

**YAPAY ZEKA İLE SOSYAL MEDYA UYGULAMALARINDA
SAHTE HABER TESPİTİ**

Hamza ERÖRS

21 14 02 206

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayara Mühendisliği Tezli Yüksek Lisans Programı
Danışman: Dr. Öğr. Üyesi Erdal GÜVENOĞLU

İstanbul
T.C. Maltepe Üniversitesi
Lisansüstü Eğitim Enstitüsü
Temmuz 2024

**YAPAY ZEKA İLE SOSYAL MEDYA UYGULAMALARINDA
SAHTE HABER TESPİTİ**

Hamza ERÖRS

21 14 02 206

ORCID: 0009-0005-9507-9165

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Tezli Yüksek Lisans Programı

Danışman: Dr. Öğr. Üyesi Erdal GÜVENOĞLU

İstanbul

T.C. Maltepe Üniversitesi

Lisansüstü Eğitim Enstitüsü

Temmuz, 2024



JÜRİ VE ENSTİTÜ ONAYI

HAMZA ERÖRS'in "Yapay Zeka İle Sosyal Medya Uygulamalarında Sahte Haber Tespiti" başlıklı tezi 23.07.2024 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Maltepe Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği" nin ilgili maddeleri uyarınca Bilgisayar Mühendisliği Anabilim Dalı Yüksek Lisans/Doktora/Sanatta Yeterlik tezi oy birliğiyle/oy çokluğuyla, başarılı/başarısız olarak kabul edilmiştir.

	Unvanı, Adı ve Soyadı	İmza
Üye (Tez Danışmanı)	Dr.Öğr.Üyesi Erdal GÜVENOĞLU Maltepe Üniversitesi
Üye	Dr.Öğr.Üyesi Engin OĞUZAY Maltepe Üniversitesi
Üye	Dr.Öğr.Üyesi Fatih YÜCALAR Manisa Celal Bayar Üniversitesi

Prof. Dr. Selva ERSÖZ
KARAKULAKOĞLU
Enstitü Müdürü

ETİK İLKE VE KURALLARA UYUM BEYANI

Bu belge, Yükseköğretim Kurulu tarafından 19.01.2021 tarihli “Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge” ile bildirilen 6698 Sayılı Kişisel Verilerin Korunması Kanunu kapsamında gizlenmiştir.



TEŐEKKÜR

Bu alıőmanın gerekleőtirilmesinde, iki yıl boyunca deęerli bilgilerini bizlerle paylaőan, kullandıęı her kelimenin hayatıma kattıęı önemini asla unutmayacaęım saygıdeęer danıőman hocam Dr. Öğr. Üyesi Erdal GÜVENOęLU 'na sonsuz teőekkürlerimi sunarım.

Hamza ERÖRS

Temmuz, 2024

ÖZET

YAPAY ZEKA İLE SOSYAL MEDYA UYGULAMALARINDA SAHTE HABER TESPİTİ

Hamza Erörs

Yüksek Lisans Tezi

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Tezli Yüksek Lisans Programı

Dr. Öğr. Üyesi Erdal Güvenoğlu

Maltepe Üniversitesi Lisansüstü Eğitim Enstitüsü, 2024

Günümüzde internete erişim kolaylığı ve teknolojinin gelişmesi ile kullanıcılar arasında bilgi ve etkileşim hızla artmıştır. Günümüzde en çok kullanılan sosyal medya uygulamaları arasında Instagram, X (Twitter), LinkedIn, Snapchat, TikTok, Reddit, Vimeo, YouTube, Dailymotion, Twitch, Vevo, TikTok (kısa videolar için), Instagram TV (IGTV), Facebook Watch ve diğerleri yer almaktadır. Bu uygulamalar aynı zamanda bilgiye erişim ve bilginin yayılma hızını da artırmaktadır. Kişilerin internet medyasına ilgi göstermesiyle, bu çevrimiçi haber kanallarının etki alanları gün geçtikçe genişlemektedir. Bu nedenle, yalan haberlerin yayılması önemli ölçüde artmıştır. Bu tez çalışması, yalan haberlerin yayılma nedenlerini, bu duruma karşı alınan önlemleri, önerilen metodolojileri, uygulanan yaklaşımları ve yeni yöntemleri ele alınmaktadır.

Anahtar Sözcükler: Yapay Zeka Uygulamaları, Yalan Haber Tespiti, Sahte Haber, Sosyal Medya

ABSTRACT

FAKE NEWS DETECTION IN SOCIAL MEDIA APPLICATIONS WITH ARTIFICIAL INTELLIGENCE

Hamza Erörs

Master Thesis

Department of Computer Engineering

Master's Program with Thesis in Computer Engineering

Thesis Advisor: Assist. Prof. Dr. Erdal Güvenođlu

Maltepe University Graduate School, 2024

With the ease of access to the internet and the advancement of technology, the rapid increase in information and interaction among users has occurred. Among the most widely used social media applications today are Instagram, X (Twitter), LinkedIn, Snapchat, TikTok, Reddit, Vimeo, YouTube, Dailymotion, Twitch, Vevo, TikTok (for short videos), Instagram TV (IGTV), Facebook Watch, and others. These applications also contribute to the increased access to and dissemination of information. As individuals show interest in online media, the influence of these online news channels is expanding day by day. Consequently, the spread of false news has significantly increased. This thesis aims to address the reasons for the spread of false news, the measures taken against this issue, proposed methodologies, approaches, and new methods applied.

Keywords: Artificial Intelligence Applications, Fake News Detection, Fake News, Social Media

İÇİNDEKİLER

JÜRİ VE ENSTİTÜ ONAYI	ii
ETİK İLKE VE KURALLARA UYUM BEYANI	iii
TEŞEKKÜR.....	iv
ÖZET	v
ABSTRACT.....	vi
İÇİNDEKİLER	vii
TABLolar LİSTESİ.....	xi
ŞEKİLLER LİSTESİ	xii
KISALTMALAR.....	xiv
BÖLÜM 1. GİRİŞ.....	1
1.1. Problem	2
1.2. Amaç	5
1.3. Önem	6
1.4. Varsayımlar	7
1.5. Sınırlıklar.....	8
1.6. Tanımlar	8
BÖLÜM 2. LİTERATÜR ARAŞTIRMASI.....	10
BÖLÜM 3. MATERYAL VE YÖNTEM	13
3.1. Yalan Haberin Toplum Üzerindeki Etkileri	13
3.2. Yalan Haberleri Tespit Etmenin Önemi.....	13
3.3. Türkçe Yalan Haber Belirlemenin Zorlukları	14
3.4. Yalan Haberin Yayılmasına Neden Olan Etkenler	15
3.4.1. Yanıltıcı manşetler	16

3.4.2.	Tıklama tuzakları	16
3.4.3.	Asparagas habercilik	16
3.4.3.1.	Yanlı kurgu.....	16
3.4.4.	Sahte hesaplar	17
3.4.5.	Şaka, latife tarzı mizah haberleri	17
3.4.6.	Hiciv ve parodi.....	17
3.4.7.	Partizan haber	17
3.4.8.	Komplo teorileri.....	17
3.4.9.	Nefret söylemi ve haberleri.....	18
3.4.10.	Uydurma haber.....	18
3.4.11.	Dedikodu haberler	18
3.4.12.	Yanlış bilgilendirme.....	18
3.4.13.	Provokatif haber	18
3.4.14.	Şehir efsaneleri.....	19
3.4.15.	Tanımsız sosyal medya hesapları.....	19
3.4.16.	Manipülasyon.....	19
3.4.17.	Propaganda.....	19
BÖLÜM 4. YALAN HABER TESPİTİNDE KULLANILAN YÖNTEMLER		20
4.1.	Doğal Dil İşleme ve Yalan Haber Tespit Yöntemi	20
4.1.1.	Yalan haberin analizi	20
4.1.2.	Dil bilimsel yaklaşımlar.....	20

4.1.3.	Ağ yaklaşımları	22
4.2.	Verilerden Özellik Çıkarımı.....	23
4.2.1.	TF-IDF modeli.....	23
4.2.2.	Word2Vec modeli.....	24
4.2.3.	Doc2Vec modeli	25
4.3.	Yapay Zeka Algoritmaları.....	26
4.3.1.	Naive Bayes	26
4.3.2.	BERT algoritması	27
4.3.3.	LSTM.....	29
4.3.4.	SVM.....	29
4.3.5.	Neural NetWorks TF	29
4.3.6.	Performans değerlendirme kriterleri.....	30
4.4.	Gerçekleştirilen Çalışma	32
4.4.1.	Verilerin toplanması	33
4.4.2.	Teyit.org sitesinde yayınlanan verilerin toplanması.....	33
4.4.3.	SnsCrape kütüphanesi ile X'den verilerin toplanması.....	33
4.4.4.	Verilerin işlenmesi	33
4.4.5.	Veri ön işleme	34
4.4.6.	Gürültülü verinin temizlenmesi	34
4.4.7.	Verilerden özellik çıkarımı	34
4.4.8.	Veri setinin bölünmesi	34

4.4.9. Verilerin görselleştirilmesi	35
4.4.10. Verilerin Etiketlenmesi	39
4.5. Yapay Zeka Algoritmalarının Kullanılması.....	39
4.5.1. Naive Bayes	40
4.5.2. BERT algoritması	45
4.5.3. LSTM algoritması.....	51
4.5.4. SVM algoritması.....	56
4.5.5. Neural NetWorks TF	61
BÖLÜM 5. DENEYSEL SONUÇLAR VE BULGULAR.....	67
5.1.Bulgular	67
5.2.Tartışma	70
BÖLÜM 6. SONUÇ ve ÖNERİLER.....	72
KAYNAKÇA.....	74
ÖZGEÇMİŞ	77

TABLULAR LİSTESİ

Tablo 1. NB Algoritması Doğruluk Oranı ve F1 Skoru Değerleri.....	40
Tablo 2. BERT Algoritması Doğruluk Oranı ve F1 Skoru Değerleri	46
Tablo 3. LSTM Algoritmasının Doğruluk Oranları ve F1 Skoru Değerleri	51
Tablo 4. SVM Algoritması Doğruluk Oranı ve F1 Skoru Değerleri.....	56
Tablo 5. Neural NetWorks TF Algoritması Doğruluk Oranı ve F1 Skoru Değerleri	61
Tablo 6. Test Oranlarına Göre Algoritmaların Doğruluk ve F1 Skor Sonuçları	68

ŞEKİLLER LİSTESİ

Şekil 1. 2023 Yılına Ait Sosyal Medya Kullanıcı Sayıları	1
Şekil 2. 2022 Dijital News Report Türkiye Medya Erişim Oranları	3
Şekil 3. Ükelere göre yalan haberlere maruz kalma oranları	5
Şekil 4. Word2Vec için CBOW ve Skipgram Eğitimi	25
Şekil 5. Bert Algoritması Öne Eğitim ve İnce Ayar	28
Şekil 6. Beş Ayrı Sınıflandırıcı Gösteren Örnek ROC Grafiği	32
Şekil 7. X’de Alından Veriler Arasında En Çok Kullanılan Kelimeler Grafiği.....	36
Şekil 8. X’de Alından Veriler Arasında Kullanıcılar Arasında Etkileşim	37
Şekil 9. X’de Alından Veriler Arasında En Çok Kullanılan Kelimeler	38
Şekil 10. NB Algoritmasında %25 Test Verisi İçin Doğruluk Matrisi	41
Şekil 11. NB Algoritmasında %50 Test Verisi İçin Doğruluk Matrisi	42
Şekil 12. NB Algoritmasında %75 Test Verisi İçin Doğruluk Matrisi	43
Şekil 13. NB Algoritmasında TF-IDF Modeli Kullanılarak Test Oranına Göre Performans Grafiği.....	45
Şekil 14. BERT Algoritmasında %25 Test Verisi İçin Doğruluk Matrisi.....	47
Şekil 15. BERT Algoritmasında %50 Test Verisi İçin Doğruluk Matrisi.....	48
Şekil 16. BERT Algoritmasında %75 Test Verisi İçin Doğruluk Matrisi.....	49
Şekil 17. BERT Algoritmasında Test Oranına Göre Performans Grafiği	50
Şekil 18. LSTM Algoritmasında %25 Test Verisi İçin Doğruluk Matrisi	52

Şekil 19. LSTM Algoritmasında %50 Test Verisi İçin Doğruluk Matrisi	53
Şekil 20. LSTM Algoritmasında %75 Test Verisi İçin Doğruluk Matrisi	54
Şekil 21. LSTM Algoritmasında Test Oranına Göre Performans Grafiği.....	55
Şekil 22. SVM Algoritmasında %25 Test Verisi İçin Doğruluk Matrisi	57
Şekil 23. SVM Algoritmasında %50 Test Verisi İçin Doğruluk Matrisi	58
Şekil 24. SVM Algoritmasında %75 Test Verisi İçin Doğruluk Matrisi	59
Şekil 25. SVM Algoritmasında Test Oranına Göre Performans Grafiği.....	60
Şekil 26. Neural NetWorks TF Algoritmasında %25 Test Verisi İçin Doğruluk Matrisi	62
Şekil 27. Neural NetWorks TF Algoritmasında %50 Test Verisi İçin Doğruluk Matrisi	63
Şekil 28. Neural NetWorks TF Algoritmasında %75 Test Verisi İçin Doğruluk Matrisi	64
Şekil 29. Neural NetWorks TF Algoritmasında Test Oranına Göre Performans Grafiği	65
Şekil 30. Algoritmaları Test Oranına Göre Performans Grafiği	70

KISALTMALAR

DDİ	:	Doğal Dil İşleme	Natural Language Processing
YSA	:	Yapay Sinir Ağları	Artificial Neural Networks
BERT	:	Transformer'dan Çift Yönlü Kodlayıcı Gösterimleri	Bidirectional Encoder Representations from Transformers
XGBoost	:	Aşırı Gradyan Artırma	eXtreme Gradient Boosting
LSTM	:	Uzun Kısa Süreli Hafıza	Long Short-Term Memory
DYZA	:	Denetimli Yapay Zeka Algoritması	Supervised Artificial Intelligence Algorithm
BERT	:	Çift Yönlü Kodlayıcı Temsilleri ile Dönüştürücüler	Bidirectional Encoder Representations from Transformers
RNN	:	Tekrarlayan Sinir Ağları	Recurrent Neural Network
SVM	:	Destek Vektör Makineleri	Support Vector Machine
API	:	Uygulama Programlama Arabirimi	Application Programming Interface
NB	:	Naive Bayes	Naive Bayes
CBOW	:	Sürekli Kelime Çantası	Continuous Bag of Words

Doc2Vec : Doküman Vektörü

Document to Vector

Word2Vec : Kelime Vektörü

Word to Vector

X :


Twitter



BÖLÜM 1. GİRİŞ

İnternetin yaygınlaşması, sosyal medyanın bilgi aktarımında merkezi bir rol üstlenmesine olanak tanımıştır. Bu platformlar, kullanıcıların birbirleriyle etkileşimde bulunmalarını sağlayarak, düşüncelerini, deneyimlerini ve bilgilerini anında paylaşmalarına imkan vermektedir. Bu sayede, bilgi akışı büyük bir hız kazanmış ve global iletişimde adeta bir devrim yaratmıştır. Sosyal medya, metin, görsel ve video içerikler aracılığıyla mesajların daha geniş kitlelere hızla ulaşmasını sağlamaktadır, bu da hem günlük yaşamdan kesitlerin hem de önemli sosyal ve politik olaylara dair anlık tepkilerin yayılmasını kolaylaştırmaktadır. Ancak, bu durum yanlış bilginin de aynı hızla yayılabilmesine yol açtığı için bilgi doğrulama ve eleştirel düşünme becerileri her zamankinden daha fazla önem arz etmektedir.

Şekil 1’de Meltwater ve We Are Social ile ortaklaşa hazırlanan Dijital 2023 Küresel Genel Bakış Raporunda 2023 yılına ait sosyal medya kullanıcı sayılarının yıl içerisindeki artışı grafikte gösterilmiştir (Report, 2023).



Şekil 1. 2023 Yılına Ait Sosyal Medya Kullanıcı Sayıları (Report, 2023)

Sosyal medyanın hızlı kullanıcı artışı bilgi yayılımını ivmelendirirken, bu bilgilerin doğrulanması zorunluluğunu da beraberinde getirmiştir.

Vosoughi ve arkadaşları tarafından yapılan arařtırmalar doęrultusunda yalan haberin yayılma hızının doęru habere göre daha geniş kitlelere %70 daha hızlı yayıldığı tespit edilmiştir (Vosoughi, Roy ve Aral, 2018).


Sosyal medyada yalan haberlerin doęru haberlere göre daha hızlı yayılmasının en önemli nedenlerinden biri, yalan haberlerin kullanıcılarda bıraktığı olumsuz etkilerin doęru haberlerinkinden çok daha güçlü ve çeşitli olmasıdır. Yalan haberler, kullanıcılar üzerinde şaşkınlık, korku ve tiksinti gibi olumsuz etkiler yaratırken; doęru haberler beklenti, üzüntü, neşe ve güven gibi duygular uyandırmaktadır (Vosoughi vd., 2018).

Bu tez çalışmasında bulgulardan yola çıkarak X'den alınan verilerden Doğal Dil İşleme (Natural Language Processing, NLP) ve yapay zeka algoritmaları kullanılarak yalan haberin tespiti yapılarak ve kullanılan algoritmaların doęruluk oranlarının kıyaslanması sağlanacaktır.

1.1. Problem

Teknolojinin gelişmesiyle birlikte günümüzde insanlar, geleneksel haber kanallarından farklı olarak gündemi takip etmek için sosyal medya platformlarını tercih etmektedir. Sosyal medya kullanıcıları, bu platformları çok yönlü amaçlarla kullanmaktadır: bazıları için bu platformlar güncel olaylar ve haberler hakkında bilgi sahibi olma aracı, bazıları için çeşitli ticari faaliyetleri destekleme ve pazarlama stratejileri geliştirme alanı, bazıları için ise günlük yaşam pratiklerini yansıtan ve sosyal kimliklerini ifade etme imkanı sunan birer yaşam tarzı unsuru olarak öne çıkmaktadır. İnsanların bu sanal iletişim kanallarını kullanım nedenleri deęişiklik gösterse de bilgiye erişimin ve yayılımının kolay ve hızlı olması ana nedenlerdendir.

Şekil 2'de, 2022 Dijital Haber Raporu'nda Türkiye'deki sosyal medya kullanım oranlarının 2015-2022 yılları arasındaki artışını gösteren analiz sonuçları yer almaktadır (Report, 2022).



Şekil 2. 2022 Dijital News Report Türkiye Medya Erişim Oranları (Report, 2022)

Geleneksel haber kanallarını denetlenmesi ve içerdikleri bilgileri kontrol edilmesi daha kolay olduğundan, yalan haberlerin yayılması engellenebilmektedir. Ancak dijitalleşen dünyada insanların haber kaynakları çeşitlenmiştir ve artık sosyal medya portalları (X, WhatsApp, Instagram vb.) kullanarak, çift yönlü bir iletişim ağı kullanmaktadır. Bu ağda genellikle karmaşık bir etki-tepki döngüsü yaşanmaktadır. Kullanıcılar arasındaki etkileşimler, paylaşım, beğeni ve yorum yapma şeklinde çeşitlenir. Bu süreç, haberlerin öznel bir perspektifle yayılmasına ve denetleyici kurumların bu bilgilerin doğruluğunu etkin bir şekilde kontrol etmesini zorlaştırır. Yapılan araştırmalar, bir haberin yayılma hızının ilk iki ile 20. saat arasında en yüksek olduğunu belirtmektedir. Bu bağlamda, yalan haberlerin hızla tespit edilerek, geliştirilen sistemler aracılığıyla derhal engellenmesi büyük önem arz etmektedir (Taşkin, KüçükSille ve Topal, 2020).

Günümüz medya koşullarında, yalan haberlerin üretimi ve yayılımı daha kolay hale gelmiştir, bu da doğru bilginin kamuoyu tarafından alınıp yayılmasını büyük ölçüde engellemektedir. "Post-truth (gerçek-sonrası)" kavramı, çağımızı tanımlayan önemli terimler arasında yer almakta ve özellikle yalan haberlerin neden olduğu olumsuz etkilere işaret etmektedir. Bu terim, toplumda gerçeklerin ve hakikat arayışının öneminin azaldığını, buna karşılık kişisel inançlar veya öznel yaklaşımlarla uyumlu olan yalan haberlerin etkisinin arttığını vurgulamaktadır. Post-truth dönemi, bireylerin ve toplumların, gerçeklerden ziyade, kendi önyargılarını ve inanç sistemlerini doğrulayan bilgilere daha fazla itibar ettikleri bir dönem olarak tanımlanabilir. Bu durum, medya

okuryazarlığı ve kritik düşünme becerilerinin geliştirilmesinin önemini artırmaktadır (Kavaklı, 2018).

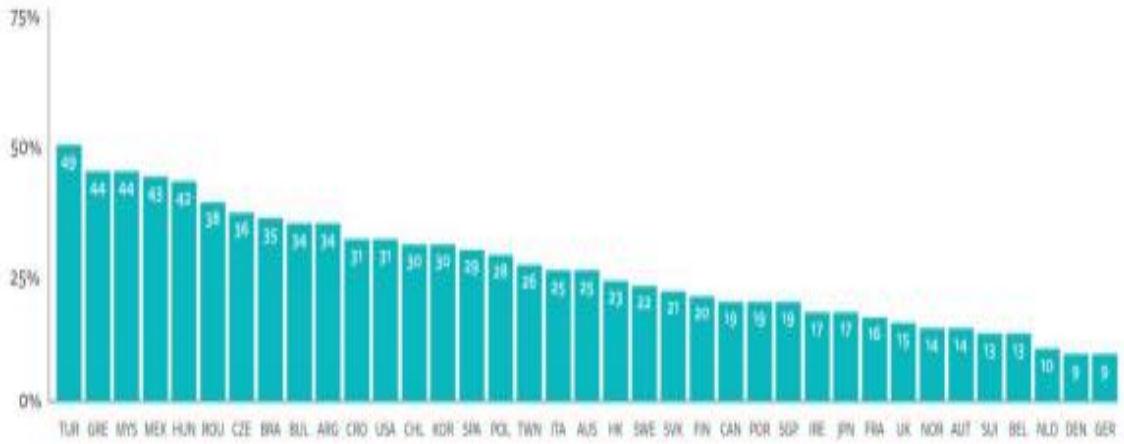
Yalan haberler, sosyal medyada hızla yayılan asılsız haberlerin ötesine geçerek, çeşitli amaçlar için kasıtlı olarak kullanılmaktadır. Bu tür haberler, genellikle hiciv, siyasi göndermeler veya muhalifleri itibarsızlaştırma gibi niyetlerle üretilir ve toplum üzerinde manipülatif bir etki yaratma potansiyeline sahiptir. Teknolojinin ve yapay zekanın ilerlemesiyle birlikte, yalan haberler artık yalnızca metinsel dezenformasyonla sınırlı kalmamakta, aynı zamanda görüntü manipülasyonları gibi daha sofistike yöntemler de kullanılmaktadır. Gelişmiş görüntü işleme yazılımları ve tekniklerin yaygınlaşmasıyla görsel yalan habercilik, giderek daha fazla dikkat çeken bir sorun haline gelmiştir. Gerçek görüntülerin ve videoların yanlış bir anlatı yaratmak için kullanıldığı bu dönemde, medya okuryazarlığının artırılması ve kullanıcıların yanıltıcı bilgilere karşı farkındalıklarının geliştirilmesi zorunlu hale gelmiştir. Bu bağlamda, kitle iletişim araçları, izleyicilerin dikkatini çekmek amacıyla bu teknikleri etkin bir şekilde kullanmaktadır (Tandoc, Lim ve Ling, 2017). Görsel yalan haberin örneklerinden biri 2012 yılında Sandy Kasırgası sırasında yaşanmıştır. Kasırganın yaşanmasından kısa süre sonra X’de dolaşan manipüle edilmiş fotoğraflarla, ilgili çalışmalarında yalan haberlerin işlevselliği kullanılmıştır. New York’taki Özgürlük Heykeli’nin dalgalar tarafından hırpalandığını gösteren fotoğraf, NY1 kanalının canlı yayınından geliyormuş gibi gösterilmiştir. Fotoğraf, gerçekte hayali bir felaket filmi ile Sandy Kasırgası’nın gerçek görüntülerinin birleşimidir (Zubiaga, Aker, Bontcheva, Liakata ve Procter, 2018).

Sosyal medya platformlarında yanlış bilgilerin hızlı bir şekilde yayılması, toplum üzerinde olumsuz etkilere neden olmaktadır. Bu durum, yanlış bilgilendirilmiş bir toplumun yanı sıra, sosyal ve politik gerilimlerin artmasına da yol açabilir. Dolayısıyla, yanlış haberlerin erken tespiti ve yayılmasının engellenmesi için etkili uygulamaların geliştirilmesi büyük önem taşımaktadır. Bu uygulamalar, algoritmik filtreleme, içerik doğrulama ve kullanıcı eğitimi gibi yöntemlerle desteklenebilir. Bu çok yönlü yaklaşım, toplumun doğru bir şekilde bilgilendirilmesini sağlamak ve yanlış bilginin zararlarını en aza indirmek için hayati öneme sahiptir.

1.2.Amaç

Bilgiye erişim ve yayılma olanaklarının sosyal medya aracılığıyla artması, doğru bilginin manipüle edilerek toplum üzerinde ciddi sorunlar doğurabileceği bir ortam yaratmaktadır. Yalan haberlerin yayılma hızı, doğru haberlere kıyasla daha yüksek olduğundan, paylaşılan bilginin doğrulanması ve sosyal medya kullanıcılarına ulaşması genellikle yetersiz kalmaktadır. Örneğin, 2023 Şubat ayında Türkiye'nin Hatay ilinde meydana gelen deprem sırasında kurtarma çalışmaları devam ederken, sosyal medyada Yerseli Barajı'nın çatladığına dair yalan bir haber yayılmıştır. Bu asılsız iddia, deprem bölgesindeki kurtarma çalışmalarının durmasına ve enkaz altındaki insanların hayatını daha da riske atmasına neden olmuştur. 2017 yılında yapılan araştırmalara göre, ülkelere göre yalan habere maruz kalma sıralamasında Türkiye ilk sırada yer almaktadır (Shu, Sliva, Wang, Tang ve Liu, 2017).

Şekil 3'te yalan habere maruz kalan ülkelerin oranları gösterilmektedir.



Şekil 3. Ünelere göre yalan haberlere maruz kalma oranları (Shu vd., 2017).

Bu çalışmada, yalan haberin toplum üzerindeki etkileri, yalan haberlerin yayılmasına neden olan faktörler ve Türkçe haberlerin tespit edilmesinde yaşanan zorluklar incelenecektir. X (Twitter)'den alınan, haber niteliği taşıyan tweetler, referans kabul edilen Teyit.org sitesindeki analizlere dayanarak etiketlendikten sonra yalan haber tespiti için farklı test oranlarında yapay zeka algoritmaları kullanılarak algoritmaların doğruluk

oranlarının kıyaslanması sağlanacaktır. Aşağıda, belirlenen bir konu üzerinden yalan haberlerin tespitinde yapılacak işlem adımları yer almaktadır.

Yalan haber tespiti için yapılacak işlem adımlarını şu şekilde özetleyebiliriz:

- X 'de alınacak veriler için analiz edilecek konunun seçilmesi.
- Python da SnsCrape kütüphanesi aracılığıyla X'den verilerin toplanması.
- X'den alınan verilerin sözcüksel dağılımlarının görselleştirilmesi.
- Teyit.org sitesinde belirlenen konuya dair yapılan analizler doğrultusunda X'den alınan verilerin doğru ve yalan olarak işaretlenmesi.
- Toplanan verilerin ön işleme tabi tutularak temizlenmesi.
- Doğru ve yalan olarak işaretlenen verilerden özellik çıkarımı
- Farklı yapay zeka algoritmalarının kullanılarak doğruluk oranlarının kıyaslanması.

1.3.Önem

Yalan haberler, yüksek öğretimde gerçekleştirilen akademik çalışmalar ve basın yasası düzenlemeleriyle ilgilenen yetkililer için giderek artan bir öneme sahiptir. Bu alanda, yapay zekanın bir alt dalı olan Doğal Dil İşleme (Natural Language Processing, NLP) tekniklerine yönelik ilgi büyük oranda artmıştır. Bu teknikler, yalan haberlerin etkin bir şekilde tespit edilmesi ve teşhis edilmesi için kullanılan Doğal Dil İşleme (DDİ) metodolojileri aracılığıyla hayata geçirilmektedir. Bu metodolojilerin geliştirilmesi, yalan haberlerin yayılımının önlenmesine katkı sağlamakta ve insanların sosyal medya ile çeşitli çevrimiçi haber platformlarına olan güvenini pekiştirmektedir. Bilgilerin ve haberlerin hızla deforme olabildiği günümüzde, çevrimiçi ortamdaki bu kontrolsüz akışı düzenlemek büyük bir zorunluluk haline gelmiştir. İletişimin karşılıklı olduğu sosyal medya ortamında büyük veri hacimleri (Big Data) oluşmakta, bu verilerin beraberinde getirdiği karmaşıklığı anlamak ve yönetmek giderek daha zor bir hâl almaktadır. Bu karmaşıklığı çözmek ve yayınlanan haberlerin sahte bilgi içerip içermediğini belirlemek için yapay zeka teknolojilerinden yararlanılmaktadır. Böylece, insan eliyle aşılması zor olan dezenformasyon problemi, yapay zeka teknolojisi aracılığıyla kontrol altına alınmaktadır. Sosyal medyada yer alan haberler ve yorumlar, insanların görüşlerini önemli ölçüde etkilemekte ve sahte olarak yayılan haberler bireylerin ve toplumların hayatlarını olumsuz yönde etkilemektedir. Yalan haberlerin zararları, yalnızca bireyler ve

toplumlarla sınırlı kalmayıp, iş dünyasını, hükümet yapılarını ve genel toplum düzenini de olumsuz yönde etkilemektedir. Bu nedenle, yapay zeka destekli çözümler, bu tür zararların önlenmesinde kritik bir rol oynamaktadır (Altunbey Özbay ve Alataş, 2020).

DDİ teknikleri, yalan haberlerin tespiti ve doğru haberlerin hızlı yayılması açısından en etkin yöntemler arasında yer almaktadır. Bu teknoloji sayesinde, kullanıcılar bilgi paylaşımlarının doğruluğunu sorgulamadan, doğrudan teknolojiye güvenerek bu bilgileri kabul edebilirler. Yalan haber tespitinin büyük bir önem taşıdığı günümüzde, konuya dair yapılan literatür taramaları, yalan haberlerle mücadelede artan akademik çalışmaları göstermektedir. Bu durum, DDİ yöntemlerinin yalan haberlerle mücadelede merkezi bir role sahip olduğunu ve bu alanda yapılan araştırmaların sürekli genişlediğini ortaya koymaktadır.

Bu tez çalışması, yalan haberlerin tespitinde kullanılan yapay zeka algoritmalarının etkinliğini incelemeyi amaçlamaktadır. Bu çalışmada, yapay zeka algoritmaları kullanılarak, sosyal medya platformları ve çevrimiçi haber kaynaklarından elde edilen veriler üzerinde yalan haberlerin tespiti gerçekleştirilecektir. Algoritmaların performansı ve doğruluk oranları karşılaştırılarak, hangi yöntemlerin sahte bilgiyi en etkili şekilde tespit edebildiği ve doğru haberlerin hızlı yayılmasını nasıl destekleyebileceği değerlendirilecektir. Bu araştırma, yalan haberlerin sosyal medyada ve çeşitli dijital platformlarda yayılmasını engellemeye yardımcı olacak teknolojik çözümleri geliştirme çabasını desteklemeyi hedeflemektedir.

1.4.Varsayımlar

Bu tez çalışmasında, milyonlarca aktif kullanıcıya sahip olan X sosyal platformu üzerinden orman yangınları ile ilgili yayınlanmış yalan haberlerin tespiti gerçekleştirilmiştir. Teyit.org sitesinde yapılan analizlere dayanarak, X platformundan alınan ve haber niteliği taşıyan tweetlerin doğru ve yalan olarak etiketlenmesinin yeterli olacağı varsayılmaktadır. Çalışmada, metinsel verileri işlemek ve değerlendirmek için DDİ metodolojileri ve yapay zeka algoritmaları kullanılmaktadır. Performans kriterlerine göre, Naive Bayes, BERT, LSTM, SVM ve Neural Networks TF (TensorFlow) olmak üzere beş farklı yapay zeka algoritmasının denemesi uygun görülmektedir. Bu

algoritmaların, metinsel verilerin işlenmesi ve yalan haberlerin tespiti konusunda etkin sonuçlar vereceği öngörülmektedir.

1.5.Sınırlıklar

Bu tez çalışmasında, yalan haberlerin tespitinde orman yangınları ile ilgili haberlerin SnsCrape kütüphanesi kullanılarak kategorize edilmesi ve bunların doğruluğunu ayırt eden yapay zeka algoritmalarının doğruluk oranlarının kıyaslanması ele alınmaktadır. Yapay zeka algoritmalarının geliştirilmesinde en önemli adımlardan biri, metinsel veri bulma ve veri seti oluşturma işlemidir. Ancak, haber verilerinin çoğunlukla ücretli olması, istenilen verilerin kolaylıkla ulaşılabilir ve yeterli düzeyde olmasını engelleyerek geliştirme sürecini sınırlamaktadır. SnsCrape kütüphanesi, X'den verileri web scraping (web kazıma) yöntemi ile topladığından, X tarafından engelleme olmaması için sınırlı sayıda veri toplanabilmiştir.

1.6.Tanımlar

Yalan Haber: Bilinçli olarak yanıltıcı veya gerçekleri çarpıtacak, toplumu yanlış bilgilendiren, kafa karışıklığına ve okuyucuların duygularına hitap eden yanlış bilgiler içeren haberdur. Yalan haberlerin yaygın olan genel özellikleri arasında bilinçli yanıltma manipülasyon, uydurma içerikler gerçek karışımı yalan bilgiler içermektedir. Yalan haberlerin yayılmasında en çok kullanılan platformlar web siteleri, sosyal medya uygulamaları, e posta ve cep telefonlarına gönderilen mesajlar aracılığıyla yapılmaktadır.

Doğal Dil İşleme: DDİ, insanların konuşma veya yazı şeklindeki doğal dilini anlayıp işleyebilme yeteneği kazandırmak için yapay zeka ve makine öğrenmesi teknolojilerinin beraber kullanıldığı bir disiplindir. DDİ temel amacı, makineleri insan dilini doğru bir şekilde anlama, yorumlama ve hatta bu dili kullanarak insanlarla etkileşime girebilme kapasitesiyle donatmaktır. DDİ, veri analizi, çeviri, duygu analizi gibi birçok farklı uygulama alanında kullanılmakta olup, teknoloji ile insan arasındaki etkileşimi daha akıcı ve anlamlı hale getirmeyi amaçlar. Kullandığımız teknolojik aletlerin konuştuğumuz dili çözümlüyor olması ve bize geri çıktı vermesi doğal dil işlemedir.

Derin Öğrenme: Derin öğrenme, insan beyninin işleyişini taklit eden yapay sinir ağları üzerine kurulu bir makine öğrenmesi tekniği olarak tanımlanabilmektedir. Temel amacı, büyük ve karmaşık veri kümelerinden öğrenerek, bu verilerdeki desenleri ve özellikleri otomatik olarak tespit etmek ve kullanmaktır. Derin öğrenme, görüntü ve ses tanıma, doğal dil işleme ve robotik gibi alanlarda geniş uygulama alanlarına sahiptir (Nielsen, 2015).

Yapay Sinir Ağları: Yapay sinir ağları (YSA), insan beyninin bilgi işleme şeklini modelleyen ve makine öğrenmesi uygulamalarında yaygın olarak kullanılan matematiksel modellerdir. Bu sistemler, gerçek sinir ağlarının işlevselliğini taklit ederek karmaşık desenleri ve veri ilişkilerini öğrenme yeteneği sunmaktadır. Yapay sinir ağları, birbiriyle bağlantılı düğümlerden (neuronlar) oluşur ve bu düğümler aracılığıyla veri işlenmektedir (Nielsen, 2015).

SnsCrape Kütüphanesi: Python kütüphanesi, sosyal medya platformlarından veri çekmek için tasarlanmış bir kütüphanedir. API (Uygulama Ara Birimi, Application Programming Interface) kullanmadan, yani platformların resmi veri erişim araçlarını kullanmadan, doğrudan web scraping yöntemiyle çalışmaktadır. Bu özelliği sayesinde kullanıcıların çoğu zaman API sınırlamaları olmadan geniş veri setlerine erişebilmelerini sağlamaktadır.

Teyit.org: 2016 yılında Türkiye'de kurulan bağımsız bir doğrulama platformudur. Bu platform, sosyal medya ve diğer dijital platformlarda yayılan bilgilerin doğruluğunu sorgulayarak yalan haberleri tespit etme ve yanıltıcı bilgilere karşı kamuoyu farkındalığı yaratma amacını taşımaktadır. Teyit.org, medya ve sosyal medyada yer alan haberler, görseller, videolar ve iddialar üzerine derinlemesine araştırmalar yaparak, bu içeriklerin kaynaklarını doğrular ve çeşitli veri tabanları ile uzman görüşlerinden yararlanarak analizler gerçekleştirmektedir. Platform, objektif ve şeffaf metodolojiler kullanarak, halkın doğru bilgiye erişimini kolaylaştırmayı hedeflemektedir.

BÖLÜM 2. LİTERATÜR ARAŞTIRMASI

K. Havai ve arkadaşlarının 2021 yılında dünya çapında meydana gelen COVID-19 aşılı hakkında X 'den almış oldukları tweetleri sınıflandırmak için bir veri seti geliştirmiştir. Bu çalışmada, 15.000'den fazla tweet, güvenilir kaynaklar ve tıbbi uzmanlar tarafından yanlış bilgi içeren veya genel aşı tweetleri olarak etiketlenmiştir. Makine öğrenimi modelleri arasında BERT (Çift Yönlü Kodlayıcı Temsilleri ile Dönüştürücüler, Bidirectional Encoder Representations from Transformers), XGBoost (Aşırı Gradyan Artırma, eXtreme Gradient Boosting) ve LSTM (Uzun Kısa Süreli Hafıza, Long Short-Term Memory) gibi çeşitli makine öğrenimi modelleri kullanılmıştır. Bu modeller, etiketlenmiş tweetleri yanlış bilgilendirme içeren veya içermeyen diye ayırt etmek için eğitilmiştir. Çalışma sonucunda BERT modelinin %98 F1 ile en iyi olduğunu tespit edilmiştir (Hayawi, Shahriar, Serhani, Taleb ve Mathew, 2022). Yapılan çalışmaya göre, sosyal medya sitelerinin yanlış bilgilendirmeyi azaltmak ve aşı karşıtı sosyal botları bulmak için bu veri setlerini ve modelleri etkili bir şekilde kullanması mümkün kılmaktadır. Ayrıca çalışmada, yanlış bilgilendirme içeren tweetlerin ve bunların zaman içindeki yayılma modellerinin daha kapsamlı bir analizini yapması konusunda çalışmalar yapılması gerektiğini vurgulamıştır (Hayawi vd., 2022).

2017 yılında, Kai Shu ve arkadaşları, LIAR, BuzzFeedNews ve FakeNewsNet gibi kaynaklardan yararlanarak sosyal medyada yalan haber tespiti için çeşitli teknikler incelenmiştir. Çalışma, yalan haberlerin tanımını, karakteristiklerini ve tespit yöntemlerini kapsamlı bir şekilde ele almışlardır. Özellikle, yalan haberlerin sosyal medyada nasıl yayıldığına dair benzersiz özellikler ve zorluklar üzerinde durulmaktadır. Bu çalışmada kullanılan başlıca teknikler arasında, sosyal medya etkileşimlerini ve kullanıcı davranışlarını analiz eden veri madenciliği yöntemleri bulunmaktadır. Yalan haber tespiti için kullanılan algoritmalar, haber içeriği yanı sıra sosyal bağlamı da göz önünde bulundurulmuştur, bu da yalan haberleri daha etkin bir şekilde tespit etmeye yardımcı olmaktadır. Örneğin, kullanıcı etkileşimleri ve yayılma modelleri gibi yardımcı bilgiler, haberlerin doğruluğunu değerlendirmede önemli rol oynamaktadır.

Ayrıca, çalışmada sosyal medya kullanıcılarının yalan haberlere karşı savunmasızlıkları ve bu haberlerin psikolojik etkileri gibi sosyal ve bilişsel dinamikler üzerinde durulmuş, yalan haberlerin bireyler ve toplumlar üzerindeki olumsuz etkileri vurgulanmıştır (Shu vd., 2017).

Kumari ve ark. tarafından yapılan çalışmada otomatik yanlış bilgi tespiti metodolojilerine yenilikçi bir yaklaşım getirerek, duygu tahmini ve metinsel yanlış tespiti öne çıkarmaktadır. Araştırmada, metinsel çıkarım teknikleri kullanılarak eğitilmiş modellerin, büyük ölçekli veri setlerindeki sahte bilgileri sınıflandırmada nasıl kullanılabilirliği incelenmiştir. Elde edilen sonuçlar, haberin yeniliği ve duygusal etkileşimi, yalan haberlerin yayılmasının önemli bir özelliği olarak göstermektedir. Araştırma, derin öğrenme ve makine öğrenimi tekniklerini bütünleştiren bir model geliştirmiş ve bu modelin, çeşitli veri setlerinde mevcut sistemlere göre daha yüksek doğruluk oranları elde edilmiştir. Bu bulgular doğrultusunda yanlış bilgiyle mücadelede duygusal ve yenilikçi unsurların nasıl etkili kullanılabilirliğini vurgulamakta ve alanında ileri araştırmalar için yeni bir perspektif sunmaktadır (Kumari, Ashok, Ghosal, Ekbal ve Management, 2022).

Mertoğlu tarafından 2020 yılında yapılan çalışmada Türkçe haber metinlerinde yalan haber tespiti için kapsamlı bir metodoloji geliştirilmiştir. Bu metodoloji, dilbilimsel analizleri ve çeşitli yapay zeka tekniklerini entegre ederek yüksek performanslı bir tespit sistemi oluşturmayı amaçlamıştır. Çalışma, klasik makine öğrenimi algoritmaları olan karar ağaçları, rastgele ormanlar ve lojistik regresyonun yanı sıra, metinlerin uzun vadeli bağlamsal özelliklerini ve duygusal tonlarını yakalayabilen LSTM gibi derin öğrenme modellerini kullanmıştır. Yapılan çalışmada, özellikle Türkçe'nin sondan eklemeli ve zengin morfolojik yapısını analiz edebilmek için özelleştirilmiş bir dil modeli geliştirmiştir. Bu model, yalan haberleri semantik ve sözlüksel özellikleri üzerinden etkili bir şekilde sınıflandırabilmekte, dilin doğal özelliklerini derinlemesine işleyebilmektedir. Geliştirilen sistem, çeşitli test veri kümeleri üzerinde gerçekleştirilen değerlendirmelerde yüksek doğruluk oranları elde ederek, Türkçe metinlerde yalan haber tespiti için güçlü ve etkili bir çözüm sunduğunu kanıtlamıştır (Mertoğlu, 2020).

Özbay ve ark. tarafından, 2020 yılında geliştirilen çalışma, sosyal medyada yalan haberlerin tespiti için iki aşamalı bir model önermektedir. İlk aşamada, yapılandırılmamış veriler yapılandırılmış verilere dönüştürülmektedir. İkinci aşamada ise, elde edilen yapılandırılmış yalan haber veri seti üzerinde çeşitli denetimli yapay zeka algoritmaları uygulanmıştır. Önerilen model, dört farklı eğitim-test bölümlenmesi kullanılarak değerlendirilmiş ve Naive Bayes (NB), JRip, J48, Rastgele Orman ve Stokastik Gradyan İnişi gibi algoritmaların performansları karşılaştırılmıştır. Bu değerlendirme, her bir algoritmanın gerçek veriler üzerindeki başarı oranlarını kıyaslayarak, modelin etkinliğini ortaya koymuştur. Bu çalışma, sosyal medya platformlarında yalan haber tespiti konusunda önemli bir metodolojik katkı sağlamaktadır (Altunbey Özbay ve Alataş, 2020).

BÖLÜM 3. MATERYAL VE YÖNTEM

Bu bölümde, yalan haberlerin etkileri ve yayılmasına neden olan faktörler üzerinde durulacak, yalan haberlerin toplum üzerindeki etkileri ve bu haberlerin tespit edilmesinin önemi detaylı bir şekilde incelenecektir. Ayrıca, yalan haberleri tespit etme süreçleri ve karşılaşılan zorluklar, yanı sıra yanıltıcı haber türleri ve yayılma yöntemleri de ele alınacaktır. Bu çalışma, yalan haberlerin sosyal medya ve diğer platformlarda nasıl bir etki yarattığına ve bu haberlerle mücadele stratejilerine ışık tutmayı amaçlamaktadır.

3.1. Yalan Haberinin Toplum Üzerindeki Etkileri

Yalan haberlerin yayılmasındaki en büyük etken, okuyucular üzerinde bıraktığı olumsuz etkilerin doğru haberlerin yarattığı etkiden daha güçlü ve etkili olmasıdır. Yalan haberler, okuyucular üzerindeki bu güçlü etki nedeniyle daha hızla yayılmakta ve doğru haberlerin manipüle edilmesi yoluyla toplumsal algıları ve kararları etkilemektedir.

Pennycook ve ark. yaptıkları çalışmada, yalan haberlerin toplum üzerindeki etkilerini incelemiştir. Araştırma, yalan haberlerin genellikle insanların mevcut inanç ve değerleriyle örtüşen hikayeleri desteklediğini ve bu nedenle bu tür haberlerin kolayca paylaşılabilirliğini ortaya koymuştur. Çalışma, insanların yalan haberlere inanma eğiliminin daha az analitik düşünme kapasitesi ile ilişkili olduğunu ve yalan haberlere daha fazla maruz kalan insanların bu tür içeriklere daha fazla inandığını ve bunları daha fazla yayma eğiliminde olduğunu sonucuna varmışlardır. Bu bulgular, yalan haberlerin sadece bireylerin davranışlarını değil, aynı zamanda toplumsal düzeyde algıları ve karar verme süreçlerini de nasıl şekillendirebileceğini göstermektedir. Çalışma, yalan haberlerin toplum üzerindeki zararlı etkilerini azaltmak için insanların eleştirel düşünme becerilerini geliştirmeye ve bilgi okuryazarlığını artırmaya yönelik stratejilerin önemini vurgulamaktadır (Pennycook, 2020).

3.2. Yalan Haberleri Tespit Etmenin Önemi

Yalan haberlerin tespit edilmesinin önemi demokratik bir toplumda doğru bilginin korunmasını sağlamak açısından da önemlidir. Güvenilir haber kaynaklarına dayalı doğru

bilgi, insanların sağlıklı bir şekilde karar vermelerine ve toplumsal konularda etkili bir şekilde tartışmalarına yardımcı olabilir. Yalan haberlerin tespit edilmesi bilgi bütünlüğünü koruma, manipülasyonları önleme, demokratik süreçlerin korunması toplumsal güvenin artması, sağlık bilgilerinin doğru yönlendirilmesi, toplumsal güvenin artması, sosyal uyumluluk, ekonomik etkilerin azaltılması gibi kritik önem taşıyan konularında taşımaktadır. Bu nedenle, sosyal medya platformları ve diğer haber kaynakları, yalan haberleri tespit etmek için çeşitli araçlar ve stratejiler geliştirilmelidir.

Yalan haberlerin tespit edilmesinin önemi, birçok akademik çalışmada vurgulanmıştır. Örneğin, Zubiaga ve ark. gerçekleştirdikleri çalışmada, yalan haberlerin tespit edilmesi ve sosyal medyada nasıl yayıldığına analizine odaklanmıştır. Bu çalışma, yalan haberlerin saptanması ve yayılmasının önlenmesi konusunda derinlemesine bir inceleme sunmakla birlikte bu konuda kullanılacak çeşitli yöntem ve teknikler sunmaktadır. Araştırmada, yalan haberlerin yayılma biçimlerini anlamak için sosyal medya platformlarında paylaşılan içerikler üzerinde kapsamlı bir veri analizi yapılmıştır. Çalışma, yalan haberlerin sıklıkla nasıl viral hale geldiğini ve gerçek haberlerden farklı olarak sosyal ağlarda nasıl bir yayılma gösterdiğini ortaya koymuştur (Zubiaga vd., 2018).

3.3.Türkçe Yalan Haber Belirlemenin Zorlukları

Sosyal medya kullanıcılarının artması ve internet kullanımının artması ile yüksek miktarda bilgi üretilmektedir. Artan bilginin hızlı bir şekilde analiz edilmesi ve bilginin yalan veya doğru olarak tespit edilmesi her geçen gün önemini artırmaktadır. Yalan ve doğru haber tespitinde DDİ yöntemleri kullanırken sonuçların yüksek oranda doğruluk oranı verebilmesinde en büyük etken verilerin doğru bir şekilde etiketlenmesi ve verilerden özellik çıkarımı olmaktadır. Verilerden özellik çıkarımı yapılırken dilin morfolojik yapısı göz önünde bulundurulduğunda doğru metodolojilerin uygulanması gerekmektedir. Türkçe morfolojik olarak zengin bir yapısına sahip olması ve dilin sondan eklemeli bir yapıya sahip olmasından dolayı verilerden özellik çıkarımı yapıldığında Türkçe diline özgü yöntemlerin uygulanması doğruluk oranının artmasına fayda sağlayacaktır. İngilizce dil yapısı olarak izole ve kurallara bağlı olmakla birlikte ünlü

uyumu gibi kurallar barındırmadığından dolayı İngilizce dilin DDİ metodolojilerin uygulanması Türkçe 'ye göre daha kolay olmaktadır.

Oflazer tarafından, Türkçe'nin doğal dil işleme alanındaki özel zorlukları ve bu zorluklara yönelik çözüm önerileri derinlemesine incelenmiştir. DDİ yöntemleri kullanılırken dilinin morfolojik yapısı göz önünde bulundurularak metin analizinde kökleri ve ekleri doğru bir şekilde tanımlanması gerektiğini, söz dizimsel esnekliği nedeniyle kelimenin yüklem, özne ve nesnenin yeri değişeceğinden dolayı kelimenin anlamını çözmekte zorlanacağını, ünlü uyumu gibi özgün dilbilimsel kuralların anlaması ve uygulanması gibi morfolojik özelliklerin DDİ metodolojilerin kullanılmasında zorluklar yaşanacağını ve bu zorluklara karşı çözüm önerileri sunmaktadır (Oflazer, 2016).

Bozuyla tarafından Türkçe yalan haberleri tespit etmek için gelişmiş dil işleme tekniklerini ve makine öğrenimi algoritmalarını ele alarak çalışmanın, Türkçe'nin zengin morfolojik yapısının doğal dil işleme için özel zorluklar oluşturduğunu belirtmektedir. Yaygın teknolojilerden biri olarak, BERT ve onun Türkçe versiyonu olan BERTurk modellerini kullanarak, geleneksel ön işleme adımlarını minimize ederek, yüksek doğrulukta yalan haber tespiti sağlamak için kullanmıştır. BERTurk, diğer makine öğrenimi modellerine kıyasla daha basit bir iş akışı sunmakla birlikte yüksek doğruluk oranları elde edilmesi sağlanmıştır. Yaptığı çalışmada ayrıca, bu teknolojilerin Türkçe yalan haber tespiti üzerine etkileri detaylı bir şekilde incelenip ve karşılaştırılması sağlanmıştır (Bozuyla, 2022).

3.4. Yalan Haberin Yayılmasına Neden Olan Etkenler

Modern hayatta internet kullanımının artması, internet kullanıcıları arasındaki etkileşim hızını da artırmıştır. Bu durum, internet kullanıcıları ve medya organları tarafından yalan haberlerin yayılmasına, doğru haberlerin manipüle edilmesine, finansal karlılık hedeflerinin artırılmasına ve toplum üzerinde siyasi ve sosyolojik etkiler yaratma amaçlarına yol açmaktadır. Bu nedenle, farklı yöntemler ve amaçlar doğrultusunda yalan haberlerin yayılması için etkili yöntemler uygulanmaktadır. Bu durum, uluslararası toplum için önemli bir sorun haline gelmiştir. Bunun temel nedeni, yalan haberlerin siyasi, ekonomik ve hatta stratejik amaçlar için kullanılmasıdır. Bu konu hem sayısal hem

de sosyal bilimlerin ilgi ve etki alanına girerek oldukça hassas bir şekilde ele alınması gereken bir mesele haline gelmiştir.

3.4.1. Yanıltıcı manşetler

Yanıltıcı manşetler, bilginin gerçekliğiyle herhangi bir ilgisi olmayan, okuyucular üzerinde bakış açısı ve fikir oluşturmayı amaçlayan, dikkat çekmek, tıklanmaları artırmak ve takip sayılarını yükseltmek hedefiyle oluşturulan görsel veya metinsel içeriklerdir. Bu tür haberler genellikle abartı, çarpıtma ve tıklanma tuzağı gibi etkiler yaratmayı hedeflemektedir.

3.4.2. Tıklama tuzakları

Genel olarak reklam yönlendirmeleri içeren, farklı haber dışı içerikler sunan ve kullanıcıyı para kazanmak için web sitesinde biraz daha uzun süre kalmayı amaçlayan alakasız bir yalan haber türüdür. Okuyucuların haber sitelerine olan güvenlerini sarsan önemli bir faktördür (Willmore, 2016).

3.4.3. Asparagas habercilik

Asparagas haberler tamamen uydurma ve ciddi bir şekilde haberlerin doğruluğunu çarpıtmayı hedefleyen haber tipleridir. Bu tür haberler genellikle dikkat çekme veya belirli bir gündemi desteklemek amacıyla yapılmaktadır. Bu tür haberler okunduğunda veya duyulduğunda genellikle hiçbir kanıt içermemektedir.

3.4.3.1. Yanlı kurgu

Yanlı kurgu haber tipleri taraflı ve genellikle politik, ideolojik, görüş veya ajandayı destekleyen gerçek olaylar ve veriler üzerine olmakla birlikte yanıltıcı yorumlar ve çarpıtmalar içeren haberleridir. Bu tür haberler genel olarak okuyucular arasında kutuplaşmalara yol açan ve okuyucuların algısını manipüle etmeyi ve savunduğu görüş ve ideolojiyi ön plana çıkarmakla birlikte karşı görüşlere karşı ön yargı oluşturmayı hedeflemektedir.

3.4.4. Sahte hesaplar

Sahte hesap, bot hesabı veya günlük dilde "trol" olarak tanımlanan hesaplar tarafından gerçekleştirilen ve genellikle hedefledikleri konuların sosyal medya uygulamaların da konun daha uzun süreli ve hızlı bir şekilde gündemde tutmayı hedefleyen hesaplar olmaktadır.

3.4.5. Şaka, latife tarzı mizah haberleri

Var olmayan bir gerçeğin veya durumun hakkında şaka veya latife tarzındaki mizah haberlerle, gerçek dışı ve eğlendirici içerikler sunan, genellikle alaycı bir üslupla yazılmış haber türleridir. Bu tür haberler, okuyucuları güldürmek ve eğlendirmek amacıyla gerçek haber formatında sunulur ancak içerikleri tamamen kurgusal veya abartılı olmaktadır.

3.4.6. Hiciv ve parodi

Hiciv ve parodi haberler, toplumsal, politik veya kültürel eleştirileri mizahi bir dil ve üslupla ele almak amacıyla üretilen içeriklerdir. Bu tür haberler, genellikle gerçek olayları veya kişileri abartılı bir şekilde tasvir ederek, okuyucuların dikkatini çekmeye ve düşündürmeye çalışmaktadır. Hiciv, genellikle mevcut sosyal normları veya politikaları eleştiren keskin ve alaycı bir mizah türleridir. Parodi ise, özellikle belirli bir eseri, kişiyi veya olayı taklit ederek komik bir şekilde yansıtmayı hedeflemektedir (Hancock, 2004).

3.4.7. Partizan haber

Partizan haberler, belirli bir siyasi parti, ideoloji veya ajandayı desteklemek amacıyla önyargılı ve taraflı bir şekilde sunulan haberlerdir. Bu tür haberler, genellikle bir görüşü desteklemek veya karşıt görüşleri kötülemek için seçici bilgi sunumu, önemli detayların çarpıtılması veya önemsizleştirilmesi gibi yöntemler kullanılmaktadır.

3.4.8. Komplo teorileri

Kamuoyunu önemli bir konuda şüpheye düşürmeyi amaçlayan, gerçeklerden farklı olarak sunulan bir yalan haber türüdür. İnanılmasa bile toplumu bozma potansiyeli bulunmaktadır.

3.4.9. Nefret söylemi ve haberleri

Genellikle siyasi olaylardan beslenen seçim mitingleri ve meclis oturumlarının (genellikle belirli bir bölümü) konuşmalarıyla ilgili bir haber türüdür. "Deep fake" olarak bilinen teknolojinin kullanımı ile içerik manipülasyonunda kullanıldığı ve son zamanlarda yapay zeka uygulamalarının artması ile birlikte bu tür haberlerin toplum üzerinde etkili bir şekilde kullanıldığı gözlemlenmektedir.

3.4.10. Uydurma haber

Uydurma haber, gerçek olmayan, tamamen kurgulanmış bilgiler içeren ve genellikle okuyucuları yanıltmak veya manipüle etmek amacıyla yayılan haber türleridir. Bu tür haberler, gerçek olayları temel almayabilir veya var olan gerçek olayları tamamen yanlış ve yanıltıcı bir şekilde sunabilmektedir. Uydurma haberlerin yayılma amacı sıklıkla siyasi, sosyal veya ekonomik çıkarları desteklemek veya zarar vermektedir.

3.4.11. Dedikodu haberler

Dedikodu haberler, genellikle doğrulanmamış, spekülatif ve kişisel konulara odaklanan haber türleridir. Ünlülerin özel hayatları, siyasi figürlerin tartışmalı davranışları veya iş dünyasındaki skandallar gibi konuları içermektedir. Dedikodu haberlerinin odak noktası, genellikle kamusal ilgi çeken kişilerin ya da olayların magazinsel yönleridir ve bu haberler, toplumda merak ve ilgi uyandırmayı amaçlamaktadır.

3.4.12. Yanlış bilgilendirme

Yanlış bilgilendirme, kasıtlı olmayan hatalar veya yanlış anlaşılabilir sonuçları yanlış veya eksik bilginin yayılmasıdır. Bu tür bilgiler, genellikle bilgi eksikliği, yanlış anlama veya araştırma hataları gibi sebeplerle ortaya çıkar ve doğru olmayan bilginin bireyler veya topluluklar arasında paylaşılmasına neden olmaktadır. Yanlış bilgilendirme, kasıtlı olarak yanıltıcı olan dezenformasyon ile karıştırılmamalıdır.

3.4.13. Provokatif haber

Provokatif haber, genellikle tartışma yaratmak, dikkat çekmek veya güçlü duygusal tepkiler uyandırmak amacıyla hazırlanan haber türleridir. Bu haberler, genellikle

sansasyonel başlıklar, abartılı ifadeler veya çarpıcı görseller ile desteklenmektedir. Amaç, okuyucuların veya izleyicilerin dikkatini çekmek ve içeriği tüketmeye teşvik etmektedir.

3.4.14. Şehir efsaneleri

Şehir efsaneleri, genellikle gerçek dışı veya abartılmış hikayelerdir ki bunlar toplum içinde doğruymuş gibi kabul edilir ve kuşaktan kuşağa, kişiden kişiye aktarılmaktadır. Bu hikayeler genellikle olağanüstü, korkutucu veya gizemli olayları içerir ve genellikle somut kanıtlar olmaksızın yayılmaktadır.

3.4.15. Tanımsız sosyal medya hesapları

Tanımsız sosyal medya hesapları, genellikle sahibinin kimliği belirsiz olan ve genellikle anonim olarak işletilen hesaplardır. Bu tür hesaplar, sahiplerinin gerçek kimliklerini gizleyerek sosyal medya platformlarında etkileşimde bulunmalarını sağlamaktadır. Anonimlik, kullanıcıların kişisel güvenlikleri veya gizlilikleri için tercih edilebilirken, bazı durumlarda manipülatif faaliyetler, yanıltıcı bilgi yayma veya taciz gibi olumsuz amaçlar için de kullanılabilir.

3.4.16. Manipülasyon

Manipülasyon haberler, kamuoyu algısını bilinçli olarak yönlendirmek veya belirli bir gündemi desteklemek amacıyla hazırlanan yanıltıcı haber türleridir. Bu haberler, genellikle belirli bir politik, ekonomik ya da sosyal amaç doğrultusunda gerçek dışı bilgiler sunar veya gerçekleri çarpıtarak sunmaktadır. Manipülasyon haberlerin ana amacı, okuyucuların düşüncelerini ve davranışlarını istenilen şekilde etkilemektir.

3.4.17. Propaganda

Propaganda haberler, genellikle bir ideolojiyi, siyasi görüşü veya belirli bir ajandayı desteklemek ve yaymak amacıyla üretilen haberlerdir. Bu tür haberler, kamuoyunu yönlendirmek, belli bir düşünceyi pekiştirmek veya karşıt görüşleri olumsuzlamak için tasarlanmaktadır. Propaganda, bilgiyi manipüle ederek veya gerçekleri seçici bir şekilde sunarak hedeflenen sonuçları elde etmeye çalışmaktadır.

BÖLÜM 4. YALAN HABER TESPİTİNDE KULLANILAN YÖNTEMLER

Bu bölümde, yalan haberleri etkili bir şekilde belirlemek ve önlemek için geliştirilen çeşitli teknolojik araçlar ve metodolojiler incelenecektir. Bu yöntemler arasında doğal dil işleme teknikleri, yapay zeka algoritmaları ve sosyal ağ analizleri gibi ileri düzey teknolojiler yer almaktadır. Bu çözümler, yalan haberlerin yayılmasını engellemeye yönelik stratejiler geliştirilmesinde önemli bir temel oluşturmaktadır.

4.1. Doğal Dil İşleme ve Yalan Haber Tespit Yöntemi

Yalan haberlerin tespitinde kullanılan DDİ teknikleri ve sosyal ağ analizlerini ayrıntılı olarak incelemektedir. Çalışmada, dilbilimsel yaklaşımlar ve sosyal ağ teorileri aracılığıyla yalan haberlerin analizi ve yayılımı ele alınmakta, bu süreçlerde etkili olan sosyal dinamikler yer almaktadır.

4.1.1. Yalan haberin analizi

Yalan haber analiz çalışmalarında sosyal medya platformlarında yanlış bilginin yayılmasını anlamak tespit etmek ve gerekli önlemlerin alınabilmesi için çeşitli teknik ve metodolojilerin incelenip gerekli geliştirmeleri sağlamak için araştırmaların yapıldığı alandır. Bu çalışmalar literatür araştırmalarında sıklıkla kullanılan ve doğruluk oranlarının yüksek olduğu bilgisayar bilimleri, veri bilimleri ve sosyal birimlerin arasında yer alan çalışmaları içermektedir.

4.1.2. Dil bilimsel yaklaşımlar

Yalan haber analizinde dil bilimsel yaklaşımlar, yalan haberlerin tespitinde dil özelliklerinin analiz edilmesini içermektedir. Dil bilimsel yaklaşımların kullanımı, yalan haberlerin tespitinde dilin yapısı, sözcük dağarcığı, söz dizimi, dilbilgisi ve anlamlandırma özelliklerinin incelenmesi yoluyla gerçekleştirilmektedir. Bazı dil bilimsel yaklaşımlar şunlardır:

Morfolojik analiz: Bir kelimenin morfolojik yapısının semantik üzerindeki etkisini detaylı bir şekilde incelemektedir. Özellikle yalan haberlerde sıklıkla başvurulan dil bilgisi öğeleri, bu analizin odak noktasını oluşturmaktadır. İsim tamlamaları gibi yapısal unsurlar üzerinden yürütülen bu analizler, kelimenin anlamını ve kullanıldığı bağlamı daha iyi anlamaya yardımcı olur, bu sayede yalan haberlerin dil yapılarındaki özellikler daha net bir şekilde ortaya çıkarılabilir.

Sözdizimsel analiz: Bir kelimenin diğer kelimelerle olan ilişkilerini ve hangi cümle yapıları içerisinde kullanıldığını inceler. Bu yöntem, özellikle yalan haberlerin tespitinde kritik bir rol oynar. Yalan haberlerde kullanılan kelime ve cümle yapılarının, bu tür haberlerin karakteristik özelliklerini yansıtmadığı bu analizle değerlendirilir. Sözdizimsel özellikler, metinlerin nasıl yapılandırıldığını ve belirli mesajların nasıl iletmeye çalışıldığını ortaya çıkarmakta önemli bir araçtır. Bu bağlamda, yalan haberlerde sıklıkla rastlanan dil yapılarının ve sözdizimsel kalıpların analizi, gerçek ve yanıltıcı bilgiler arasındaki ayrımı netleştirmeye yardımcı olur.

Semantik analiz: Kelimelerin anlamlarını ve bu anlamların çeşitli bağlamlar içinde nasıl değişebileceğini incelemektedir. Bu yöntem, özellikle yalan haberlerin tespitinde önemlidir, zira yalan haberlerde sıklıkla rastlanan yanıltıcı terimler veya ifadeler bu analiz aracılığıyla belirlenmektedir. Semantik analiz, bir kelimenin veya ifadenin kullanıldığı bağlama göre nasıl farklı anlamlar kazanabileceğini aydınlatarak, metinlerdeki gizli niyetleri ve alt metinleri ortaya çıkarabilir. Bu tür bir analiz, yalan haberlerde manipülatif dil kullanımını ve bu dilin nasıl stratejik olarak seçildiğini anlamak için kritik bir araç olmaktadır.

Dilbilgisel analiz: Bu yöntemde, yalan haberlerin dilbilgisi yapısı incelenmektedir. Dilbilgisel analiz, kelime seçimlerindeki tutarsızlıklar, yanlış zaman kullanımı veya olası diğer dilbilgisi hatalarını tespit edebilir. Bu yaklaşımlar, yalan haber analizinde dilin incelenmesi ve tespit edilmesi yoluyla daha doğru sonuçlar elde edilmesine yardımcı olmaktadır ancak dil bilimsel yaklaşımların tek başına yeterli olmadığı göz önünde bulundurulmalıdır ve bilgi kaynaklarının doğruluğunun kontrolü, kaynaklar arasındaki çelişkilerin analizi gibi başka teknikler de kullanılmalıdır.

4.1.3. Ağ yaklaşımları

Yalan haber analizinde ağ yaklaşımları, yalan haberlerin yayılması ve etkilerini anlamak için sosyal ağlardaki kullanıcıların etkileşimleri ve bağlantılarına odaklanmaktadır. Ağ yaklaşımları, yalan haberlerin nasıl yayıldığını ve hangi toplulukları etkilediğini anlamak için kullanılabilir. Bazı ağ yaklaşımları şunlardır:

Sosyal ağ analizi: Sosyal medya platformlarında kullanıcılar arasındaki etkileşimlerin ve bağlantıların incelenmesi yöntemidir. Bu analiz, yalan haberlerin nasıl ve hangi yollarla yayıldığını, hangi kullanıcılar tarafından daha fazla paylaşıldığını ortaya koyarak, bilgi akışının yapısal özelliklerini ve dinamiklerini detaylı bir şekilde tespit edilmesini sağlamaktadır. Ayrıca, yalan haberlerin belirli topluluklar veya ağlar içinde nasıl viral hale geldiği, hangi bağlantılar üzerinden hızla yayıldığı gibi bilgileri de sağlamaktadır. Bu tür analizler, yanıltıcı bilgilerin izini sürmek ve bu tür içeriklerin önlenmesine yönelik stratejiler geliştirmek için değerli veriler sunmaktadır.

Topluluk algılama: Sosyal ağlarda kullanıcıları benzer özellikler veya etkileşimler temelinde farklı gruplara ayırarak analiz etmektedir. Bu yöntem, kullanıcıların sosyal yapılarını ve grup dinamiklerini detaylıca inceleyerek, yalan haberlerin belirli topluluklar üzerindeki etkisini belirlemeye yardımcı olmaktadır. Kullanıcıların hangi topluluklara ait olduğunu tespit etmek, yalan haberlerin yayılma modellerini ve bu haberlerin hangi demografik veya sosyal gruplar tarafından daha sık kabul edildiğini anlamada kritik öneme sahiptir. Bu bilgiler, yalan haber mücadelesinde hedeflenen müdahalelerin ve iletişim stratejilerinin daha etkin şekilde planlanmasına olanak tanımaktadır.

Makine öğrenmesi: Bu yöntemde, yalan haberlerin tespitinde yapay zeka teknolojileri kullanılır. Bu yöntemde, yalan haberleri yaymak için kullanılan kullanıcı hesaplarının belirlenmesi, yalan haberlerin nasıl yayıldığı ve hangi toplulukları etkilediği hakkında bilgi sağlayabilir. Bu yaklaşımlar, yalan haberlerin yayılması ve etkilerinin anlaşılması için farklı yollar sağlamaktadır. Ancak ağ yaklaşımları da tek başına yeterli olmayabilir, özellikle de yalan haberlerin doğruluğunun kontrol edilmesi ve bilgi kaynaklarının analizi gibi diğer teknikler de kullanılmalıdır.

4.2. Verilerden Özellik Çıkarımı

Metin madenciliği ve DDİ alanında verilerden anlamlı sonuçlar çıkartımı süreci büyük önem taşımaktadır. Bu bağlamda metin içerisindeki özerkliği ve ilişkileri ortaya koymak için literatürde çeşitli modeller ve algoritmalar kullanılmaktadır. Bu modeller veriyi daha iyi analiz etmek ve sınıflandırmak için farklı yaklaşımlar sunmaktadır.

4.2.1. TF-IDF modeli

Terim Frenkası-Test Belge Frekansısı (Term Frequency-Inverse Document Frequency, TF-IDF) metin madenciliği ve bilgi işlemede kullanılan bir ağırlıklandırma yaklaşımıdır. Bir kelimenin bir dokümanda ne kadar önemli olduğunu belirlemek için iki faktör kullanılır. Kelimenin toplam belge koleksiyonunda ne kadar nadir olduğu ve kelimenin belgede ne sıklıkta geçtiği belirlemektedir. TF-IDF, bir kelimenin sadece bir dokümanda değil, tüm doküman koleksiyonunda ne kadar bilgi taşıdığını değerlendirmek için kullanılır (Manning, Raghavan ve Schütze, 2008).

Terim Frekansısı (Term Frequency, TF), bir terimin belirli bir dosyada ne kadar sık kullanıldığını gösterir. Bu ifade denklem 4.1'de gösterilmektedir.

$$TF(t, d) = \frac{\text{Belgedeki } X \text{ Terim Sayısı}}{\text{Belgedeki Toplam Terim Sayısı}} \quad (4.1)$$

Ters Belge Frekansısı (Inverse Document Frequency ,IDF), bir terimin tüm belge koleksiyonlarında ne kadar nadir bir değer olduğunu ölçmektedir. Bir kelimenin ne kadar yaygın kullanıldığını ters orantılı bir şekilde değerlendirir. Bir kelimenin tüm dokümanlarda çok sık geçmesi durumunda, bu kelimenin belirli bir dokümanda özgünlüğü düşük kabul edilir ve dolayısıyla düşük bir IDF değeri alır. Buna karşın, daha nadir kelimeler yüksek IDF değeri alınmaktadır. Denklem 4.2'de kelimenin IDF değerinin ölçümü göstermektedir.

$$IDF(d) = \log \frac{\text{Toplam Belge Sayısı}}{X \text{ Terimini İçeren Belge Sayısı} + 1} \quad (4.2)$$

TF ve IDF değerleri hesaplanmasıyla bu değerlerin çarpımı X teriminin belgedeki değeri hesaplanmış olur ve bu yöntem sayesinde hem çok sık kullanılan hem de çok nadir kullanılan kelimelerin ağırlığı belirlenir. Denklem 4.3'te terimin belgedeki ağırlık ölçümü verilmektedir.

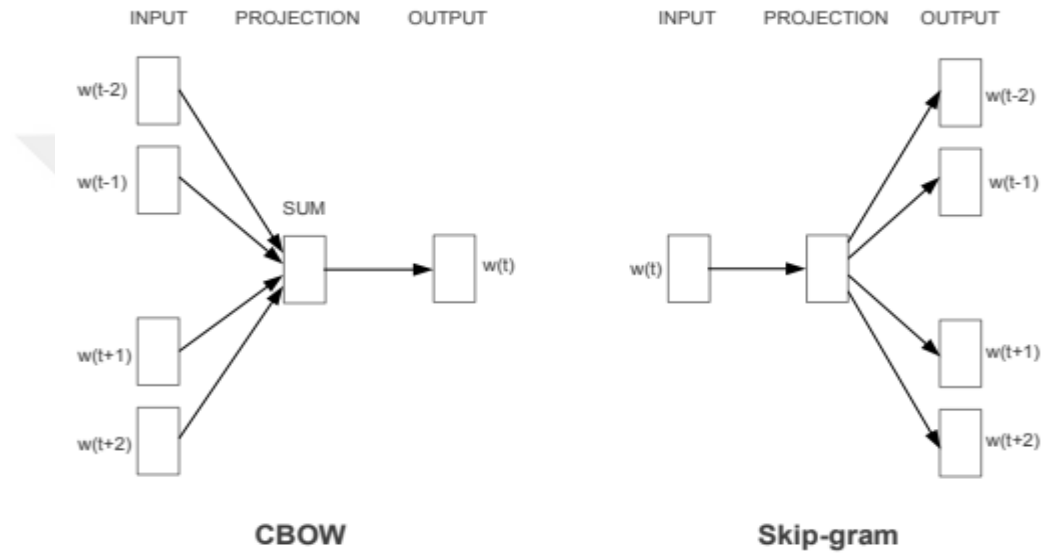
$$TF - IDF = TF(t, d) \times IDF(d) \quad (4.3)$$

Yalan haber tespiti çalışmasında derin öğrenme algoritmaları çalıştırılırken model özelinde metinleri sınıflandırmak için herhangi bir model kullanılmaması durumunda TF-IDF modeli kullanılarak verilerden özellik çıkarımı sağlanacaktır. Bu tez çalışmasında NB, SVM (Destek Vektör Makineleri, Support Vector Machine) yapay zeka algoritmalarında TF-IDF modeli kullanılmıştır. BERT, LSTM, Neural Networks TF (TensorFlow) algoritmalarında model içinde kullanılan kelime gömme (word embeddings) veya dönüşümlü modeller (transformer models) kullanılmaktadır.

4.2.2. Word2Vec modeli

Kelime Vektörü (Word to Vector, Word2Vec), kelimeleri çok boyutlu vektör uzayında temsil eden ve bu sayede kelimeler arasındaki semantik ilişkileri yakalayabilen bir model olarak kullanılmaktadır. Google, Mikolov ve ekibinin geliştirdiği bu modelde kelimeleri yoğun, yani çok boyutlu vektörler olarak gösterir. Bu temsil, kelimelerin vektör uzayında birbirlerine yakın olmalarını sağlar. Word2Vec, özellikle DDİ alanında büyük bir etki yaratarak dil modellerinin anlamı daha iyi anlaşılabilir hale gelmesini sağlamıştır. Word2Vec, Skip-Gram ve Sürekli Kelime Çantası (Continuous Bag of Words , CBOW) model mimarilerini kullanır. Her iki model de derin öğrenme ve büyük veri kümeleri kullanılarak eğitilir. CBOW modeli, belirli bir kelimeyi etrafındaki (veya bağlamındaki) kelimeler kullanarak tahmin etmeye çalışır. Bu model bağlam kelimelerini girdi ve hedef

kelimeyi çıktı olarak kullanmaktadır ve CBOW, özellikle daha az veri ile çalışıldığında daha iyi çalışmaktadır. Skip-Gram modeli bir kelimenin ne anlama geldiğini tahmin etmeye odaklanmıştır. Bu model, girdi olarak bir kelimeyi verir ve çıktı olarak kelimenin etrafındaki kelimeleri oluşturmaktadır. Nadir kelimeler ve büyük veri kümeleri için Skip-Gram modeli daha iyi çalışmaktadır (Mikolov, Chen, Corrado ve Dean, 2013). Şekil 4'te Word2Vec modeli için Skip-Gram ve CBOW modelini modelinin karşılaştırılması verilmiştir.



Şekil 4. Word2Vec için CBOW ve Skipgram Eğitimi (Mikolov vd., 2013)

4.2.3. Doc2Vec modeli

Doc2Vec, Word2Vec modelinin genişletilmiş bir versiyonu olup, tam belgeleri, paragrafları veya cümleleri vektörel olarak temsil etmek için kullanılır. Bu model, Word2Vec'in aksine kelime düzeyinden öteye geçerek belge düzeyinde metinleri temsil edebilmektedir. Doc2Vec, iki ana mimari yapıdan oluşmaktadır: Dağıtık Bellek (Distributed Memory, DM) ve Dağıtık Kelime Çantası (Distributed Bag of Words, DBOW). DM modeli, her belge için özgün bir "doküman vektörü" oluşturur ve bu vektörü, çevresindeki kelimelerle birlikte kullanarak hedef kelimeyi tahmin etmeye yönelik bir yöntem sunar. Bu yaklaşım, belgenin geniş kapsamlı semantik içeriğini yakalamaya olanak tanır. Öte yandan, DBOW modeli, Skip-Gram modeline benzer bir işlev görür ve belgenin doküman vektörünü kullanarak, rastgele seçilen kelimeleri tahmin

etmeye çalışır. Büyük veri kümeleri üzerinde çalışırken DBOW modeli, hız ve etkinlik açısından üstün sonuçlar sunar. Her iki model de, belgelerin semantik bağlamını derinlemesine analiz ederken, metinler arası ilişkileri ve yapısal özellikleri koruyarak zenginleştirilmiş veri yorumları sağlar (Le ve Mikolov, 2014).

4.3.Yapay Zeka Algoritmaları

Son yıllarda, yapay zeka ve makine öğrenmesi alanlarında derin öğrenme giderek daha fazla popülerlik kazanmış ve çeşitli endüstrilerde önemli dönüşümlere öncülük etmiştir. Bu algoritmalar, büyük ve karmaşık veri kümelerinden öğrenme ve tahmin yapma kabiliyetleriyle öne çıkarken, insan beyninin işleyiş mekanizmalarından esinlenen yapay sinir ağları teknolojisine dayanmaktadır. Gelişmiş modelleme teknikleri sayesinde, derin öğrenme algoritmaları, görüntü ve ses işleme, doğal dil işleme, otomatik çeviri ve daha birçok alanda etkileyici başarılar göstermiştir. Bu çalışmada, literatürde en çok kullanılan yapay zeka algoritmalarından beşi hakkında bilgi ve performans değerlendirme kriterleri hakkında bilgiler sunulmuştur.

4.3.1. Naive Bayes

Naive Bayes (NB) algoritması, ilk olarak Thomas Bayes tarafından temellendirilen Bayes Teoremi'ne dayanır. Thomas Bayes, 18. yüzyılda yaşamış bir İngiliz istatistikçi ve papazdır ve "Bayes Teoremi" olarak bilinen olasılık teorisine önemli katkılarda bulunmuştur. Ancak, "Naive Bayes" adı verilen ve özelliklerin sınıfa bağlı olarak birbirlerinden bağımsız olduğu varsayımına dayanan sınıflandırma modeli, modern bilgisayar bilimleri ve istatistik alanında daha sonra, 20. yüzyılda geliştirilmiştir (Bishop ve Nasrabadi, 2006).

NB algoritması, arama motorları ve spam e posta filtreleri oluşturmak için geliştirilmiştir. Bayes Teoremi, bir olayın ya da durumun meydana gelme olasılığının, olaya yönelik ek bilgi edinilmesi durumunda nasıl değişeceğini göstermektedir. Bayes Teoreminin basit ama güçlü örneği olan NB, metin sınıflandırmada tatmin edici sonuçlar veren avantajlar göstermektedir (Zhang ve Li, 2007). NB algoritması, sınıflandırma problemlerinin çözülmesi için kullanılan bir makine öğrenmesi algoritmasıdır ve bu algoritma, veri özelliklerinin birbirinden bağımsız olduğu varsayımına dayandığından "naive" veya saf

olarak adlandırılır (Rish, 2001). Çalışma mantığı verilen bir koşul altında olasılıkları hesaplamak için kullanılır. Algoritma, bir örneğin her bir sınıfa ait olma olasılığını hesaplar ve en yüksek olasılığa sahip sınıfı tahmin olarak seçmektedir. Denklem 4.4'te kelimenin olasılık hesaplaması verilmiştir.

$$P(y|x) = \frac{P(x|y) \times P(y)}{P(x)} \quad (4.4)$$

Burada,

$P(y|x)$ x göz önünde bulundurulduğunda, sınıf y olma olasılığıdır.

$P(x|y)$ sınıf y verildiğinde, öznitelikler x olma olasılığıdır.

$P(y)$ sınıf y olma olasılığıdır.

$P(x)$ öznitelikler x olma olasılığıdır.

Bayes teoremi, bir olayın olasılığının, bu olayın gerçekleşmesi durumunda başka bir olayın olasılığına bağlı olduğunu söylemektedir. Bu teoreme göre, sınıf etiketinin olasılığı, veri özelliklerinin olasılıkları ve sınıf etiketinin öncül olasılıklarının bir kombinasyonudur. NB algoritması, sınıf etiketi için en yüksek olasılığı hesaplar ve veri örneğini bu sınıfa atamasını sağlamaktadır (Bishop ve Nasrabadi, 2006).

4.3.2. BERT algoritması

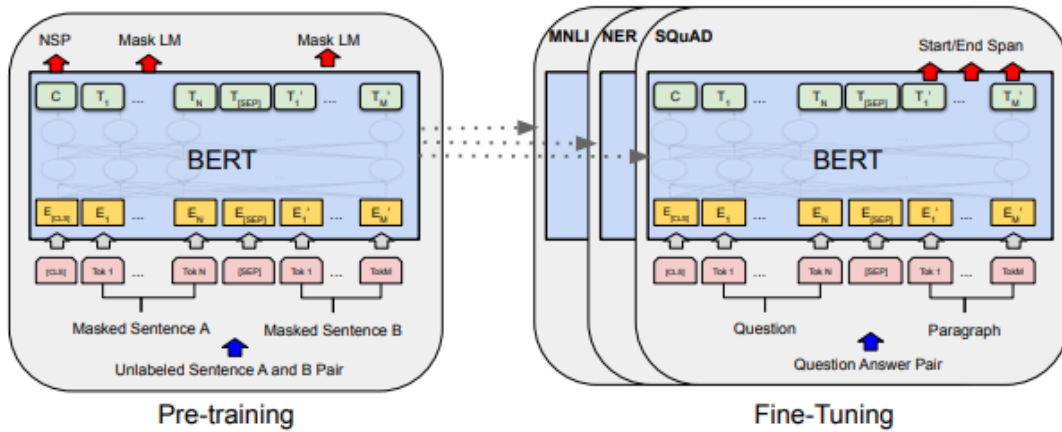
BERT doğal dil işleme alanında sınıflandırma, çeviri ve benzeri görevler için kullanılan bir makine öğrenmesi algoritmasıdır. BERT, Google tarafından 2018 yılında geliştirilmiştir. BERT in çalışma mantığı, bir "dil modeli" olarak adlandırılan derin öğrenme modeli üzerine kurulur. Dil modelleri, derinlemesine dil öğrenme için bir kelimenin, cümlenin veya belgenin anlamını öğrenmek için kullanılır. Mevcut dil temsili modellerinden farklı olarak, BERT metin üzerinde hem sağ hem de sol bağlamda

eşzamanlı olarak çalışarak BERT in dilin çift yönlü temsillerini daha kapsamlı bir şekilde anlamasını sağlamaktadır (Devlin, Chang, Lee ve Toutanova, 2018).

BERT, büyük ve etiketlenmemiş bir ver seti üzerinde ön eğitimden geçmektedir. Ön eğitimde iki ana görev kullanılmaktadır, Maskeli Dil Modeli (Masked Language Model, MLM), metin içerisinde rastgele seçilen bazı tokenler gizlenir (maskelenir), ve modelin bu gizlenen tokenleri yalnızca kendilerine dair bağlamı kullanarak tahmin etmesi beklenmektedir. Bu süreç, modelin metni her iki yönden de anlamasına yardımcı olmaktadır.

Sonraki Cümle Tahmini (Next Sentence Prediction, NSP), model, bir cümlele gelip gelmeyeceği doğru bir şekilde tahmin edilmeye çalışılan iki cümle çifti alınmaktadır. Bu görev, modelin iki cümle arasındaki ilişkiyi anlamasına yardımcı olmaktadır.

Ön eğitimden sonra BERT, belirli görevlere uygun hale getirilmek için ince ayar yapılır. Bu ince ayar sürecinde, modelin parametreleri spesifik bir göreve uyacak şekilde ayarlanır ve model, bu göreve özel verilerle eğitilir. Şekil 5'te BERT modelinin ön eğitim ve ince ayar süreçlerini göstermektedir.



Şekil 5. Bert Algoritması Öne Eğitim ve İnce Ayar (Devlin vd., 2018)

4.3.3. LSTM

LSTM Jürgen Schmidhuber ve Sepp Hochreiter tarafından 1997 yılında üretilmiştir. Bu iki araştırmacı, klasik tekrarlayan sinir ağlarının RNN (Tekrarlayan Sinir Ağları, Recurrent Neural Network) uzun süreli bağımlılıkları öğrenmedeki zorluklarını aşmak için LSTM mimarisini geliştirmişlerdir (Hochreiter ve Schmidhuber, 1997).

LSTM algoritması, hafıza ve öğrenme süreçlerinde uzun süreli bağımlılıkları işleyebilme kapasitesiyle öne çıkan bir RNN çeşididir. LSTM birimleri, hücre durumu (cell state) ve üç kapıdan (gates) oluşmaktadır. Bunlar giriş kapısı (input gate), unutma kapısı (forget gate) ve çıkış kapısı (output gate)' dir. Bu yapı, bilginin uzun veya kısa süre hafızada tutulmasını sağlamaktadır. LSTM, uzun süreli bağımlılıkları hatırlayabilme kapasitesiyle öne çıkmaktadır. Bu özellik, zaman serisi tahmini, dil modelleme ve metin üretimi gibi pek çok alanda LSTM'i ideal bir yapay zeka algoritmasıdır.

4.3.4. SVM

SVM (Destek Vektör Makineleri, Support Vector Machine), özellikle sınıflandırma problemlerinde sıklıkla kullanılan bir makine öğrenmesi algoritması türüdür. Temel olarak, verileri belirli sınıflara ayırmak için kullanılır. SVM algoritması, birçok özelliikle karakterize edilen verileri sınıflandırmak için kullanılabilir. SVM algoritması, iki sınıfın arasındaki karar sınırını belirleyen bir hiper düzlem oluşturur. Bu hiper düzlem, iki sınıfın ayrımını en iyi şekilde sağlayacak şekilde belirlenir. Algoritma, sınıflandırma problemindeki her veri noktasını bu hiper düzlem üzerindeki konumuna göre sınıflandırır. Veri noktaları, hiper düzleme olan uzaklıklarına göre de ayrıca sınıflandırılabilir (Hochreiter ve Schmidhuber, 1997).

4.3.5. Neural NetWorks TF

Neural NetWorks TF (TensorFlow), açık kaynaklı bir makine öğrenmesi kütüphanesidir. Özellikle yapay sinir ağlarının oluşturulması ve eğitmesi amacıyla kullanılmaktadır. Google tarafından geliştirilen TensorFlow, araştırmacılar ve endüstriyel uygulayıcılar tarafından yaygın bir şekilde kullanılmaktadır. TensorFlow, hesaplama grafi adı verilen bir yapıyı kullanır. Bu yapıda, veriler tensörler olarak adlandırılır ve her bir tensör belirli bir boyut ve şekle sahiptir. Graf, matematiksel işlemlerin sırasını ve ilişkilerini gösterir

ve verilerin nasıl işleneceğini belirler. Bu yapı sayesinde, TensorFlow, büyük ve karmaşık hesaplamaları optimize etmek ve paralelleştirmek için kullanılabilir (Abadi vd., 2016).

4.3.6. Performans değerlendirme kriterleri

Model performansını değerlendirmek için kullanılan metrikler, sınıflandırma modellerinin tahmin başarısını belirlemede temel bir role sahiptir. Sınıflandırma modellerinin ne derece iyi çalıştığını anlamak amacıyla bu metrikler önemli ölçütler sağlamaktadır. Burada TP (Doğru Pozitif, True Positive) ve TN (Doğru Negatif, True Negative) doğru tahminlerdir; FP (Yanlış Pozitif, False Positive) ve FN (Yanlış Negatif, False Negative) yanlış tahminlerdir. Bu metriklerin kullanımı ve faydaları aşağıdaki gibidir:

Doğruluk (Accuracy): Bir modelin genel doğruluğunu değerlendirmek için kullanılır, ancak dengesiz veri kümelerinde yanıltıcı olabilir. Model çoğunluk sınıfını tahmin etmeye eğilimli olabilir, özellikle azınlık sınıfı çok küçükse. Bununla birlikte, yüksek doğruluk düzeyine sahip olabilir (Hastie, Tibshirani, Friedman ve Friedman, 2009). Denklem 4.5'te doğruluk oranının hesaplanması verilmiştir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.5)$$

Hassasiyet (Precision): Modelin pozitif olarak tahmin ettiği örneklerin gerçekte ne kadarının pozitif olduğunu hesaplar ve özellikle yanlış pozitiflerin fazla olduğu durumlarda önemlidir (Powers, 2020). Denklem 4.6'da hassasiyet oranının hesaplanması verilmiştir.

$$\text{Hassasiyet} = \frac{TP}{TP + FP} \quad (4.6)$$

Duyarlılık (Recall): Gerçekte pozitif olan tüm örneklerin ne kadarının doğru tahmin edildiğini ölçmektedir. Bu, tüm pozitif vakaları elde etmek istediğimiz tıbbi testler gibi durumlarda hayati önem taşır (Powers, 2020). Denklem 4.7’de duyarlılık oranının hesaplanması verilmiştir.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (4.7)$$

F1-Skoru (F1-Score): Hassasiyet ve duyarlılıktan oluşan değerlerin harmonik ortalamasıdır. Bu skor, sınıflandırma modelinin performansını değerlendirmek için sıklıkla kullanılır (Rijsbergen, 1979). Denklem 4.8’de F1 skor oranının hesaplanması verilmiştir.

$$F1 \text{ Skoru} = 2 \times \frac{\text{Hassasiyet} \times \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}} \quad (4.8)$$

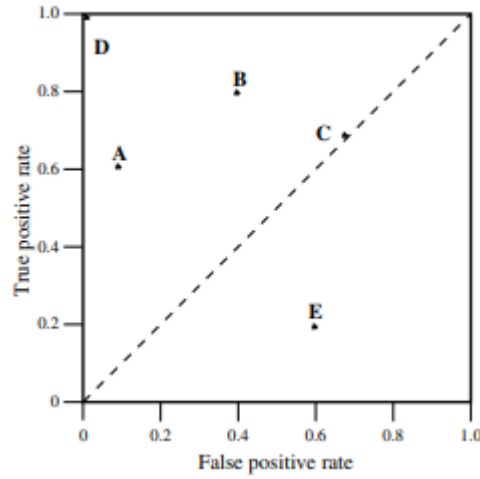
ROC (Alıcı Çalışma Özelliği, Receiver Operating Characteristic): Modelin performansını çeşitli eşik değerleri aracılığıyla değerlendirir. Doğru pozitif oranı (True Positive Rate, TPR) ve yanlış pozitif oranı (False Positive Rate, FPR) arasındaki ilişki, ROC eğrisi aracılığıyla gösterilir. Bu eğrinin altında kalan alanın büyüklüğü olan AUC (Eğri Altındaki Alan, Area Under Curve), modelin rastgele tahminlerden daha iyi çalıştığını gösterir (Fawcett, 2006).

TPR (Doğru Pozitif Oranı, True Positive Rate) ve FPR (Yanlış Pozitif Oranı, False Positive Rate) olarak değerlendirildiğinde Denklem 4.9’da TPR oranı ve Denklem 4.10’da FPR oranının hesaplanması verilmiştir.

$$TPR = \frac{TP}{TP + FN} \quad (4.9)$$

$$FPR = \frac{FP}{TN + FP} \quad (4.10)$$

Şekil 6'da 5 ayrı sınıflandırıcı içeren ROC eğrisi grafiği örneği verilmiştir.



Şekil 6. Beş Ayrı Sınıflandırıcı Gösteren Örnek ROC Grafiği (Fawcett, 2006)

AUC (Eğri Altındaki Alan, Area Under Curve): ROC eğrisinin altında bulunan alandır. Bu metrik, algoritmanın sınıflandırma yeteneğini ölçmek için kullanılan başka bir kritik ölçüttür. Algoritma, AUC değeri bire yakınsa mükemmel bir şekilde sınıflandırma yapar. Bu kriterler, bir algoritmanın performansını değerlendirmek ve belirli bir veri kümesi için hangi algoritmanın en iyi sonuçları verdiğini belirlemek için kullanılır (Fawcett, 2006).

4.4. Gerçekleştirilen Çalışma

Yalan haber tespiti araştırmaları genellikle otomatik sistemler oluşturmak için makine öğrenimi ve yapay zeka yöntemlerini kullanılmaktadır. Bu sistemler, büyük veri kümelerinden öğrenerek gerçek ve yalan haberleri ayırt edebilmektedir. Yapay zeka,

metin analizi yoluyla haber içeriğinin dilbilimsel ve stilistik yönlerini analiz ederek haberlerin doğruluğunu değerlendirilmesi amaçlanmaktadır.

4.4.1. Verilerin toplanması

Yalan haber tespiti için öncelikle belirlenen bir konu için çıkan haber kaynaklarının tespit edilip verilerin toplanıp etiketlenmesi gerekmektedir. Teyit.org sitesinde belirlenen konular için çıkan haberlerin doğru veya yalan haber olup olmadığı analizi gerçekleştirildiği için doğru kaynak olarak teyit.org sitesinde yer alan analizlerin toplanıp veri tabanının da tutulması sağlanmıştır. Orman yangınları ile ilgili, sosyal medya uygulamaları arasında en çok kullanılan X platformundaki #orman, #ormanyanginlari ve #yangin etiketli tweetler, Python'da SnsCrape kütüphanesi kullanılarak toplanmış ve bir veri tabanında saklanmıştır.

4.4.2. Teyit.org sitesinde yayınlanan verilerin toparlanması

Sosyal medya uygulamalarında yayınlanan haberler doğrultusunda teyit.org sitesinde ilgili haberler veya söylemler için haberin doğruluğunu veya yalan olup olmadığı analizini gerçekleştirdiğinden dolayı doğru haber kaynağı olarak referans alınıp Python da 2023 04 01 tarihinde verilerin alınıp veri tabanına kaydedilmesi sağlanmıştır.

4.4.3. SnsCrape kütüphanesi ile X'den verilerin toplanması

Marmaris de başlayan 2022 06 21 tarihinde başlayan orman yangınlarıyla ilgili X'de #orman #yangin ve #ormanyangini hashtagleri kullanarak tweet atan kullanıcıların 10.000 adet tweetin SnsCrape kütüphanesi kullanılarak tweetlerin alınıp veri tabanına kaydedilmesi sağlanmıştır. X 'in web scraping yöntemi ile sınırlı sayıda veri sağlayıp ve birden fazla kez gelen istekleri X tarafından engelleme durumu olduğundan dolayı veri sayısını 10.000 olarak sınırlandırılmıştır.

4.4.4. Verilerin işlenmesi

Veri bilimi projelerinde yalan haber tespiti çok önemlidir. Bu sürecin başarısı, kullanılan verinin kalitesine ve bu verinin işleme sürecine uygulanmasına bağlıdır. Veri temizleme, verileri analiz için uygun hale getirmek için yapılan bir dizi prosedürden oluşur. Bu adımları uygulamak için Python'da pandas kütüphanesi ile veri okuması sağlanarak ve

NLTK (Doğal Dil Araç Kiti, Natural Language Toolkit) kullanarak metinlerde ön işleme gerçekleştirilmiştir.

4.4.5. Veri ön işleme

- Metin içinden URL'ler, HTML etiketleri, özel karakterler ve sayılar gibi analiz için gereksiz olan bilgiler çıkarılır.
- Tüm metin, büyük/küçük harflerin duyarlılığını ortadan kaldırmak amacıyla küçük harfe dönüştürülür.
- Metin, kelimeler veya ifadeler (tokenlar) halinde bölünür.
- "ve", "veya" gibi sık kullanılan ancak analitik değeri olmayan kelimeler çıkarılır.
- Kelimelerin köklerine inilerek çeşitli kelime türevleri tek bir kök altında toplanır.

4.4.6. Gürültülü verinin temizlenmesi

- Tekrar eden veri kayıtları çıkarılır.
- Eksik veri içeren kayıtlar ya tamamlanır ya da çıkarılır.
- Veri setinde mantıksal olarak mümkün olmayan veya yanlış kaydedilmiş veriler tespit edilip düzeltilir.

4.4.7. Verilerden özellik çıkarımı

Metin verisinden, makine öğrenimi modellerinde kullanılacak özellikler (feature) çıkarılır. Bu tez çalışmasında NB, SVM yapay zeka algoritmalarında TF-IDF modeli kullanılmıştır. BERT, LSTM, Neural NetWorks TF algoritmalarında model içinde kullanılan kelime gömme veya dönüşümlü modeller kullanılmaktadır.

4.4.8. Veri setinin bölünmesi

Hazırlanan veri seti, BERT, LSTM, TensorFlow, NB ve SVM algoritmaları kullanılarak, eğitim sırasında veri setinin %25, %50 ve %75'lik kısımları rastgele olarak test verisi olarak ayrılmıştır. Bu algoritmaların performanslarını karşılaştırmak amacıyla, veri setinden çeşitli oranlarda ayrılan bu test verileri kullanılmıştır. Bu yaklaşım, her bir algoritmanın yalan haber tespiti konusundaki etkinliğini ve doğruluk oranlarını değerlendirmek için uygulanmıştır.

4.4.9. Verilerin görselleştirilmesi


Wordcloud kütüphanesi, Python'da metin verilerinden kelime bulutları oluşturmak için kullanılan yaygın bir araçtır. Bir metin koleksiyonunda bulunan kelimelerin frekanslarını veya önemlerini görselleştirmek için kelime bulutları kullanılır. Bu görselleştirme yöntemi, daha büyük ve/veya daha kalın olan kelimeleri gösterir. Wordcloud kütüphanesi, metinlerden elde edilen bilgileri özetleyerek hızlı bir içgörü sağlar.

SnsCrape açık kaynak kodlu kütüphane kullanılarak 2022-06-21 tarihinde X'de orman yangınları ile ilgili #orman, #yangın, #OrmanYangını hashtag adı altında 10.000 adet tweet alınarak kullanıcılar arasındaki ilişki, kelime bulutu ve en çok kullanan kelimeler Python da verilerin görselleştirilmesi sağlanmıştır.

Şekil 7'de X'de #orman, #yangın, #OrmanYangını etiketi kullanarak atılan tweetlerde en çok kullanılan 100 kelimenin grafiği verilmiştir.

Şekil 8’de X’de alınan verilerde kullanıcıların atmış oldukları twetler ile birbirleri ile etkileşimde bulunan kullanıcılar arasındaki bağlantılar verilmiştir.

Kullanıcılar Arası Bağlantılar (URL Paylaşımı)



Şekil 8. X’de Alından Veriler Arasında Kullanıcılar Arasında Etkileşim

4.4.10. Verilerin Etiketlenmesi

Teyit.org sitesinde orman yangınları ile ilgili teyit edilen doğru ve yalan haberler listelenerek 54 adet doğru ve yalan haber analizi incelenerek analizi tamamlan haberlerle ilgili çıkan haberler ve sosyal medyadan alınan veriler filtrelenerek 97 adet verilerin doğru ve yalan olarak etiketlenmesi sağlanmıştır. Veri setinde yer alan veri setinde 0 yalan haber 1 ise doğru haber olarak etiketlenmiştir. Literatür taramalarında genellikle yazarlar daha önce hazırlanan COVID-19 ile ilgili yayınlanan haberler veya ABD (Amerika Birleşik Devleti) de gerçekleşen seçimlerle ilgili hazırlanan veri seti üzerinden farklı yapay zeka algoritmalarını kullanarak performans sonuçlarının kıyaslanmasını sağlanmıştır. Bu tez çalışmasında ise hazır bir veri seti kullanmadan orman yangınları ile ilgili alınan verilerin ön işlemlerini gerçekleştirip yapay zeka algoritmalarının performans sonuçlarının kıyaslanması ve verilerin elde edilip doğru bir şekilde ön işlemlerinin önemi vurgulanmaktadır.

4.5.Yapay Zeka Algoritmalarının Kullanılması

Yalan haber tespitinde en yaygın kullanılan yapay zeka algoritmaları, %25, %50 ve %75 olarak ayrılan test veri setleri kullanılarak değerlendirilmiştir. Bu modellerin doğruluk ve F1 skorları, her bir test ve eğitim verisi oranına göre oluşturulan doğruluk (confusion) matrislerinde gösterilmiş ve böylece her bir modelin performans grafiği detaylı bir şekilde oluşturulmuştur. Karışıklık matrisi, modelin her iki sınıf için tahmin performansını özetleyerek, Şekil 10'da verilen alanlarda şu bilgileri sunar:

Sol Üst (TP): Modelin yalan haber olarak doğru sınıflandırdığı göstermektedir.

Sağ Üst (FN): Modelin doğru haber olduğunu yanlışlıkla yalan haber olarak sınıflandırdığı göstermektedir.

Sol Alt (FP): Modelin yalan haber olduğunu yanlışlıkla doğru haber olarak sınıflandırdığı göstermektedir.

Sağ Alt (TN): Modelin doğru haber olarak doğru sınıflandırdığı göstermektedir.


4.5.1. Naive Bayes

Yalan haber tespitinde NB modeli eğitilmeden önce veri setindeki kelimelerin önemini ağırlıklarına göre belirlemek için TD-IDF vektörleştirme modeli kullanılmıştır. Tablo 1’de yer alan %25, %50 ve %75 test oranlarına göre modelin eğitilip F1 skoru ve doğruluk oranı hesaplanması sağlanmıştır. Tablodaki sonuçlar göz önünde bulundurulduğunda veri setinin genişletilmesi durumunda daha iyi sonuçlar elde edilebilmektedir. NB modeli metinsel sınıflandırmada sıklıkla kullanılan bir algoritma olmakla birlikte metinlerin doğru bir şekilde etiketlenip ve verilerin çeşitlendirilmesi durumunda yalan haber tespitinde daha iyi sonuçlar vermesi sağlanabilmektedir.

Tablo 1: NB Algoritması Doğruluk Oranı ve F1 Skoru Değerleri

Sıra No	Test Oranı	Accuracy	F1 Score
1	0.25	0.833333	0.785714
2	0.50	0.833333	0.793844
3	0.75	0.861111	0.861111

Şekil 10’da %25 oranında test verisi kullanılarak oluşan doğruluk matrisinin grafiği verilmiştir.



Şekil 10. NB Algoritmasında %25 Test Verisi İçin Doğruluk Matrisi

Karışıklık matrisinde (Confusion Matrix) test verisinin %25 olduğu durumda NB modelinin doğruluk (Accuracy) oranının hesaplanması aşağıda verilmiştir ve karışıklık matrisindeki değerlere göre:

Doğru Pozitif (True Positive, TP): Gerçekte "0" olan ve model tarafından doğru olarak "0" tahmin edilen 19 durum bulunmaktadır.

Doğru Negatif (True Negative, TN): Gerçekte "1" olan ve model tarafından doğru olarak "1" tahmin edilen 1 durum bulunmaktadır.


Yanlış Pozitif (False Positive, FP): Gerçekte "1" olan ancak model tarafından yanlışlıkla "0" olarak tahmin edilen 4 durum bulunmaktadır.

Yanlış Negatif (False Negative, FN): Gerçekte "0" olan ancak model tarafından yanlışlıkla "1" olarak tahmin edilen 0 durum bulunmaktadır.

Toplam doğru tahminler (TP + TN) toplam veri sayısına (TP + TN + FP + FN) bölünerek doğruluk oranı elde edilir. Denklem 4.11'de doğruluk oranı hesaplaması verilmiştir.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{19 + 1}{19 + 1 + 4 + 0} = \frac{20}{24} \approx 0.83333 \quad (4.11)$$

Şekil 11'de %50 oranında test verisi kullanılarak oluşan doğruluk matrisinin grafiği verilmiştir.



Şekil 11. NB Algoritmasında %50 Test Verisi İçin Doğruluk Matrisi

Karışıklık matrisinde test verisinin %50 olduğu durumda NB modelinin doğruluk oranının hesaplanması aşağıda verilmiştir ve karışıklık matrisindeki değerlere göre:

Doğru Pozitif (True Positive, TP): Gerçekte "0" olan ve model tarafından doğru olarak "0" tahmin edilen 37 durum bulunmaktadır.

Doğru Negatif (True Negative, TN): Gerçekte "1" olan ve model tarafından doğru olarak "1" tahmin edilen 3 durum bulunmaktadır.

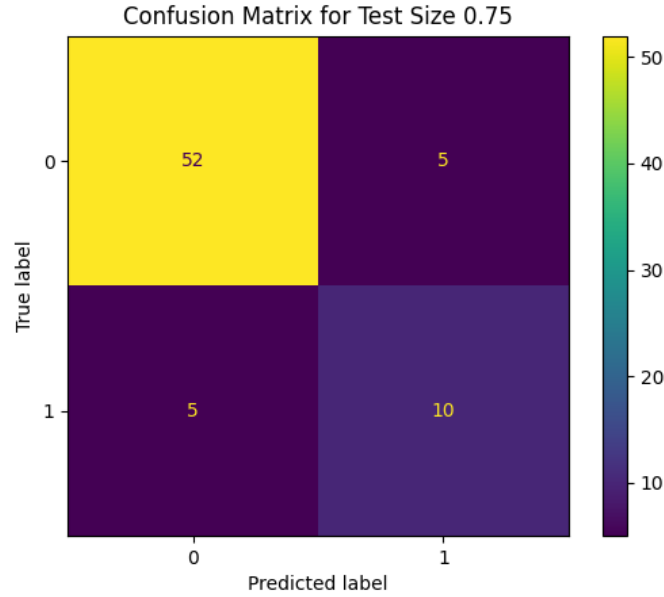
Yanlış Pozitif (False Positive, FP): Gerçekte "1" olan ancak model tarafından yanlışlıkla "0" olarak tahmin edilen 8 durum bulunmaktadır.

Yanlış Negatif (False Negative, FN): Gerçekte "0" olan ancak model tarafından yanlışlıkla "1" olarak tahmin edilen 0 durum bulunmaktadır.

Toplam doğru tahminler (TP + TN) toplam veri sayısına (TP + TN + FP + FN) bölünerek doğruluk oranı elde edilir. Denklem 4.12'de doğruluk oranı hesaplaması verilmiştir.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{37 + 3}{37 + 3 + 8 + 0} = \frac{40}{48} \approx 0.83333 \quad (4.12)$$

Şekil 12'de %75 oranında test verisi kullanılarak oluşan doğruluk matrisinin grafiği verilmiştir.



Şekil 12. NB Algoritmasında %75 Test Verisi İçin Doğruluk Matrisi

Karışıklık matrisinde test verisinin %75 olduğu durumda NB modelinin doğruluk oranının hesaplanması aşağıda verilmiştir ve karışıklık matrisindeki değerlere göre:

Doğru Pozitif (True Positive, TP): Gerçekte "0" olan ve model tarafından doğru olarak "0" tahmin edilen 52 durum bulunmaktadır.

Dođru Negatif (True Negative, TN): Gerçekte "1" olan ve model tarafından dođru olarak "1" tahmin edilen 10 durum bulunmaktadır.


Yanlıř Pozitif (False Positive, FP): Gerçekte "1" olan ancak model tarafından yanlışlıkla "0" olarak tahmin edilen 5 durum bulunmaktadır.

Yanlıř Negatif (False Negative, FN): Gerçekte "0" olan ancak model tarafından yanlışlıkla "1" olarak tahmin edilen 5 durum bulunmaktadır.

Toplam dođru tahminler (TP + TN) toplam veri sayısına (TP + TN + FP + FN) bölünerek dođruluk oranı elde edilir. Denklem 4.13'te dođruluk oranı hesaplaması verilmiştir.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{52 + 10}{52 + 10 + 5 + 5} = \frac{62}{72} \approx 0.8611 \quad (4.13)$$

řekil 13'de yer alan grafikte NB algoritması kullanılarak TF-IDF vektörleştirme yöntemi ile eğitilen modelin farklı test boyutlarına göre performansını göstermektedir.



Şekil 13. NB Algoritmasında TF-IDF Modeli Kullanılarak Test Oranına Göre Performans Grafiği

Grafikte test boyutları (x-ekseni) arttıkça modelin doğruluk ve F1 Skoru değerlerinin (y-ekseni) nasıl değiştiği belirtilmiştir.

Doğruluk Oranı: Modelin doğruluk oranı, farklı test seti büyüklüklerinde incelendiğinde, %25 ve %50 test oranlarında sabit bir şekilde %83.33 olarak gözlemlenmiştir. Ancak test seti büyüklüğü %75'e çıkarıldığında, doğruluk oranı %86.11'e yükselmiştir. Bu artış, modelin genişlemiş bir veri seti üzerinde daha iyi genelleme yapma kapasitesine sahip olduğunu ve bu büyüklükteki veri setlerinin modelin performansını daha iyi yansıttığını göstermektedir.

F1 Skoru: Modelin F1 skoru, test seti boyutunun büyüklüğü ile doğru orantılı olarak artmıştır. %25'lik test seti boyutunda %78.57 olarak ölçülen F1 skoru, %75'lik test seti boyutunda %86.11'e çıkmıştır. F1 skorunun artışı, modelin hassasiyet ve geri çağırma dengesinin, genişletilmiş test setleri ile daha iyi hale geldiğini ifade etmektedir.

4.5.2. BERT algoritması

Yalan haber tespitinde sık kullanılan BERT algoritması ile %25, %50 ve %75 test verisi kullanılarak algoritmanın doğruluk ve F1 skorunun hesaplanması sağlanmıştır. BERT algoritmasında sonuçlar hesaplanır iken TF-IDF, Word2Vec veya Doc2Vec modelleri


yerine kendine özgü olan transformer modeli kullanılmaktadır. BERT modeli, metinlerin tokenleştirilmesi ve bunların bağlam temelli gömülülerinin elde edilmesi için özel bir tokenleştirici ve model yapısı kullanılmaktadır.

Tablo 2’de yer alan sonuçlarda yalan haber veri setinin %25, %50 ve %75 oranında test verisi olarak kullanılarak eğitilmiş modelin doğruluk ve F1 skoru sonuçları yer almaktadır. Tabloda yer alan sonuçlar göz önünde bulundurulduğunda veri setinin büyüklüğü artıkça doğruluk oranında artış gözlenmektedir.

Tablo 2. BERT Algoritması Doğruluk Oranı ve F1 Skoru Değerleri

Sıra No	Test Oranı	Accuracy	F1 Score
1	0.25	0.750000	0.750000
2	0.50	0.770833	0.671078
3	0.75	0.791667	0.699612

Şekil 14’te %25 oranında test verisi kullanılarak oluşan doğruluk matrisinin grafiği verilmiştir.



Şekil 14. BERT Algoritmasında %25 Test Verisi İçin Doğruluk Matrisi

Karışıklık matrisinde test verisinin %25 olduğu durumda BERT modelinin doğruluk oranının hesaplanması aşağıda verilmiştir ve karışıklık matrisindeki değerlere göre:

Doğru Pozitif (True Positive, TP): Gerçekte "0" olan ve model tarafından doğru olarak "0" tahmin edilen 16 durum bulunmaktadır.

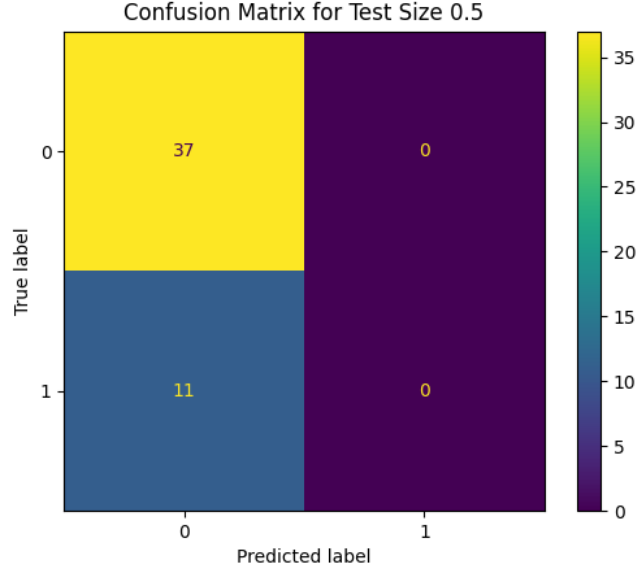
Doğru Negatif (True Negative, TN): Gerçekte "1" olan ve model tarafından doğru olarak "1" tahmin edilen 2 durum bulunmaktadır

Yanlış Pozitif (False Positive, FP): Gerçekte "1" olan ancak model tarafından yanlışlıkla "0" olarak tahmin edilen 3 durum bulunmaktadır.

Yanlış Negatif (False Negative, FN): Gerçekte "0" olan ancak model tarafından yanlışlıkla "1" olarak tahmin edilen 3 durum bulunmaktadır. Denklem 4.14'te doğruluk oranı hesaplaması verilmiştir.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{16 + 2}{16 + 2 + 3 + 3} = \frac{18}{24} \approx 0.75000 \quad (4.14)$$

Şekil 15’de %50 oranında test verisi kullanılarak oluşan doğruluk matrisinin grafiği verilmiştir.



Şekil 15. BERT Algoritmasında %50 Test Verisi İçin Doğruluk Matrisi

Karışıklık matrisinde test verisinin %50 olduğu durumda BERT modelinin doğruluk oranının hesaplanması aşağıda verilmiştir ve karışıklık matrisindeki değerlere göre:

Doğru Pozitif (True Positive, TP): Gerçekte "0" olan ve model tarafından doğru olarak "0" tahmin edilen 37 durum bulunmaktadır

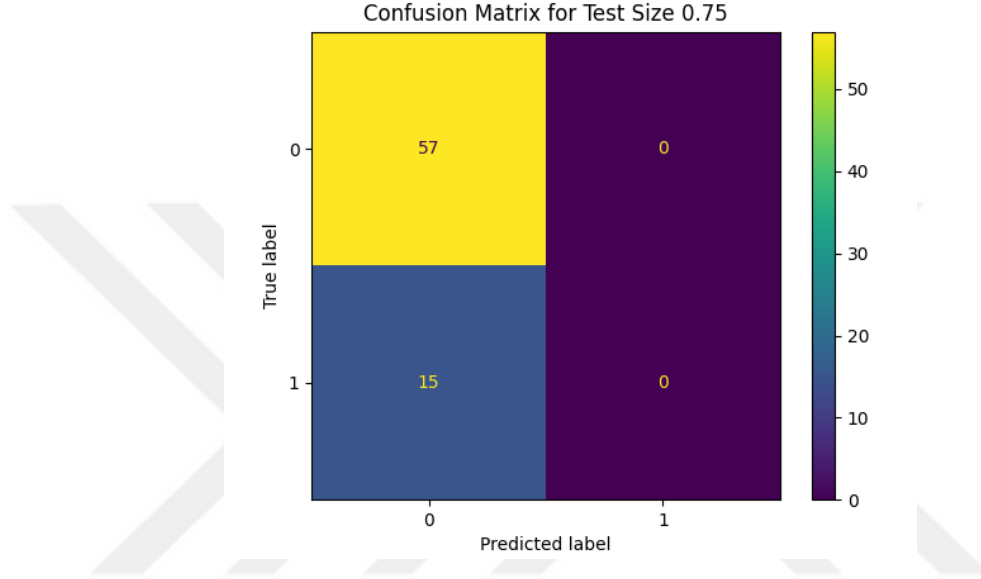
Doğru Negatif (True Negative, TN): Gerçekte "1" olan ve model tarafından doğru olarak "1" tahmin edilen 0 durum bulunmaktadır

Yanlış Pozitif (False Positive, FP): Gerçekte "1" olan ancak model tarafından yanlışlıkla "0" olarak tahmin edilen 11 durum bulunmaktadır.

Yanlış Negatif (False Negative, FN): Gerçekte "0" olan ancak model tarafından yanlışlıkla "1" olarak tahmin edilen 0 durum bulunmaktadır. Denklem 4.15’te doğruluk oranı hesaplaması verilmiştir.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{37 + 0}{37 + 11 + 0 + 0} = \frac{37}{48} \approx 0.77083 \quad (4.15)$$

Şekil 16'da %75 oranında test verisi kullanılarak oluşan doğruluk matrisinin grafiği verilmiştir.



Şekil 16. BERT Algoritmasında %75 Test Verisi İçin Doğruluk Matrisi

Karışıklık matrisinde test verisinin %75 olduğu durumda BERT modelinin doğruluk oranının hesaplanması aşağıda verilmiştir ve karışıklık matrisindeki değerlere göre:

Doğru Pozitif (True Positive, TP): Gerçekte "0" olan ve model tarafından doğru olarak "0" tahmin edilen 57 durum bulunmaktadır.


Doğru Negatif (True Negative, TN): Gerçekte "1" olan ve model tarafından doğru olarak "1" tahmin edilen 0 durum (bu kısım önemli çünkü model hiçbir "1" tahmini doğru yapmamış) bulunmaktadır.

Yanlış Pozitif (False Positive, FP): Gerçekte "1" olan ancak model tarafından yanlışlıkla "0" olarak tahmin edilen 0 durum bulunmaktadır.

Yanlış Negatif (False Negative, FN): Gerçekte "0" olan ancak model tarafından yanlışlıkla "1" olarak tahmin edilen 15 durum bulunmaktadır. Denklem 4.16'da doğruluk oranı hesaplaması verilmiştir.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{57 + 0}{57 + 15 + 0 + 0} = \frac{57}{72} \approx 0.791667 \quad (4.16)$$

Şekil 17'de yer alan grafikte BERT algoritması kullanılarak eğitilmiş bir modelin farklı test boyutları için performans değerleri gösterilmektedir.



Şekil 17. BERT Algoritmasında Test Oranına Göre Performans Grafiği

Doğruluk Oranı: Modelin performansı, farklı test boyutlarında incelendiğinde, doğruluk oranında kademeli bir artış gözlenmiştir. Test oranı %25'te başlangıç değeri %75 olarak ölçülmüş, bu oran test boyutunun %50'ye çıkmasıyla %77.08'e, ardından %75'e çıkmasıyla %79.17'ye yükselmiştir. Bu artış, modelin daha geniş veri setleriyle daha iyi genelleştirme yapabildiğini gösterir, bu da modelin çeşitli durumları kapsayacak şekilde daha doğru tahminler yapabilme kapasitesinin arttığını işaret etmektedir.

F1 Skoru: F1 skoru, doğruluk kadar düzenli bir artış göstermemiştir. %25'lik test oranında %75 olan F1 skoru, %50'lik test oranında %67.11'e düşmüş ancak %75'lik test oranında tekrar %69.96'ya çıkmıştır. Bu durum, modelin hassasiyet ve geri çağırma oranlarının farklı test seti büyüklüklerinde nasıl değiştiğini göstermektedir. Özellikle, %50'lik test oranında F1 skorunun düşmesi, bu test boyutunda modelin bazı sınıfları yanlış tahmin etme oranının arttığını işaret edebilir. Büyük test setinde ise bu skorun tekrar artması, modelin geniş veri setleri karşısında daha dengeli bir performans sergilediğini göstermektedir.

4.5.3. LSTM algoritması


Yalan haber tespitinde sıklıkla kullanılan LSTM modeli bu çalışmada kullanılarak metin işleme ve sınıflandırma işlemi için bir LSTM tabanlı derin öğrenme modeli kullanılmıştır.

Tablo 3'te LSTM algoritmasının performansı, veri setinin %25, %50 ve %75 test seti büyüklüklerinde F1 skoru ve doğruluk oranı ölçülmüştür. Tablodaki sonuçlar göz önünde bulundurulduğunda farklı test oranlarında doğruluk oranları tutarlı bir şekilde yakın sonuçlar oluşturduğu gözlenmektedir.

Tablo 3. LSTM Algoritmasının Doğruluk Oranları ve F1 Skoru Değerleri

Sıra No	Test Oranı	Accuracy	F1 Score
1	0.25	0.7917	0.6996
2	0.50	0.7708	0.6711
3	0.75	0.7917	0.6996

Şekil 18’de %25 oranında test verisi kullanılarak oluşan doğruluk matrisinin grafiği verilmiştir.



Şekil 18. LSTM Algoritmasında %25 Test Verisi İçin Doğruluk Matrisi

Karışıklık matrisinde test verisinin %25 olduğu durumda LSTM modelinin doğruluk oranının hesaplanması aşağıda verilmiştir ve karışıklık matrisindeki değerlere göre:

Doğru Pozitif (True Positive, TP): Gerçekte "0" olan ve model tarafından doğru olarak "0" olarak tahmin edilen 19 durum bulunmaktadır.

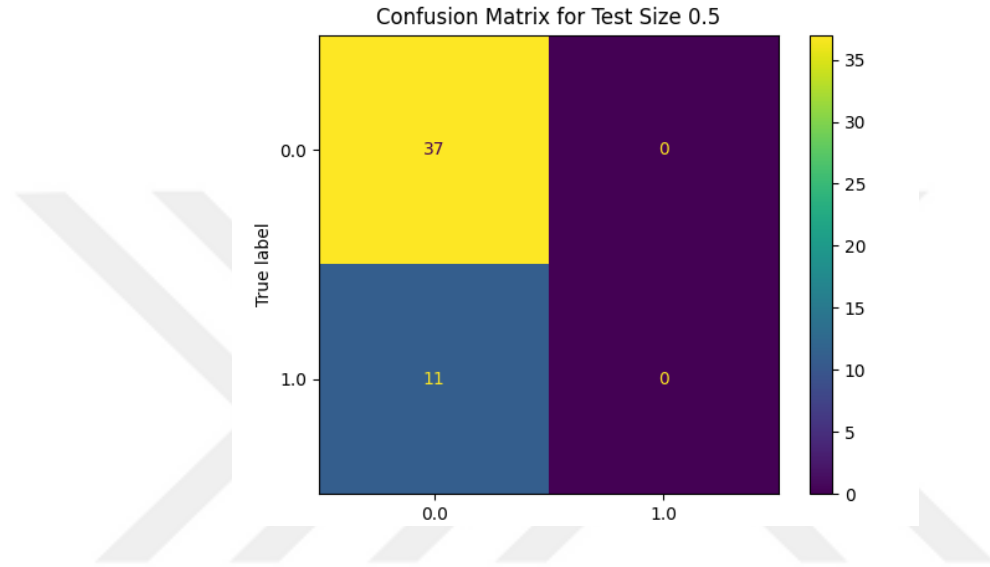
Doğru Negatif (True Negative, TN): Gerçekte "1" olan ve model tarafından doğru olarak "1" tahmin edilen 0 durum (model hiçbir "1" durumunu doğru tahmin edememiştir) bulunmaktadır.

Yanlış Pozitif (False Positive, FP): Gerçekte "1" olan ancak model tarafından yanlışlıkla "0" tahmin edilen 0 durum bulunmaktadır.

Yanlış Negatif (False Negative, FN): Gerçekte "0" olan ancak model tarafından yanlışlıkla "1" olarak tahmin edilen 5 durum bulunmaktadır. Denklem 4.17’de doğruluk oranı hesaplaması verilmiştir.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{19 + 0}{19 + 5 + 0 + 0} = \frac{19}{24} \approx 0.7917 \quad (4.17)$$

Şekil 19'da %50 oranında test verisi kullanılarak oluşan doğruluk matrisinin grafiği verilmiştir.



Şekil 19. LSTM Algoritmasında %50 Test Verisi İçin Doğruluk Matrisi

Karışıklık matrisinde test verisinin %50 olduğu durumda LSTM modelinin doğruluk oranının hesaplanması aşağıda verilmiştir ve karışıklık matrisindeki değerlere göre:

Doğru Pozitif (True Positive, TP): Gerçekte "0" olan ve model tarafından doğru olarak "0" tahmin edilen 37 durum bulunmaktadır.


Doğru Negatif (True Negative, TN): Gerçekte "1" olan ve model tarafından doğru olarak "1" tahmin edilen 0 durum (model hiçbir "1" durumunu doğru tahmin edememiştir) bulunmaktadır.

Yanlış Pozitif (False Positive, FP): Gerçekte "1" olan ancak model tarafından yanlışlıkla "0" olarak tahmin edilen 0 durum bulunmaktadır.

Yanlış Negatif (False Negative, FN): Gerçekte "0" olan ancak model tarafından yanlışlıkla "1" olarak tahmin edilen 11 durum bulunmaktadır. Denklem 4.18'de doğruluk oranı hesaplaması verilmiştir.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{37 + 0}{37 + 0 + 11 + 0} = \frac{37}{48} \approx 0.7708 \quad (4.18)$$

Şekil 20'de %75 oranında test verisi kullanılarak oluşan doğruluk matrisinin grafiği verilmiştir.



Şekil 20. LSTM Algoritmasında %75 Test Verisi İçin Doğruluk Matrisi

Karışıklık matrisinde test verisinin %75 olduğu durumda LSTM modelinin doğruluk oranının hesaplanması aşağıda verilmiştir ve karışıklık matrisindeki değerlere göre:

Doğru Pozitif (True Positive, TP): Gerçekte "0" olan ve model tarafından doğru olarak "0" tahmin edilen 57 durum bulunmaktadır.

Doğru Negatif (True Negative, TN): Gerçekte "1" olan ve model tarafından doğru olarak "1" tahmin edilen 0 durum (model hiçbir "1" durumunu doğru tahmin edememiştir) bulunmaktadır.

Yanlış Pozitif (False Positive, FP): Gerçekte "1" olan ancak model tarafından yanlışlıkla "0" olarak tahmin edilen 0 durum bulunmaktadır.

Yanlış Negatif (False Negative, FN): Gerçekte "0" olan ancak model tarafından yanlışlıkla "1" olarak tahmin edilen 15 durum bulunmaktadır. Denklem 4.19'da doğruluk oranı hesaplaması verilmiştir.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{57 + 0}{57 + 0 + 15 + 0} = \frac{57}{72} \approx 0.7917 \quad (4.19)$$

Şekil 21'de yer alan grafikte LSTM algoritması kullanılarak eğitilmiş bir modelin farklı test boyutları için performans değerleri gösterilmektedir.



Şekil 21. LSTM Algoritmasında Test Oranına Göre Performans Grafiği

Doğruluk Oranı: Doğruluk oranı 0.25 test oranında 0.7917 ile en yüksek değerini almış, 0.50 test oranında 0.7708'e düşmüş ve tekrar 0.75 test oranında 0.7917'ye yükselmiştir. Bu dalgalanma, modelin farklı test boyutlarında nasıl performans gösterdiğini ve genelleştirme kabiliyetinin test setinin büyüklüğüne bağlı olarak nasıl değişebileceğini göstermektedir.

F1 Skoru: F1 skoru, 0.25 test oranında 0.6996, 0.50 test oranında 0.6711, ve 0.75 test oranında tekrar 0.6996 olarak kaydedilmiştir. Test boyutunun artışı ile F1 skorundaki bu değişim, modelin farklı test boyutlarında sınıfları ne derece dengeli tahmin ettiğini ortaya koymaktadır. Daha büyük test boyutları ile modelin dengeli bir şekilde performans gösterdiği ve hem doğruluk hem de F1 skorlarının artış gösterdiği gözlemlenmiştir. Bu durum, modelin geniş test setlerinde daha stabil ve güvenilir sonuçlar verdiğini göstermektedir.

4.5.4. SVM algoritması


Yalan haber tespitinde sıklıkla kullanılan derin öğrenme modeli, SVM modeli kullanılmıştır. SVM modeli, SVC (Destek Vektör Sınıflandırıcısı, Support Vector Classifier) sınıfı aracılığıyla uygulanmıştır. SVC sınıfı kernel='linear' parametresi ile yapılandırılmış, yani doğrusal bir çekirdek (kernel) kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. SVM modeli eğitilmeden önce veri setindeki kelimelerin önemini ağırlıklarına göre belirlemek için TD-IDF vektörleştirme modeli kullanılmıştır

Tablo 4'de %25, %50 ve %75 test verisi kullanılarak doğruluk oranları ve F1 skorunun hesaplanması sağlanarak her bir test oranı için doğruluk matrisi oluşturulup modelin performans tablosu oluşturulmuştur. Tablodaki sonuçlar göz önünde bulundurulduğunda modelin daha küçük veriler üzerinde daha iyi performans gösterdiği saptanmıştır.

Tablo 4. SVM Algoritması Doğruluk Oranı ve F1 Skoru Değerleri

Sıra No	Test Oranı	Accuracy	F1 Score
1	0.25	0.916667	0.921296
2	0.50	0.875000	0.875000
3	0.75	0.791667	0.804559

Şekil 22’de %25 oranında test verisi kullanılarak oluşan doğruluk matrisinin grafiği verilmiştir.



Şekil 22. SVM Algoritmasında %25 Test Verisi İçin Doğruluk Matrisi

Karışıklık matrisinde test verisinin %25 olduğu durumda SVM modelinin doğruluk oranının hesaplanması aşağıda verilmiştir ve karışıklık matrisindeki değerlere göre:

Doğru Pozitif (True Positive, TP): Gerçekte "0" olan ve model tarafından doğru olarak "0" tahmin edilen 17 durum bulunmaktadır.


Doğru Negatif (True Negative, TN): Gerçekte "1" olan ve model tarafından doğru olarak "1" tahmin edilen 5 durum bulunmaktadır.

Yanlış Pozitif (False Positive, FP): Gerçekte "1" olan ancak model tarafından yanlışlıkla "0" olarak tahmin edilen 2 durum bulunmaktadır.

Yanlış Negatif (False Negative, FN): Gerçekte "0" olan ancak model tarafından yanlışlıkla "1" olarak tahmin edilen 0 durum bulunmaktadır. Denklem 4.20’te doğruluk oranı hesaplaması verilmiştir.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{17 + 5}{17 + 5 + 2 + 0} = \frac{22}{24} \approx 0.916667 \quad (4.20)$$

Şekil 23'te %50 oranında test verisi kullanılarak oluşan doğruluk matrisinin grafiği verilmiştir.



Şekil 23. SVM Algoritmasında %50 Test Verisi İçin Doğruluk Matrisi

Karışıklık matrisinde test verisinin %50 olduğu durumda SVM modelinin doğruluk oranının hesaplanması aşağıda verilmiştir ve karışıklık matrisindeki değerlere göre:

Doğru Pozitif (True Positive, TP): Gerçekte "0" olan ve model tarafından doğru olarak "0" tahmin edilen 34 durum bulunmaktadır.


Doğru Negatif (True Negative, TN): Gerçekte "1" olan ve model tarafından doğru olarak "1" tahmin edilen 8 durum bulunmaktadır.

Yanlış Pozitif (False Positive, FP): Gerçekte "1" olan ancak model tarafından yanlışlıkla "0" olarak tahmin edilen 3 durum bulunmaktadır.

Yanlış Negatif (False Negative, FN): Gerçekte "0" olan ancak model tarafından yanlışlıkla "1" olarak tahmin edilen 3 durum bulunmaktadır. Denklem 4.21'te doğruluk oranı hesaplaması verilmiştir.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{34 + 8}{34 + 8 + 3 + 3} = \frac{42}{48} \approx 0.875000 \quad (4.21)$$

Şekil 24'de %75 oranında test verisi kullanılarak oluşan doğruluk matrisinin grafiği verilmiştir.



Şekil 24. SVM Algoritmasında %75 Test Verisi İçin Doğruluk Matrisi

Karışıklık matrisinde test verisinin %75 olduğu durumda SVM modelinin doğruluk oranının hesaplanması aşağıda verilmiştir ve karışıklık matrisindeki değerlere göre:

Doğru Pozitif (True Positive, TP): Gerçekte "0" olan ve model tarafından doğru olarak "0" tahmin edilen 46 durum bulunmaktadır.


Doğru Negatif (True Negative, TN): Gerçekte "1" olan ve model tarafından doğru olarak "1" tahmin edilen 11 durum bulunmaktadır.

Yanlış Pozitif (False Positive, FP): Gerçekte "1" olan ancak model tarafından yanlışlıkla "0" olarak tahmin edilen 4 durum bulunmaktadır.

Yanlış Negatif (False Negative, FN): Gerçekte "0" olan ancak model tarafından yanlışlıkla "1" olarak tahmin edilen 11 durum bulunmaktadır. Denklem 4.22'te doğruluk oranı hesaplaması verilmiştir.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{34 + 8}{34 + 8 + 3 + 3} = \frac{42}{48} \approx 0.791667 \quad (4.22)$$

Şekil 25'de yer alan grafikte SVM algoritması kullanılarak eğitilmiş bir modelin farklı test boyutları için performans değerleri gösterilmektedir.



Şekil 25. SVM Algoritmasında Test Oranına Göre Performans Grafiği

Doğruluk Oranı: %25 test oranında doğruluk oranı en yüksek düzeyde, %91.67 olarak kaydedilmiştir. Bu, modelin daha küçük bir test seti üzerinde çalışırken yüksek bir genelleştirme kabiliyetine sahip olduğunu ve veri setindeki örnekleri etkili bir şekilde sınıflandırabildiğini göstermektedir. Ancak, test oranı %50'ye çıkarıldığında doğruluk oranı %87.50'ye düşmektedir. Bu durum, modelin genişletilmiş bir veri seti üzerindeki performansının azaldığını, fakat hala kabul edilebilir bir seviyede olduğunu belirtir. Test boyutu %75'e ulaştığında ise doğruluk oranı %79.17'ye düşmektedir, bu da modelin geniş test setlerinde genelleme yapmakta zorlandığını ve performansının daha belirgin şekilde düşüş gösterdiğini işaret etmektedir.

F1 Skoru: Modelin F1 skoru, test boyutu arttıkça düşmüş olup, bu düşüş doğruluk oranına kıyasla daha yavaş gerçekleşmiştir. %25 test oranında F1 skoru en yüksek seviyede, %92.13 olarak ölçülmüştür. Test oranı %50'ye çıktığında F1 skoru %87.50'ye düşmüştür;

bu düşüş, doğruluk oranındaki azalma ile paralel olarak modelin sınıflar arası performans dengesinde bazı zorluklar yaşadığını işaret etmektedir. Test boyutu %75'e ulaştığında ise F1 skoru %80.46'ya düşmüş, bu da modelin genişletilmiş test setlerinde performansının azaldığını ve özellikle azınlık sınıfı tahminlerinde zorlanmaya başladığını göstermektedir.

4.5.5. Neural NetWorks TF


Yalan haber tespitinde sıklıkla kullanılan derin öğrenme modeli, Neural NetWorks TF modelinde TensorFlow/Keras kütüphanesini kullanarak sınıflandırma işlemi gerçekleştirilmiştir. Modelde Embedding, GlobalAveragePooling1D, Dense katmanları eklenerek modelin eğitilmesi sağlanmıştır.

Tablo 5'de %25, %50 ve %75 test verisi kullanılarak doğruluk oranları ve F1 skorunun hesaplanması sağlanarak her bir test oranı için doğruluk matrisi oluşturulup modelin performans tablosu oluşturulmuştur. Tablodaki sonuçlar göz önünde bulundurulduğunda veri setinin artması durumunda modelin daha iyi bir performans gösterdiği saptanmıştır.

Tablo 5. Neural NetWorks TF Algoritması Doğruluk Oranı ve F1 Skoru Değerleri

Sıra No	Test Oranı	Accuracy	F1 Score
1	0.25	0.791667	0.699612
2	0.50	0.812500	0.757762
3	0.75	0.833333	0.785714

Şekil 26'da %25 oranında test verisi kullanılarak oluşan doğruluk matrisinin grafiği verilmiştir.



Şekil 26. Neural NetWorks TF Algoritmasında %25 Test Verisi İçin Doğruluk Matrisi
 Karışıklık matrisinde test verisinin %25 olduğu durumda : Neural NetWorks TF (TensorFlow) modelinin doğruluk oranının hesaplanması aşağıda verilmiştir ve karışıklık matrisindeki değerlere göre:

True Positives (Doğru Pozitif, TP): Gerçekte "0" olan ve model tarafından doğru olarak "0" tahmin edilen 19 durum bulunmaktadır.


Doğru Negatif (True Negative, TN): Gerçekte "1" olan ve model tarafından doğru olarak "1" tahmin edilen 0 durum bulunmaktadır.

Yanlış Pozitif (False Positive, FP): Gerçekte "1" olan ancak model tarafından yanlışlıkla "0" olarak tahmin edilen 5 durum bulunmaktadır.

Yanlış Negatif (False Negative, FN): Gerçekte "0" olan ancak model tarafından yanlışlıkla "1" olarak tahmin edilen 0 durum bulunmaktadır. Denklem 4.23'de doğruluk oranı hesaplaması verilmiştir.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} = \frac{19 + 0}{19 + 0 + 5 + 0} = \frac{19}{24} \approx 0.791667 \quad (4.23)$$

Şekil 27’de %50 oranında test verisi kullanılarak oluşan doğruluk matrisinin grafiği verilmiştir.



Şekil 27. Neural NetWorks TF Algoritmasında %50 Test Verisi İçin Doğruluk Matrisi
Karışıklık matrisinde test verisinin %50 olduğu durumda modelinin doğruluk oranını hesaplanması aşağıda verilmiştir ve karışıklık matrisindeki değerlere göre:

Doğru Pozitif (True Positive, TP): Gerçekte "0" olan ve model tarafından doğru olarak "0" tahmin edilen 37 durum bulunmaktadır.


Doğru Negatif (True Negative, TN): Gerçekte "1" olan ve model tarafından doğru olarak "1" tahmin edilen 2 durum bulunmaktadır.

Yanlış Pozitif (False Positive, FP): Gerçekte "1" olan ancak model tarafından yanlışlıkla "0" olarak tahmin edilen 9 durum bulunmaktadır.

Yanlış Negatif (False Negative, FN): Gerçekte "0" olan ancak model tarafından yanlışlıkla "1" olarak tahmin edilen 0 durum bulunmaktadır. Denklem 4.24’de doğruluk oranı hesaplaması verilmiştir.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{37 + 2}{37 + 9 + 2 + 0} = \frac{39}{48} \approx 0.812500 \quad (4.24)$$

Şekil 28’de %75 oranında test verisi kullanılarak oluşan doğruluk matrisinin grafiği verilmiştir.



Şekil 28. Neural NetWorks TF Algoritmasında %75 Test Verisi İçin Doğruluk Matrisi
Karışıklık matrisinde test verisinin %75 olduğu durumda modelinin doğruluk oranını hesaplanması aşağıda verilmiştir ve karışıklık matrisindeki değerlere göre:

Doğru Pozitif (True Positive, TP): Gerçekte "0" olan ve model tarafından doğru olarak "0" tahmin edilen 57 durum bulunmaktadır.


Doğru Negatif (True Negative, TN): Gerçekte "1" olan ve model tarafından doğru olarak "1" tahmin edilen 3 durum bulunmaktadır.

Yanlış Pozitif (False Positive, FP): Gerçekte "1" olan ancak model tarafından yanlışlıkla "0" olarak tahmin edilen 12 durum bulunmaktadır.

Yanlış Negatif (False Negative, FN): Gerçekte "0" olan ancak model tarafından yanlışlıkla "1" olarak tahmin edilen 0 durum bulunmaktadır. Denklem 4.25’de doğruluk oranı hesaplaması verilmiştir.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{57 + 3}{57 + 12 + 3 + 0} = \frac{60}{72} \approx 0.833333 \quad (4.25)$$

Şekil 29’da yer alan grafikte Neural NetWorks TF (TensorFlow) algoritması kullanılarak eğitilmiş bir modelin farklı test boyutları için performans değerleri gösterilmektedir.



Şekil 29. Neural NetWorks TF Algoritmasında Test Oranına Göre Performans Grafiği

Doğruluk Oranı: Test seti boyutu arttıkça hem doğruluk hem de F1 skorunda genel bir iyileşme gözlemlenmektedir. %25 test oranında modelin doğruluk oranı %79.17'dir. Bu, modelin daha küçük bir test setiyle çalışırken oldukça iyi performans gösterdiğini ve veri setindeki örnekleri doğru bir şekilde genellebildiğini göstermektedir. %50 test oranı doğruluk oranı %81.25'e yükselmiştir. Bu, test seti büyüklüğünün artmasıyla modelin performansında bir iyileşme olduğunu, daha geniş bir veri çeşitliliğiyle karşılaştığında bile modelin genelleme kabiliyetinin arttığını gösterir. %75 test oranı doğruluk oranı %83.33'e çıkmaktadır. Bu, modelin en büyük test setinde en iyi performansı gösterdiğini, büyük veri setlerinde bile yüksek doğruluk oranları elde edebildiğini göstermektedir.

F1 Skoru: F1 skoru, %25'lik test oranında %69.96 olarak ölçülmüştür. Bu düşük skor, modelin küçük test setleri karşısında sınıflar arası dengesizlikleri etkin bir şekilde yönetme konusunda zorluklar yaşadığını göstermektedir. Test oranı %50'ye yükseldiğinde, F1 skoru %75.78'e çıkmıştır, bu da modelin artan test seti büyüklüğü ile sınıflar arasındaki dengesizlikleri daha iyi yönetebildiğini ve daha dengeli bir sınıflandırma performansı sergilediğini işaret etmektedir. %75'lik test oranında ise F1 skoru %78.57'ye ulaşmıştır. Bu artış, modelin büyük test setlerinde bile sınıflar arası

dengesizlikleri başarıyla yönettiğini ve dolayısıyla yüksek bir F1 skoru elde ettiğini göstermektedir.



BÖLÜM 5. DENEYSEL SONUÇLAR VE BULGULAR

Bu çalışmanın temel amacı, metin sınıflandırma görevlerinde farklı yapay zeka modellerinin performansını değerlendirmek ve bu modellerin genişletilmiş veri setlerine olan uyumlarını karşılaştırmaktır. Çalışma, modellerin doğruluk ve F1 skorları üzerinden genelleme yeteneklerini ve dengeli performanslarını ölçmeyi hedeflemektedir. Naive Bayes, BERT, LSTM, SVM ve Neural Networks TF modellerinin farklı test boyutlarındaki (%25, %50, %75) doğruluk ve F1 skoru değerlerini karşılaştırmaktadır. Bu yaklaşım, model seçiminde ve yapay zeka algoritmalarının kullanımında daha etkin çözümlerinde yol gösterici olmaktadır.

5.1.Bulgular

Yalan haber tespiti çalışmasında farklı özelliklere sahip modellerin benzer test oranları ile eğitilip performans sonuçları incelenmiştir. Kullanılan modellerin performans sonuçlarını değerlendirilirken veri setinin büyüklüğü, verilerin doğru bir şekilde etiketlenmesi ve verilerin modelde eğitilmeden önce yapılan ön işlemlerin doğru bir şekilde yapılması modellerin performansı üzerinde ciddi etki yaratmaktadır. Bununla birlikte, haberin doğruluğunun teyit edilmesi en zor ve ciddi şekilde zaman harcayan bir işlemdir. Yalan haberin sosyal medya uygulamalarında bu denli hızlı bir şekilde yayılması söz konusu olduğundan dolayı yalan haberlerin tespit edilip etiketlenmesi için harcanan efor dan dolayı yalan haberlerin yayılmasının önüne geçilmesini zorlamaktadır. Modellerin eğitilip performans sonuçları bir araya getirilerek Tablo 6'da tez çalışmasında kullanılan NB, BERT, LSTM, SVM, Neural Networks TF algoritmalarının %25, %50 ve %75 oranında test verisi kullanılarak eğitilmiş modellerin doğruluk ve F1 skorunun sonuçlarını göstermektedir.

Tablo 6. Test Oranlarına Göre Algoritmaların Doğruluk ve F1 Skor Sonuçları

Yöntem	Accuracy %25	F1 Score %25	Accuracy %50	F1 Score %50	Accuracy %75	F1 Score %75
NB	0.833333	0.785714	0.833333	0.793844	0.861111	0.861111
BERT	0.750000	0.750000	0.770833	0.671078	0.791667	0.699612
LSTM	0.7917	0.6996	0.7708	0.6711	0.7917	0.6996
SVM	0.916667	0.921296	0.875000	0.875000	0.791667	0.804559
Neural NetWorks TF	0.791667	0.699612	0.812500	0.757762	0.833333	0.785714

NB: Tüm test boyutlarında doğruluk oranları 0.83 civarında seyrederek, %75 test boyutunda doğruluk 0.86'ya çıkmıştır. F1 skoru %25 test boyutunda 0.79 iken, %75 test boyutunda 0.86'ya ulaşmıştır. Bu, modelin genişlemiş test setlerinde dengeli ve tutarlı performans sergilediğini göstermektedir.

BERT: Doğruluk oranları %25 test boyutunda 0.75'ten başlayıp, %75 test boyutunda 0.79'a çıkmıştır. F1 skoru ise, özellikle %50 ve %75 test boyutlarında düşük kalmıştır (0.67 ve 0.70). Bu, modelin bazı sınıflandırma senaryolarında zorlandığını göstermektedir.

LSTM: Doğruluk oranları ve F1 skorları tüm test boyutlarında benzer seviyelerde seyretmiştir (%0.77 - %0.79 doğruluk ve yaklaşık %0.70 F1 skoru). Modelin daha geniş veri setleriyle daha iyi öğrenmediğini ve dengeli bir sınıflandırma performansı sergilemediğini göstermiştir.

SVM: Doğruluk oranları %25 test boyutunda en yüksek değeri olan 0.92'den başlayıp, %75 test boyutunda 0.79'a düşmüştür. F1 skoru da benzer şekilde azalmıştır. Bu, modelin küçük veri setlerinde daha iyi performans gösterdiğini göstermiştir.

Neural NetWorks TF: Doğruluk oranları %25 test boyutunda 0.79'dan, %75 test boyutunda 0.83'e çıkmış, F1 skoru ise %25 test boyutunda 0.70'den %75 test boyutunda 0.79'a yükselmiştir. Bu, modelin artan veri boyutları ile performansını artırdığını göstermiştir.

Tablo 6'da yer alan sonuçlar doğrultusunda %25 test seti oranı ile yapılan testlerde aşağıdaki sonuçlar elde edilmiştir.

Naive Bayes: Doğruluk ve F1 skoru, %25 test boyutu oranında en yüksek olduğu görülmektedir. Bu, Naive Bayes modelinin küçük veri setleriyle iyi performans gösterebildiğine işaret etmektedir. Literatürde, Naive Bayes'in özellikle öznitelik bağımsızlığı varsayımı altında, az veriyle bile iyi sonuçlar verebildiği bilinmektedir.

BERT: Hem doğruluk hem de F1 skorunda, test seti oranı arttıkça performans artmıştır. Bu durum, BERT gibi derin öğrenme tabanlı modellerin büyük veri setlerinden daha fazla faydalanabildiğini göstermektedir.

LSTM: Düşük test seti oranında, performansın nispeten daha yüksek olduğu görülürken, oran arttıkça performans düşmüştür. LSTM modelleri genellikle uzun bağımlılıkları modelleyebilmesine rağmen, veri boyutunun azalması modelin performansını olumsuz etkileyebilir.

Tablo 6'da yer alan sonuçlar doğrultusunda %50 test seti oranı ile yapılan testlerde aşağıdaki sonuçlar elde edilmiştir.

SVM: %50 test oranında doğruluk oranında belirgin bir düşüş yaşamıştır. SVM, eğitim verilerinin kalitesine ve miktarına duyarlı olabilir; bu nedenle dengesiz veri setlerinde performansı düşebilir.

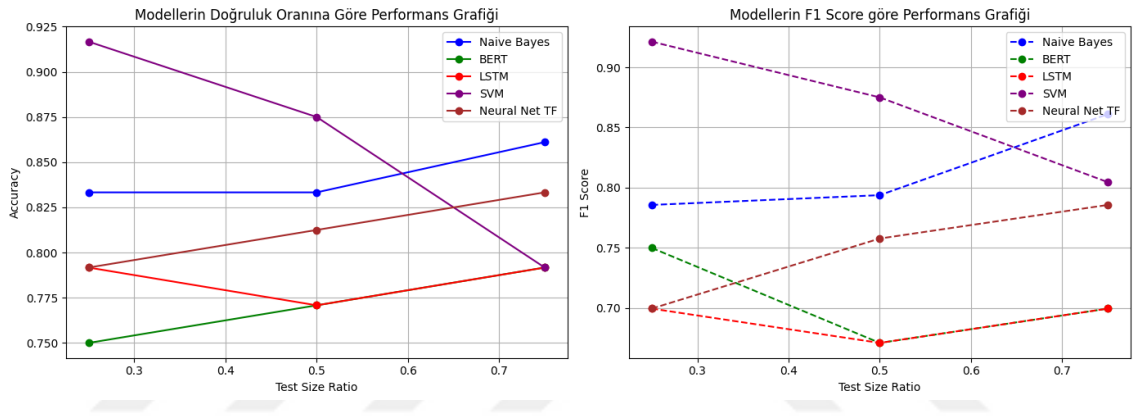
Neural NetWorks TF: %50 test boyutu oranında doğruluk ve F1 skorlarında düşüş yaşamıştır. Yapay sinir ağları, büyük veri setlerini tercih eden modellerdir, bu yüzden veri miktarının azalması bu modellerin performansını olumsuz etkilemiştir.

Tablo 6'da yer alan sonuçlar doğrultusunda %75 test seti oranı ile yapılan testlerde aşağıdaki sonuçlar elde edilmiştir.

Naive Bayes: %75 oranında en düşük performansı sergilemiştir. Naive Bayes modelinin büyük test setlerinde karşılaştığı çeşitlilik ve karmaşıklık, modelin varsayımları nedeniyle zorluklara yol açabilir.

BERT ve LSTM: Her iki derin öğrenme modeli de %75 oranında yüksek performans göstermiştir. Bu, derin öğrenme modellerinin büyük veri setlerinden, karmaşık öznelik ve bağlamları öğrenme kapasitesi nedeniyle daha fazla faydalanabildiğini gösterir.

Şekil 30'da kullanılan algoritmaların doğruluk oranları ve F1 skorlarının sonuçları özetlenerek gösterilmiştir.



Şekil 30. Algoritmaları Test Oranına Göre Performans Grafiği

5.2. Tartışma

Bu araştırmada ele alınan yalan haber tespiti çalışması, NB, BERT, LSTM, SVM ve Neural Networks TF gibi çeşitli makine öğrenimi ve derin öğrenme modellerinin farklı test seti büyüklüklerindeki performanslarını karşılaştırmaktadır. Bu analiz, modellerin veri hazırlığı, etiketleme doğruluğu ve ön işlemlerin kalitesi gibi kritik faktörlere duyarlılığını ortaya koymaktadır.

Çalışmada gözlemlenen bulgular, küçük veri setleriyle çalışırken NB ve SVM modellerinin yüksek doğruluk ve F1 skorları elde ettiğini göstermektedir. Modellerin az veriyle iyi performans sergileyebileceği anlamına gelmektedir. Öte yandan, BERT ve LSTM gibi derin öğrenme tabanlı modeller büyük veri setlerinde daha iyi performans gösterdiği saptanmıştır. Bu modellerin karmaşık yapıları, daha fazla veri ile daha iyi eğitilerek, daha geniş kontekstlerde daha doğru sonuçlar üretilebilmektedir.

Modellerin performansındaki farklılıklar, yalan haber tespiti gibi karmaşık görevlerde hangi modelin tercih edilmesi gerektiği konusunda önemli ipuçları sunmaktadır. Ayrıca, veri seti dengesizlikleri ve ön işleme tekniklerinin kalitesi gibi faktörlerin model başarısını önemli ölçüde etkilediği görülmektedir. Bu bağlamda, daha dengeli veri setleri oluşturulması, verilerden özellik çıkarılmasının iyileştirilmesi ve hatalı etiketlemelerin minimize edilmesi, modellerin genel başarımını artırabilir.



BÖLÜM 6. SONUÇ ve ÖNERİLER

Bu çalışma, yalan haber tespiti için farklı yapay zeka algoritmalarının performansını analiz ederek, çeşitli test seti büyüklüklerinde NB, BERT, LSTM, SVM ve Neural NetWorks TF modellerini değerlendirmiştir. Elde edilen sonuçlar, model seçiminin ve test verisi büyüklüğünün model performansı üzerindeki etkisini ortaya koymuştur.

- Küçük veri setlerinde NB ve SVM modelleri yüksek doğruluk ve F1 skorları ile öne çıkmıştır. Bu, bu modellerin az veri ile iyi performans gösterebildiğini göstermektedir.
- Orta ve büyük veri setlerinde BERT ve LSTM gibi derin öğrenme modelleri, veri setinin büyüklüğü arttıkça daha iyi performans sergilemiştir. Bu durum, bu tür modellerin karmaşık dil yapılarını ve bağlamları daha iyi öğrenebildiğini ve büyük veri setlerinden daha fazla faydalandığını göstermektedir.
- Veri işleme ve etiketleme verilerin doğru şekilde etiketlenmesi ve uygun ön işlemler yapılması, tüm modellerin performansını ciddi şekilde etkilemiştir.
- Model seçimi proje gereksinimlerine göre model seçimi yapılmalıdır. Küçük veri setleri için NB veya SVM gibi modeller tercih edilirken, büyük ve karmaşık veri setleri için BERT veya LSTM gibi derin öğrenme modelleri daha uygun olacaktır.
- Veri hazırlığı yüksek kaliteli veri setlerinin oluşturulması ve etiketlemenin doğrulukla yapılması, model performansını optimize etmek için kritik öneme sahiptir.
- Performans iyileştirme farklı test seti oranlarında modellerin performansını düzenli olarak değerlendirerek, en uygun model yapılandırmalarını belirlemek ve gerekirse hiperparametre ayarlamaları yapmak önemlidir.
- Teknolojik yatırımlar derin öğrenme modellerinin eğitimi için gerekli hesaplama kaynaklarına yatırım yapılması, bu modellerin potansiyelini tam olarak kullanmayı sağlamaktadır.

Sonuç olarak bu çalışma, yalan haber tespitinde kullanılan modellerin daha etkili bir biçimde nasıl uygulanabileceği noktasında değerli öneriler sunarak, alandaki bilgi birikimine katkıda bulunmuştur. Öneriler, gelecekteki uygulamalar için bir yol haritası sağlamakta ve model seçiminden veri işlemeye kadar bir dizi stratejik kararda rehberlik etmektedir.



KAYNAKÇA

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., vd. (2016). Tensorflow: Large-scale machine learning on heterogeneous distributed systems. *arXiv*, 1-19.
- Altunbey Özbay, F., ve Alataş, B. (2020). Çevrimiçi sosyal medyada sahte haber tespiti. *DÜMF Mühendislik Dergisi*, 11(1), 91-103.
- Bishop, C. M., ve Nasrabadi, N. M. (2006). *Pattern recognition and machine learning*: New York: Springer.
- Bozuyula, M. (2022). Advanced Turkish Fake News Prediction With Bidirectional Encoder Representations From Transformers. *Konya Mühendislik Bilimleri Dergisi*, 10(3), 750-761.
- Devlin, J., Chang, M.-W., Lee, K., ve Toutanova, K. (2018). Bert: Pre-training of deep bidirectional transformers for language understanding. *arXiv*, 1-16.
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861-874.
- Hancock, E. (2004). *Ideas into words: Mastering the craft of science writing*: United States: Johns Hopkins University Press.
- Hastie, T., Tibshirani, R., Friedman, J. H., ve Friedman, J. H. (2009). *The elements of statistical learning: data mining, inference, and prediction*: UK: Springer.
- Hayawi, K., Shahriar, S., Serhani, M. A., Taleb, I., ve Mathew, S. S. P. h. (2022). ANTi-Vax: a novel Twitter dataset for COVID-19 vaccine misinformation detection. *Public health*, 203, 23-30.
- Hochreiter, S., ve Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.

- Kavaklı, N. (2018). Yalan Haberle Mücadele ve İnternet Teyit/Doğrulama Platformları. *Erciyes İletişim Dergisi*, 6(1), 663-682.
- Kumari, R., Ashok, N., Ghosal, T., Ekbal, A., ve Management. (2022). What the fake? Probing misinformation detection standing on the shoulder of novelty and emotion. *Information Processing & Management*, 59(1), 102740.
- Le, Q., ve Mikolov, T. (2014). *Distributed representations of sentences and documents*. International conference on machine learning, Beijing, China.
- Manning, C. D., Raghavan, P., ve Schütze, H. (2008). *Introduction to information retrieval*: New York: Cambridge university press.
- Mertoğlu, U. (2020). *Türkçe İçin Sahte Haber Tespit Modelinin Oluşturulması* (Yayın no: 651275), [Doktora, Hacettepe Üniversitesi]. <https://tez.yok.gov.tr/UlusalTezMerkezi/tezSorguSonucYeni.jsp>
- Mikolov, T., Chen, K., Corrado, G., ve Dean, J. a. p. a. (2013). Efficient estimation of word representations in vector space. *arXiv*, 1-12.
- Nielsen, M. A. (2015). *Neural networks and deep learning*: San Francisco, CA, USA: Determination press.
- Oflazer, K. (2016). Türkçe ve Doğal Dil İşleme. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 5(2), 1-12.
- Powers, D. M. (2020). Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. *arXiv*, 37-63.
- Report, D. N. (2022). *Digital 2022: Digital News Report*. 12.10.2023 tarihinde <https://reutersinstitute.politics.ox.ac.uk/digital-news-report/2022/dnr-executive-summary>. adresinden indirildi.
- Report, D. N. (2023). *Digital 2023: Global Overview Report*. 12.10.2023 tarihinde <https://datareportal.com/reports/digital-2023-global-overview-report>. adresinden indirildi.

- Rijsbergen, C. v. (1979). *Information retrieval*: UK: Butterworth-Heinemann.
- Rish, I. (2001). *An empirical study of the naive Bayes classifier*. IJCAI 2001 workshop on empirical methods in artificial intelligence, Seattle, Washington, USA.
- Shu, K., Sliva, A., Wang, S., Tang, J., ve Liu, H. (2017). Fake News Detection on Social Media. *ACM SIGKDD Explorations Newsletter*, 19(1), 22-36.
- Tandoc, E. C., Lim, Z. W., ve Ling, R. (2017). Defining “Fake News”. *Digital Journalism*, 6(2), 137-153.
- Taşkin, S. G., KüçükSille, E. U., ve Topal, K. (2020). Twitter üzerinde Türkçe sahte haber tespiti. *Balikesir Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 151-172.
- Vosoughi, S., Roy, D., ve Aral, S. (2018). The spread of true and false news online. *Science*, 359(6380), 1146-1151.
- Willmore, A. (2016). This analysis shows how viral fake election news stories outperformed real news on facebook. In: Tech. Rep. 10.12.2023, <https://www.buzzfeednews.com/article/craigsilverman/viral-fake-election-news-outperformed-real-news-on-facebook> adresinden alındı.
- Zhang, H., ve Li, D. (2007). *Naïve Bayes text classifier*. 2007 IEEE international conference on granular computing (GRC 2007), California San Jose,
- Zubiaga, A., Aker, A., Bontcheva, K., Liakata, M., ve Procter, R. (2018). Detection and resolution of rumours in social media: A survey. *ACM Computing Surveys*, 51(2), 1-36.

ÖZGEÇMİŞ

Hamza ERÖRS

Eğitim

Yüksek Lisans 2024 Maltepe Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilgisayar
Mühendisliği Anabilim Dalı
Lisans 2024 Fırat Üniversitesi Teknoloji Fakültesi Yazılım Mühendisliği
Lise 2024 Şehit Koray Ak Oğuz Lisesi

İş/İstihdam (Varsa)

2014 LOGO Yazılım- Kıdemli Yazılım Geliştirme Danışmanı
2013 LOGO Yazılım- Stajyer
2012 SaldemSoft Yazılım ve Bilişim Teknolojiler- Stajyer

