşüm geçirmeye başlamıştır. Geçmişte bu hizmet geleneksel yöntemlerle satın alınırken, artık herhangi bir sınırlamaya bağlı kalmadan, istenilen her yerden ve noktadan online kanallar aracılığıyla herkesin kendi bütçe ve koşullarına uygun şekilde konaklama satın alması mümkün hale gelmiştir. Bilhassa maddi şartlar ve hatta uzaklıklar göz önüne alındığında herkesin konaklama hizmetlerine ulaşabilmesi, istenilen seviyede konaklama hizmeti alabilmesi çok önemlidir. Tüm bu maddi ve mekânsal durumlara bağlı kalmadan konaklama hizmetine duyulan ihtiyaç neticesinde teknolojinin de gelişmesiyle farklı çözümler üretilmiştir. Bu çözümler herkes için ulaşılabilir, herkese açık ve istenilen zaman ve mekânda çoğu zaman ücretsiz olan online ağlar ile internet ortamında web siteleri aracılığıyla müşterilere ulaştırılmıştır. Bu siteler, otel sahiplerinin otellerini, müşterilere ulaşmasını istediği şekilde düzenleyerek mekân sorunu olmadan kilometrelerce ve hatta kıtalararası ziyaret edilmesine ve satın alınmasına olanak sağlar.

Hotels.com, Tatilbudur, Etstur, Jolly Tur, Tatilsepeti, Trivago, Neredekal, Trip.com, Priceline bu sitelerden bazılarıdır. Bu siteler otellerin ücretsiz bir şekilde ziyaret edilmesine olanak sağlar. Müşteriler otellerde konaklama hizmeti satın alırken, birçok çevrimiçi satın alımında olduğu gibi burada da oteller ile ilgili yorumlara bakmaktadırlar. Ancak otel sayıları ve yorum sayıları göz önüne alındığında bu yorumlara bakma işlemleri çok zor ve zaman kaybedici bir hal alabiliyor. Bu çalışmada, müşterilerin yorumları tek tek incelemelerine gerek kalmaksızın, oteller hakkında olumlu, olumsuz veya nötr bir karar verebilmelerini sağlamak amacıyla derin öğrenme yöntemleri kullanılmış ve yorumlar sınıflandırılmıştır. Sınıflandırmanın yapılabilmesi için Etstur web sitesinden otellere yapılan yorumlar elde edilmiştir. 66,667 olumlu, 66,667 adet olumsuz, 66,667 adet nötr yorum olmak üzere 200.001 veri elde edilmiştir. Bu veri setine kelime gömmesi ve derin öğrenme modelleri olarak Word2vec, GloVe, Random, BERT, FastText kelime gömmesi CNN-LSTM, GRU ve DENSE modelleri kullanılarak eğitim gerçekleştirilmiştir. Kullanılan modellerin doğruluk, geri çağırma, kesinlik ve kayıp değerleri ölçülerek karşılaştırması

yapılmıştır. Derin öğrenme modeli olan GRU modeliyle en başarılı sonuca FastText kelime gömmesi ile doğruluk değeri %84,32; %83,14 geri çağırma, %85,30 kesinlik ve %35,61 kayıp değerleri ile ulaşılmıştır. CNN-LSTM karma modelini kullanarak en başarılı değerlere, Random kelime gömmesi için filtre boyutu 3, dropout 0,2; pool size 4 değerleri ile yapılan analizde doğruluk değeri %84,42; %84,37 geri çağırma, %84,49 kesinlik ve %129,81 kayıp değerleri, GloVe kelime gömmesi için filtre boyutu 3, dropout 0,2; pool size 1 değerleri ile yapılan analizde doğruluk değeri %85,94; %85,74 geri çağırma, %86,20 kesinlik ve %56,10 kayıp değerlerine, Word2Vec kelime gömmesi için filtre boyutu 3, dropout 0,2; pool size 1 değerleri ile yapılan analizde doğruluk değeri %84,67; %84,22 geri çağırma, %85,12 kesinlik ve %47,24 kayıp değerlerine, BERT kelime gömmesi için filtre boyutu 3, dropout 0,2; pool size 1 değerleri ile yapılan analizde doğruluk değeri %82,49; %80,91 geri çağırma, %83,77 kesinlik ve %40,11 kayıp değerlerine, FastText kelime gömmesi için filtre boyutu 3, dropout 0,2; pool size 1 değerleri ile yapılan analizde doğruluk değeri %85,90; %85,59 geri çağırma, %86,24 kesinlik ve %45,18 kayıp değerleri ile ulaşılmıştır. GloVe kelime gömme yöntemi kullanıldıktan sonra, CNN-LSTM modelleriyle elde edilen sonuçların, diğer yöntemlere kıyasla küçük bir farkla en başarılı olduğu görülmüştür. Derin öğrenme modeli olan DENSE modeliyle en başarılı sonuca, Glove kelime gömmesi ile doğruluk değeri %82,75; %82,63 geri çağırma, %82,90 kesinlik ve %128,02 kayıp değerleri ile ulaşılmıştır.

Sonuçlar incelendiğinde GRU, CNN-LSTM ve DENSE modelleri karşılaştırıldığında doğruluk değeri %85,94; %85,74 geri çağırma, %86,20 kesinlik ve %56,10 kayıp değerlerine ulaşılan GloVe kelime gömmesinin ardından uygulanan CNN-LSTM derin öğrenme yöntemi en yüksek başarı gösteren yöntem ve model olmuştur. GloVe (Global Vectors for Word Representation) kelime gömme tekniği, istatistiksel yaklaşımlar ve dağıtımsal anlambilim prensiplerini birleştirerek kelimeler arasındaki ilişkileri daha güçlü bir şekilde modelleyebilmesiyle öne çıkmaktadır. En büyük avantajlarından biri, küresel bağlam bilgisini kullanarak kelimeler arasındaki anlam ilişkilerini daha iyi öğrenmesidir. Word2Vec gibi yöntemler yerel bağlam penceresinde çalışırken, GloVe kelime çiftleri arasındaki ortaklık istatistiklerini büyük veri kümeleri üzerinden hesaplayarak daha geniş ve anlamlı vektör temsilleri oluşturur. Bu sayede anlam açısından benzer kelimeler arasındaki ilişkileri daha iyi yansıtır ve özellikle duygu analizi gibi doğal dil işleme görevlerinde yüksek başarı sağlar. Ayrıca, GloVe'nin önceden eğitilmiş vektörlerinin geniş veri kümeleri üzerinden öğrenilmiş olması, düşük kaynaklı veya sınırlı veriyle çalışılan durumlarda da

güçlü performans sergilemesine olanak tanımaktadır.

Bu çalışmada elde edilen sonuçlar, literatürdeki benzer çalışmalarla kıyaslanarak, ortak yönleri ve farklılıkları değerlendirilmiştir. Yapılan karşılaştırmalar sonucunda aşağıdaki bulgular elde edilmiştir:

- Literatürdeki çalışmaların büyük bir kısmı Word2Vec ve GloVe gibi geleneksel kelime gömme tekniklerini kullanmıştır (Büyükeke, 2020; Öztürk, 2020). Ancak, bağlamsal kelime gömme teknikleri üzerine yapılan çalışmalar sınırlı olup, BERT'in duygu analizi üzerindeki etkisi daha kapsamlı incelenmemiştir.
- Bu çalışmada, Word2Vec ve GloVe'nin yanı sıra BERT ve FastText gibi modern kelime gömme teknikleri de kullanılmıştır. Sonuçlar, GloVe kelime gömme tekniğinin en yüksek başarıyı sağladığını göstermiştir. Bu bulgu, bazı çalışmalarla örtüşmekte ancak BERT gibi ileri düzey tekniklerin geleneksel yöntemlerden daha iyi performans göstereceğine dair literatürdeki bazı beklentilere ters düşmektedir.
- Literatürde yaygın olarak kullanılan yöntemler arasında Naïve Bayes, Destek Vektör Makineleri ve Lojistik Regresyon gibi geleneksel makine öğrenmesi algoritmaları bulunmaktadır (Tuna, 2019; Mengutaycı, 2020).
- Bu çalışmada, CNN-LSTM ve GRU gibi derin öğrenme modelleri kullanılmış ve geleneksel yöntemlere kıyasla daha yüksek doğruluk elde edilmiştir. CNN-LSTM modelinin en başarılı yöntem olduğu belirlenmiştir. Bu bulgu, metin madenciliği ve duygu analizi alanında derin öğrenmenin geleneksel makine öğrenmesi yöntemlerine üstünlük sağladığını gösteren önceki çalışmalarla uyumludur (Çiğdemli, 2024).
- Literatürdeki birçok çalışma, genellikle 10.000 ila 50.000 arasında veri içeren küçük ölçekli veri setleri ile gerçekleştirilmiştir (Tükenmez, 2023; Ay, 2021).
- Bu çalışmada ise 200.001 yorum içeren büyük ölçekli bir veri kümesi kullanılarak analiz yapılmıştır. Büyük veri kullanımı, modelin genelleme yeteneğini artırarak daha güvenilir sonuçlar elde edilmesini sağlamıştır. Bu yönüyle çalışma, önceki çalışmalardan farklılaşmaktadır.
- Literatürdeki çalışmaların çoğu tek bir platformdan (örn. Tripadvisor, Booking, CruiseCritic) alınan verilerle yapılmıştır (Shwaish, 2022; Caner, 2019).

- Bu çalışmada ise Etstur platformundan veri çekilmiş ve analiz edilmiştir. Farklı platformlardan veri çekilmemiş olması, modelin genelleme yeteneğini sınırlayabilecek bir faktör olarak değerlendirilebilir. Ancak, tek bir platforma odaklanarak derinlemesine bir analiz yapılması, çalışmanın güçlü yönlerinden biri olmuştur.
- Literatürdeki bazı çalışmalar, müşteri yorumlarının büyük ölçüde olumlu olduğunu ve olumsuz yorumların daha az sayıda yer aldığını göstermektedir (Elsadığ, 2021).
- Bu çalışmada da benzer şekilde, olumsuz yorumların sınırlı olduğu ve dengeli bir veri kümesi oluşturabilmek için daha fazla otelden veri toplanması gerektiği görülmüştür. Bu durum, literatürdeki bulgularla tutarlıdır.
- Literatürdeki çalışmalar genellikle akademik düzeyde analizler gerçekleştirmiş ve sektörle entegrasyon konusunda sınırlı kalmıştır (Çelik, 2023; Budak, 2021).
- Bu çalışmada, otel işletmelerinin müşteri yorumlarını analiz edebilmesine olanak tanıyacak bir karar destek sistemi geliştirilmesi hedeflenmiştir. Bu yönüyle, çalışma yalnızca akademik katkı sağlamakla kalmayıp, uygulanabilir bir model ortaya koyarak literatüre de katkıda bulunmaktadır.

Sonuç olarak, bu çalışma, literatürdeki önceki çalışmalarla kelime gömme teknikleri, derin öğrenme modelleri ve veri seti büyüklüğü açısından benzerlikler ve farklılıklar taşımaktadır. Özellikle BERT gibi gelişmiş kelime gömme tekniklerinin değerlendirilmesi ve CNN-LSTM modelinin başarılı bulunması, literatüre yeni bir bakış açısı sunmaktadır. Bunun yanı sıra, büyük ölçekli veri kullanımı ve pratik uygulanabilirlik hedefi, çalışmayı diğer çalışmalardan farklılaştıran önemli unsurlar arasında yer almaktadır.

Bu çalışma, otel yorumlarının analizinde derin öğrenme ve metin madenciliği tekniklerini kullanarak literatüre teorik katkılar sağlamaktadır. Önceki çalışmalarda genellikle geleneksel makine öğrenmesi algoritmaları ve temel kelime gömme teknikleri kullanılmışken, bu çalışmada daha gelişmiş ve güncel yöntemler kullanılmıştır. Birincisi, metin madenciliği ve duygu analizi alanında yaygın olarak kullanılan Word2Vec ve GloVe tekniklerinin yanı sıra, günümüzün en güçlü kelime gömme tekniklerinden biri olan BERT (Bidirectional Encoder Representations from Transformers) bu çalışmada uygulanmıştır. BERT'in kullanılması, kelimeler arasındaki bağlamı çift yönlü olarak değerlendirebilmesi

sayesinde önceki çalışmalara kıyasla daha derin ve anlamlı bir metin analizi sunmaktadır. Aynı zamanda FastText tekniği de kullanılarak, kelime kökleri ve ekler üzerindeki etkilerin modellenmesi sağlanmıştır. Bu yöntemlerin dahil edilmesi, metin madenciliği alanında teorik bir gelişim sunmaktadır. İkinci olarak, çalışmada CNN-LSTM ve GRU gibi hibrit derin öğrenme teknikleri uygulanmıştır. Literatürde otel yorumları üzerine yapılan çalışmalarda genellikle tek bir model (örneğin yalnızca LSTM veya yalnızca CNN) kullanılırken, bu çalışmada farklı modeller karşılaştırılmış ve CNN-LSTM hibrit modelinin en yüksek başarı oranına ulaştığı tespit edilmiştir. Bu bulgu, literatüre katkı sağlayarak otel yorumları analizinde hibrit modellerin etkili olduğunu göstermektedir. Üçüncü olarak, veri kümesi oluşturma ve sınıflandırma süreçlerinde kullanılan yöntemler literatüre katkı sunmaktadır. Çalışmada Etstur platformundan elde edilen 200.001 otel yorumu kullanılmıştır. Büyük ölçekli bu veri kümesi, otel yorumları üzerine yapılan diğer çalışmalara kıyasla daha kapsamlıdır. Ayrıca yorumlar olumlu, olumsuz ve nötr olarak sınıflandırılmış ve duygu analizi üzerine daha dengeli bir veri dağılımı oluşturulmuştur. Son olarak, çalışmada geleneksel duygu analizi teknikleri ile derin öğrenme tabanlı yöntemler kıyaslanmış ve günümüz teknolojisiyle hangi yaklaşımların daha başarılı olduğu ortaya konulmuştur. Bu tür karşılaştırmalı analizler, literatürde farklı yöntemlerin etkinliğini test etmek açısından önemli bir teorik katkı sağlamaktadır.

Bu çalışmanın sunduğu pratik katkılar hem otel işletmecileri hem de müşteriler açısından çeşitli faydalar sağlamaktadır. Özellikle büyük ölçekli otel yorumlarının analiz edilerek hızlı ve doğru sonuçlar elde edilmesi, sektör açısından önemli bir yenilik sunmaktadır. Birincisi, çalışmada geliştirilen model sayesinde otel yöneticileri, müşteri yorumlarını daha hızlı ve sistematik bir şekilde analiz edebilir hale gelmiştir. Geleneksel yöntemlerle yorumları tek tek incelemek zaman alıcı ve maliyetli bir süreçken, bu çalışma ile yorumlar otomatik olarak olumlu, olumsuz ve nötr olarak sınıflandırılabilir. Bu sayede, işletmeler müşteri memnuniyetsizliklerini daha hızlı tespit edip gerekli iyileştirmeleri yapabilir. İkincisi, müşteriler için karar verme sürecini kolaylaştırmaktadır. Otel tercihleri yapılırken, yüzlerce yorumu okumak yerine modelin sunduğu sınıflandırmalar sayesinde, potansiyel müşteriler daha hızlı bir şekilde bilgiye ulaşabilmektedir. Bu durum, özellikle tatil ve iş amaçlı seyahat eden kişiler için zaman tasarrufu sağlamaktadır. Üçüncüsü, turizm sektöründe veri odaklı karar alma süreçlerine katkı sağlamaktadır. Otel işletmecileri, model tarafından sağlanan analizleri kullanarak hizmet kalitesini artırabilir, müşteri geri bildirimlerine dayalı stratejik kararlar alabilir ve rekabet avantajı elde edebilirler. Özellikle olumsuz yorumları analiz

ederek müşteri şikayetlerine yönelik çözümler üretmek mümkün olmaktadır.

Bu çalışma, otel yorumlarının metin madenciliği ve derin öğrenme yöntemleriyle analiz edilmesini sağlamış ve başarılı sonuçlar elde edilmiştir. Ancak, araştırma sürecinde bazı sınırlılıklar ile karşılaşmış ve çalışmanın kapsamını belirleyen çeşitli faktörler ortaya çıkmıştır. Birincisi, çalışmada kullanılan BERT gibi gelişmiş kelime gömme teknikleri, yüksek donanımsal gereksinimlere ihtiyaç duymaktadır. BERT modeli, büyük miktarda veri işleyerek bağlam ilişkilerini anlamlandıran bir yapıya sahiptir ve bu işlem için yüksek RAM ve güçlü bir GPU gerekmektedir. Çalışma sırasında donanımsal sınırlamalar nedeniyle modelin eğitim süresi uzamış ve daha büyük veri setleri ile çalışmak zorlaşmıştır. Bu durum, derin öğrenme modellerinin eğitim süreçlerinde yüksek donanım ihtiyacının önemli bir sınırlayıcı faktör olduğunu göstermektedir. İkincisi, veri toplama sürecinde karşılaşılan zaman kısıtlamaları ve teknik engeller de çalışmanın sınırlılıklarından biri olmuştur. Web sitelerinden veri çekme sürecinde, aşırı istek (request) gönderimi nedeniyle sunucu tarafından IP engelleme (rate limiting) veya CAPTCHA doğrulama mekanizmalarının devreye girmesi gibi güvenlik önlemleriyle karşılaşılabilir. Bu durumu önlemek amacıyla, isteklerin belirli aralıklarla ve rastgele zaman dilimlerinde gönderilmesi, ayrıca proxy ve user-agent değişiklikleri kullanılarak taleplerin insan etkileşimine benzetilmesi gibi yöntemler uygulanmıştır. Ancak, bu tekniklerin kullanılması veri çekme sürecini önemli ölçüde yavaşlatmış ve veri setinin oluşturulmasını zaman açısından kısıtlayıcı bir faktör haline getirmiştir. Üçüncüsü, çalışmada kullanılan otel yorumlarının dağılımı da önemli bir sınırlılıktır. Çekilen verilerde, her otel için eşit sayıda yorum bulunmaması sebebiyle analiz edilen veri setinin dengeli hale getirilmesi zorlaşmıştır. Bazı otellerde yüksek sayıda yorum bulunurken, bazı otellerde oldukça sınırlı sayıda yorum olduğu gözlemlenmiştir. Bu nedenle, çalışmada daha geniş kapsamlı bir analiz yapabilmek adına daha fazla otelden veri toplanması gerekmiştir. Bu durum, veri çekme sürecinin uzamasına ve analiz sürecinde farklı otel grupları arasında veri dengesizlikleri yaşanmasına yol açmıştır. Dördüncüsü, otellerin yorumlarında olumsuz yorum bulmak sınırlıydı ve bu durum veri toplama sürecini zorlaştırdı. Veri sayısını eşitleyebilmek ve modelin dengeli bir veri kümesi ile eğitilmesini sağlamak amacıyla, daha fazla otelden yorum çekmek zorunda kalındı. Olumsuz yorum sayısının azlığı, modelin duygu analizi performansını belirli ölçüde etkileyebilecek bir faktör olmuştur. Bu çalışma başarılı analiz sonuçları sunmasına rağmen, yüksek donanım gereksinimleri, veri toplama sürecinde karşılaşılan teknik kısıtlamalar, otel yorumlarının dengesiz dağılımı ve olumsuz yorumların azlığı gibi sınırlamalarla karşılaşmıştır.

Gelecekteki alıřmalarda, daha gl donanım altyapısı kullanarak modelin eēitimi hızlandırılabilir ve farklı veri kaynaklarından daha dengeli bir veri kümesi oluşturularak analiz kapsamı genişletilebilir.

Gelecekteki alıřmaların daha gl ve kapsamlı modelleri içerebilmesi için Transformers ve LNN gibi yeni nesil tekniklerin kullanımı, veri kümesi çeřitliliēinin artırılması ve modelin farklı sektörlere uygulanması gibi konular üzerinde durulması önerilmektedir. Bu yaklaşımlar, duygu analizi alanında daha başarılı sonuçlar elde edilmesini sağlayacaktır.



KAYNAKÇA

- Ak, B. (2021). *Deep learning-based preprocessing tools for Turkish natural language processing* (Tez No. 910997) [Yüksek Lisans Tezi, Boğaziçi Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Akay, O. F. (2024). *Türkiye’de ulaştırma teknolojilerinin patent analizi ile incelenmesi* (Tez No. 855436) [Yüksek Lisans tezi, Fırat Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Aksoy, S. (2024). *Marka farkındalığının olumlu ağızdan ağıza iletişim üzerindeki etkisinde marka güveni, müşteri memnuniyeti ve marka sadakatinin aracılık rolleri* (Tez No. 867211) [Doktora tezi, Ankara Hacı Bayram Veli Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Aksu, M. Ç. (2021). *Turizm için sosyal medya temelli mekânsal karar destek sisteminin geliştirilmesi ve uygulaması: Artvin ili örneği* (Tez No. 707283) [Doktora tezi, Atatürk Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Aksu, S. (2024). *Kuantum hesaplama kullanan derin öğrenme ile karşılıklı görüşmelerde duygu analizi* (Tez No. 855436) [Yüksek Lisans tezi, Fırat Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Aktaş, T. (2023). *Müşteri yorumlarının duygu analizi: Konaklama işletmeleri* (Tez No. 837813) [Doktora tezi, Maltepe Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Alfigi, H. (2023). *Multi-label and single-label text classification using standard machine learning algorithms and pre-trained BERT transformer* (Tez No. 782308) [Yüksek Lisans tezi, Çankaya Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Alkhasawe, B. S. (2018). *Classification of Arabic text using convolutional neural networks* (Tez No. 533343) [Yüksek Lisans tezi, Erciyes Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

- Amalı, F. (2024). *Çevrimiçi otel değerlendirme yorumları için transformatör tabanlı duygu analizi çerçevesi* (Tez No. 896868) [Yüksek Lisans tezi, Kocaeli Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Amidi, A., & Amidi, S. (2018, Kasım 26). *Tekrarlayan Yapay Sinir Ağları el kitabı CS 230 - Derin Öğrenme* <https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-recurrent-neural-networks> adresinden alındı
- Arslan, Ö. (2021). *Evrşimsel sinir ağları ve metin benzerliği kullanılarak fatura görüntülerinde sınıflandırma* (Tez No. 661903) [Yüksek Lisans tezi, Konya Teknik Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Asutay, A. (2024). *Raylı sistemlerde yolcu sayısının derin öğrenme algoritmaları ile tahminlenmesi* (Tez No. 881186) [Yüksek Lisans tezi, İzmir Bakırçay Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Atabay, L. (2020). *Otel yorumlarının metin madenciliği yöntemleri ile karşılaştırmalı analizi: Mayorka, Antalya, Şarm-el Şeyh örneği* (Tez No. 644900) [Yüksek Lisans tezi, Akdeniz Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Atun, H. (2024). *Üretken yapay zeka destekli programlama eğitiminde sorgu mühendisliğinin çeşitli değişkenler açısından değerlendirilmesi* (Tez No. 883715) [Doktora tezi, Ankara Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Ay, R. A. (2021). *Doğal dil işleme ve kümeleme yöntemleri ile müşteri yorumlarının incelenmesi* (Tez No. 670906) [Yüksek Lisans tezi, KTO Karatay Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Bağdatoğlu, E. (2020). *Derin öğrenme yöntemiyle kapalı alanlarda suç davranışlarının tespitine yönelik bir uygulama* (Tez No. 643749) [Yüksek Lisans tezi, Başkent Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Balta, B. K. (2020). *5846 sayılı fikir ve sanat eserleri kanunu kapsamında eser kavramı ve yapay zekâ ürünleri* (Tez No. 619505) [Yüksek Lisans tezi, İstanbul Şehir Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Bardız, A. (2019). *Turkish medical text parsing and classification* (Tez No. 563834) [Yüksek Lisans tezi, Galatasaray Üniversitesi]. Yükseköğretim Kurulu Ulusal

Tez Merkezi.

Batmaz, Ş. (2017). *A SEQ2SEQ transformer model for Turkish spelling correction* (Tez No. 761161) [Yüksek Lisans tezi, Boğaziçi Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Berger, J. (2014). Word of mouth and interpersonal communication: A review and directions for future research. *Journal of Consumer Psychology*, 24(4), 586-607. doi:https://doi.org/10.1016/j.jcps.2014.05.002

Bhakta, S. S. (2024, Ağustos 22). *How to Generate Word Embedding using BERT?* <https://www.geeksforgeeks.org/how-to-generate-word-embedding-using-bert/>

Boztürk Kılınç, E. (2024). *Çin restoranına yapılan müşteri yorumlarının metin madenciliği teknikleri ve makine öğrenme yöntemleriyle analiz edilmesi* (Tez No. 887984) [Yüksek Lisans tezi, Gazi Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Budak, İ. (2021). *Veri ve metin madenciliği ile hava yolu işletmelerinin sosyal medya yorum ve skorlarının değerlendirilmesi* (Tez No. 678432) [Doktora tezi, Pamukkale Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Büyükeke, A. (2020). *Sosyal medya analizine dayalı rekabetçi zekâ model önerisi: Antalya bölgesi otel işletmeleri analizi*. (Tez No. 672681) [Doktora tezi, Gazi Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Caner, F. (2019). *Topic modeling and sentiment analysis of hotel reviews* (Tez No. 588155) Yüksek Lisans tezi, Bahçeşehir Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Canlı, H. (2022). *IoT tabanlı akıllı şehirlerde derin öğrenme ve mobil tabanlı akıllı park sistemi yaklaşımı* (Tez No. 729389) [Doktora Tezi, Düzce Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Çelenli, H. İ. (2020). *Gizli dirichlet ayrımı ve word2vec yöntemlerinin birleşimi ile özgün bir metin temsil modeli geliştirilmesi* (Tez No. 629631) [Yüksek Lisans tezi, Kocaeli Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Çelik, H. (2023). *Yeni trend bungalov işletmelerine ilişkin çevrimiçi yorumların duygu analizi ile incelenmesi* (Tez No. 819726) [Yüksek Lisans tezi, Gazi

Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Çiğdemli, B. S. (2024). *Akıllı otel ziyaretçilerinin duygularının karma analiz yöntemiyle incelenmesi: Tripadvisor örneği* (Tez No. 868418) [Yüksek Lisans tezi, Karamanoğlu Mehmetbey Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Çoban, T. (2018). *Sinemada yapay zekâ* (Tez No. 541965) [Yüksek Lisans tezi, Ordu Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Daşgın, R. (2023). *Kitlesel çevrimiçi ders platformlarında kurslara yapılan yorumların metin madenciliği kullanılarak duygu analizi* (Tez No. 785007) [Yüksek Lisans tezi, Aksaray Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Demirbaş, F. (2024). *İklim değişikliğinin içme suyu temini amaçlı kullanılan barajların doluluk oranlarına etkisinin yapay sinir ağı modellenmesi ile belirlenmesi* (Tez No. 881659) [Doktora Tezi, İstanbul Üniversitesi-Cerrahpaşa]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Dikici, S. (2024). *Python söz dizimi hatalarının derin öğrenme yöntemleri ile onarılması* (Tez No. 849512) [Yüksek Lisans tezi, Bursa Teknik Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Elsadığ, A. M. (2021). *Otel işletmelerinde müşteri memnuniyetine etki eden unsurların karma yöntem kullanılarak incelenmesi* (Tez No. 677109) [Yüksek Lisans tezi, Mersin Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Elverişli, M. Ç. (2024). *Derin öğrenme algoritmalarıyla duygu analizi* (Tez No. 893120) [Yüksek Lisans tezi, Sakarya Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Emekli, B. (2024). *Yazılım tanımlı ağlarda makine öğrenme temelli saldırı tespit sistemi* (Tez No. 856467) [Yüksek Lisans tezi, Sakarya Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Ergöktaş, M. (2024). *Müşteri memnuniyetinin kalite boyutları bakımından metin madenciliği ile keşfi* (Tez No. 892986) [Doktora tezi, Erciyes Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Ertürk, G. İ. (2024). *Elektronik ağızdan ağıza iletişimin müşterilerin yiyecek içecek işletmesi*

tercihleri üzerindeki etkisinin müşteriler ve işletmeler açısından incelenmesi: Ankara ili örneği (Tez No. 896353) [Yüksek Lisans tezi, Başkent Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Etstur. (2025, Ocak 22). *Hakkımızda*. Etstur <https://www.etstur.com/>

Google Travel. (2025, Ocak 22). *Hakkımızda*. Google Travel: <https://www.google.com/travel/flights>

Gretzel, U., & Yoo, K. H. (2008). Use and impact of online travel reviews. Information and communication technologies in tourism. *Laboratory for Intelligent Systems in Tourism Department of Recreation, Park and Tourism Sciences*, 35-46. doi:10.1007/978-3-211-77280-5_4

Gümüş, F. (2019). *Müzelerde yapay zekâ uygulamaları, etkileri ve geleceği* (Tez No. 554647) [Yüksek Lisans tezi, İstanbul Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Gündüz, G. (2019). *Derin öğrenme ile fotoğraftan yaş ve cinsiyet tespiti* (Tez No. 571076) [Yüksek Lisans tezi, Sakarya Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Gürbüz, F. B. (2020, Mayıs 18). *Uzun Kısa Dönemli Bellek(Long / Short Term Memory)(LSTM)*. Medium. <https://medium.com/@batincangurbuz/uzun-k%C4%B1sa-d%C3%B6nemli-bellek-long-short-term-memory-lstm-c526980c28b1>

Hotels.com.(2025, Ocak 22). *Hakkımızda*. Hotels.com. https://tr.hotels.com/?locale=tr_TR&pos=HCOM_TR&siteid=300000028

Karagöl, T. (2024). *E-commerce product categorization through text classification* (Tez No. 875990) [Yüksek Lisans tezi, Bahçeşehir Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Karakaya, O. (2024). *Derin öğrenme mimarileri ve kelime yerleştirme tekniklerini kullanarak antikanser peptit tahminleme* (Tez No. 892947) [Yüksek Lisans tezi, Kocaeli Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Karaöz, B. (2018). *Büyük veri ve işletme analitiği: Sosyal medya ve duygu analizi ile bir öngörü modeli* (Tez No. 497098) [Doktora tezi, İstanbul Üniversitesi].

Yükseköğretim Kurulu Ulusal Tez Merkezi.

Kaya, Ş. (2024). *Sosyal medya verilerinde derin öğrenme modelleriyle ırkçılık ve yabancı düşmanlığı tespiti* (Tez No. 847750) [Yüksek Lisans tezi, Fırat Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Keskenler, M. F. (2024). *Tam otomatik ve metasezgisel tabanlı yeni bir derin öğrenme mimarisi üreticinin geliştirilmesi ve cilt kanseri teşhisi için etkinliğinin gösterilmesi* (Tez No. 872354) [Doktora tezi, Atatürk Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Keskin, M. (2018, Ağustos 6). *Word2Vec, FastText, GloVe*: <https://medium.com/codable/word2vec-fasttext-glove-d4402fa8cce0>

Kılıçer, S. (2024). *Türkçe metinler için yapay zeka yöntemleri kullanılarak duygu analizi* (Tez No. 907406) [Doktora tezi, İstanbul Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Kınalıoğlu, İ. H. (2019). *Yapay zekâ tabanlı yöntemler kullanılarak futbol müsabakalarının sonuçlarının kestirilmesi ve hibrit model önerileri* (Tez No. 607261) [Doktora tezi, Selçuk Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Kuş, İ. (2023). *Akademik makale öneri sistemi* (Tez No. 816203) [Yüksek Lisans tezi, Eskişehir Osmangazi Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Memiş, E. (2024). *Sentiment analysis of Turkish financial tweets using deep learning models for Bist 100 index* (Tez No. 854278) [Doktora tezi, Ankara Yıldırım Beyazıt Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Mengutaycı, Ü. (2021). *Yapay sinir ağları ile otel müşteri yorumlarının metinsel yolla sınıflandırılarak duygu analizlerinin tespiti* (Tez No. 673051) [Yüksek Lisans tezi, Kütahya Dumlupınar Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Naderalvojud, B. (2020). *Duygu analizi için sinirsel sözcük öz yerleşikleri* (Tez No. 650984) [Doktora tezi, Hacettepe Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Otelpuan. (2025, Ocak 22). *Hakkımızda*. Otelpuan. <https://www.otelpuan.com/>

Öğüt, H., & Onur Taş, B. K. (2011). The influence of internet customer reviews on the online sales and prices in hotel industry. *The Service Industries Journal*, 32(2), 197-214.

doi:<https://doi.org/10.1080/02642069.2010.529436>

- Önal, M. (2017). *Sözlüksel benzeşim yöntemi ile android tabanlı duygu analizi* (Tez No. 463062) [Yüksek Lisans tezi, Fırat Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Önün, F. (2019). *Derin öğrenme ile yüksek çözünürlüklü hava görüntülerinde yolların tespit edilmesi* (Tez No. 572614) [Yüksek Lisans tezi, Fırat Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Özçelik, N. (2021). *Video görüntüleri üzerinde derin öğrenme tabanlı anormal durum tespiti ve derinlik tahmini* (Tez No. 676583) [Yüksek Lisans tezi, Akdeniz Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Özdemir Tekir, R. (2023). *Çizge evrişimli sinir ağları kullanılarak metin sınıflandırma* (Tez No. 805511) [Yüksek Lisans tezi, İstanbul Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Özdemir, M. (2024). *Çağrı merkezine gelen aramaların metin tabanlı sınıflandırılması* (Tez No. 848696) [Yüksek Lisans tezi, Karabük Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Öztürk, G. (2020). *Kruvaziyer turistlere ait çevrimiçi seyahat yorumlarının metin madenciliği yöntemi ile değerlendirilmesi* (Tez No. 659640) [Doktora tezi, Aydın Adnan Menderes Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Paksın, B. (2020). *Görsel sanatlarda yapay zekâ ve yaratıcılık ilişkisi* (Tez No. 573934) [Yüksek Lisans tezi, Dokuz Eylül Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Pervan, N. (2019). *Derin öğrenme yaklaşımları kullanarak Türkçe metinlerden anlamsal çıkarım yapma* (Tez No. 534423) [Yüksek Lisans tezi, Ankara Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Polat, B. (2021). *Türkçe ürün yorumları verisi ile duygu analizi*. (Tez No. 676313) [Yüksek Lisans tezi, Ankara Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Saltürk, S. (2024). *Havada imza ve yüz tanımaya dayalı çoklu biyometrik sistem tasarımı* (Tez No. 865077) [Doktora tezi, Yıldız Teknik Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

- Saraçoğlu, F. (2024). *İş zekası ve duygu analizi: Sakarya merkezli sosyal medya verilerinin doğal dil işleme yaklaşımlarıyla incelenmesi* (Tez No. 855970) [Yüksek Lisans tezi, Sakarya Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Schuckert, M., Liu, X., & Law, R. (2015). Hospitality and tourism online reviews: Recent trends and future directions. *Journal of Travel and Tourism Marketing*, 32(5), 608-621. doi:10.1080/10548408.2014.933154
- Shwaish, M. S. (2022). *Sentiment analysis for hotels customer reviews using artificial neural network algorithm* (Tez No. 798957) [Yüksek Lisans tezi, Altınbaş Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Sundaram, D. S., Mitra, K., & Webster C. (1998). Word of mouth communications: A motivational analysis. *NA Advances in Consumer Research*, 25, 527-531. <http://acrwebsite.org/volumes/8208/volumes/v25/NA-25>
- Sungur, F. (2024). *Hiper parametre ayarlarının saldırı tespit sistemleri performansı üzerindeki etkilerinin incelenmesi* (Tez No. 847093) [Yüksek Lisans tezi, Sivas Bilim ve Teknoloji Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Şahin, S. (2024). *Çevrimiçi sosyal ağlarda rahatsız edici davranış tespiti ve azaltma stratejileri* (Tez No. 847591) [Yüksek Lisans tezi, Marmara Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Şahin, V. (2024). *Uygulama programlama arayüzü çağruları kullanarak sistem güvenliğinin analiz edilmesi* (Tez No. 893482) [Yüksek Lisans tezi, Ondokuz Mayıs Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Talo, T. (2024). *Derin evrimsel ağlar kullanarak çevrimdışı sahte imza ve gerçek imza sınıflandırılması* (Tez No. 877776) [Yüksek Lisans tezi, Fırat Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Tolan, N. (2024). *Tek boyutlu hibrit evrimsel sinir ağları ve uzun kısa süreli bellek mimarileri kullanarak EKG sinyallerinin sınıflandırılması* (Tez No. 877810) [Yüksek Lisans tezi, Fırat Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- TripAdvisor. (2025, Ocak 22). *Hakkımızda*. TripAdvisor: <https://www.tripadvisor.com.tr/>
- Trivago. (2025, Ocak 22). *Hakkımızda*. Trivago: <https://www.trivago.com.tr/>

- Tufan, Ö. (2022). *Elektronik ağızdan ağıza iletişimin turist satın alma davranışına etkisi* (Tez No. 817172) [Yüksek Lisans tezi, Süleyman Demirel Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Tuna, M. F. (2019). *Çevrimiçi yorum ve şikâyetlerin otel işletmeleri üzerinden duygu analizi ile incelenmesi* (Tez No. 607473) [Doktora tezi, Erciyes Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Tunç, T. (2024). *Akıllı batarya kapasitesinin derin öğrenme yöntemleriyle tahmini* (Tez No. 856925) [Yüksek Lisans tezi, Başkent Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Tunçalp, O. (2018). *Turizm pazarlamasında çevrimiçi sitelerindeki müşteri yorumları ve puanlama sisteminin otel satış fiyat tercihlerine etkisi* (Tez No. 515510) [Yüksek Lisans tezi, Başkent Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Tükenmez, E. G. (2023). *Makine öğrenmesine dayalı çevrimiçi otel görüşlerinin duygu analizi ve konu modelleme yaklaşımlarıyla değerlendirilmesi* (Tez No. 845438) [Doktora tezi, Alanya Alaaddin Keykubat Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Türk Dil Kurumu. (2025). *İletişim*. Türk Dil Kurumu.<https://sozluk.gov.tr/?ara=ileti%C5%9Fim>
- Ucuzal, H. (2020). *Yapay zekâya dayalı anlamsal video işleme yöntemlerinin tıpta kullanılabilirliğinin araştırılması* (Tez No. 639767) [Yüksek Lisans tezi, İnönü Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Venugopal, K. (2021, Mayıs 8). *Mathematical Introduction to GloVe Word Embedding*. <https://becominghuman.ai/mathematical-introduction-to-glove-word-embedding-60f24154e54c>
- Yalçın, M. O. (2023). *Kelime gömme yaklaşımlarının iadesiz torbalanmasına dayanan uzun kısa süreli bellek mimarisi ve metin sınıflandırmasına uygulanması* (Tez No. 830420) [Doktora tezi, Muğla Sıtkı Koçman Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.
- Yardı, Z. (2022). *Düşük maliyetli havayolu işletmelerinde maliyet liderliği stratejisinin derin öğrenme yöntemiyle analizi* (Tez No. 748059) [Doktora tezi, Anadolu

Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Yıldırım, M. K. (2024). *Bilgisayar destekli derin öğrenme yöntemleri ile bitki sağlığının tespit ve izlenmesi* (Tez No. 856994) [Yüksek Lisans tezi, Mersin Üniversitesi]. Yükseköğretim Kurulu Ulusal Tez Merkezi.

Yılmaz, A. (2019). Yapay zeka. H. Üstünel (Ed.), *Yapay Zeka Nedir?- Zeka Nedir?- içinde* (s. 1-16). Kodlab.



EKLER

Tez kapsamında geliştirilen duygu analizi kodları ekte sunularak paylaşılmıştır.

EKİ: Python Uygulama Kodları

Alternatif İndirme Linki:

1. GitHub Repository:

<https://github.com/kaanakgunybs/master.git>

EK 1. GLOVE CNN-LSTM 1

```

import numpy as np
import pandas as pd
import tensorflow
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, GRU, Embedding
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.preprocessing.text import Tokenizer
from tensorflow.keras.preprocessing.sequence import pad_sequences
from sklearn.model_selection import train_test_split
from tensorflow.keras.utils import to_categorical
from gensim.models import KeyedVectors
from tensorflow.keras.layers import Embedding, Conv1D,
MaxPooling1D, Dropout, LSTM, Dense, Flatten
import IPython.display as display
from tensorflow.keras.callbacks import Callback
import matplotlib.pyplot as plt

word_to_vec_map=
KeyedVectors.load_word2vec_format('trmodel',binary=True)
dataset= pd.read_csv('Tüm veri.csv', delimiter=',')
target= dataset['Sonuç'].values.tolist()
data = dataset['Metin'].values.tolist()
# Veri bölme (%70 train, %10 validation, %20 test)
X_train, X_kalan, y_train, y_kalan = train_test_split(data, target,
test_size=0.3, random_state=42) # Eğitim için %70, kalan için %30
X_val, X_test, y_val, y_test = train_test_split(X_kalan, y_kalan,
test_size=2/3, random_state=42) # Kalanın %2/3'ü test, %1/3'ü
doğrulama
num_words = 128000
tokenizer = Tokenizer(num_words=num_words)
tokenizer.fit_on_texts(data)
words_to_index = tokenizer.word_index
x_egitim_tokens= tokenizer.texts_to_sequences(X_train)
x_test_tokens= tokenizer.texts_to_sequences(X_test)
x_val_tokens = tokenizer.texts_to_sequences(X_val)
x_kalan_tokens = tokenizer.texts_to_sequences(X_kalan)
max_tokens=512
x_egitim_pad= pad_sequences(x_egitim_tokens,
maxlen=max_tokens)
x_test_pad= pad_sequences(x_test_tokens,maxlen=max_tokens)
x_val_pad= pad_sequences(x_val_tokens, maxlen=max_tokens)
x_kalan_pad=
pad_sequences(x_kalan_tokens,maxlen=max_tokens)
y_train= to_categorical(y_train, num_classes=3)
y_test=to_categorical(y_test, num_classes=3)
y_val=to_categorical(y_val, num_classes=3)
y_kalan=to_categorical(y_kalan, num_classes=3)
Word_to_indeks=tokenizer.word_index
vocab_len= len(Word_to_indeks)
embedding_vector_len= word_to_vec_map['bir'].shape[0]
embedding_matrix= np.zeros((vocab_len,embedding_vector_len))
for word, index in Word_to_indeks.items():
    try:
        embedding_vector= word_to_vec_map[word]
        embedding_matrix[index,:]=embedding_vector
    except KeyError:
        continue
model = Sequential()
model.add(Embedding(input_dim=vocab_len,
output_dim=embedding_vector_len, input_length=max_tokens,
weights = [embedding_matrix], trainable=False))
model.add(Conv1D(filters=128, kernel_size=3,
activation='relu', padding='same'))
model.add(MaxPooling1D(pool_size=1))
model.add(Dropout(0.2))
model.add(LSTM(units=64, return_sequences=False))
model.add(Dense(3, activation='softmax'))
optimizer= tensorflow.keras.optimizers.Adam(learning_rate=1e-3)
model.compile(loss='categorical_crossentropy',
optimizer=optimizer,
metrics=['Precision', 'Recall', 'accuracy'])
model.summary()
x_egitim_pad = np.array(x_egitim_pad)
x_test_pad = np.array(x_test_pad)
x_val_pad=np.array(x_val_pad)
x_kalan_pad=np.array(x_kalan_pad)
y_egitim = np.array(y_train)
y_test = np.array(y_test)
y_val=np.array(y_val)
y_kalan=np.array(y_kalan)
# Grafik güncelleme callback'i
class PlotMetrics(Callback):
    def on_train_begin(self, logs=None):
        self.epochs = []
        self.train_loss = []
        self.val_loss = []

        self.test_loss = [] # Test loss değerleri için liste
        self.train_acc = []
        self.val_acc = []
        self.test_acc = [] # Test accuracy değerleri için liste
        self.train_precision = [] # Precision değerlerini saklamak için
        self.val_precision = [] # Precision değerlerini saklamak için
        self.train_recall = [] # Recall değerlerini saklamak için liste
        self.val_recall = [] # Recall değerlerini saklamak için liste
    def on_epoch_end(self, epoch, logs=None):
        self.epochs.append(epoch + 1)
        self.train_loss.append(logs['loss'])
        self.val_loss.append(logs['val_loss'])
        self.train_acc.append(logs['accuracy'])
        self.val_acc.append(logs['val_accuracy'])
        self.train_precision.append(logs.get('precision', 0)) #
        self.train_recall.append(logs.get('recall', 0)) # Recall değerini
        self.val_precision.append(logs.get('val_precision', 0)) #
        self.val_recall.append(logs.get('val_recall', 0)) # Recall
        self.test_loss.append(logs.get('test_loss', 0)) # Test seti değerlerini hesaplama
        self.test_acc.append(logs.get('test_accuracy', 0)) # Test seti değerlerini hesaplama
        self.test_precision.append(logs.get('test_precision', 0)) # Test seti değerlerini hesaplama
        self.test_recall.append(logs.get('test_recall', 0)) # Test seti değerlerini hesaplama
        model.evaluate(x_test_pad, y_test, verbose=0)
        self.test_loss.append(test_loss)
        self.test_acc.append(test_accuracy)
        # Değerleri yazdırma
        print(f"Epoch {epoch + 1} Sonuçları:")
        print(f" Eğitim Kaybı: {logs['loss']:.4f}")
        print(f" Doğrulama Kaybı: {logs['val_loss']:.4f}")
        print(f" Eğitim Doğruluğu: {logs['accuracy']:.4f}")
        print(f" Doğrulama Doğruluğu: {logs['val_accuracy']:.4f}")
        print(f" Eğitim Precision: {logs.get('precision', 0):.4f}")
        print(f" Doğrulama Precision: {logs.get('val_precision', 0):.4f}")
        print(f" Eğitim Recall: {logs.get('recall', 0):.4f}")
        print(f" Doğrulama Recall: {logs.get('val_recall', 0):.4f}")
        print(f" Test Kaybı: {test_loss:.4f}")
        print(f" Test Doğruluğu: {test_accuracy:.4f}")
        # Grafik gösterimi (Loss)
        plt.figure(figsize=(8, 6))
        plt.plot(self.epochs, self.train_loss, label="Train Loss",
marker='o', color='blue')
        plt.plot(self.epochs, self.val_loss, label="Validation Loss",
marker='o', color='orange')
        plt.plot(self.epochs, self.test_loss, label="Test Loss",
marker='o', color='green') # Test Loss
        plt.title("Loss vs. Epochs")
        plt.xlabel("Epochs")
        plt.ylabel("Loss")
        plt.legend()
        plt.grid()
        plt.show()
        # Grafik gösterimi (Accuracy)
        plt.figure(figsize=(8, 6))
        plt.plot(self.epochs, self.train_acc, label="Train Accuracy",
marker='o', color='blue')
        plt.plot(self.epochs, self.val_acc, label="Validation Accuracy",
marker='o', color='orange')
        plt.plot(self.epochs, self.test_acc, label="Test Accuracy",
marker='o', color='green') # Test Accuracy
        plt.title("Accuracy vs. Epochs")
        plt.xlabel("Epochs")
        plt.ylabel("Accuracy")
        plt.legend()
        plt.grid()
        plt.show()
# Model eğitimi
plot_metrics = PlotMetrics()
history = model.fit(
    x_egitim_pad, y_egitim,
    epochs=50, # Maksimum epoch sayısı
    batch_size=128,
    validation_data=(x_val_pad, y_val),
    callbacks=[plot_metrics] # Metric callback
)
sonuc = model.evaluate(x_test_pad, y_test)
print(sonuc)
# Sonuçları sırayla al ve yazdır
loss, precision, recall, accuracy = sonuc
print(f"Test Kaybı: {loss:.4f}")
print(f"Test Precision: {precision:.4f}")
print(f"Test Recall: {recall:.4f}")
print(f"Test Doğruluğu: {accuracy:.4f}")

```

AKSARAY ÜNİVERSİTESİ TEZ DEĞERLENDİRME FORMU		
Öğrencinin Adı Soyadı: Muhammed Kaan Akgün		EVET
Kapak		X
1	Tez başlığı, tutanaktaki başlıkla aynı mı?	X
2	Kapaktaki ay ve yıl savunmaya girilen tarihle tutarlı mı?	X
3	Kapak format kılavuzdaki kapak formatına uygun mu?	X
4	Kapakta yazılan tüm yazılar doğru olarak verilmiş mi?	X
İçindekiler		
5	Sayfa numaraları tam verilmiş mi?	X
6	Şekil, çizelge vb. listeleri verilmiş mi? Sıralaması doğru mu?	X
7	Özet, abstract, giriş, sonuçlar vb. bölümler var mı?	X
8	Yazım hataları kontrolü yapıldı mı?	X
Giriş		
9	Hazırlanan tezin önemini anlatıyor mu?	X
10	İkinci ve üçüncü dereceden başlık içermemeli kuralına uyuldu mu?	X
Özet/Abstract		
11	Kılavuza uygun mu?	X
12	Ay ve yıl savunmaya girilen tarihle tutarlı mı?	X
13	Özet; tek sayfa, tek aralık, tek paragraf kuralına uygun olarak yazıldı mı?	X
14	Bilim kodu, sayfa adedi, anahtar kelimeler ve tez danışmanı yazıldı mı?	X
Kaynakça		
15	Kaynakların tamamına metin içinde atıf yapıldı mı?	X
16	Kaynak formatı kılavuzdaki kaynak formatına uygun olarak hazırlanmış mı?	X
17	Atıf formatı kılavuzdaki atıf formatına uygun mu?	X
Atıf Yöntemi APA 7 CMS İSNAD		
Genel Değerlendirme		
18	Etik beyan açıklaması okundu, uyuldu ve imzalandı mı?	X
19	Kabul/Onay sayfası kılavuzdaki formata uygun olarak düzenlenmiş mi?	X
20	Kabul /Onay sayfasında belirtilen oy birliği/oy çokluğu seçeneklerinden uygun olanı savunmayla tutarlı olacak şekilde belirlenmiş mi?	X
21	Sayfa kenar boşlukları ve sayfa numaraları kılavuzdaki formatına uygun mu?	X
22	Paragraf boşlukları ve metin satır aralığı kılavuza uygun olacak şekilde düzenlenmiş mi?	X
23	Başlık yazımları kılavuzdaki başlık formatlarına uygun mu?	X
24	Yazı tipi ve boyutu kılavuzdaki yazı tipi ve boyutu formatına uygun mu?	X
25	Şekil, çizelge vb. açıklama ve numaralandırmaları kılavuzdaki formata uygun olarak yazılmış mı?	X

İmza:

Danışman Adı Soyadı:

Doç. Dr. Kemal ADEM