



T.C.

**ÇANAKKALE ONSEKİZ MART ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**YALAN HABER YAYILIMIN ÖNLENMESİNE YÖNELİK BİR
WEB TARAYICI UZANTISI GELİŞTİRİLMESİ**

YÜKSEK LİSANS TEZİ

MERVE ESRA TAŞCI

TEZ DANIŞMANI

DR. ÖĞRETİM ÜYESİ YONCA BAYRAKDAR YILMAZ

ÇANAKKALE – 2023



T.C.

ÇANAKKALE ONSEKİZ MART ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**YALAN HABER YAYILIMININ ÖNLENMESİNE YÖNELİK BİR WEB
TARAYICI UZANTISI GELİŞTİRİLMESİ**

YÜKSEK LİSANS TEZİ

MERVE ESRA TAŞCI

TEZ DANIŞMANI

DR. ÖĞRETİM ÜYESİ YONCA BAYRAKDAR YILMAZ

ÇANAKKALE – 2023



T.C.
ÇANAKKALE ONSEKİZ MART ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



Merve Esra TAŞCI tarafından Dr. Öğr. Üyesi Yonca BAYRAKDAR YILMAZ yönetiminde **13/04/2023** tarihinde aşağıdaki jüri karşısında sunulan “**Yalan Haber Yayılımının Önlenmesine Yönelik Bir Web Tarayıcı Uzantısı Geliştirilmesi**” başlıklı çalışma, Çanakkale Onsekiz Mart Üniversitesi Lisansüstü Eğitim Enstitüsü **Bilgisayar Mühendisliği Anabilim Dalı**’nda **YÜKSEK LİSANS TEZİ** olarak oy birliği/oy çokluğu ile kabul edilmiştir.

Jüri Üyeleri

Dr. Öğr. Üyesi Yonca BAYRAKDAR YILMAZ

(Danışman)

Dr. Öğr. Üyesi Sait Can YÜCEBAŞ

Dr. Öğr. Üyesi Birol ÇİLOĞLUGİL

İmza

.....

.....

.....

Tez No :

Tez Savunma Tarihi : 13/04/2023

.....
Doç. Dr. Yener PAZARCIK

Enstitü Müdürü

.././2023

ETİK BEYAN

Çanakkale Onsekiz Mart Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kuralları'na uygun olarak hazırladığım bu tez çalışmada; tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi, tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu, tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi, kullanılan verilerde herhangi bir değişiklik yapmadığımı, bu tezde sunduğum çalışmanın özgün olduğunu, bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi taahhüt ve beyan ederim.

(İmza)

Merve Esra TAŞCI

.../.../2023

TEŐEKKÜR

Bu tezin gerekleŐtirilmesinde, alıŐmam boyunca benden bir an olsun yardımlarımı esirgemeyen saygı deęer danıŐman hocam Dr. Öğretim Üyesi Yonca BAYRAKDAR YILMAZ, alıŐma süresince tüm zorlukları benimle göęüsleyen ve hayatımın her evresinde bana destek olan deęerli aileme sonsuz teşekkürlerimi sunarım.

Merve Esra TAŐCI

anakkale, ... 2023



ÖZET

YALAN HABER YAYILIMININ ÖNLENMESİNE YÖNELİK BİR WEB TARAYICI UZANTISI GELİŞTİRİLMESİ

Merve Esra TAŞCI

Çanakkale Onsekiz Mart Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı Yüksek Lisans Tezi

Danışman: Dr. Öğretim Üyesi Yonca BAYRAKDAR YILMAZ

13/04/2023, 73

Yalan haber, çevrimiçi platformlarda çok hızlı yayılması ve tespit edilmesinin zor olması nedeniyle günümüzün en büyük sorunlarından biridir. Yalan haberler çok hızlı yayılarak kitlelerin yanlış yönlendirilmesi, kışkırtılması, korku salınarak kaos ortamı yaratılması gibi toplumsal ve sosyal çok büyük sorunlara neden olmaktadır. Olumsuz etkilerinden dolayı, yalan haberlerin tespit edilip yayılmasının önlenmesi önemli ve öncelikli bir mesele olmuştur.

Çalışmanın amacı, yalan haberlerin tespit edilerek yayılmasının önlenmesidir. Bunun için yalan haber tespiti yapan yeni bir Chrome uzantısı geliştirilmiştir. Doğal dil işleme, veri madenciliği yöntemleri, denetimli öğrenme algoritmaları, çevrimiçi öğrenme algoritması, derin öğrenme algoritması ve Python programlama dili kullanılarak uzantı geliştirilmiştir. İlk olarak veri setine, veri ön işleme için doğal dil işleme yöntemleri uygulanmıştır. Veri seti, %80 eğitim ve %20 test olmak üzere ikiye ayrılmıştır. Kelime vektörlerini oluşturmak için, Terim Frekansı – Ters Doküman Frekansı vektörizasyonu kullanılmıştır. En önemli aşama olan model uygulamada; Pasif agresif, Destek Vektör Makinesi, Rassal Orman, AdaBoost, XGBoost ve Uzun-kısa Süreli Bellek (LSTM) algoritmaları kullanılmıştır. Kullanılan algoritmaların doğruluk oranları ve karmaşıklık matrisleri karşılaştırılmıştır. En yüksek tahmin sonucunu %90.72'lik bir oranla LSTM algoritması vermiştir. Oluşturulan makine öğrenmesi modeli, Python programında Flask ve Rest API kullanılarak çevrimiçi internet ortamında çalışabilir hale getirilmiştir. Son olarak tarayıcı uzantı arayüzü; Javascript, HTML ve CSS kullanılarak oluşturulmuştur.

Anahtar Kelimeler: Yalan Haber, Doğal Dil İşleme, Makine Öğrenmesi Algoritmaları, Veri Madenciliği, Python Programlama

ABSTRACT

DEVELOPMENT OF A WEB BROWSER EXTENSION TO PREVENT FAKE NEWS

Merve Esra TAŞCI

Çanakkale Onsekiz Mart University

School of Graduate Studies

Master of Science Thesis in Computer Science

Assistant Professor Yonca BAYRAKDAR YILMAZ

13/04/2023, 73

Fake news is one of the biggest problems of today, as it spreads so fast on online platforms and is difficult to detect. Fake news spreads fairly quickly, causing huge social problems such as misdirecting and provoking the masses, creating an atmosphere of chaos by spreading fear. Due to its negative effects, detecting and preventing the spread of fake news has been an important and priority issue.

The aim of the study is to detect and prevent the spread of fake news. For the purpose, a new Chrome extension has been developed that detects fake news. The extension was developed using natural language processing, data mining methods, supervised learning algorithms, online learning algorithm and Python programming language. Firstly, natural language processing methods were applied to the data set for data preprocessing. The data set is divided into two as 80% training and 20% testing. Term Frequency – Inverse Document Frequency vectorization was used for feature selection. In the model application, which is the most important stage; Passive Aggressive, Support Vector Machine, Random Forest, AdaBoost, XGBoost and Long-Short-Term Memory (LSTM) algorithms are used. The accuracy rates and confusion matrix of the algorithms used were compared. The LSTM algorithm gave the highest prediction result with a rate of %90.72. The created machine learning model has been made workable in the online internet environment by using Flask and Rest API in the Python program. Finally, the browser extension interface have been built using Javascript, HTML and CSS.

Keywords: Fake news, Natural language processing, Machine learning algorithms, Data mining, Python programming

İÇİNDEKİLER

Sayfa No

JÜRİ ONAY SAYFASI.....	i
ETİK BEYAN.....	ii
TEŞEKKÜR.....	iii
ÖZET	iv
ABSTRACT	v
İÇİNDEKİLER	vi
SİMGELER ve KISALTMALAR.....	viii
TABLolar DİZİNİ.....	ix
ŞEKİLLER DİZİNİ.....	x
BİRİNCİ BÖLÜM	
GİRİŞ	
İKİNCİ BÖLÜM	
KURAMSAL ÇERÇEVE/ÖNCEKİ ÇALIŞMALAR	
2.1. KURAMSAL ÇERÇEVE.....	4
2.1.1. Yalan Haber.....	4
2.1.2. Veri Madenciliği.....	5
2.1.3. Makine Öğrenmesi ve Derin Öğrenme.....	5
2.2. ÖNCEKİ ÇALIŞMALAR.....	6
ÜÇÜNCÜ BÖLÜM	
ARAŞTIRMA YÖNTEMİ/MATERYAL YÖNTEM	
3.1. MATERYAL.....	21
3.2. YÖNTEM.....	22
3.2.1 Veri Madenciliği Aşamaları.....	23

3.2.2. Chrome Uzantısı Geliştirme Aşaması.....	38
3.2.3. Yalan Haber Dedektörü Kullanıcı Arayüzü.....	40
DÖRDÜNCÜ BÖLÜM	
ARAŞTIRMA BULGULARI	43
BEŞİNCİ BÖLÜM	
SONUÇ ve ÖNERİLER	66
KAYNAKÇA	68
ÖZGEÇMİŞ.....	I

SİMGELER VE KISALTMALAR

AUC	ROC Eğrisi Altındaki Alan (Area Under Curve)
ROC	Alıcı Çalışma Karakteristik Eğrileri (Receiver Operating Characteristic Curve)
LSTM	Uzun Kısa Süreli Bellek (Long Short-Term Memory)
TF-IDF	Terim Frekansı – Ters Doküman Frekansı (Term Frequency – Inverse Document Frequency)
TF	Terim Frekansı (Term Frequency)
IDF	Tersine Doküman Frekansı (Inverse Document Frequency)
SVM	Destek Vektör Makineleri (Support Vector Machine)
RNN	Yinelemeli Sinir Ağı (Recursive Neural Network)
HTTP	Hiper-Metin Transfer Protokolü (Hyper-Text Transfer Protocol)
AJAX	Eşzamansız JavaScript ve XML (Asynchronous JavaScript and XML)
HTML	Hiper Metin İşaretleme Dili (İngilizce Hypertext Markup Language)
URL	Tekdüzen Kaynak Bulucu (Uniform Resource Locator)
LDA	Gizli Dirichlet Tahsisi (Latent Dirichlet Allocation)
XGB	Aşırı Gradyan Yükseltme Algoritması (Extreme Gradient Boosting)
LIWC	Dil Sorgulama ve Kelime Sayımı (Linguistic Inquiry and Word Count)
MSE	Ortalama Kare Hatası (Mean Squared Error)
LR	Lojistik Regresyon (Logistic Regression)
KNN	En Yakın Komşuluk (K Nearest Neighbour)
DT	Karar Ağacı (Decision Tree)
RF	Rassal Orman (Random Forest)
CNN	Evrışimli Sinir Ağları (Convolutional Neural Network)
GRU	Kapılı Yinelemeli Üniteler (Gated Recurrent Units)
BFS	Sığ Öncelikli Arama (Breath First Search)
ARI	Otomatik Okunabilirlik İndeksi (Automatic Readability Index)
CFG	Bağlamdan Bağımsız Dilbilgisi (Context Free Grammer)
TP	Gerçek Pozitif (True Positive)
FP	Yanlış Pozitif (False Positive)
FN	Yanlış Negatif (False Negative)
TN	Gerçek Negatif (True Negative)

TABLULAR DİZİNİ

Tablo No	Tablo Adı	Sayfa No
Tablo 1	Yalan haberle ilgili yapılmış çalışmaların karşılaştırılması	17
Tablo 2	Politika veri setinde kullanılan algoritmalar için doğruluk ve çapraz doğrulama oranlarının karşılaştırılması	43
Tablo 3	Politika veri setinde kullanılan algoritmaların ortalama kare hatalarının karşılaştırılması	45
Tablo 4	Toplumsal olaylar veri setinde kullanılan algoritmalar için doğruluk ve çapraz doğrulama oranlarının karşılaştırılması	49
Tablo 5	Toplumsal olaylar veri setinde kullanılan algoritmaların ortalama kare hatalarının karşılaştırılması	50
Tablo 6	Kültür-Sanat veri setinde kullanılan algoritmalar için doğruluk ve çapraz doğrulama oranlarının karşılaştırılması	55
Tablo 7	Kültür-sanat veri setinde kullanılan algoritmaların ortalama kare hatalarının karşılaştırılması	56
Tablo 8	Veri setinde kullanılan algoritmalar için doğruluk ve çapraz doğrulama oranlarının karşılaştırılması	60
Tablo 9	Veri setinde kullanılan algoritmaların ortalama kare hatalarının karşılaştırılması	61

ŞEKİLLER DİZİNİ

Şekil No	Şekil Adı	Sayfa No
Şekil 1	Çalışmada veri setine uygulanan veri madenciliği aşamaları ve bu aşamalarda uygulanan işlemler	23
Şekil 2	Veri setinin eğitim ve test olarak ikiye ayrılması	25
Şekil 3	Pasif aşamasında yeni gelen verinin sınıflandırılması (a), agresif aşamasında hiperdüzlemin değiştirilmesi (b)	29
Şekil 4	Rassal Orman algoritması model oluşturularak sınıflandırma yapılması	31
Şekil 5	Destek Vektör Makinesi oluşturulan marjine göre sınıflandırma yapılması	32
Şekil 6	Hard ve Soft margin kullanılarak verilerin sınıflandırılması	32
Şekil 7	Polinomial Kernel	34
Şekil 8	Gauss Kernel	34
Şekil 9	RNN mimari yapısı	36
Şekil 10	LSTM model mimari yapısı	37
Şekil 11	Rest API çalışma yapısı	39
Şekil 12	Yalan haber detektörü arayüzü (a), metin girmeden butona basıldığında arayüzde çıkan uyarı yazısı (b)	30
Şekil 13	Kontrol edilen haberin yalan olması durumunda arayüzde çıkan yazı ve görsel (a), kontrol edilen haberin gerçek olması durumunda arayüzde çıkan yazı ve görsel (b)	42
Şekil 14	Politika veri setine uygulanan modellerin karmaşık matrisleri	46
Şekil 15	Karmaşıklık matrisi	47
Şekil 16	Politika veri setine uygulanan modellerin ROC eğrileri	48
Şekil 17	Toplumsal olaylar veri setinde kullanılan modellerin karmaşıklık matrisleri	52
Şekil 18	Toplumsal olaylar veri setinde kullanılan modellerin ROC eğrileri	54

Şekil 19	Kültür-sanat veri setine uygulanan modellerin karmaşıklık matrisleri	57
Şekil 20	Kültür-sanat veri setine uygulanan modellerin ROC eğrileri	59
Şekil 21	Politika, Toplumsal Olaylar ve Kültür-sanat haberlerinden oluşan veri setine uygulanan modellerin karmaşıklık matrisleri	62
Şekil 22	Politika, Toplumsal Olaylar ve Kültür-sanat haberlerinden oluşan veri setine uygulanan modellerin ROC eğrileri	64



BİRİNCİ BÖLÜM

GİRİŞ

Teknolojinin gelişmesiyle bilgisayar ve telefon gibi araçlarla internette olan bilgilere erişim kolaylaşmıştır. İçerik paylaşmak, günlük tutmak, yorum yapmak kullanıcılar için daha kolay hale gelmiştir. Çevrimiçi ortamda fikir ve görüş paylaşmak için forum siteleri oluşturulmuştur. Böylece kullanıcılar daha fazla kişiyle iletişime geçerek duygu, düşünce ve fikir alışverişinde bulunabilme fırsatı yakalamış oldular. Forum siteleri şimdiki sosyal ağların gelişmesine öncülük etmiştir. Sosyal ağlar; ilk geliştirildiklerinde insanların birbirleri ile bağlantı kurmasını, fotoğraf, metin gibi içerik paylaşmasını sağlarken, şimdi kitle iletişim araçlarının yerini almıştır. Dünya genelinde insanlar yeni çıkan haberleri radyo ya da televizyondan seyretmek yerine sosyal ağlardan takip etmektedir. Taşınabilir mobil aygıtlardan internete erişmek, haberleri takip etmek ve herhangi bir bilgiye ulaşmak modern teknolojik toplumların alışkanlığı olmuştur (Klyuev, 2018: 1).

İnternete erişimin ve kullanımının yaygınlaşması beraberinde çok sayıda içeriği kontrol edilmemiş yalan haberin, söylentinin, yanlış bilginin paylaşılmasına ve yayılmasına neden olmuştur. Mobil telefonlarla internete girip herhangi bir haber içeriğine ulaşmak çok kolayken, ulaşılan haberin doğruluğu ve güvenilirliği insanları ve toplumları etkileyen çok önemli bir sorun olmuştur (Vo, vd., 2018: 1). İnternet ve sosyal medyayla birlikte paylaşılan bir haber çığ etkisi misali çok kısa sürede büyük kitlelere ulaşabilmektedir. Aktif ve büyük kitlelerin yaptığı çok sayıdaki paylaşım, paylaşılan bilginin doğruluğunun kontrol edilememesine neden olmuştur. Dijital veriler üzerindeki kontrol gücünü gerçek olmayan ve hiçbir doğruluğu bulunmayan metin, resim video içeren yapılandırılmamış verilerin beğeniler, paylaşımlar ve tavsiye sistemleriyle web sayfaları, sosyal medya, sohbet sayfaları gibi farklı ortamlarda çok hızlı bir şekilde yayılmasına ve kitlelerin kasıtlı olarak yanlış yönlendirilmesine neden olmaktadır. Gerçek olmayan bu verilerin büyük çoğunluğunu yalan haberler oluşturmaktadır. Kasıtlı olarak toplumun duygu, düşünce ve hareketlerini etkileyerek istenilen yönde manipüle edilmesi yalan haberi diğer haber türlerinden ayırmaktadır. Gerçek haberlere göre daha fazla ilgi duyulduğu için yayılmasının önüne geçilmesi zordur.

Twitter, Facebook, Instagram gibi sosyal ağların popüler olması ve çok büyük bir kullanıcı kitlesi tarafından kullanılmasından dolayı yalan haber içeriklerini oluşturan ve yayan kişi ya da gruplar bu platformları sıklıkla kullanmaktadır. Özellikle Twitter’da, 2016 yılındaki Amerikan başkanlık seçimlerinde Trump ile ilgili çok fazla yalan haber içeriğe sahip tweet atılmıştır (Bovet, vd., 2019: 1). Twitter ve diğer sosyal medya platformlardaki bazı sistemselsel eksikliklerden dolayı yalan haberler hızlı olarak yayılmaktadır.

Çok sayıda yalan haber büyük kitleleri yanlış yönlendirmek, korku salmak ve kaos ortamı yaratmak için kasıtlı olarak sosyal medyada yayınlanmaktadır. Yalan haberler bireyler ve toplum üzerinde çok büyük olumsuz etkilere sahiptir. İnsanların yalan haberlere ve yalan haberlerin neden olduğu olumsuz durumlara maruz kalması önlenmelidir. Bu tez kapsamında, insanların yanlış yönlendirilmesine engel olmak ve kullanıcıların yalan haber ayırımı yapabilmelerine yardımcı olabilmek için otomatik yalan haber tespiti yapan Chrome uzantısı geliştirilmiştir. Geliştirilen tarayıcı uzantısıyla yalan haberlerin büyük kitlelere yayılmasının önlenmesi amaçlanmıştır.

Tez çalışması; Giriş, Kuramsal Çerçeve/Önceki çalışmalar, Materyal ve Yöntem, Araştırma Bulguları, Sonuç ve Öneriler bölümlerinden oluşmaktadır. İlk bölüm olan Giriş bölümünde; yalan haberin tanımı, kitleler üzerindeki olumsuz etkisi ve yayılmasının önlenmesinin önemiyle ilgili açıklamalar yapılmıştır. Çalışmanın yapılma amacı ve neden böyle bir çalışma yapıldığı belirtilmiştir. Çalışmada kullanılan kavramlar, algoritmalar ve yöntemler hakkında bilgi verilmiştir. İkinci bölümde, kuramsal çerçeve başlığında yalan haber, veri madenciliği, makine öğrenmesi ve derin öğrenme hakkında ayrıntılı açıklamalar yapılmıştır. Önceki çalışmalar başlığında, yalan haberin tespit edilmesi ve yayılmasının önlenmesi üzerine daha önce yapılmış olan çalışmalar hakkında kapsamlı bir literatür taraması yapılmıştır. Önemli çalışmalar hakkında bilgi verilmiştir. Üçüncü bölümde; çalışmada kullanılan materyal ve yöntemler ayrıntılı olarak anlatılmıştır. Kullanılan veri seti, veri madenciliği aşamalarının nasıl yapıldığı, kullanılan makine ve derin öğrenme algoritmaları, Chrome uzantısının nasıl oluşturulduğu, kullanılan geliştirme ortamları ve programlama dilleri hakkında bilgi verilmiştir. Dördüncü bölümde, yalan haber tespiti için veri setlerine uygulanan modellerin doğruluk oranları, çapraz doğrulama değerleri (cross_val_score), karmaşıklık matrisleri, Alıcı Çalışma Karakteristik Eğrileri (Receiver Operating Characteristic Curve) ve ROC Eğrisi Altındaki Alan (Area Under Curve)

karşılaştırılmıştır. Diğer çalışmalarda kullanılmış olan farklı makine öğrenmesi modelleri, çalışmada kullanılmış olan veri setine uygulanmış ve çıkan doğruluk sonuçları karşılaştırılmıştır. En yüksek oranı veren modelin derin öğrenme modellerinden biri olan LSTM modelin olduğu, yapılan karşılaştırma sonucu tespit edilmiştir. Son bölümde, yapılan çalışmada kullanılan materyal/yöntemler, çalışmanın hangi aşamalar takip edilerek yapıldığı, kullanılan modeller ve performans sonuçları hakkında genel bir açıklama yapılmıştır. Çalışmanın faydası ve önemi üzerinde durulmuştur.



İKİNCİ BÖLÜM

KURAMSAL ÇERÇEVE/ÖNCEKİ ÇALIŞMALAR

2.1. KURAMSAL ÇERÇEVE

2.1.1. Yalan Haber

Günümüzde internetin ve sosyal medyanın hayatımızdaki etkisi çok büyüktür. Eğitim kurumlarından işyerlerine kadar internet ve sosyal medya hayatımızın en önemli parçası olmuştur. Bu derece öneme sahip olmasının asıl nedeni aranılan bilgiye ya da habere istenilen yerden istenilen zamanda ulaşılabilmesidir. İnternetin olmadığı ya da henüz yaygınlaşmadığı zamanlarda aranılan bilgiye ansiklopedilerden ya da kütüphanelerden erişilebiliyordu. Ülkedeki ya da dünyadaki gündemden haberdar olabilmek için ertesi gün çıkacak olan gazete sayısının beklenmesi gerekiyordu.

İnternetin yaygınlaşmasıyla birlikte geleneksel kitle iletişim araçlarının yerini internet ve sosyal medya almıştır. Sosyal medyadan önce ülke ve dünya gündemindeki yaşanan olaylardan gazeteler ve televizyon sayesinde haberdar olunabiliyordu. Şimdi dünyanın herhangi bir ücra köşesinde yaşanan bir olay sosyal medyada çok kısa sürede büyük kitlelere ulaşabilmektedir. Özellikle son on yılda insanların birbirleriyle etkileşime girmeleri ve sosyalleşmeleri için dijital dünya ve sosyal medya önemli ve popüler hale gelmiştir. Sosyal medyanın ücretsiz olması, herhangi bir bilgiye kolay ulaşılabilmesi ve insanlara kendilerini özgürce ifade edebilme olanağı vermesi gibi sağladığı olanaklardan dolayı geniş kitleler tarafından kullanılmaktadır (Shu, vd., 2018).

Haberlerin kısa sürede çok sayıda kişiye ulaşması çok büyük bir avantajdır. Ancak bu avantaj büyük bir dezavantaja dönüşmüştür. Aktif kullanıcılar tarafından yapılan çok sayıda paylaşım, paylaşılan içeriklerin kontrol edilememesine neden olmuştur. Dijital veriler üzerindeki kontrol gücü gerçek olmayan ve hiçbir doğruluğu bulunmayan metin, resim ve video içeren yapılandırılmamış verilerin beğeniler, paylaşımlar ve öneri sistemleri ile web sayfaları, sosyal medya ve sohbet sayfaları gibi farklı ortamlarda çok hızlı yayılması ve kitlelerin kasıtlı olarak yanlış yönlendirilmesi problemini beraberinde getirmiştir. Özellikle Twitter ve Facebook gibi sosyal medya platformları toplumdaki popüleriteleri

nedeniyle yalan haberlerin yayılması için sıklıkla kullanılan sosyal medya mecraları olmuştur (Vo, vd., 2018).

Yalan haber; toplumun ilgisini çekecek fakat herhangi bir gerçeğe dayanmayan bir konunun bilerek yanlış ya da yanıltıcı haber haline dönüştürülerek hedef kitleye sunulmasıdır. Genellikle bireylerin ya da kurumların itibarını zedeleme, gözden düşürme, toplumlarda güvensizlik ve kaos ortamı yaratma ya da reklam yoluyla para kazanma amacına sahiptir.

2.1.2. Veri Madenciliği

İnternetin gelişmesiyle birlikte çok sayıda verinin olduğu veri setleri oluşmuştur. Verinin sayı olarak fazla olması avantajlı gibi görünmesinin yanında, kaliteli ve kullanılabilir verinin devasa boyutlardaki veri tabanlarında kaybolması gibi bir dezavantaja neden olmuştur. Kaliteli verinin bulunup kullanılması amacıyla, veri madenciliği son yıllarda popüler hale gelmiştir. Kaliteli, değerli, ilginç, beklenmeyen verilerin çok büyük veri setlerinde bulunması, analiz edilmesi ve işe yarar verilerin ayıklanması “veri madenciliği” olarak tanımlanır (Hand, 2007: 1).

Veri madenciliği işlemi belirli bir süreç içinde gerçekleştirilmelidir. Verilerin toplanıp, kullanılacak olan modelin uygulanmasına kadar geçen süreçte uygulanacak olan işlemlerin belirlenmiş olması gerekir. Veri madenciliği; veri setini toplama, veri ön işleme, veri setini ayırma, özellik seçimi, model uygulama ve uydurma, değerlendirme ve yükleme aşamalarından oluşmaktadır.

2.1.3. Makine Öğrenmesi ve Derin Öğrenme

Makine öğrenmesi, yapay zekanın alt bilim dalıdır. Makinelere kendi programlarını öğrenme ve geliştirme yeteneği vererek davranışlarında ve kararlarında daha insani hale getirme çalışmasıdır. Öğrenme süreci, süreç boyunca makinelerin deneyimlerine dayalı olarak otomatikleştirilir ve geliştirilir. Makinelere kaliteli veriler beslenir ve makineleri bu veriler üzerinde eğitmek ve makine öğrenmesi modelleri oluşturmak için farklı algoritmalar kullanılır. Örüntü tanıma, bilgisayar görüşü, uzay aracı mühendisliği, finans, eğlence ve

hesaplamalı biyolojiden biyomedikal ve tıbbi uygulamalara kadar çeşitli alanlarda başarıyla uygulanmıştır (El Naqa ve Murphy, 2015).

Derin öğrenme, beyin hücrelerinin yapısı referans alınarak geliştirilmiş olan yapay sinir ağlarını temel alan makine öğrenmesinin alt bilim dalıdır. Son yıllarda veri miktarının artması ve büyük veriyi işleyebilecek olan makinelerin hesaplama gücünün artmasıyla daha karmaşık yapılara sahip olan modellere ihtiyaç duyulmuştur. Bunun için yapay sinir ağları geliştirilmiş ve yaygın olarak farklı alanlarda uygulanmıştır (Hao vd., 2016). Yapay sinir ağlarında, büyük veri setlerindeki kalıpları ve yapıları keşfetmek için birden çok ağ katmanı kullanılmaktadır. Her katmanda, sonraki katmanların üzerine inşa edilen verilerden bir kavram öğrenilmektedir. Katman seviyesi arttıkça öğrenilen kavramlar o derecede soyut olmaktadır. Yapay sinir ağlarında öğrenme sadece önceki veri işlemeye bağlı değildir. Daha önceki katmanlarda öğrenilen özellikler daha sonraki katmanlarda otomatik olarak çıkarılabilmektedir. Matematiksel şekilleri yorumlamakla görevli bir derin sinir ağına, modelin ilk katmanda basit şekil kenarları tanımayı öğrenmesi ve bu kenarlardan oluşan daha karmaşık şekilleri sonraki katmanlarda tanıyacak olması bu duruma örnek verilebilir (Rusk vd., 2016).

2.2. ÖNCEKİ ÇALIŞMALAR

Yalan haber tespiti yapılabilmesi için; içerik kontrolü (fact-checker) yapan profesyonel insanların bulunduğu içerik kontrol gruplarının oluşturulması, makine öğrenmesi, doğal dil işleme, derin öğrenme gibi yöntemlerin kullanılması, gerçek haberlerin önerildiği öneri sistemi yaklaşımı ve hibrid yöntem gibi çok çeşitli yöntemler geliştirilmiştir (Collins, vd., 2020: 9-16). Yapılan literatür taramasında yalan haber tespiti ve önlenmesi üzerine yapılmış çok sayıda çalışmanın olduğu görülmüştür.

Vo ve Lee, içeriği kontrol edilmiş Tekdüzen Kaynak Bulucu (Uniform Resource Locator) öneri sistemini geliştirmişlerdir. Haber içeriğini kontrol edip, yalan ya da gerçek olarak tespit edilen haberi diğer kullanıcılara yayan bir grup insanın kullanılması fikrini

ortaya atmışlardır. İçeriği kontrol edilmiş haberleri yayan kullanıcılar nasıl bulunacak ve tespit ettikleri haberleri diğer kullanıcılara yaymaları için nasıl teşvik edilecekler gibi iki önemli problem ortaya çıkmıştır. Bu soruna “guardians” adı verilen yalan haberleri tespit etmekle ilgilenen kullanıcıların kullanılması gibi bir çözüm bulmuşlardır. Bir örnekle guardians yönteminin nasıl çalıştığını anlatmak daha açıklayıcı olacaktır. Bir twitter kullanıcısının bilimle ilgili gerçekliği olmayan bir tweet attığını düşünelim. Başka bir kullanıcı da güvenilir siteleri kullanarak bu tweet’i çürütmüş olsun. Yalan haber tweet’ini çürütmek için atılan tweetlere D-tweets (direct fact checking tweets) adı verilmiştir. Bu tweet’leri atan kullanıcılar D-guardians (Direct guardians) olarak adlandırılmıştır. Yalan haberi tespit eden kullanıcının verdiği yanıtı tekrar retweet eden kullanıcılara S-guardians ve bu kişinin yapmış olduğu paylaşımlara S-tweets adı verilmiştir. D-tweets ve S-tweets kullanıcıları, içeriği kontrol edilmiş gerçek haberi yayan vasilerdir. D-tweets ve S-tweets içeriği kontrol edilmiş haberleri içeren tweet’lerdir. Vasilerin gerçek haber içeren tweet’leri paylaşarak yalan haberlerin diğer kullanıcılara yayılması önlenmeye çalışılmıştır (Vo ve Lee, 2018: 2-3).

Patankar ve arkadaşları, yapmış oldukları literatür araştırmasında genellikle yapılan çalışmaların yalan haberleri tespit etmek üzerine olduğunu saptamışlardır. Sadece yalan haber tespiti yapmak yerine kullanıcının okuduğu haber içeriğine benzer yeni haberleri de öneren yeni bir tarayıcı uzantısı geliştirmişlerdir. Tarayıcı uzantısı, kullanıcının okuduğu haberin Tekdüzen Kaynak Yükleyici kısaca URL’ini alarak sunucuya (server) gönderir. Gönderilen URL, sunucu tarafından alınarak eğilim skorunun hesaplandığı RESTfull API’ye gönderilir. Daha önce farklı içeriklere sahip, online ortamda bulunan veri setleri seçilmişti. Yeni URL’ler alındığında, ilk olarak seçilen farklı haber kaynaklarından kullanıcının okuduğu haber içeriğine benzer olan yeni haberler taranır. Yeni haber içerikleri toplandıktan sonra her bir haber metni için eğilim skoru (bias score) hesaplanır. Eğilim skoru, dizin (index) yapabilmek için hesaplanmıştır. Index için doğal dil işlemede kullanılan konu modelleme örneği olan Gizli Dirichlet Tahsisi (Latent Dirichlet Allocation) kullanılmıştır. Gizli Dirichlet Tahsisi kısaca LDA modeli ile veri seti içindeki konu dağılımı hesaplanır. Konu dağılımına göre kullanıcının okumakta olduğu metin ile önerilecek metin arasındaki kosinüs mesafesi hesaplanarak anlamsal ilişki dizini (index) bulunur. Kullanıcının okuduğu haber yalan olarak tespit edildikten sonra, hesaplanan dizin’e (index) göre kullanıcının

okuduđu haber içeriđine benzer olan içerikteki gerçek haberler kullanıcıya sunulur. Mobil ve desktop için ayrı ayrı geliştirilmiştir (Patankar, vd., 2019: 232-234).

Becker, yalan haber yayılımının, mobil uygulama geliştirilerek önüne geçilebileceđini savunmuştur. Çalışmasında sağlık, politika, çevre, çevrimiçi oyunlar gibi farklı kategorilere sahip on iki mobil uygulama geliştirilmiştir. Mobil uygulamalarda, yalan haber içeriđinin nasıl tespit edileceđinin bilgisini kullanıcılara veren, içerik kontrolü yapan uzman kişilerden yararlanılmıştır (Becker, 2021: 57-59).

Shu ve arkadaşları, gelecekte karşılaşılabilecekleri yalan haberleri daha iyi görselleştirme teknikleri kullanarak anlamak ve tahmin edebilmek için “FakeNewsTracker” adlı bir araç geliştirmişlerdir. Yalan ve gerçek haberlerin olduđu veri setleri kullanılmıştır. Bu çalışmada, diğerlerinden farklı olarak veri seti sürekli yeni yalan haber verileri eklenerek güncellenmektedir. Twitter API kullanılarak, tweet edilen gerçek ve yalan haberler toplanmıştır. Haberlerin yanı sıra kullanıcıların yapmış olduđu tweet, retweet gibi kullanıcı hareketleri de toplanmıştır. Bir kullanıcı yalan haber ile karşılaşıp bunu paylaştığı zaman, yankı odası (echo chamber) etkisinden dolayı kullanıcının arkadaşları da yalan habere maruz kalacaktır. Ayrıca kullanıcı karşılaştığı bir yalan haberi paylaşıırken yorum yapabilir ve bu yorumdan yalan habere maruz kalıp kalmadığı tespit edilebilir. Bu gibi nedenlerden dolayı Twitter API ile kullanıcı davranışları da toplanmıştır. Toplanan kullanıcı bilgileri derin öğrenme yöntemlerinden biri olan LSTM kullanılmıştır. LSTM algoritması, geliştirilen modelinin ilk katmanda kullanılmıştır. Genel olarak haber içeriđi ve kullanıcı davranışları bir arada kullanılarak yalan haber tespit edilmeye çalışılmıştır (Shu, vd., 2018).

Botnevik ve arkadaşları, sayfa URL’lerini alıp yalan haber tespiti yapan BRENDA adını verdikleri tarayıcı uzantısı geliştirmişlerdir. Tarayıcı uzantısında haber metni içeriđini ve başlığını ayrı ayrı kontrol eden iki buton vardır. Bu butonların herhangi birine basıldığında RESTfull API etkinleşerek sayfa URL’ini uzantıya gönderir. Python kütüphanesi olan Newspaper3k kullanılarak sayfada bulunan metinlerin özetleri, yazarları gibi bilgileri çıkarılarak yalan haber tespiti için, projede yeni geliştirilmiş olan SADHAN

modeline gönderilmiştir. SADHAN modelinde makine öğrenmesi algoritmaları kullanılarak yalan haber tespiti yapılmıştır (Botnevik, vd., 2020).

Paschalides ve arkadaşları; genetik algoritması ve çok boyutluluğa çözüm sunan, aşırı öğrenmeye karşı dirençli olan L2 regulasyonunu kullanarak tarayıcı uzantısı geliştirmişlerdir. Kullanılan algoritmalar %90'lık bir tahmin oranı ile yalan haber tespiti yapmıştır. Geliştirdikleri uzantı Chrome, Mozilla, Firefox gibi farklı tarayıcılara eklenebilmektedir (Paschalides, vd., 2021: 4).

Paka ve arkadaşları, Twitter'da paylaşılan gönderilerde yalan haber tespiti yapan Cross-SEAN adlı tarayıcı uzantısı geliştirmişlerdir. Uzantıda, ilk olarak atılan tweet ID'lerin sayfa URL'leri alınarak POST API ile sunucuya gönderilir. Sunucuya gönderilen ham veri makinenin işleyebileceği formata çevrilir. Uzantı popup'ında kontrol edilen tweet'le ilgili yalan ya da gerçek olduğu ve bu tespitin yüzde kaçlık bir oranla yapıldığı kullanıcıya gösterilmiştir (Paka, vd., 2021: 10).

Singhal ve arkadaşları yalan haberi otomatik olarak tespit eden SpotFake adında birden fazla modülü bir arada bulunduran çerçeve (framework) geliştirmişlerdir. Metin analizinin yanında haberle birlikte yayınlanan resimlerin de analiz edilmesi gerektiğini düşünmüşlerdir. Geliştirilen SpotFake, üç alt modelden oluşmaktadır. İlk alt model; dil modeli kullanarak metinlerden bağlamsal özelliklerini çıkaran modüldür. Metinlerin ya da cümlelerin bağlamsal anlamlarını çıkarabilmek için BERT tabanlı on iki kodlayıcı katmandan oluşan Çift Yönlü Kodlayıcı (Bidirectional Encoder Representations) kullanılmıştır. Alınan her kelime ya da cümle işlenerek elde edilen sonuçlar diğer katmana gönderilir. Bu şekilde metinlerin bağlamsal anlamları çıkarılmış olur. İkinci alt model, paylaşılan gönderilerdeki görsel özellikleri çıkaran modeldir. Son alt model, yeni özellik vektörü (feature vector) kullanılarak metinsel özellik ve görsel özellik çıkarımı yapan modellerden gelen özelliklerin birleştirildiği ve yapay sinir ağları kullanılarak yalan haberin tespit edildiği füzyon modelidir. Veri seti olarak; farklı olaylara gerçek ve yalan haberlerden oluşan Twitter veri seti ve güvenilir kaynaklardan toplanan gerçek haberlerden oluşan Weibo Veri seti kullanılmıştır (Singhal, vd., 2019: 3-5). Yalan haber tespitinde kullanılan

yöntemlerden farklı olarak; Dil Transfer Modeli, metin ve resim özellik çekim vektörü, çok katmanlı yapay sinir ağları gibi modelleri bir arada kullanılarak hem metin hem de resim analizi yapılarak yalan haber tespiti yapılmaya çalışılmıştır (Singhal, vd., 2019).

Jain ve Kasbe, Web Scrapping yöntemi ve Naive Bayes algoritmasını kullanarak yalan haber tespiti yapmışlardır. Web Scrapping; herhangi bir blog, web sitesi gibi veri kaynağından anlamlı veri çıkarılması işidir. Bulunulan sayfa URL'i alınarak; sayfadaki metin, metin başlığı, yazar adı gibi özellikler çekilir ve işlenmek üzere sunucuya gönderilir. Çalışmada, Web Scrapping ile alınan farklı uzunluktaki metinlerin yalan olarak tespit edilmesinde, Naive Bayes sınıflandırma algoritmasının nasıl performans gösterdiği ölçülmeye çalışılmıştır. Veri seti GitHub'dan elde edilmiştir. İş, bilim, teknoloji, eğlence, sağlık gibi farklı alanlara ait 11000 adet veri "GERÇEK" ve "YALAN" olarak etiketlenmiştir. Kullanılacak olan Naive Bayes modelini eğitebilmek için; veri setinin %75'i eğitim, %25'i test olarak ayrılmıştır. Kelimeler makinenin anlayabileceği formatta değildir. Kelime torbası ve Countvectorizer yöntemleri kullanılarak metinsel ifadeler makinenin anlayabileceği format olan 1-0 yapılarak vektör matrisleri oluşturulmuştur. Ayrılmış olan eğitim veri setine Naive Bayes modeli uygulanmıştır. Test veri setine Naive Bayes modeli uygulanmıştır. Web Scrapping ile alınan metin başlıkları ve metinler için ayrı ayrı model uygulanarak, ROC eğrisi altında kalan alan (AUC) oranları karşılaştırılmıştır. AUC oranı metinlerde daha yüksek çıkmıştır. Veri madenciliğinde ne kadar çok veri kullanılırsa tahmin oranı daha yüksek olmaktadır. Metinler, başlıklara göre daha fazla kelime ve ifade barındırdığı için daha yüksek tahmin oranı vermiştir (Jain ve Kasbe, 2018).

Yapılan başka bir çalışmada Jiang ve arkadaşları çeşitli makine öğrenmesi algoritmaları, derin öğrenme algoritmaları ve üç tane kelime indirme yönteminin bir arada kullanıldığı yeni bir sıkıştırılmış model geliştirmişlerdir. Lojistik Regresyon (LR), Destek Vektör Makinesi, En Yakın Komşuluk Algoritması (KNN), Karar Ağacı (DT), Rrassal Orman (RF), Evrişimli Sinir Ağları (Convolutional Neural Network) kısaca CNN, Kapılı Yinelemeli Üniteler (Gated Recurrent Units) kısaca GRU ve LSTM algoritmaları kullanılmıştır. LR, SVM, KNN, DT, RF, CNN, GRU ve LSTM algoritmaları yalan haber

tespiti için uygulanarak performans oranları karşılaştırılmıştır. Doküman matrisi oluşturmak için TF ve TF-IDF yöntemleri kullanılmıştır (Jiang, vd., 2021).

Var olan çalışmalarda yalan haber tespiti yaparken ya metin içeriğine ya haberi yayınlayan kaynağa ya da yayınlanan habere yapılan kullanıcı yorumlarına odaklanılmıştır. Runcansky ve arkadaşları, bu üç özellik birlikte kullanıldığı zaman sistemin daha yüksek tahmin performansına sahip olacağını savunmuşlardır. Üç özelliğin birlikte kullanıldığı CSI adlı bir model geliştirmişlerdir. CSI modeli; Capture, Score ve Integrate modüllerinden oluşmaktadır. Capture modülünde, kullanıcı yalan haber içeriğine sahip bir haber metniyle karşılaştığında nasıl bir davranış sergilediği yakalanıp ölçülür. Score modülünde, kullanıcının karşılaştığı haberin güvenilirliğine ne kadar şüpheyile yaklaştığını hesaplayan şüphe tahmin oranı oluşturulur. Son modül olan Integrate modülünde, Capture ve Score modüllerinden elde edilen sonuçlar da kullanılarak, haberi yalan ya da doğru olduğunu veren tahmin etiketi oluşturulur. Üç modülün birlikte kullanılmasıyla sistemin tahmin performansı arttırılmıştır (Ruchansky, vd., 2017).

Conroy ve arkadaşları, yalan haber tespiti için dilbilimsel (linguistic) ve ağ tabanlı (network) yaklaşımını birlikte kullandıkları bir sistem geliştirmişlerdir. Dilbilimsel yaklaşım yönteminde, metin içeriklerinde bulunan yanıltıcı ve gerçek olmayan dil kalıpları çıkarılarak analiz edilir. Yapılandırılmış bilgi ağları ya da metadata mesajları yalan haber yaymak için kullanılmış, zarar görmüş ya da saldırıya uğramış olabilir. Ağ tabanlı yaklaşımda, yalan haber tespiti için ağ analizi yapılır. Dilbilimsel ve ağ tabanlı yaklaşım kullanılarak analiz yapılmış ve makine öğrenmesi algoritmaları uygulanmıştır. Kullanılan iki yaklaşım, sınırlı veri setlerinde bile çok yüksek doğruluk oranında sonuçlar vermiştir (Conroy, vd., 2015).

Yapılan başka bir çalışmada Sayfa URL'leri alınarak metin başlık ve içerikleri çekilmiş, makine öğrenmesi algoritmaları uygulanmıştır. Al Asaad ve arkadaşının geliştirdiği sistem girdi olarak alınan haberin türüne göre aynı tür çıktı vermektedir. Kontrol edilmek istenen haber girdi olarak sisteme yalan/gerçek olarak verildiğinde, çıktı olarak kullanıcıya yalan/gerçek haber bilgisi verilmektedir. Sisteme girdi olarak tıklama haberi (clickbait) verildiğinde, çıktı olarak kullanıcıya tıklama haberi ya da tıklama haberi değil

bilgisi verilecektir. Kullanılan ayrıştırma (parsing) yöntemiyle, sayfa URL'i alınmıştır. Alınan sayfa URL'inde bulunan haberin başlığı, içeriği, yazar adı haber yayın tarihi gibi özellikler çekilmiştir. Haberın yalan olup olmadığına belirlenen üç kritere göre karar verilmiştir. Eğer haberın yazarı yoksa, güncel olmayan bir tarihte yayınlanmışsa ve makine öğrenmesi yöntemleriyle kontrol edilen içerik yalan haber olarak tespit edilmişse; kontrol edilen haber yalan olarak tespit edilmiştir. Haber içeriği farklı makine öğrenmesi yöntemleri kullanılarak haberın yalan olup olmadığı tespit edilmiştir. Al Asaad ve Erascu makine öğrenmesi yöntemi olarak denetimli öğrenme algoritmalarından olan Naive Bayes ve Destek Vektör Makinesi algoritmalarını kullanmışlardır (Al Asaad ve Erascu, 2018).

Yalan haber tespitinde içerik analizi, yaygın olarak kullanılan bir yöntemdir; ancak tek başına bu yöntemin kullanılması tahmin oranının düşük olmasına neden olmaktadır. Della ve arkadaşları; tahmin oranının artması için içerik analizinin yapıldığı içerik modeli ve kullanıcı davranışlarının baz alındığı sosyal modeli birlikte kullanarak yeni model geliştirmişlerdir. İçerik modelinde, haberın içeriği alınarak analiz edilmektedir. Haber içeriği analizi; metin, başlık, metadata gibi alanlarda bulunan metinler çekilerek yapılır. Sosyal modelinde, kullanıcıların sistemlerde bırakmış olduğu kullanıcı davranışları referans alınmaktadır. Paylaşılan içeriğe yorum yapma, beğenme, paylaşma, yeni bir tweet'i retweet etme gibi davranışlar sosyal medyada kullanıcıların yapmış olduğu sosyal davranışlardır. Kullanıcılar sisteme ilk kaydolduklarında çok az sosyal davranışta bulunabilir. Bu durum tahmin oranının düşmesine neden olmaktadır. İçerik modeli ve sosyal model birlikte kullanılarak, birinin sahip olduğu sistemsel eksiklikler diğeriyle tolere edilmiş ve yüksek tahmin oranları elde edilmiştir (Della, vd., 2018).

Yapılan çoğu çalışmada, metin içeriği analizi yaparak yalan haber tespiti yapılmıştır. Cui ve arkadaşları; sadece metin analizinin yeterli olmayacağını düşünmüşlerdir. Sosyal medyada çok yapılan herhangi bir paylaşımına çok kısa sürede binlerce yorum yapılmaktadır. Yapılan yorumlar paylaşımların içerikleriyle ilgili olduğu için, yalan olarak tespit edilen haberın neden yalan olduğuyula ilgili bilgi verebilir. Kullanıcı yorumlarında bilgi çıkarılabileceğinden dolayı Cui ve arkadaşları, yalan haber tespiti yaparken metin içeriği ve kullanıcı yorumlarını birlikte kullandıkları DEFEND adlı yeni bir derin öğrenme altyapısına

sahip çatı geliřtirmişlerdir. Geliřtirilen yeni sistem, yalan haber tespitinin yanında haberin neden yalan olduđuyla ilgili bilgi vermektedir. Sistem, web tabanlı kullanıcı arayüzü ve arka uç (backend) olmak üzere iki temel bileşenden oluşmaktadır. Web tabanlı arayüz, kullanıcılara kontrol etmek istedikleri haberleri girebildikleri bir sayfa sunmaktadır. Arka uçta, yalan haber tespiti yapan çeşitli makine öğrenmesi algoritmaları kullanılmıştır. dFEND sistemi; haber içerik analizinin yapıldığı içerik kodlayıcı bileşeni, kullanıcı yorumlarının alınıp değerlendirildiği kullanıcı yorum kodlayıcı bileşeni, cümle-yorum bileşeni ve yalan haber tahminin yapıldığı bileşen olmak üzere dört bileşen kullanılarak oluşturulmuştur. Bu bileşenlerle; kullanıcı yorumlarına dayanarak, açıklanabilir sonuç ve oranlarla kullanıcıya bilgi veren yeni bir yalan haber tespit sistemi geliřtirilmiştir (Cui, vd., 2019).

Yang ve arkadaşları, Cui ve arkadaşlarının yapmış olduđu çalışmaya benzer bir çalışma yapmışlardır. Haberin yalan olup olmadığını tahmin eden ve yapılan tahminle ilgili kanıtlayıcı açıklamalar yapan XFake adını verdikleri yeni bir araç geliřtirmişlerdir. Cui ve arkadaşlarının yapmış oldukları çalışmadan farklı olarak MIMIC, ATTN ve PERT olmak üzere haber analizini farklı bakış açıları kullanarak yapan üç çatı (framework) geliřtirmişlerdir. Yang ve arkadaşlarının yaptıđı çalışma, farklı bakış açılarının kullanıldığı ilk açıklanabilir yalan haber detektörüdür. MIMIC çatısı, kontrol edilen haberlerde bulunan özniteliklerin analizi için geliřtirilmiştir. Derin sinir ađları ve Shallow modeli kullanılarak öznitelik analizi yapılmıştır. ATTN çatısı, haberlerin metin içeriđini anlamsal açılarından analiz etmek için tasarlanmıştır. Doğruluk oranı yüksek ve iyi bir performansla sahip analiz için kelime gömme (word embedding), CNN, kelimelerin vektör gösterimi için word2vec gibi yöntemler kullanılmıştır. PERT çatısı, haber açıklaması analizinin dilsel (linguistic) perspektiften yapıldığı çatıdır. Dilsel özellikler çekilerek, XGBoost (XGB) algoritmasında eğitilmek üzere kullanılmıştır. Eğitilen XGB algoritmasıyla yalan haber tespiti yapılmış, pertürbasyon (perturbation-based) yöntemiyle tahmin kullanıcıya gösterilmiştir. Sistem Python programı kullanılarak geliřtirilmiştir. Kullanıcı arayüzü HTML ile kodlanmış, Flask çatısıyla web sayfasına uygulanmıştır. Sistem haberlerin öznitelik özellikleri girdi olarak alır, haberin yalan olduđuna dair tahmin puanını ve yapılan tahmini kanıtlamak için çeşitli açıklamaları çıktı olarak verir. XFake, birden fazla analiz yöntemi kullanarak yalan haber tespitinde bulunmaktadır. Kullanıcı arayüzünde haberin yalan olduđu bilgisinin yanında

çeşitli açıklamalarda bulunan ve görselleştirmeye kullanıcılara daha iyi bir deneyim sunan bir sistemdir (Yang, vd., 2019).

Aldwairi ve arkadaşı; arama motorlarında kullanıcıya öneri olarak sunulan web sayfalarının hangilerinin yalan haber içerdiğini tespit eden yeni bir araç (tool) geliştirmişlerdir. Kullanıcı arama motoruna herhangi bir terim girdiğinde, arama motoru aranan terimi içeren web sayfalarını arayarak sonuçları kullanıcıya gösterir. Sosyal medyanın yanında web sayfaları da yalan haberlerin yayıldığı ortamlar olmuştur. Geliştirilen araç, tarayıcının bulduğu web sitesi linklerini kullanıcıya gönderilmeden önce kontrol ederek, yalan haber içeren tıklama tuzağı amacıyla oluşturulmuş olan web sayfalarını tespit eder. Tespit edilen web sitesi adreslerini vurgulayarak kullanıcıların yalan haber içeriğine sahip olan web sayfalarını fark etmesi sağlanır. Geliştirilen aracın kullanılabilmesi için ilk olarak kişisel bilgisayara indirilmelidir. İndirilen araç, kullanılan tarayıcıya eklenerek kullanılabilir. Geliştirilen araç bütün tarayıcılarla uyumlu olarak çalışmaktadır. Kullanıcı belirli bir terimi arama motoruna yazdığına, geliştirilen araç devreye girer. Arama motorunun bulduğu sonuçların link URL'leri kontrol edilerek yalan haber içeriğine sahip olan siteler işaretlenir. Alınan URL linklerindeki başlık ve metin içerikleri, kelime metriği (wording metric) ve kelimelerin sözdizimsel özellikleri kullanılarak kontrol edilir. Yapılan araştırmalarda yalan haber içeriğine sahip olan haber başlıklarının çok fazla kelimeye ve ünlem gibi noktalama işaretlerine sahip olduğu tespit edilmiştir. Aldwairi ve arkadaşı, kelime sınır eşiği olarak sekiz kelime belirlemişlerdir. Haber başlığı sekizden fazla kelime içeriyorsa, yalan haber olarak kabul edilecektir. Kelime sayısının yanında, haber başlık ve içeriğindeki noktalama işaretleri de kontrol edilmiştir. Haber metni ya da başlığı; çok fazla ünlem, soru işareti gibi kullanıcının ilgisini çekecek noktalama işaretleri barındırıyorsa yalan haber olma olasılığı çok yüksektir. Geliştirilen araç, fazla sayıda noktalama işareti bulunduran haberleri yalan olarak tespit etmiştir. Aldwairi ve Alwahedi, Web sayfası URL'lerindeki başlık ve metinlerde bulunan kelime ya da noktalama işaretleri gibi özellikleri çeken Python scripti yazmışlardır (Aldwairi ve Alwahedi, 2018).

Başka bir çalışmada, genellikle internette sanal paranın (Bitcoin) güvenliği için kullanılan Blockchain kullanılmıştır. Paul ve arkadaşları yalan haber tespitinde kullanılan

geleneksel yöntemlerden farklı olarak Ethereum, Blockchain, Sığ Öncelikli Arama (Breadth First Search) kısaca BFS algoritması yöntemlerini kullanmışlardır. Yaptıkları çalışmada, sosyal medya uygulamalarını Blockchain'e entegre etmişlerdir. Böylece sosyal medyada paylaşılan herhangi bir haber, kullanıcı numarasıyla birlikte zincire (chain) gönderilecektir. Sistem; çok fazla paylaşılan, yorum yapılan ve değerlendirilen haberlerin blockchain zinciri üzerinde yayılmasına izin verecek şekilde tasarlanmıştır. Blockchain üzerinde bulunan haberlerden, değerlendirme oranı yüksek olan güvenilir haberler kullanıcılara gösterilecektir. Hangi doğrulanmış haberin kullanıcılara gösterileceği, ağırlık tabanlı (weight-based) doğrulama yöntemi kullanılarak belirlenmiştir. Ağırlıkları, haber doğrulayıcılar oluşturmaktadır. Haber doğrulayıcılar, gazeteci gibi güvenilir bilgiye sahip olabilecek kullanıcılardan oluşmaktadır. Her haber doğrulayıcının ağırlık ortalaması vardır. Doğrulayıcıların ağırlık ortalamaları BFS algoritması ile karşılaştırılarak, ortalama ağırlığı yüksek olan haber doğrulayıcının değerlendirdiği haberler yayınlanmaktadır. Ağırlık ortalamaları, doğrulayıcıların haberlerin içeriğiyle ilgili yaptıkları yorumlar arttıkça yükselmektedir (Paul, vd., 2019).

Castelo ve arkadaşları, herhangi bir web sayfasının yalan haber içerip içermediğini tespit etmeye çalıştıkları bir çalışma yapmışlardır. Çoğu çalışmada içerik analizi yapılarak, haberin yalan olup olmadığı tespit edilmeye çalışılmıştır. Castelo ve arkadaşları sadece içerik analizi yapmanın yalan haber tespiti için yeterli olmayacağını savunmuşlardır. İçerik analizi, metinlerde geçen kelime sayısını hesaplayan kelime torbası yöntemi kullanılarak yapılır. Kelime torbası yöntemiyle içerik analizi yapılması yerine, geliştirdikleri başlık agnostik sınıflandırma (topic-agnostic classifier) yönteminin kullanılmasını önermişlerdir (Castelo, vd., 2019).

P'erez-Rosas ve diğerleri, yalan haber tespiti yapan yeni bir otomatik dedektör geliştirmişlerdir. Yaptıkları çalışmada, yalan haberlerden oluşan iki yeni veri seti oluşturmuşlardır. İlk veri seti, kitle kaynak kullanımı (Crowdsourcing) kullanılarak toplanmış olan teknoloji, eğitim, spor, politika ve eğlence kategorilerine ait yalan haberlerden oluşmaktadır. İkinci veri seti, çevrimiçi web ortamından alınmış magazin konulu yalan haberlerden oluşmaktadır. Yalan haber sınıflandırması için; kelimelerin

sözcüksel (lexical), sözdizimsel (syntactic) ve anlamsal (semantic) gibi dilsel özellikleri (linguistic features) çıkarılmıştır. Ayrıca Dil Sorgulama ve Kelime Sayımı (Linguistic Inquiry and Word Count) kısaca LIWC, Bağlamdan Bağımsız Dilbilgisi (Context Free Grammer) kısaca CFG, Gunning Sis İndeksi (Gunning Fog), Otomatik Okunabilirlik İndeksi (Automatic Readability Index) kısaca ARI ve Flesch–Kincaid Okunabilirlik Testlerini uygulamışlardır (P’erez-Rosas vd., 2017).

Kesarwani ve arkadaşları; makine öğrenmesi algoritmalarından En yakın komşuluk algoritmasını kullanarak yalan haber tespiti yapmışlardır (Kesarwani, vd., 2020). Çalışmalarında, Facebook’da paylaşılmış olan yalan haberlerden oluşan Buzz Feed veri setini kullanmışlardır. Diğer çalışmalarda yapılanın aksine, karmaşıklık matrisinde haberleri “neredeysel yalan”, “kayda değer içerik yok”, “gerçek ve yalan haber karışık” ve “neredeysel gerçek” olarak sınıflandırmışlardır. Kullandıkları veri setine KNN modelini uygulamaları sonucu %79’luk bir doğruluk oranı elde etmişlerdir.

Reis ve diğerleri, sosyal medyanın yaygınlaşması ve paylaşılan içeriklerin kontrol edilememesinden dolayı, yalan haber üreten kötü niyetli kişilerin çevrimiçi sosyal ağları yaygın olarak kullandıklarını tespit etmişlerdir. Bunun için çalışmalarında, sosyal ağlarda yayınlanmış olan yalan haberlerden oluşan veri setini kullanarak, yalan haber dedektörü yapmışlardır. Oluşturdukları veri setinde yalan haber tespiti için KNN, Naive Bayes (NB), RF, SVM ve XGB algoritmalarını kullanmışlardır. Algoritmaların vermiş olduğu doğruluk, AUC ve F1 skor oranlarını birbirleriyle karşılaştırmışlardır. En yüksek AUC oranını XGB ve RF algoritmalarının vermiş olduğunu tespit etmişlerdir. (Reis, vd., 2019).

Bahad ve arkadaşları, yalan haber tespiti için kullandıkları veri setini 60-20-20 olarak üçe ayırmışlardır. Veri setinin %60’lık kısmını test, %20’lik kısmını eğitim geri kalan %20’lik kısmını doğrulama veri seti olarak kullanmışlardır. Kelime vektörizasyonu için GloVe tekniğini kullanmışlardır. Test için ayırdıkları verilere derin öğrenme modelleri olan LSTM-RNN, CNN, vanilla RNN ve Bi-directional LSTM algoritmalarını uygulamışlardır. En yüksek doğruluk oranını Bi-directional LSTM-RNN modelinin verdiğini tespit etmişlerdir (Bahad, vd., 2019).

Vyas ve diğeri, e-ticaret sitelerinde yapılan kullanıcı yorumlarının güvenilir olup olmadığını tespit etmeye çalışmışlardır. Alınan kullanıcı yorumlarına kelime sayımı (word count), cümle uzunluğu (sentence length), anlamsal (sentiment) ve N-gram tekniklerini uygulamışlardır. Derin öğrenme algoritması olarak LSTM modelini kullanmışlardır (Vyas, vd., 2021).

Tablo 1

Yalan haberle ilgili yapılmış çalışmaların karşılaştırılması

Yazarlar	Kullanılan Yöntemler	Yapılan Çalışmalar Hakkında Özet Bilgi
Vo vd. (2018)	Guardian-Guardian SPPMI matrix, D-tweets, S-tweets, D-guardians, S-guardians	İçeriği kontrol edilmiş URL öneri sistemi geliştirmişlerdir. İçerik kontrolünü yapan “Guardians” adını verdikleri kullanıcıların kullanılmasını önermişlerdir.
Patankar vd. (2019)	Eğilim skoru, LDA	Yalan haber tespitinin yanında, haber içeriğine benzer yeni haberlerin önerildiği yeni bir tarayıcı uzantısı geliştirmişlerdir.
Becker (2021)	İçerik kontrolü yapan uzman kişiler	Farklı alanlarla ilgili, yalan haberlerin nasıl tespit edileceğine dair bilgi veren mobil uygulama geliştirmişlerdir.
Shu vd. (2018)	GRU	Yalan haber tespitinin, haber içeriği ve kullanıcı davranışlarının bir arada kullanılarak yapıldığı FakenewsTracker adlı yeni bir araç geliştirmişlerdir.
Botnevik vd. (2020)	Derin öğrenme algoritmaları kullanılarak geliştirilen SADHAN modeli	Sayfa URL’lerinin alınıp kontrol edildiği BRENDA adı verilen tarayıcı uzantısı geliştirmişlerdir.
Paschalides vd. (2021)	L2 regülasyonu, genetik algoritması	Overfitting’e karşı L2 regülasyonunu kullandıkları, farklı tarayıcılarda çalışan uzantı geliştirmişlerdir.

Paka vd. (2021)	Bi-LSTM	Twitter’da paylaşılan yeni içerikleri tweet ID kullanarak alan ve kontrol eden, CROSS-SEAN adı verilen tarayıcı uzantısı geliştirmişlerdir.
Singhal vd. (2019)	BERT, VGG-19	Metin analizinin yanında resim analizi yaparak yalan haber tespiti yapan, SpotFake adını verdikleri yeni bir araç geliştirmişlerdir.
Jain ve Kasbe (2018)	Naive Bayes algoritması, Web Scrapping	Naive Bayes algoritması ve Web Scrapping kullanarak yalan haber tespiti yapmışlardır.
Jiang vd. (2021)	Çeşitli makine ve derin öğrenme algoritmaları	Makine öğrenmesi ve derin öğrenme algoritmalarını kullanarak yalan haber tespiti yapmışlardır.
Runcansky vd.	Geliştirilen CSI adlı yeni bir çatı kullanılmıştır.	Metin içeriği ve kullanıcıların bir haberle karşılaştıklarında verdikleri tepki davranışlarını kullanarak yalan haber tespiti yapmışlardır.
Conroy vd. (2015)	Dil bilimsel ve ağ tabanlı yaklaşım	Yanılıcı dil kalıplarını çıkardıkları dil bilimsel yaklaşım ve ağ analizi yaptıkları ağ tabanlı yaklaşımı bir arada kullanarak yalan haber tespiti yapmışlardır.
Al Asaad vd. (2018)	Naive Bayes ve SVM algoritmaları	Alınan sayfa URL’lerindeki yalan haberleri Naive Bayes ve SVM algoritmaları kullanarak tespit etmişlerdir.
Della vd. (2018)	TriFN, HC-CB-3	İçerik analizi ve kullanıcı davranışlarını bir arada kullanmışlardır.
Cui vd. (2019)	GRU, yeni geliştirilen dEFEND algoritması	Yalan haber tespiti için içerik analizi ve kullanıcı yorumlarının birlikte kullanıldığı, dEFEND adını verdikleri yeni bir araç geliştirmişlerdir.

Yang vd. (2019)	MIMIC, ATTN ve PERT adı verilen yeni çatı geliştirilmiştir.	MIMIC, ATTN ve PERT adını verdikleri üç yeni çatı geliştirmişlerdir. Geliştirilen üç çatıyı, XFake adını verdikleri araçta kullanarak yalan haber tespiti yapmışlardır.
Aldwairi vd. (2018)	Bayes Net, Logistic, RandomTree, Naive Bayes	Arama motorlarında kullanıcıya öneri olarak sunulan web sayfalarının içerik kontrolü yaparak, yalan haber içeriğine sahip web sayfaları tespit edip kullanıcıya sunan yeni bir araç geliştirmişlerdir.
Paul vd. (2019)	Blockchain, Enthereum ve BFS	Blockchain, Enthereum ve BFS yaklaşımlarının bir arada kullanılarak yalan haber tespiti yapılmıştır.
Castelo vd. (2019)	Konu-Agnostik özellik yaklaşımı	Açılan web sayfasının yalan haber içerip içermediği agnostik sınıflandırma kullanarak kontrol edilmiştir.
P'erez-Rosas vd. (2017)	Dilsel özellikler, LIWC, CFG, ARI, Gunning Sis İndeksi	Yalan haberlerden oluşan ve farklı tekniklerle toplanmış iki yeni veri seti oluşturmuşlardır. Kelimelerin dilsel özelliklerinin çıkarılarak yalan haber tespiti yapan, otomatik dedektör geliştirmişler.
Kesarwani vd. (2020)	KNN	Facebook gönderilerinden oluşan Buzz Feed veri setine KNN algoritmasını uygulamışlardır. Karmaşıklık matrisini “neredeyse yalan”, “kayda değer içerik yok”, “gerçek ve yalan haber karışık” ve “neredeyse gerçek” olarak ayırmışlardır.
Reis vd. (2019)	KNN, NB, RF, SVM, XGB	Sosyal ağlarda yayınlanmış olan yalan haberlerden oluşan veri setine farklı makine öğrenmesi algoritmalarını uygulamışlardır. Algoritmaların vermiş olduğu doğruluk, AUC ve F1 skor oranlarını birbirleriyle karşılaştırmışlardır.

Bahad vd. (2019)	GloVe, LSTM-RNN CNN, vanilla RNN, Bi-directional LSTM	Yalan haber tespiti için kullandıkları veri setini 60-20-20 oranlarında test-eğitim ve doğrulama olarak üçe ayırmışlardır. Farklı derin öğrenme modellerini uygulamışlardır.
Vyas vd. (2021)	N-gram, LSTM	E-ticaret sitelerindeki kullanıcı yorumlarının güvenilir olup olmadığını LSTM modelini kullanarak sınıflandırmaya çalışmışlardır.

Tablo 1’de, yapılan literatür taramasında yalan haber tespiti için uygulanan farklı yöntemler ve kullanılan teknikler özet olarak yazılmıştır. Her bir çalışmada farklı bir yaklaşım öne sürülmüştür. Bu tez kapsamında yalan haberlerin yüksek bir oranda tespit edilmesi amaçlanmıştır. Kaggle sitesinden alınan üç farklı veri seti ve bu üç veri setinden seçilmiş karışık verilerin bulunduğu dördüncü bir veri seti kullanılmıştır. Kullanılan veri setlerine; doğal dil işleme yöntemleri Pasif agresif, SVM, Rassal Orman, AdaBoost, XGBoost ve LSTM algoritmaları uygulanmıştır. Chrome uzantısı aracı geliştirilerek yapılan yalan haber tespiti süreci otomatikleştirilmiştir. Diğer çalışmalarda Twitter’da paylaşılmış olan gönderiler ya da açılan bir haber sayfasını gibi daha dar alanlarda yalan haber tespitinin yapıldığı görülmüştür. Geliştirilen Chrome uzantısı çalışma diğer çalışmalardan farklı olarak web siteleri ve sosyal medya platformları gibi bütün çevrimiçi platformlarda kullanılabilir. Ayrıca bazı çalışmalarda, açılan haberlerin URL adreslerinin otomatik alınarak kontrol edildiği görülmüştür. Çalışmada, bu yöntemden farklı olarak kullanıcılara istedikleri haber ya da başlığı diledikleri zaman uzantıda kontrol edebilme özgürlüğü sunulmuştur.

ÜÇÜNCÜ BÖLÜM

ARAŞTIRMA YÖNTEMİ/MATERYAL VE YÖNTEM

3.1. MATERYAL

Bu tez kapsamında, yalan haberlerin tespit edilip yayılmasının önlenmesi amacıyla Chrome uzantısı geliştirilmiştir. Yalan haber tespiti için, Kaggle sitesinden alınmış olan politika haberlerinden oluşan veri seti¹, toplumsal olaylardan oluşan veri seti², kültür-sanat haberlerinden oluşan veri seti³ ve bu üç veri setinin verileri kullanılarak oluşturulan dördüncü bir veri seti kullanılmıştır.

Politika veri setinde 23481 adet yalan haber ve 21417 adet gerçek haber bulunmaktadır. Veri setinde bulunan bütün veriler ve belirli sayıda verinin kullanılmasıyla aynı doğruluk oranları elde edilmiştir. Yani 40000 adet veri ile 2000 adet veriye doğal dil işleme ve makine öğrenmesi teknikleri uygulanmasıyla yaklaşık aynı değerler elde edilmiştir. Bu da kullanılan veri setindeki bütün verilerin homojen olduğunu göstermektedir. Bundan dolayı uygulanan tekniklerin daha hızlı tamamlanması ve daha az bellek kullanımı için yalan haberlerden 5000 adet, gerçek haberlerden 4800 adet veri kullanılmıştır. Toplumsal olaylardan oluşan veri setinde yalan ve gerçek haberlerin karışık olarak bulunduğu 72134 adet veri bulunmaktadır. Yine uygulanan tekniklerin daha hızlı tamamlanması ve daha az bellek kullanımı için 10000 adet veri kullanılmıştır. Kültür-sanat haberlerinden oluşan veri setinde yalan ve gerçek haberlerin karışık olarak bulunduğu 23196 adet veri bulunmaktadır. Yine uygulanan tekniklerin daha hızlı tamamlanması ve daha az bellek kullanımı için 10000 veri kullanılmıştır. Son veri seti, diğer üç veri setinden toplamda 16285 adet veri alınarak oluşturulmuştur.

¹ <https://www.kaggle.com/datasets/emineyetm/fake-news-detection-datasets>

² <https://www.kaggle.com/datasets/saurabhshahane/fake-news-classification>

³ <https://www.kaggle.com/datasets/algord/fake-news>

Yalan haberlerin tespit edilebilmesi için ilk olarak yalan ve gerçek haberlerin bulunduğu veri setine çeşitli doğal dil işleme ve makine öğrenmesi yöntemlerinin uygulanması gerekir. Not alır gibi kod yazma, kalınan yerden devam etme, istenilen kod bloğunu çalıştırma gibi özelliklerinden dolayı Python programlama diline göre daha esnek olduğu için geliştirme ortamı olarak Jupyter Notebook programı kullanılmıştır.

Chrome uzantısı geliştirmek için Spyder programı kullanılmıştır. Python programlama diliyle yazılmış ve Python ile program geliştirmek için kullanılacak açık kaynak kodlu bir geliştirme ortamıdır. Projede Spyder geliştirme ortamının seçilmesinin en önemli nedeni, Spyder'in özellikle veri bilimi için geliştirilmiş olmasıdır. Numpy, SciPy, Matplotlib, Panda, SymPy, Python paketleri ve daha birçok açık kaynak yazılım paketiyle entegre olabilmektedir.

3.2.YÖNTEM

Yalan haber tespiti yapan Chrome uzantısı iki aşamada geliştirilmiştir. İlk aşamada, kullanılacak olan veri setine veri madenciliği işlemleri uygulanmıştır. İkinci aşamada, Chrome uzantısı geliştirilmiştir.

3.2.1. Veri Madenciliği Aşamaları



Şekil 1. Çalışmada veri setine uygulanan veri madenciliği aşamaları ve bu aşamalarda uygulanan işlemler.

Şekil 1’de, veri setine uygulan veri madenciliği aşamaları gösterilmiştir. Her adımda yapılan işlemler ayrıntılı olarak başlıklar halinde açıklanmıştır.

1-) Veri Setini Toplama

Veri madenciliği sürecinin ilk ve en önemli aşamasını, üzerinde çalışılacak olan veri seti için uygun verilerin toplanması oluşturur. Çalışmamızda daha önce başka çalışmalar için oluşturulmuş üç veri seti ve bu veri setlerinden alınan verilerle oluşturulmuş dördüncü veri seti kullanılmıştır.

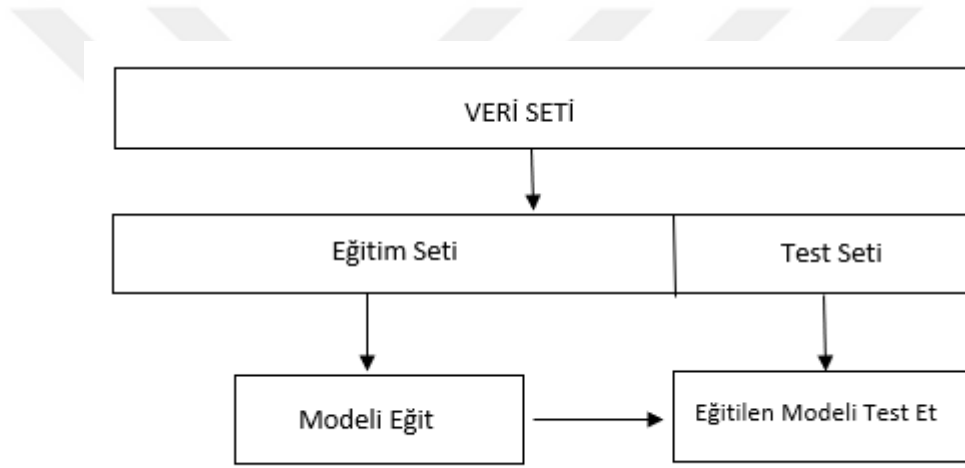
2-) Veri Ön İşleme

Veri ön işleme, veri madenciliğinde veri setinin oluşturulmasından sonraki adımda gerçekleştirilir. Veri ön işlemede; doğal dil işleme teknikleri uygulanarak veri tutarlılığı sağlanır. Böylece hem sonraki adımlarda gerçekleştirilecek olan işlemler daha kolay ve verimli hale getirilmiş hem de ham veri (raw) makinenin anlayabileceği formata dönüştürülmüş olur.

Haberler veri setlerine; haber başlığı, haber metin içeriği, haber konusu, yayınlanma tarihi, haber etiketi gibi sütunlara eklenmiştir. Çalışmamızda veri madenciliği işlemleri uygulanırken sadece haber başlığı, haber içeriği ve etiket kullanılacağı için gereksiz sütunlar silinmiştir. Haber başlığı ve haber metni birleştirilerek yeni bir sütun oluşturulmuştur. Son olarak satır ve sütunlarda eksik ve bozuk veri olup olmadığı kontrol edilmiştir. Eksik ya da bozuk veri olmadığı tespit edilmiştir. Yapılan kontrollerden sonra, veri setine doğal dil işleme işlemlerinin uygulandığı veri ön işleme aşamasına geçilmiştir. Kullanılan veriler makinenin anlayabileceği formata dönüştürülmeden önce verilerdeki gereksiz işaret, sembol, rakam, noktalama işaretleri, kelime değeri olmayan ifadeler kaldırılmalıdır. Kullanılan veri setindeki verilerde bulunan büyük harfler küçük harfe çevrilmiştir. Kelime değeri olmayan işaretler, sayılar ve semboller kaldırılmıştır. Noktalama işaretleri ve boşluklar kaldırılmıştır. Metinlerde ya da cümlelerde her zaman kelimeler bulunmaz. Kelime olmayan ama kelime gibi olan edat, bağlaç gibi ifadeler bulunmaktadır. Stopwords adı verilen bu ifadeler veri setinden kaldırılmıştır.

3-) Veri Setini Ayırma (Data Splitting)

Veri seti ayırma işlemi, tahminde bulunacak olan modelin eğitilmesi için kullanılır. Veri seti genel olarak eğitim (train) seti ve test seti olmak üzere ikiye ayrılır. Eğitim seti, modelin eğitilmesi için kullanılan veri setidir. Model, kullanılan veri ile eğitilerek nasıl sınıflandırma ya da regresyon yapması gerektiğini öğrenir. Model başka veri setlerinde öğrendiklerini kullanarak yapılan tahminleri kullanıcıya sunar. Uygulanan bu eğitimin ne kadar doğru ve güvenilir sonuçlar verdiği de test verileriyle test edilerek, kullanılacak olan modelin uygun olup olmadığına karar verilir.



Şekil 2. Veri setinin eğitim ve test olarak ikiye ayrılması.

Kaynak: (Crisci, vd., 2012).

Çalışmamızda veri setini bölme aşamasında, veri seti %80 eğitim ve %20 test olarak ayrılmıştır. Veri seti, kullanılan modeli eğitmek amacıyla ikiye bölünmüştür. Bu çalışmada, yalan haber tespiti için farklı algoritmalar kullanılmıştır. Denetimli öğrenmede, kullanılan modeller ayrılmış olan %80'lik eğitim verisi üzerinde eğitilir. Bu eğitimin ne kadar sağlıklı ve doğru olduğunu görmek için %20'lik bir oranla ayrılmış olan test veri seti üzerinde denir. Bu eğitim sonucunda, model başka veri setlerinde öğrendiklerini kullanarak yeni tahmin sonuçları döndürür. Modelin öğrenme oranı, eğitim için kullanılan veri sayısı arttıkça artar. Modelin öğrenme oranının yüksek olması için, veri setinin %80'lik gibi çok büyük bir kısmı eğitim verisi olarak ayrılmıştır. Şekil 2'de, çalışmada kullanılan veri setlerinin test ve

eđitim olarak ikiye b6lünmesi ve b6lünen veri setinin nasıl eđitilip test edildiđi g6sterilmektedir.

4-) 6zellik Seęimi (Feature Extraction)

Veri madenciliđinde, veriler genellikle metin, rakam olarak veri tabanlarına eklenir. Kullanılan metin, rakam, noktalama iřaretleri gibi ifadeler, bilgisayarın anlayacađı makine dili formatında olmadıđı ięin 6zerinde bir iřlem yapılamaz. Bunun ięin sisteme y6klenen verilerden spesifik olanlar 6zellik seęimiyle seęilerek ęıkarılır ve vekt6rizasyon uygulanarak her bir kelime makinenin anlayacađı formata ęevrilir. ęalıřmamızda TF-IDF algoritmasıyla, veri setinde en sık kullanılan kelimeler d6n6řt6r6lerek kelime vekt6rleri olarak temsil edilmiřtir.

Terim Frekansı – Ters Dok6man Frekansı

Terim Frekansı – Ters Dok6man Frekansı yani kısaca TF-IDF; bir veri seti, dok6man ya da kelime s6zl6đünde (corpora) geęen bir kelimenin ne kadar 6nemli olduđunun deđerlendirildiđi istatistiksel bir algoritmadır (Liu, vd., 2018: 1). Kelime torbasında (Bag of words), veri setine eklenmiř olan kelimelerin sayısı ve frekansı 6nemlidir. Bir kelime ne kadar ok ve sık kullanılırsa frekansı artar. Frekansı y6ksek olan kelime, diđer kelimelere g6re daha 6nemli olur. Bu durum az kullanılan ama sınıflandırmada daha y6ksek tahmin oranını verebilecek olan kelimelerin g6rmezden gelinmesine neden olabilir. Bunun ięin TF-IDF vekt6rizasyon y6ntemi geliřtirilmiřtir. TF-IDF algoritmasındaki temel d6ř6nce, bir kelimenin bir dok6manın ya da veri setinin herhangi bir b6l6m6nde sık kullanılıp, bařka b6l6mlerinde ok nadir kullanılması durumunda frekansı az olduđu ięin g6z ardı edilmesinin yanlıř olduđudur. Kelimenin bazı b6l6mlerde sık kullanılmıř olması, sınıflandırma ięin iyi bir yeteneđinin olabileceđi ve bundan dolayı sınıflandırma yapılırken kullanılabileceđi d6ř6ncesi TF-IDF algoritmasında hakimdir (Liu, vd., 2018: 1).

TF-IDF algoritması TF ve IDF fonksiyonlarının birleştirilmesiyle oluşturulmuştur. TF (Term Frequency), terim frekansı olarak geçmektedir. Bir metinde geçen kelime sayısının toplam kelime sayısına bölünmesi ile elde edilir

$$tf_{i,j} = \frac{n_{i,j}}{\sum_k n_{i,j}} \quad (3.1)$$

Denklem 1.1’de, terim frekansının nasıl hesaplandığı gösterilmektedir. $tf_{i,j}$, terim frekansını ifade etmektedir. j olarak adlandırılan dokümanda i teriminin ne kadar sıklıkta bulunduğu; $n_{i,j}$ yani j dokümanında toplam geçen i anahtar teriminin, j dokümanında geçen toplam terim sayısına bölünmesiyle bulunmaktadır.

IDF (Inverse Document Frequency), tersine doküman frekansı olarak geçmektedir. Bir kelimenin hesaplanan genel önemini temsil eder. Toplam doküman sayısının, spesifik kelimenin geçtiği doküman sayısına bölünmesiyle elde edilir

$$idf(w) = \log\left(\frac{N}{df_t}\right) \quad (3.2)$$

Denklem 1.2’de, tersine doküman frekansının nasıl hesaplandığı gösterilmektedir. Farklı dokümanlarda geçen bir terim olan $idf(w)$; toplam doküman sayısı olan N ’nin, terimi içeren doküman sayısı olan df_t ‘e bölünerek logaritmasının alınmasıyla bulunmaktadır.

$$w_{i,j} = tf_{i,j} \times \log\left(\frac{N}{df_i}\right) \quad (3.3)$$

Denklem 1.3’te, TF-IDF formülünün nasıl hesaplandığı gösterilmektedir. w , dokümanlarda geçen kelimenin ağırlığıdır. Belirli bir dokümandaki yüksek terim sıklığına sahip; ancak tüm veri setinde kullanılan dokümanlarda düşük terim sıklığına sahip olan bir kelime TF-IDF algoritması ile yüksek ağırlığa sahip olabilir. Terim frekansı olan $tf_{i,j}$ ve

tersine doküman frekansı olan $\log\left(\frac{N}{df_t}\right)$ çarpılarak Terim Frekansı – Ters Doküman Frekansı hesaplanır.

5-) Model Uygulama ve Model Uydurma (Model Deployment and Model Fitting)

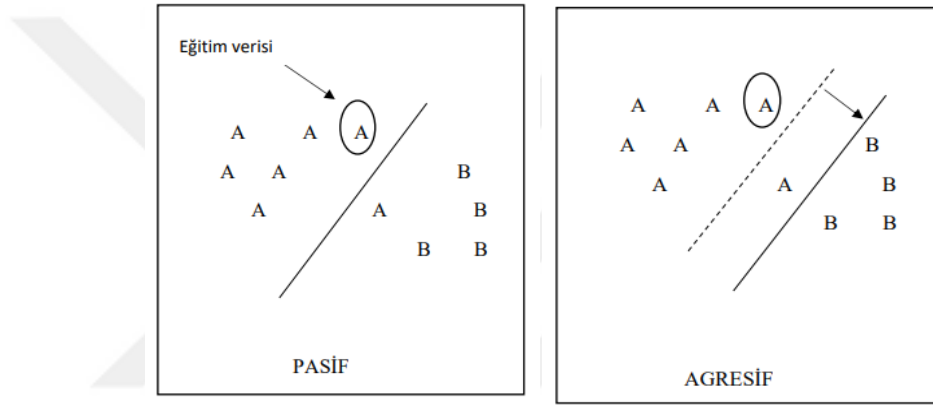
Model uygulama aşamasında eğitim veri setini eğitmek için makine öğrenmesi algoritmaları kullanılır. Eğitim seti algoritmalarla eğitildikten sonra, model uydurma aşamasında algoritmaların performansı ölçülmek üzere test veri seti üzerinde tekrar uygulanır.

Çalışmada model uygulama aşamasında, kullanılacak olan makine öğrenmesi algoritmaları eğitim veri setine uygulanmıştır. Çalışmamızda, çevrimiçi öğrenme algoritması olan Pasif Agresif sınıflandırma, gözetimli öğrenme algoritmalarından Destek Vektör Makinesi, Rassal Orman, güçlendirme algoritmalarından AdaBoost ve XGBoost algoritması, derin öğrenme algoritmasından LSTM algoritması dört veri setine uygulanmıştır. Algoritma performansları, doğruluk oranları ve karmaşıklık matrisleri kullanılarak ölçülmüştür.

Pasif Agresif Sınıflandırma Algoritması (Passive Aggressive Classifier)

Pasif agresif sınıflandırma algoritması, pasif ve agresif olmak üzere iki yöntem kullanılarak sınıflandırma yapan çevrimiçi öğrenme (online-learning) algoritmasıdır. Pasif adımında, eğer tahmin doğruysa model değiştirilmez ve sonraki yapılacak olan tahminlerde aynı model kullanılır. Agresif adımında, yapılan tahmin yanlışsa kullanılan model değiştirilerek daha sonra yapılacak olan tahminlerde değiştirilmiş olan model kullanılır. Makine öğrenmesi algoritmalarında öğrenme yöntemi olarak genellikle gözetimli (supervised) ve gözetimsiz (unsupervised) öğrenme yöntemleri kullanılır. Bu iki yöntemden farklı olarak pekiştirmeli öğrenme (reinforcement), batch, örnek tabanlı (instance-based), model tabanlı (model-based) ve çevrimiçi öğrenme gibi öğrenme algoritmaları

geliştirilmiştir. Çevrimiçi öğrenmede, diğer öğrenmelerden farklı olarak girdi (input) olarak kullanılan eğitim örnekleri sıralı olarak sisteme verilerek makine öğrenmesi algoritması sürekli güncellenir. Çevrimiçi pasif agresif öğrenme algoritması çok büyük veri setlerinde (large-scale) ve özellikle sürekli yeni veri eklenen veri setlerinde daha doğru tahminler yapabilmektedir (Shi ve Zhu, 2014: 378). En önemli özelliği tahmin yanlış yapıldığında modelin değiştirilmesidir. Yeni ağırlık vektörü bulunarak marjin noktası değiştirilir ve kullanılan modelde optimizasyon yapılmış olur (Jorge ve Paredes, 2018: 168). Öğrenme oranına ihtiyacı olmadığı ve aynı sorgulama stratejisine sahip olduğu için Çok Katmanlı Model (perceptron model) ile benzerdir (Lu, vd., 2016: 141).



Şekil 3. Pasif aşamasında yeni gelen verinin sınıflandırılması (a), agresif aşamasında hiperdüzlemin değiştirilmesi (b).

Kaynak: (Kiranmayee , vd., 2021).

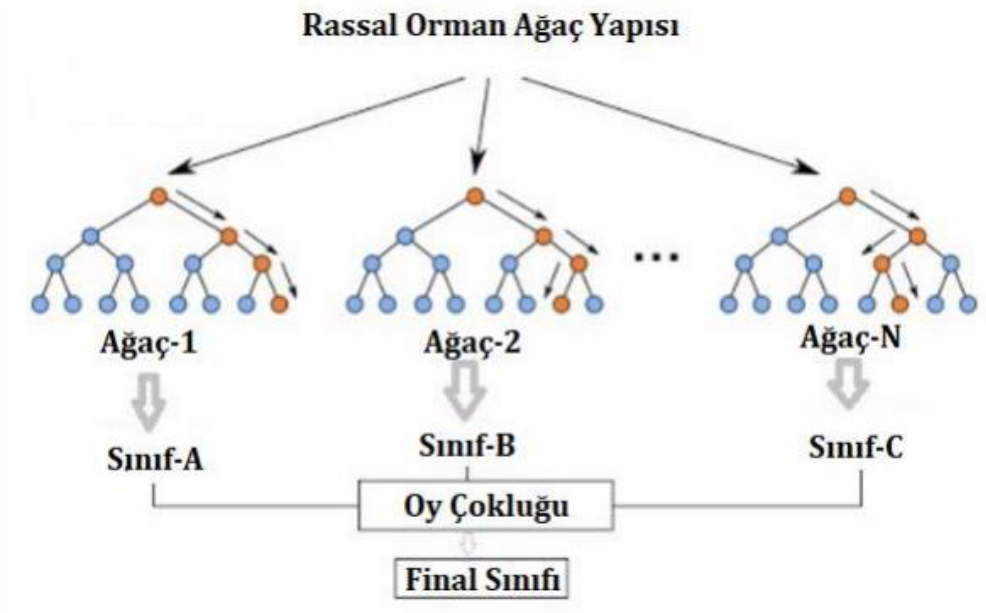
Şekil 3’Te pasif ve agresif adımlarının nasıl çalıştığı gösterilmiştir. Pasif adımda, yeni gelen bir veri doğru sınıflandırıldığında iki ayrı sınıfı ayıran hiperdüzlemin bulunduğu yer değişmeyerek sabit kalmaktadır. Sonra gelen yeni veriler bu hiperdüzlemin bulunduğu yere göre tekrar sınıflandırılmaktadır. Agresif adımında, gelen veri yanlış sınıflandırıldığı zaman hiperdüzlemin bulunduğu konum değiştirilerek tekrar sınıflandırma yapılmaktadır. Şekil 3’teki örnekte, yeni gelen A verisi, A verilerinin bulunduğu grup yerine B verilerinin bulunduğu grupta gösterilerek yanlış sınıflandırılmıştır. Yanlış sınıflandırma durumunda, Pasif Agresif sınıflandırmanın Agresif adımı çalıştırılmaktadır. Hiperdüzlemin bulunduğu konum, yeni gelen veriyi doğru sınıflandırmak için sağa ya da sola kaydırılabilmektedir. Yeni gelen A verisinin doğru sınıflandırılabilmesi için, hiperdüzlem sağa kaydırılmıştır.

Tekrar sınıflandırma yapılmıştır. A verisi, A verilerinin bulunduğu gruba ait gösterilerek doğru sınıflandırılmıştır.

Rassal Orman Algoritması (Random Forest Algorithm)

Rassal Orman sınıflandırma algoritması, kullandığı geliştirilmiş tekniklerden dolayı yüksek oranda tahmin bulunan en başarılı denetimli öğrenme tekniklerinden biridir. Karar ağacı (desicion tree) algoritması, belirli aralıkta aynı tahminleri verdiği için, karar ağaçlarının bir fonksiyonu olan Rassal Orman algoritması geliştirilmiştir. Rassal Orman algoritması, karar ağaçlarından farklı olarak veri ve öznitelik setinden rastgele N tane örnek alır. Alınan bu her N tane örnek ayrı ayrı eğitilerek karar ağaçları oluşturulur. Eğitim aşamasında en yüksek tahmin oranını bulabilmek için çok sayıda karar ağacı oluşturulur. Eğitim sonunda oluşturulan her bir karar ağacının verdiği çıktı alınır. Her bir çıktı karşılaştırılarak en yüksek tahmini yapan karar ağacı algoritması çıktısı kullanılır. Bu yöntem ile karar ağaçlarında oluşan aşırı öğrenme (overfitting) ve veriyi ezberleme sorununa çözüm bulunmuş olunur (Azar, vd., 2013: 467).

Rassal Orman algoritmasında, topluluk (ensemble) öğrenmesi algoritmasından bagging yöntemiyle seçilen veriler eğitilir ve ağaçlar oluşturulur. Bagging yöntemi de “Boostrapping” ve “Aggregating” adımlarından oluşur. Çalışılacak olan veri setinden rastgele n tane örnek seçilerek, seçilen her bir örnekten model oluşturulması “Boostrapping” adımını oluşturur. Oluşturulan her bir model ayrı ayrı eğitilerek, bu eğitim sonucu her ağacın verdiği tahmin değeri için oylama yapılır. En yüksek oylamayı alan (majority voting) karar ağacının seçilmesi ya da her bir ağacın verdiği tahminlerin ortalamasının alınması “Aggregation” adımını oluşturur (Panov, vd., 2007: 120). Regresyon ya da sınıflandırma sorununa göre yapılacak olan işlem değişir. Regresyon yapılacağı zaman karar ağaçlarının verdiği tahminlerin ortalaması alınır. Sınıflandırma için çıkan tahminler arasında en çok oy alan seçilir.




Şekil 4. Rassal Orman algoritması model oluşturularak sınıflandırma yapılması.

Kaynak: (Güven, 2020).

Rassal orman algoritmasının nasıl sınıflandırma yaptığı Şekil 4'te gösterilmiştir. Şekil 4'te, rastgele üç ağaç oluşturulmuştur. Oluşturulan ağaçlar eğitilmiştir. Her bir ağacın verdiği tahmin oranı için oylama yapılmıştır. En yüksek oyu alan tahmin, sınıflandırma için kullanılmıştır.

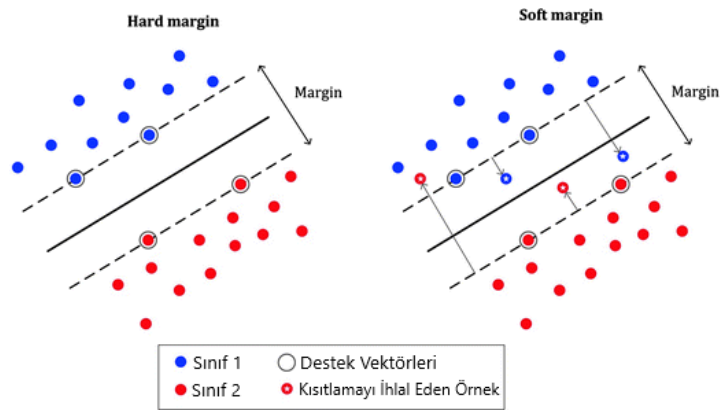
Destek Vektör Makinesi (Support Vector Machine)

Karmaşık, küçük ve orta ölçekli verilerde, bir düzlem çizerek verileri sınıflandırmaya çalışan gözetimli öğrenme algoritmasıdır. Sınıflandırmada asıl sorun gelen yeni verinin hangi gruba ait olduğunun bulunmasıdır. Destek Vektör makinesi algoritması, düzlem üzerinde iki grubu ayıran bir doğru çizer. İki gruba ayrılmış olan veriler arasında doğrusal düzlem oluşturularak gelen yeni verilerin sınıflandırılması bu düzleme göre yapılır.



Şekil 5. Destek Vektör Makinesi oluşturulan marjine göre sınıflandırma yapılması.
Kaynak: (Akca, 2020).

Destek vektör makinesi kısaca SVM algoritması fonksiyonu oluşturmanın en önemli adımı, iki farklı gruba ait olan destekleyici vektörler (support vectors) arasındaki “marjin” adı verilen uzaklığı maksimize eden hiperdüzlemin (hyperline) oluşturulmasıdır. Hiperdüzlem oluşturulduktan sonra yeni gelen veriler bu düzleme göre sınıflandırılır (Pisner, vd., 2020: 102). Şekil 5’te, destekleyici vektörler arasındaki hiperdüzlem ve marjin uzaklıkları gösterilmektedir.




Şekil 6. Hard ve Soft margin kullanılarak verilerin sınıflandırılması.
Kaynak: (Akca, 2020).

Destek vektörleri arasındaki maksimum uzaklığı bularak hiperdüzlem oluşturabilmek için hard ve soft marjın olmak üzere iki yöntem geliştirilmiştir. Hard marjinde, verilerin doğrusal olarak ayrılabilmesi durumunda, doğrusal düzlem çekilerek sınıflandırma yapılabilir. Hard marjin için en önemli nokta, verilerin doğrusal ve kesin olarak iki sınıflandırma grubuna ayrılabilmesi olmasıdır. Yanlış sınıflandırma hard marjin için kabul edilemez bir durumdur. Bunun için, marjin uzaklığı fazla tutularak yanlış sınıflandırma olasılığı azaltılabilir. Verinin doğrusal olmaması gibi durumlarda marjin uzaklığının artırılması çözüm olmayabilir ve sınıflandırma yapılacak olan hiperdüzlem hiç oluşturulamaz. Soft marjin, hard marjinden farklı olarak yanlış sınıflandırma durumuna izin verir (Pisner, vd., 2020: 104). Şekil 6'da, hard marjin ve soft marjine göre yeni gelen verilerin nasıl sınıflandırıldığı gösterilmektedir.

Çekirdek Hilesi (Kernel Trick)


Veriler doğrusal olduğunda düzlem üzerinde doğrusal bir doğru oluşturularak sınıflandırma yapılabilir. Bazı durumlarda veriler doğrusal değil ve düzlem üzerinde birbirinden ayıramayacak şekilde karışık halde bulunduğu Çekirdek Hilesi yöntemi kullanılır.

Kernel trick, bir düzlem ile ayrılarak sınıflandırma yapılamayacak şekilde karışık halde bulunan verilerin iki ya da üç boyutlu hale getirilerek sınıflandırma yapılmasıdır (Jakkula, 2006, 7). Polinomial (Polynomial) ve Gauss Dairesel Tabanlı İşlev Çekirdeği (Gaussian RBF Kernel) olmak üzere iki çeşittir. Polinomial çekirdekleme, belirli bir uzayda ya da düzlemdeyken, bir üst ya da alt uzaya geçişlerde kullanılan kernel yöntemidir. Genellikle ikinci boyuttan n. boyuta geçişlerde kullanılır. Gauss çekirdeklemesinde, hiper parametre değeri olan gamma değişkeni ile her bir destekleyici vektörün birbirine olan benzerliği ölçülerek sınıflandırma yapılır.



Şekil 7. Polinomial Kernel.

Kaynak: (Elen, vd., 2022).



Şekil 8. Gauss Kernel.

Kaynak: (Liu, vd., 2019).

İki boyutlu olan ve sınıflandırma yapılamayacak olan verilerin Polinomial Kernel kullanılarak üç boyutlu hale getirilmesi Şekil 6'da gösterilmiştir. Şekil 7'de, Gauss Kernel'in çan eğrisi yapısı gösterilmektedir.

AdaBoost Algoritması (Adaptive Boosting Algorithm)

AdaBoost algoritması; sınıflandırma ve regresyon için kullanılan, karar ağacı temelli topluluk makine öğrenmesi algoritmalarından bir tanesidir (Tomar, 2020: 238). Topluluk öğrenmesi, sadece bir makine öğrenmesi modeli kullanmak yerine birden fazla makine öğrenmesi modeli kullanarak modeli eğitmeyi amaçlayan öğrenme yöntemidir (Kelle, vd., 2022). Genel olarak, birden fazla modelin kullanılarak yapılan sınıflandırma başarı oranı, tek bir model kullanılarak yapılan sınıflandırma oranına göre daha yüksek olmaktadır.

AdaBoost algoritması, yüksek tahmin oranı elde etmek amacıyla birçok zayıf sınıflandırıcının bir araya getirilmesiyle oluşturulmuş son derece yüksek performans gösteren bir makine öğrenimi yaklaşımıdır (Schapire, 2013: 37). Temel çalışma yapısı, yapılan yanlış tahminlerin ağırlıkları bir sonraki sınıflandırma aşamasında artırılarak algoritmanın tekrar tekrar çalıştırılması mantığına dayanmaktadır. Yanlış yapılan tahminlere odaklanılarak, oluşturulan modelin sınıflandırmadaki doğruluk oranını yükseltmek amaçlanmaktadır. AdaBoost algoritması, Rassal orman algoritmasının geliştirilmesiyle oluşturulmuştur. İlk olarak Freund ve Schapire tarafından geliştirilerek önerilen AdaBoost algoritması sık kullanılan yükseltme (boosting) algoritmalarındandır (Bulut, 2016).

Aşırı Gradyan Yükseltme Algoritması (Extreme Gradient Boosting Algorithm)


Aşırı Gradyan Yükseltme Algoritması diğer bir ifadeyle XGBoosting algoritması, Gradyan Yükseltme (Gradient Boosting) algoritmasının geliştirilmesiyle oluşturulmuş, yükseltme algoritmaları arasında en yüksek performansı gösteren algoritmadır. Yapmış olduğu yüksek oranlardaki tahmin, gerçek zamanda hızlı çalışması, veri setinde bulunan boş verileri kullanabilmesi ve aşırı öğrenmeye yatkın olmaması XGBoost algoritmasının diğer algoritmalarından ayrılan özellikleridir.

XGBoost algoritması, Gradyan Yükseltme algoritmasının geliştirilmesiyle; Gradyan Yükseltme algoritması da AdaBoost algoritmasının geliştirilmesiyle oluşturulmuştur. Yükseltme algoritmaları birbirine benzer prensiple çalışmaktadır. Genel prensip olarak yükseltme algoritmalarında bir grup sıralı model bağımsız şekilde eğitilir. Her çalışmada önceki modelden elde edilen hatalar yani zayıf öğrenciler, her iterasyonda belirli kurallar çerçevesinde birleştirilerek güçlü bir öğrenci elde etmeye çalışır. AdaBoost algoritmasındaki tahmin performansını arttırmak amacıyla zayıf öğrenci sınıflandırıcıları kullanılarak yüksek öğrenci sınıfları oluşturulur. Zayıf öğrenci sınıflarını kullanarak güçlü öğrenci sınıflandırma oluşturulması, iterasyonlar ile aşamalı olarak yapılır. Geliştirilen yükseltme algoritmaları arasındaki farkı, zayıf öğrencilerin eksikliğini nasıl tanımladıkları ve buna nasıl çözüm buldukları oluşturmaktadır. AdaBoost algoritması eksiklikleri yani sınıflandırması zor olan eksiklikleri yüksek-ağırlıklara (high-weight) göre belirlerken, Gradyan Yükseltme algoritması sınıflandırması zor olan eksiklikleri gradyanlara göre tanımlamaktadır (Tomar, 2020: 238). Gradyan artırma yöntemi kullanılarak zayıf

öğreniciler güçlü öğrenicilere dönüştürülür. XGBoost algoritması da Gradyan Yükseltme algoritmasıyla aynı mantıkta çalışmaktadır. Regülerizasyon, budama, boş değer, sistem optimizasyonu gibi farklı özellikler XGBoost algoritmasını Gradyan Yükseltme algoritmasından ayırmaktadır.

Uzun-Kısa Süreli Bellek (Long-Short Term Memory)

Derin öğrenme alanında kullanılan yapay bir Yinelemeli Sinir Ağı (Recursive Neural Network) mimarisidir. Yinelemeli Sinir Ağı kısaca RNN algoritması, genelde bir sonraki adımı tahmin etmek için kullanılan derin öğrenme algoritmalarından bir tanesidir. RNN algoritmasının diğer sinir ağlarında olmayan mimari yapısı, algoritmaya tahmin edebilme özelliği sağlamıştır. Yinelemeli sinir ağları, birbirleriyle bağlantılı ve ilişkili hücrelerden oluşmaktadır. Bir önceki hücrenin çıktısı bir sonraki hücrenin girdisi olmaktadır. Hücreler arasındaki ilişkinin kalıcı olması için döngüye benzer bir yapı oluşturulmuştur.

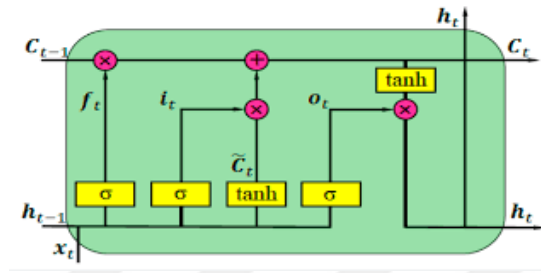


Şekil 9. RNN mimari yapısı.

Kaynak: (Tai, vd., 2016).

Şekil 9'da RNN mimarisinin döngüsel yapısı ve hücreler arasındaki ilişki gösterilmektedir. RNN algoritmasının mimari yapısı, kısa süreli hafıza özelliği vererek bir sonraki adımı tahmin edilebilmesine olanak sağlamıştır. Kısa süreli hafıza durumu giriş verisi çok uzun olan verilerde yetersiz kalarak, algoritmanın tahminde bulunamaması sorununa neden olmuştur. RNN algoritmasının sahip olduğu bir diğer sorun, geriye yayılım (backpropagation) sırasında gradyan yok olması sorunudur. Geriye yayılma sırasında gradyan değerleri çok fazla küçülmesi, RNN algoritmasının eski bilgileri hatırlayamamasına

ve öğrenme gücünü çekmesine neden olmaktadır. Kısa süreli hafıza ve gradyan yok olması problemlerinden dolayı RNN mimari yapısı geliştirilerek LSTM algoritması oluşturulmuştur. Farklı giriş ve çıkış kapıları eklenerek bilgilerin daha iyi depolanması ve daha sonra kullanılmak üzere hatırlanması sağlanarak, RNN algoritmasında dezavantaja neden olan kısa süreli hafıza sorununa çözüm bulunmuştur.



Şekil 10. LSTM model mimari yapısı.

Kaynak: (Kara, 2019).

Şekil 10'da LSTM mimari yapısı gösterilmektedir. LSTM mimarisi; bellek durumu (cell state), unutma kapısı (forget gate), giriş kapısı (input gate) ve çıkış kapısından (output gate) oluşmaktadır. Hücre durumu; LSTM mimarisine hafıza özelliği veren, anlamlı bilgilerin gerekli durumlarda kullanılabilmesi için bir hat boyunca taşınabilmesine sağlayan yapıdır. Unutma kapısında; hangi bilgilerin tutulacağına, hangi bilgilerin unutulup atılacağına karar verilmektedir. Giriş kapısında, önceki bilgi ve var olan bilginin sigmoid ve tanh fonksiyonları uygulandıktan sonra bellek durumunun güncellenip güncellenmeyeceğine karar verilmektedir. Sigmoid ve tanh işlemleri uygulandıktan sonra, sonucu 0 olan bilgi önemsiz olarak, sonucu 1 olan bilgi önemli olarak kabul edilmektedir. Çıktı kapısı, girdi ve hücrenin belleğine bağlı olarak neyin çıktı alınacağına karar verir. Önceki hücreden gelen bilgi ve mevcut olan girişin bilgisi sigmoid fonksiyonundan geçirilir. Durum hücresinde bulunan bilgiye tanh fonksiyonu uygulanır. Elde edilen iki sonuç çarpılarak, hangi bilginin sonraki hücrenin giriş bilgisi olacağına karar verilir (Gavcar, vd., 2021).

6-) Değerlendirme (Evaluation)

Değerlendirme aşamasında uygulana makine öğrenmesi algoritmalarının yaptığı tahmin oranları karşılaştırılır. Doğruluk oranı (accuracy score), karmaşıklık matrisi (confusion matrix), sınıflandırma raporu (classification report) bu aşamada uygulanarak kullanılan makine öğrenmesi algoritmasının performansı ölçülür. En iyi sonucu veren makine öğrenmesi algoritması diğer bir ifadeyle model, bu aşamada değerlendirilerek seçilir.

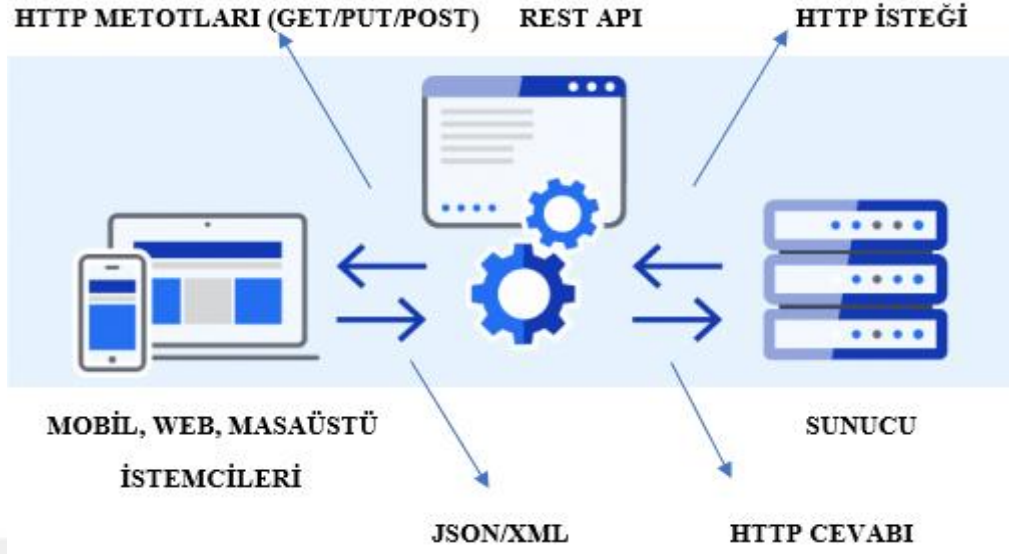
Çalışmada, uygulanan makine öğrenmesi algoritmalarının verdiği doğruluk oranları, karmaşıklık matrisleri, ROC eğrileri birbirleriyle karşılaştırılmıştır. Kullanılan dört veri setinde en yüksek doğruluk oranını LSTM algoritması vermiştir.

7-) Yükleme (Deployment)

Model yükleme kullanılacak olan makine öğrenmesi modelinin paketlenip son kullanıcıyla paylaşıldığı aşamadır. Yüklemeyle birlikte sistemin yapacağı tahminler kullanıcılar, geliştiriciler ya da sistemler için erişilebilir ve kullanılabilir hale gelir. Ayrıca yükleme, oluşturulan makine öğrenmesi modelinin diğer programlara daha kolay uygulanabilmesini sağlar. Çalışmada en yüksek doğruluk oranını veren LSTM algoritması, Spyder programında kullanılmak üzere diske kaydedilmiştir.

3.2.2. Chrome Uzantısı Geliştirme Aşaması

Spyder IDE programı kullanılarak Chrome uzantısının arayüzü tasarlanmıştır. Uzantı popup arayüzü HTML ve CSS kullanılarak tasarlanmıştır. Uzantı popup'ında bulunan butonlar Javascript kullanılarak aktifleştirilmiştir. Uzantı, web ortamında çalışan bir web uygulaması olarak tasarlanmıştır. Web uygulamaları, kullanıcı arayüzünden oluşan istemci ve kullanıcı hareketlerinin alınıp işlendiği sunucudan oluşmaktadır. Kullanıcı ile sunucu arasındaki bağlantı Rest API kullanılarak sağlanmıştır.



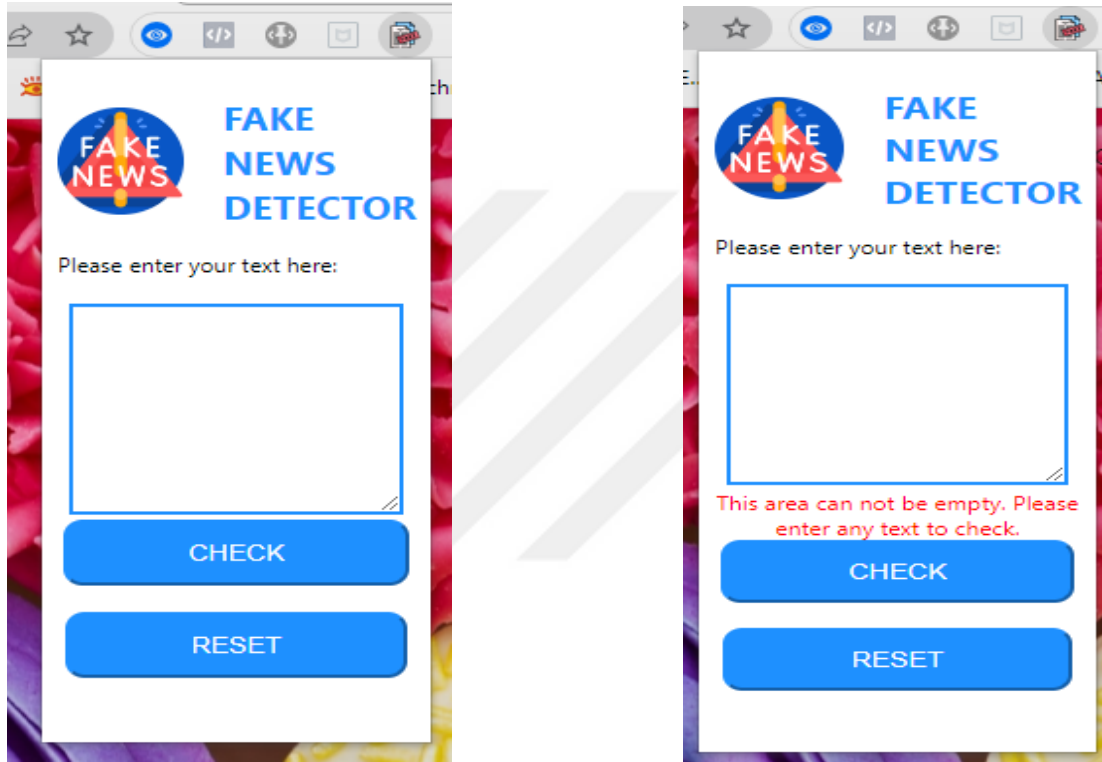
Şekil 11. Rest API çalışma yapısı.

Kaynak: (Panchar, 2021).

Rest API çalışma yapısı Şekil 10'da ayrıntılı olarak gösterilmiştir. Rest API; Üstmetin transfer protokolü (Hyper-Text Transfer Protocol) protokolünü kullanarak sunucuya GET ve POST metotlarıyla istekte bulunan, aldığı yanıtları geri döndüren, web uygulamalarıyla sunucu arasında iletişim sağlayan uygulama arayüzdür. Çalışmamızda, sunucuya yapılan istekler Eşzamansız Javascript-XML (Asynchronous JavaScript and XML) ve XMLHttpRequest nesnesi kullanılarak yapılmıştır. Eşzamansız Javascript-XML (AJAX) çağrısı tarayıcı tarafından alındığında, XMLHttpRequest aktifleşir. Web tarayıcısı tarafından sunucuya Üstmetin transfer protokolü (HTTP) isteği oluşturulur. Oluşturulan HTTP isteğiyle sunucu tarafından veri GET, PUT, PUSH gibi komutlarla alınır, işlenir ve web tarayıcısına geri gönderilir. Web tarayıcısı gönderilen veriyi alarak kullanıcı sayfasında gösterir. İlk aşamada kullanılacak olan model diske kaydedilmiştir. Bu modelin uzantıda kullanılabilmesi için Python dosyası oluşturulmuştur. Python dosyasına, diske kaydedilmiş olan model dosyası eklenmiştir. Ayrıca Python dosyası; kullanıcı arayüzünde bulunan metin kutusuna eklenen haber metninin alınıp işlendiği ve bu metne tahmin fonksiyonunun uygulandığı dosyadır. Web ortamında çalışabilmesi için Flask çatısı kullanılmıştır. Flask; Python programı kullanılarak geliştirilmiş, web uygulaması geliştirilmesi için kullanılan mikro çatı çerçevesidir. Web çerçevesi (web framework); web sayfaları, blog, wiki gibi web

tabanlı uygulama geliştirebilmek için araçlar, kütüphaneler, modüller ve diğer teknolojilerini sağlayan yazılım iskeletleridir.

3.2.3. Yalan Haber Detektörü Kullanıcı Arayüzü

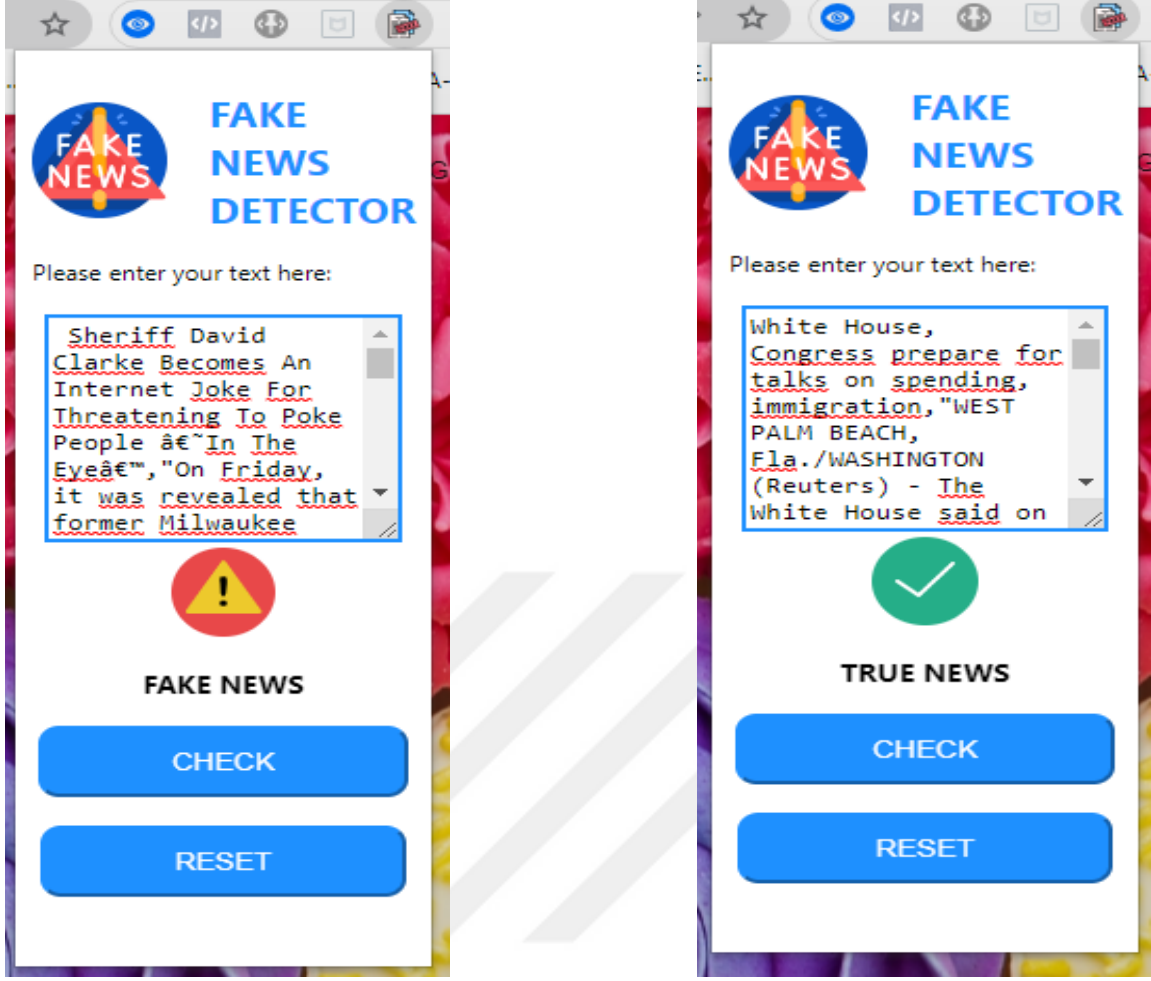


Şekil 12. Yalan haber detektörü arayüzü (a), metin girmeden butona basıldığında arayüzde çıkan uyarı yazısı (b).

Yalan haber tespiti için Chrome tarayıcısına eklenebilen uzantı geliştirilmiştir. Uzantıya tıklanıldığında kullanıcıların haber metinlerini girebilecekleri popup arayüzü açılmaktadır. Sistem İngilizce metinler için geliştirilmiştir. Eğitim veri seti politika, toplumsal olaylar ve kültür-sanat haberlerinden oluştuğu için bu haber içeriklerine benzer haberlerin kontrol edilmesi sistemin daha doğru tahminlerde bulunmasını sağlayacaktır. Kullanıcı arayüzünde, kontrol edilecek haber metninin girilebileceği metin kutusu bulunmaktadır. Diğer çalışmalarda sistemler genel olarak, haber URL adresini otomatik alıp kontrol etmek üzerine tasarlanmıştır. Haber sitelerinin ana sayfalarında çok sayıda haber

başlığı ve haber özetini içerek şekilde bulunmaktadır. Her haberin kullanıcı tarafından ilgi görmeyebileceği düşünülerek böyle bir tarayıcı uzantısı tasarlanmıştır. Kullanıcı ana sayfada haberlere göz gezdirirken bir haberin içeriğinden şüphelenip kontrol etmek isteyebilir. Geliştirilen uzantıyla; kullanıcının istediği haber başlığını ya da metnini, o habere tıklamadan metin kutusuna manuel olarak ekleyerek kontrol etme fırsatı sunmuştur.

Metin kutusunun altında CHECK ve RESET olmak üzere iki buton bulunmaktadır. Kontrol edilmek istenen haber metni, metin kutusuna eklendikten sonra CHECK butonuna tıklanarak yalan ya da gerçek olup olmadığı kontrol edilebilmektedir. Metin kutusuna eklenen bir başlık ya da metin ya da daha önce kontrol edilip TRUE ya da FAKE olarak dönen sonuçlar RESET butonuna tıklanarak temizlenebilmektedir. Metin kutusuna herhangi bir metin girilmeden CHECK butonuna tıklanıldığında, ekrana “This area can not be empty. Please enter any text to check.” yazısı popup’ta çıkmaktadır. Şekil 12’de, yalan haber detektörü arayüzü ve metin girmeden butona basıldığında arayüzde çıkan uyarı yazısı gösterilmiştir.



Şekil 13. Kontrol edilen haberin yalan olması durumunda arayüzde çıkan yazı ve görsel (a), kontrol edilen haberin gerçek olması durumunda arayüzde çıkan yazı ve görsel (b).

Metin kutusuna girilen haber gerçekse “TRUE NEWS” yazısı ve yeşil tik görseli popup’ta gösterilmektedir. Haber yalansa “FAKE NEWS” yazısı ve ünlem görseli popup’ta gösterilmektedir. Şekil 13’te, yalan ve gerçek haber için kullanıcı arayüzünde gösterilen yazı ve simgeler gösterilmiştir.

DÖRDÜNCÜ BÖLÜM

ARAŞTIRMA BULGULARI

Çalışmada politika, toplumsal olaylar, kültür-sanat haberlerinden oluşan veri setleri ve bu üç veri setinin verileri kullanılarak oluşturulan yeni veri seti kullanılmıştır. Dört veri setine farklı makine ve derin öğrenme algoritmaları uygulanmıştır. Makine öğrenmesi algoritmalarından Destek Vektör Makinesi, Rassal Orman, çevrimiçi öğrenme algoritması olan Pasif Agresif Sınıflandırma, yükseltme algoritmalarından AdaBoost algoritması, XGBoost algoritması ve derin öğrenme algoritmalarından LSTM algoritması kullanılmıştır. Kullanılan dört veri setine altı algoritma uygulanmıştır. Her bir veri setine uygulanan altı algoritmanın doğruluk oranları, çapraz doğrulama değerleri, tahmin edilen değerlerin gerçek değerden ne kadar farklı olduğuna dair mutlak bir sayı veren Ortalama Kare Hataları (Mean Squared Error - MSE), karmaşıklık matrisleri, ROC eğrileri ve AUC oranları hesaplanarak karşılaştırılmıştır.

Politika Haberlerinden Oluşan Veri Seti

Politika haberlerinden oluşan veri seti kullanılmıştır. Veri setine çeşitli doğal dil işleme ve makine öğrenmesi algoritmaları uygulanarak, elde edilen sonuçlar tablolarda gösterilerek karşılaştırılmıştır.

Tablo 2

Politika veri setinde kullanılan algoritmalar için doğruluk ve çapraz doğrulama oranlarının karşılaştırılması.

	Doğruluk Oranları	Çapraz Doğrulama Oranları
Pasif Agresif Sınıflandırma	99.44%	99.60%
Destek Vektör Makinesi	99.54%	99.60%
Rassal Orman	99.74%	99.80%
AdaBoost	99.90%	99.95%
XGBoost	99.90%	99.95%
LSTM	99.95%	99.93%

Tablo 2’de, politika veri setine uygulanan algoritmaların verdiği doğruluk değerleri gösterilmektedir. Pasif Agrasif sınıflandırma %99.64 doğruluk oranında, Destek vektör Makinesi %99.54’lük doğruluk oranında, Rassal Orman %99.74’lük bir doğruluk oranında, AdaBoost algoritması %99.90, XGBoost algoritması %99.90 ve LSTM algoritması %99.95’lik doğruluk oranlarında yalan haber tespitinde bulunmuştur. Doğruluk oranlarına bakıldığında en yüksek oranı, derin öğrenme algoritmalarından biri olan LSTM algoritmasının verdiği görülmüştür. LSTM algoritmasından sonra en yüksek doğruluk oranlarını XGBoost ve AdaBoost algoritmaları vermiştir. Algoritmaların verdiği oranlar yüksek olduğundan dolayı aşırı uyma olup olmadığını kontrol etmek için çapraz doğrulama tekniği uygulanmıştır.

Çapraz doğrulama; oluşturulan modelin eğitim verileriyle elde edilen performansının doğrulama verileriyle nasıl olacağını tahmin etmek için kullanılan bir tekniktir. Bu teknik; eğitim verileriyle modeli eğitirken, geri kalan doğrulama verilerini kullanarak modelin performansını değerlendirir. Politika veri setinin test verilerine çeşitli makine öğrenmesi ve derin öğrenme teknikleri uygulanmıştır. Tablo 2’deki doğruluk oranlarına bakıldığında çok yüksek oranlar çıktığı görülmektedir. Bunun için çapraz doğrulama tekniği kullanılarak modellerin test verileri üzerinde göstermiş olduğu performansı, doğrulama verilerinde gösterip göstermeyeceği kontrol edilmiştir.

Tablo 2’te modellere çapraz doğrulama uyguladıktan sonra elde edilen oranlar gösterilmektedir. Çapraz doğrulama tekniği uygulandıktan sonra test ve doğrulama verilerinde yapılan tahmin oranlarının birbirine yakın olduğu görülmüştür. Sonuçlara bakılarak aşırı öğrenme olmadığı doğrulanmıştır. Doğruluk oranlarının çok yüksek olması durumunda her zaman için aşırı öğrenme olduğu ihtimali düşünülmemelidir. Kullanılan politika veri setinin kaliteli verilerden oluşması yüksek doğruluk oranlarının elde edilmesini sağlamıştır.

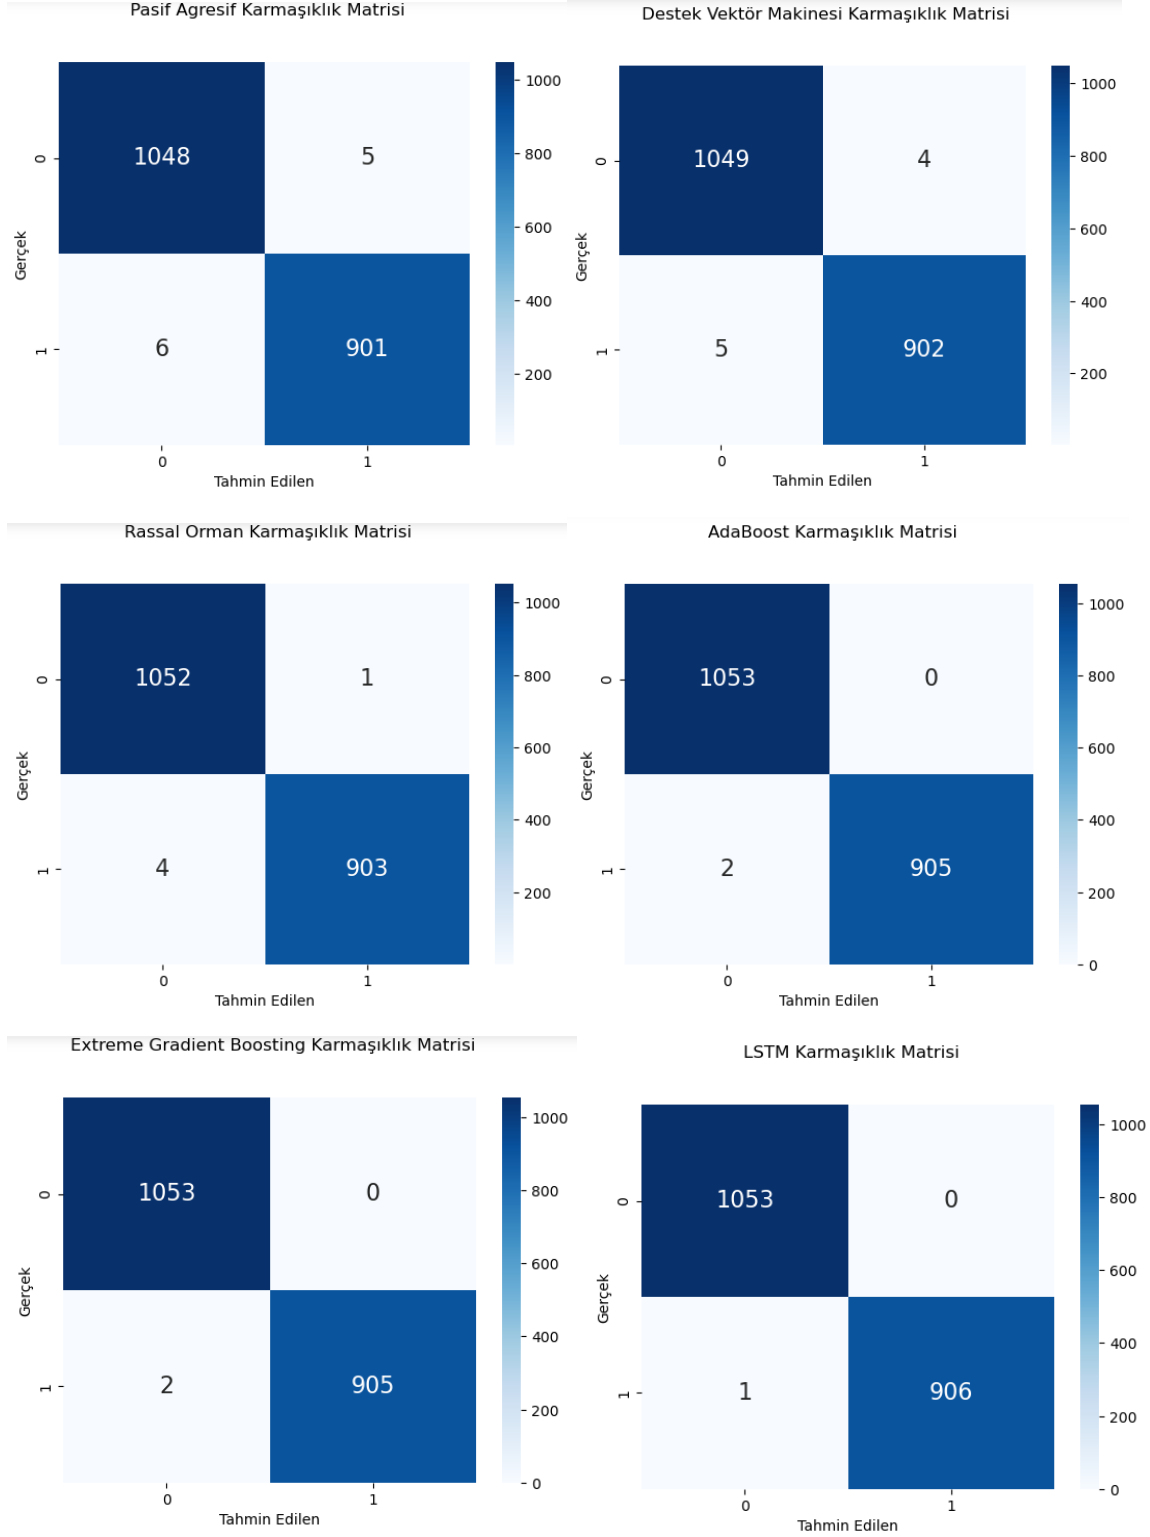
Tablo 3

Politika veri setinde kullanılan algoritmaların ortalama kare hatalarının karşılaştırılması.

	Ortalama Kare Hatası (MSE)
Pasif Agresif Sınıflandırma	0.56%
Destek Vektör Makinesi	0.46%
Rassal Orman	0.26%
AdaBoost	0.10%
XGBoost	0.10%
LSTM	0.05%

Farklı makine öğrenmesi ya da derin öğrenme tahmin modelleri arasından birini seçebilmek için modelin yaptığı tahmin ile gerçek değer arasındaki hata farkını ölçen çeşitli istatistiksel modeller geliştirilmiştir. Tek bir değerlendirme metriği modellerin performansının değerlendirmesi için yeterli olmaz. Hata oranları, diğer model sonuçlarıyla karşılaştırmak için gerçek bir sayı vererek en iyi modelin seçilmesine yardımcı olur. Mutlak ortalama hatası (Mean Absolute Error), ortalama kare hatası (Mean Squared Error), kök ortalama kare hatası (Root Mean Squared Error) ve R kare (R-squared) geliştirilmiş olan hata teknikleridir.

Çalışmada R kare, ortalama kare hatası ve kök ortalama kare hatası kullanılarak hata oranları hesaplanmıştır. R kare uygulandıktan sonra 0-1 arasında hata oranları elde edilmiştir. Değerler birbirleriyle karşılaştırılmayacak kadar çok yakın elde edildiği için R kare yöntemi kullanılmamıştır. Veri setlerine, ortalama kare hatası ve kök ortalama kare hatası yöntemleri uygulanmıştır. Ortalama kare hatası; tahmin edilen sonuçların, gerçek sayıdan ne kadar farklı olduğuna dair mutlak bir sayı vermektedir. Kök ortalama kare hatası, ortalama kare hatasının karekökünün alınmasıyla elde edilmektedir. Genellikle hata oranlarını hesaplamak için kök ortalama kare hatası yaygın olarak kullanılmaktadır. Ancak farklı hata oranları yöntemleri uygulandıktan sonra karşılaştırılabilir en uygun değerleri MSE verdiği için çalışmada bu yöntem tercih edilmiştir. Tablo 3'te; hata oranlarına bakıldığında en düşük hata oranını %0.05'lik bir oranla LSTM, en yüksek hata oranını %0.56 ile Pasif Agresif algoritması vermiştir.



Şekil 14. Politika veri setine uygulanan modellerin karmaşık matrisleri.



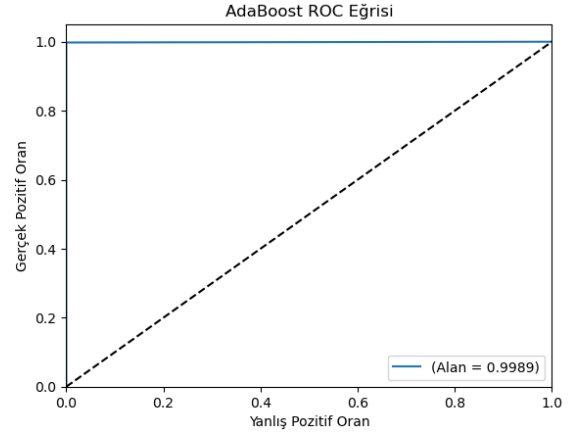
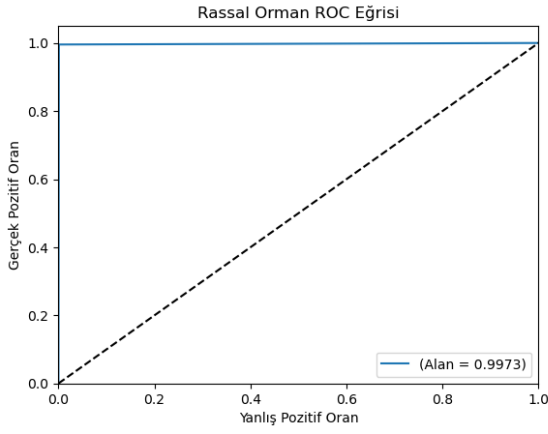
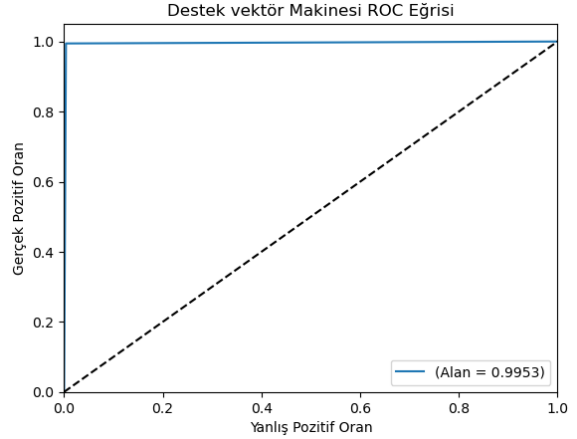
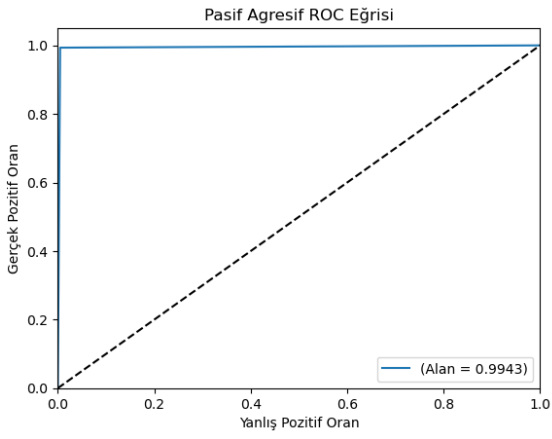
Karmaşıklık matrisi, kullanılan makine öğrenmesi algoritmalarının performansının tablo olarak görselleştirilmesidir.

		Tahmin	
		Negatif (0)	Pozitif (1)
Gerçek	Negatif (0)	Gerçek Negatif (TN)	Yanlış Pozitif (FP)
	Pozitif (1)	Yanlış Negatif (FN)	Gerçek Pozitif (TP)

Şekil 15. Karmaşıklık matrisi.

Şekil 15’te karmaşıklık matrisinin yapısı gösterilmektedir. Gerçek Negatif (True Negative), gerçekte negatif olan bir durumun sınıflandırıcı tarafından da negatif olarak tahmin edilmesidir. Yanlış Pozitif (False Positive), gerçekte negatif olan bir durumun sınıflandırıcı tarafından pozitif olarak tahmin edilmesidir. Yanlış Negatif (False Negative), gerçekte pozitif olan bir durumun sınıflandırıcı tarafından negatif olarak tahmin edilmesidir. Gerçek Pozitif (True Positive) pozitif olan bir durumun sınıflandırıcı tarafından pozitif olarak tahmin edilmesidir. Modellerin göstermiş olduğu performans, bu değerlere bakılarak ölçülebilmektedir (Cengil, vd., 2020: 517).

Veri setindeki yalan haberler “0” olarak, gerçek haberler “1” olarak etiketlenmiştir. Tablodaki “0” etiketi yalan haberleri, “1” etiketi gerçek haberleri temsil etmektedir. Şekil 14’te her bir modelin karmaşıklık matrisleri gösterilmektedir. Değerlere bakıldığında en yüksek performansı LSTM, XGBoost ve AdaBoost algoritmaları vermiştir. AdaBoost ve XGBoost algoritmalarında; 1053 adet yalan haberin hepsi yalan haber olarak, 907 adet gerçek haberin sadece 2 tanesi yalan haber olarak tahmin edilmiştir. LSTM algoritması; 1053 adet yalan haberin hepsini yalan olarak, 907 adet gerçek haberin sadece 1 tanesini yalan haber olarak tahmin etmiştir. Sonuçlara bakarak, politika veri setinde en iyi performansı LSTM algoritması sergilemiştir denilebilir.



Şekil 16. Politika veri setine uygulanan modellerin ROC eğrileri.

ROC-AUC eğrisi, özellikle makine öğrenmesi modellerinin performansının görsel anlamda değerlendirilmesinde etkili bir yöntemdir. Birden fazla sınıflı problemlerinde model sonuçlarındaki parametreleri hassaslık derecesinde grafikleştirilerek tahmin yaparken bir karşılaştırma ölçüğü olarak kullanılmaktadır. ROC-AUC eğrileri, çeşitli eşik değerlerinde sınıflandırma problemleri için kullanılan performans metriğidir. AUC değerinin altında kalan alan ne kadar fazlaysa, modelin performansı o kadar yüksektir. ROC, bir olasılık eğrisidir. AUC ise parametrelerin ayrıştırılabilir ölçüsünü veya derecesini temsil eder. Bu grafik sayesinde model sonucu tahmin edilmek istenen sınıfların ne ölçüde farklılaştıkları izlenebilmektedir. Yüksek AUC derecesi sınıflar arasındaki ayrışmanın ne derece geçerli olduğunu göstermektedir.

Şekil 16’da bütün modeller %99’un üzerinde AUC değerine sahip olduğu için grafiklerin tamamı neredeyse aynıdır. Değerlerin 1’e yakın olması modellerin gerçek ve yalan haber ayrımını çok iyi yapabildiğini göstermektedir.

Toplumsal Olaylardan Oluşan Veri Seti

Toplumsal olaylardan oluşan veri seti kullanılmıştır. Veri setine çeşitli doğal dil işleme ve makine öğrenmesi algoritmaları uygulanarak, elde edilen sonuçlar tablolarda gösterilerek karşılaştırılmıştır.

Tablo 4

Toplumsal olaylar veri setinde kullanılan algoritmalar için doğruluk ve çapraz doğrulama oranlarının karşılaştırılması.

	Doğruluk Oranları	Çapraz Doğrulama Oranları
Pasif Agresif Sınıflandırma	93.2%	91.9%
Destek Vektör Makinesi	93.7%	91.76%
Rassal Orman	90.0%	88.79%
AdaBoost	91.8%	91.60%
XGBoost	93.8%	93.56%
LSTM	95.65%	95.15%

Tablo 4’te toplumsal olaylar veri setine uygulanan algoritmaların verdiği doğruluk ve çapraz doğrulama oranları gösterilmektedir. Pasif Agresif sınıflandırma %93.2 doğruluk oranında, Destek vektör Makinesi %93.7’lik doğruluk oranında, Rassal Orman %90.0’lık bir doğruluk oranında, AdaBoost algoritması %91.8, XGBoost algoritması %93.8 ve LSTM algoritması %95.65’lik doğruluk oranında yalan haber tespitinde bulunmuştur. Doğruluk oranlarına bakıldığında en yüksek oranı yine LSTM algoritmasının verdiği görülmüştür. LSTM algoritmasından sonra en yüksek doğruluk oranlarını XGBoost ve Destek Vektör Makinesi algoritmaları vermiştir. Politika veri seti kadar olmasa da algoritmaların verdiği oranlar yüksek olduğu ve aşırı uyma olup olmadığını kontrol etmek için çapraz doğrulama tekniği uygulanmıştır.

Çapraz doğrulama tekniği uygulandıktan sonra test ve doğrulama verilerinde yapılan tahmin oranlarının birbirine yakın olduğu görülmüştür. Sonuçlara bakılarak aşırı öğrenme (overfitting) olmadığı doğrulanmıştır. Toplumsal olaylardan oluşan veri seti, politika haberlerinden oluşan veri seti gibi çok yüksek doğruluk oranında tahminde bulunmasa da iyi bir performans göstermiştir.

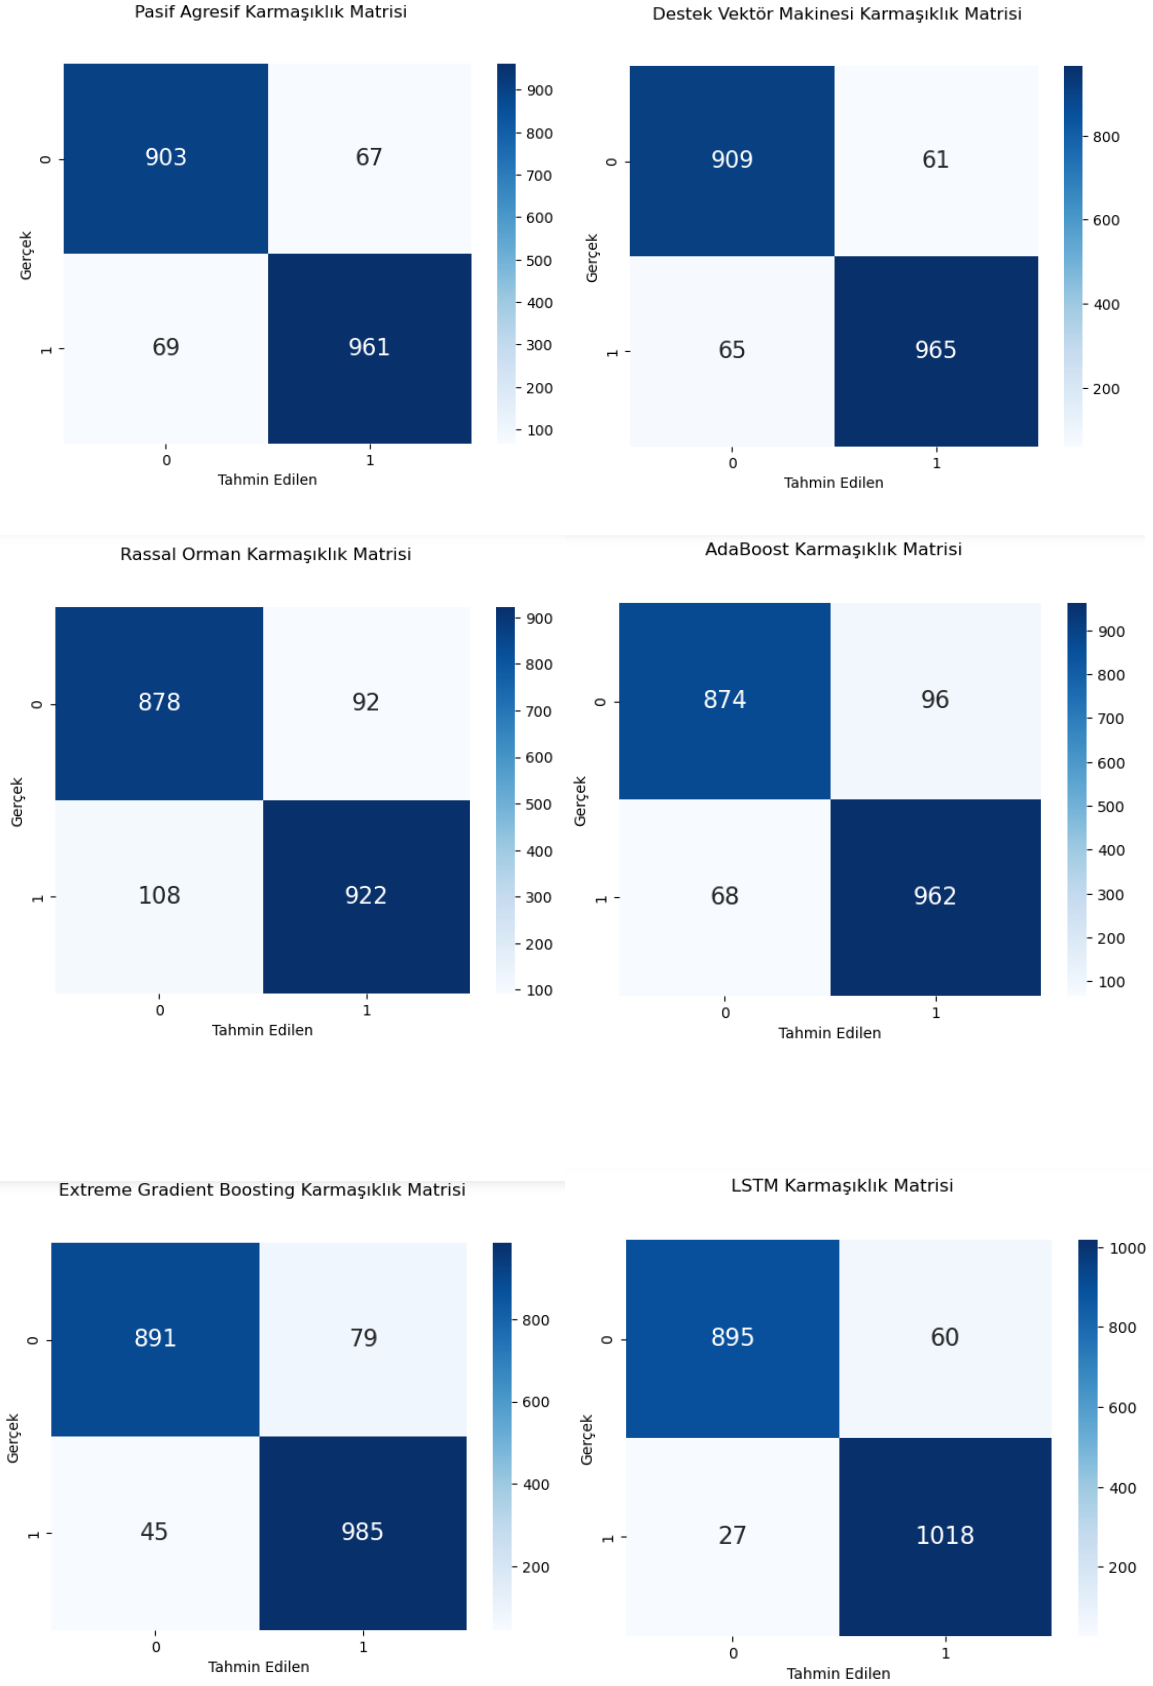
Tablo 5

Toplumsal olaylar veri setinde kullanılan algoritmaların ortalama kare hatalarının karşılaştırılması.

	Ortalama Kare Hatası (MSE)
Pasif Agresif Sınıflandırma	6.8%
Destek Vektör Makinesi	6.3%
Rassal Orman	10.0%
AdaBoost	8.2%
XGBoost	6.2%
LSTM	4.35%

Tablo 5’te, toplumsal olaylar veri setine uygulanan modellerin ortalama kare hataları gösterilmektedir. Hata oranlarına bakıldığında; en düşük hata oranını %4.35’lik bir oranla LSTM algoritması, en yüksek hata oranını %10’luk bir oranla Rassal Orman algoritması vermiştir. LSTM algoritması yine yüksek performans göstermiştir.

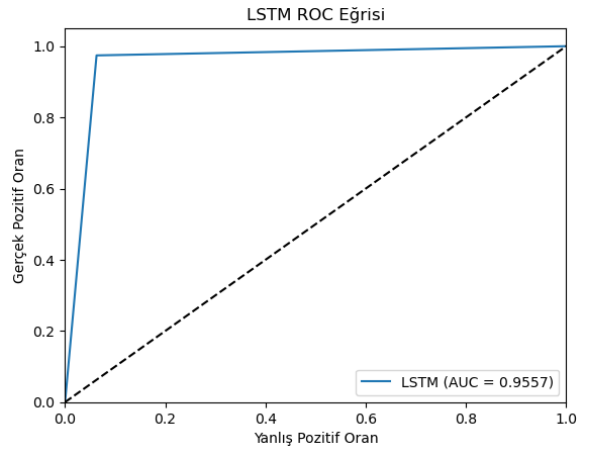
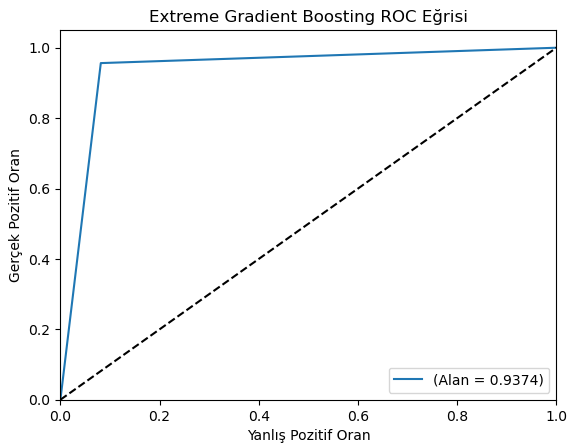
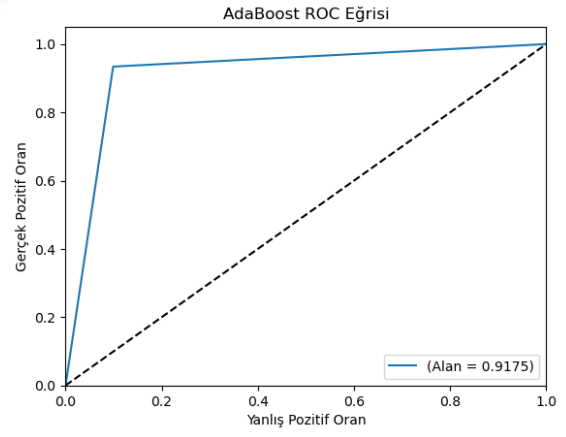

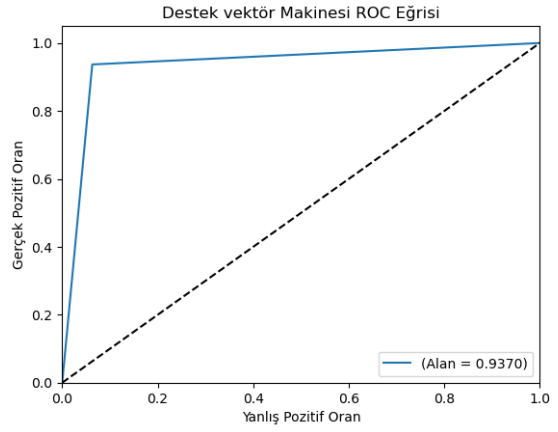





Şekil 17. Toplumsal olaylar veri setinde kullanılan modellerin karmaşıklık matrisleri.

Şekil 17’de, her bir modelin karmaşıklık matrisleri gösterilmektedir. Değerlere bakıldığında en yüksek performansı Destek Vektör Makinesi, XGBoost ve LSTM algoritmaları vermiştir. Destek Vektör makinesi 970 adet yalan haberin sadece 61 tanesini gerçek olarak sınıflandırmıştır. 1030 adet gerçek haberin 65 tanesini yalan olarak sınıflandırmıştır. XGBoost algoritması 970 adet yalan haberin 79 tanesini gerçek olarak, 1030 adet gerçek haberin sadece 45 tanesini yalan olarak sınıflandırmıştır. LSTM algoritması 955 adet yalan haberin 60 tanesini gerçek olarak sınıflandırmıştır. 1045 adet gerçek haberin sadece 27 tanesini yalan olarak sınıflandırmıştır.





Şekil 18. Toplumsal olaylar veri setinde kullanılan modellerin ROC eğrileri.

Şekil 18’de, modellerin ROC eğrilerine bakıldığında doğruluk oranı ve karmaşıklık matrislerinde olduğu gibi gerçek ve yanlış arasındaki en iyi ayrımı LSTM, XGBoost ve Destek Vektör Makinesi algoritmaları yapmıştır. LSTM algoritması %95.57, XGBoost %93.74 ve Destek Vektör Makinesi %93.70’lik AUC oranlarına sahiptir.

Kültür-Sanat Haberlerinden Oluşan Veri Seti

Kültür-sanat haberlerinden oluşan veri seti kullanılmıştır. Veri setine çeşitli doğal dil işleme ve makine öğrenmesi algoritmaları uygulanarak, elde edilen sonuçlar tablolarda gösterilerek karşılaştırılmıştır.

Tablo 6

Kültür-Sanat veri setinde kullanılan algoritmalar için doğruluk ve çapraz doğrulama oranlarının karşılaştırılması.

	Doğruluk Oranları	Çapraz Doğrulama Oranları
Pasif Agresif Sınıflandırma	77.90%	78.34%
Destek Vektör Makinesi	82.75%	82.84%
Rassal Orman	81.30%	81.99%
AdaBoost	80.05%	80.32%
XGBoost	81.75%	81.16%
LSTM	89.30%	89.45%

Tablo 6’da, kültür-sanat veri setine uygulanan algoritmaların verdiği doğruluk ve çapraz doğrulama oranları gösterilmektedir. Pasif Agresif sınıflandırma %77.90’luk doğruluk oranında, Destek Vektör Makinesi %82.75’lik doğruluk oranında, Rassal Orman %81.30’luk bir doğruluk oranında, AdaBoost algoritması %80.05’lik, XGBoost algoritması %81.75’lik ve LSTM algoritması %89.30’luk doğruluk oranında yalan haber tespitinde bulunmuştur. Doğruluk oranlarına bakıldığında en yüksek oranı yine LSTM algoritmasının verdiği görülmüştür. LSTM algoritmasından sonra en yüksek doğruluk oranlarını Destek Vektör Makinesi ve XGBoost algoritmaları vermiştir.

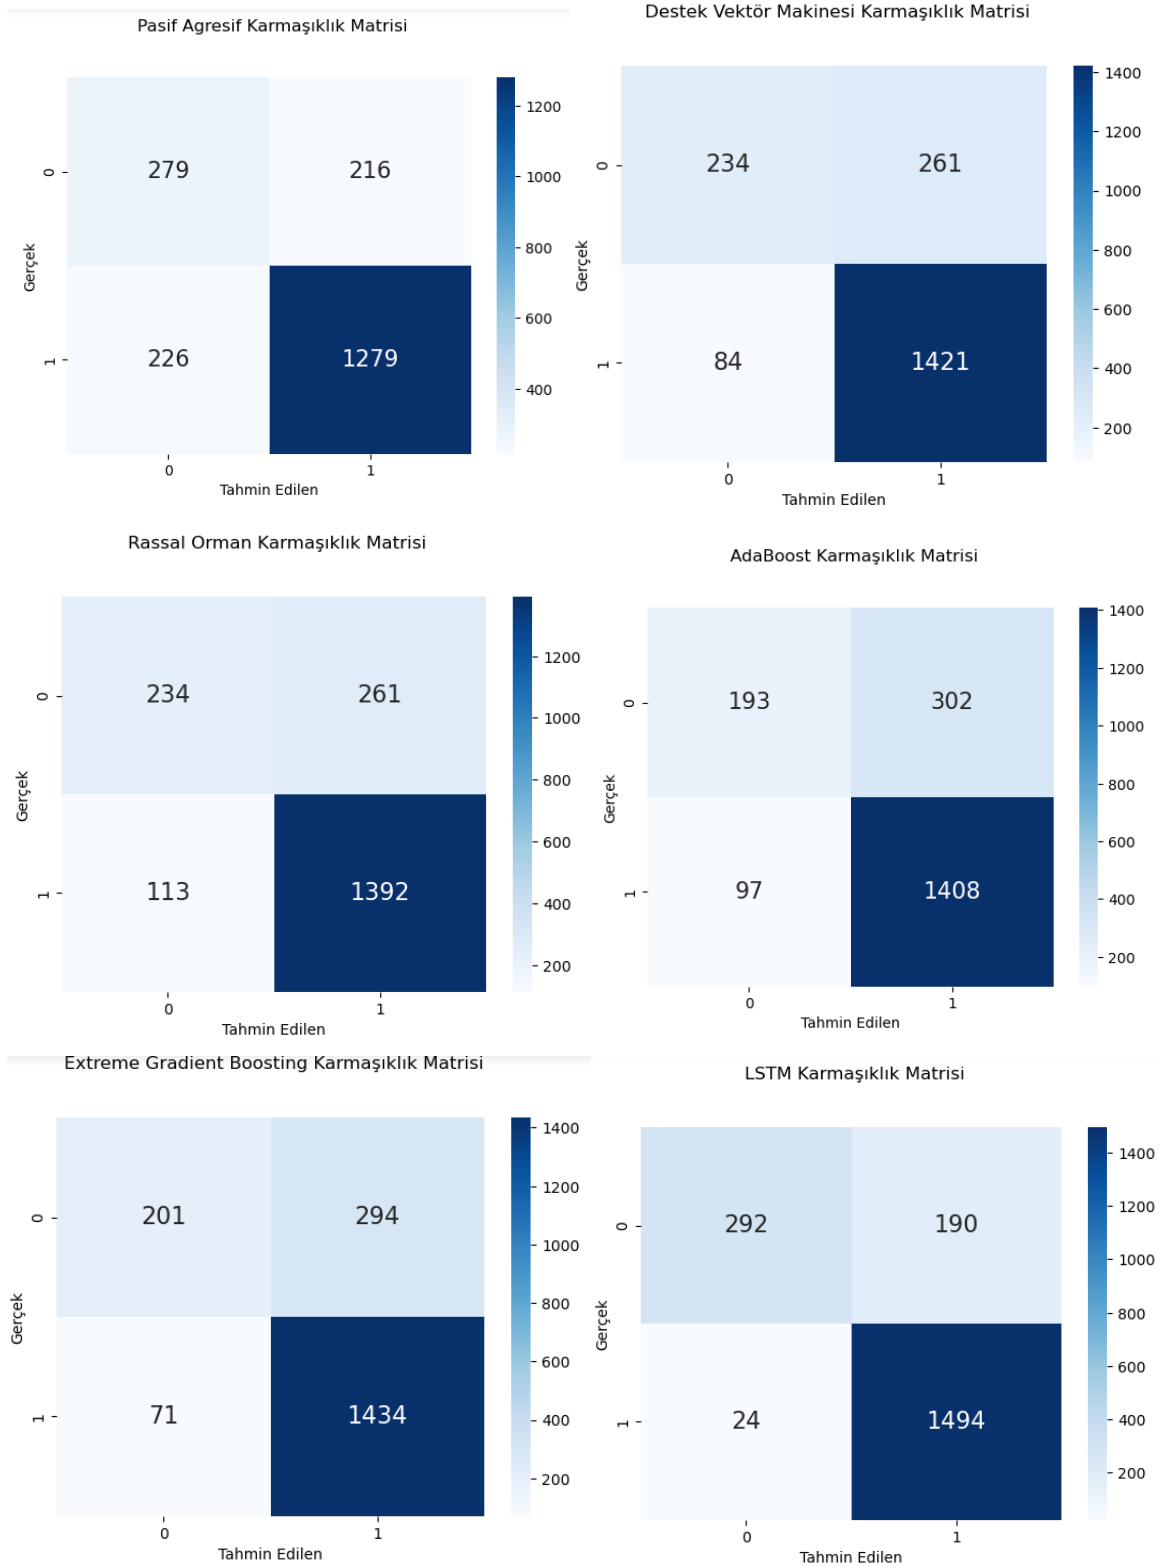
Politika ve toplumsal olaylardan oluşan veri setleriyle karşılaştırıldığında kültür-sanat haberlerinden oluşan veri setine uygulanan modeller çok daha düşük oranlarda tahmin yapmıştır. Aşırı öğrenme olup olmadığı tespit etmek için çapraz doğrulama tekniği uygulanmıştır. Çapraz doğrulama tekniği uygulandıktan sonra test ve doğrulama verilerinde yapılan tahmin oranlarının birbirine yakın olduğu görülmüştür. Sonuçlara bakılarak aşırı öğrenme olmadığı doğrulanmıştır.

Tablo 7

Kültür-sanat veri setinde kullanılan algoritmaların ortalama kare hatalarının karşılaştırılması.

	Ortalama Kare Hatası (MSE)
Pasif Agresif Sınıflandırma	22.10%
Destek Vektör Makinesi	17.25%
Rassal Orman	18.70%
AdaBoost	19.95%
XGBoost	18.25%
LSTM	10.7%

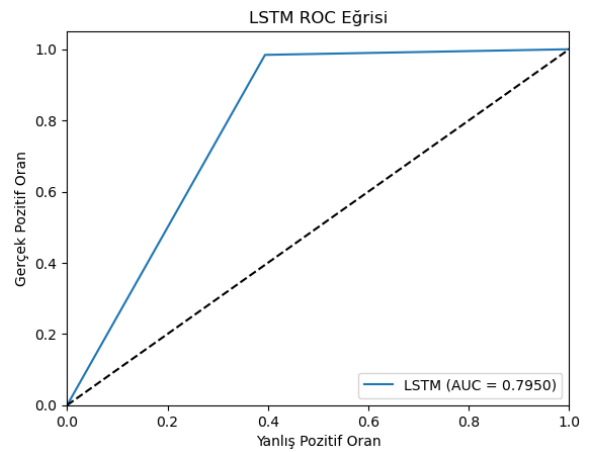
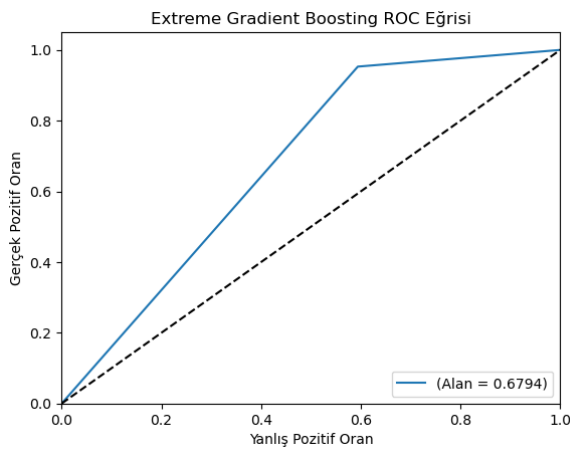

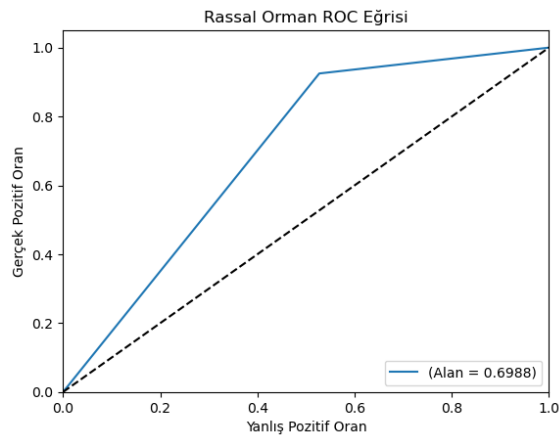
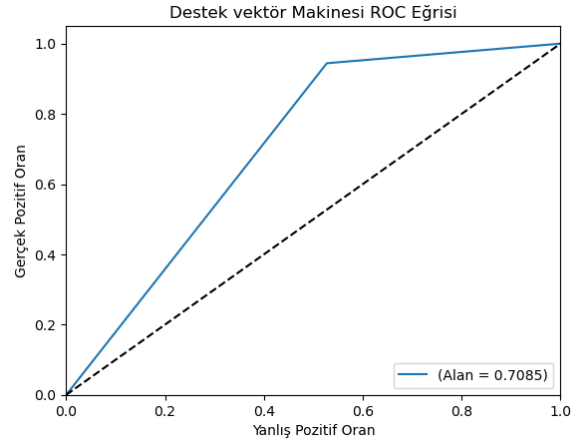
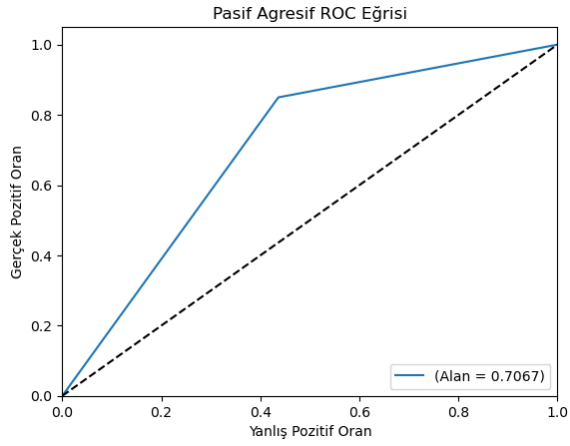
Tablo 7’de, kültür-sanat haberlerinden oluşan veri setine uygulanan modellerin ortalama kare hataları gösterilmektedir. Hata oranlarına bakıldığında; en düşük hata oranını % 10.7’lik bir oranla LSTM algoritması, en yüksek hata oranını %22.10’luk bir oranla Pasif Agresif sınıflandırma algoritması vermiştir.



Şekil 19. Kültür-sanat veri setine uygulanan modellerin karmaşıklık matrisleri.

Şekil 19’da, her bir modelin karmaşıklık matrisleri gösterilmektedir. Değerlere bakıldığında en yüksek performansı Destek Vektör Makinesi, XGBoost ve LSTM algoritmaları vermiştir. En düşük performansı Pasif Agresif sınıflandırma göstermiştir. Destek Vektör makinesi, 495 adet yalan haberin sadece 261 tanesini gerçek olarak sınıflandırmıştır. 1505 adet gerçek haberin 84 tanesini yalan olarak sınıflandırmıştır. XGBoost algoritması, 495 adet yalan haberin 294 tanesini gerçek olarak sınıflandırmıştır. 1505 adet gerçek haberin sadece 71 tanesini yalan olarak sınıflandırmıştır. LSTM algoritması, 482 adet yalan haberin 190 tanesini gerçek olarak sınıflandırmıştır. 1518 adet gerçek haberin sadece 24 tanesini yalan olarak sınıflandırmıştır.

Karmaşıklık matrislerine bakıldığında, LSTM algoritması hariç diğer algoritmalarda yalan haberlerin yarısından fazlası gerçek olarak tespit edilmiştir. AdaBoost algoritmasında yalan haberlerin neredeyse %75’lik kısmı gerçek olarak tahmin edilmiştir. Sonuçlara bakıldığında LSTM algoritması diğer algoritmalar göre daha yüksek doğruluk oranında tahminde bulunmuştur. Yine de diğer veri setlerine kıyasla yüksek bir oranda yalan haber tespiti yapamayarak zayıf performans göstermiştir. Kültür-sanat veri setine uygulanan modeller; gerçek haberleri yüksek oranda tespit ederken, yalan haberleri çok daha düşük oranda tespit edilmiştir. Doğruluk oranlarının karşılaştırıldığı Tablo 6’da, modellerin yalan haber tespitini ortalama olarak %80’lik bir oranda yaptığı görülmüştür. Sadece bu oranlara bakılarak modellerin yalan haber tespitinde yüksek bir performans gösterdiği söylenebilir. Ancak karmaşıklık matrisinde, gerçek haberler daha yüksek bir oranda tahmin edildiği için modellerin yüksek doğruluk oranını verdiği görülmüştür. Böyle bir sonucun alınmasının en önemli nedeni, kültür-sanat veri setindeki gerçek haberlerin yalan haberlerden daha fazla sayıda olmasıdır.



Şekil 20. Kültür-sanat veri setine uygulanan modellerin ROC eğrileri.

Şekil 20’de modellerin ROC eğrilerine bakıldığında en yüksek AUC oranlarını LSTM, Destek Vektör Makinesi ve Pasif agresif sınıflandırma algoritmaları vermiştir. Diğer modellerden farklı olarak, Pasif Agresif algoritmasının doğruluk oranı düşük olduğu halde yüksek AUC oranına sahiptir. Rassal Orman, AdaBoost ve XGBoost algoritmaları ortalama %80’lik doğruluk oranlarına sahipken, AUC oranları düşüktür. Diğer veri setlerine bakıldığında kültür-sanat veri setine uygulanan modellerin AUC oranlarının çok daha düşük olduğu görülmektedir. ROC grafikleri, yalan ve gerçek haber tespitinin çok iyi yapılamadığını göstermektedir.

Politika, Toplumsal Olaylar ve Kültür-sanat haberlerinden Oluşan Veri Seti

Son veri seti, diğer üç veri setinden alınan verilerle oluşturulmuştur. Veri setine çeşitli doğal dil işleme ve makine öğrenmesi algoritmaları uygulanarak, elde edilen sonuçlar tablolarda gösterilerek karşılaştırılmıştır.

Tablo 8

Veri setinde kullanılan algoritmalar için doğruluk ve çapraz doğrulama oranlarının karşılaştırılması.

	Doğruluk Oranları	Çapraz Doğrulama Oranları
Pasif Agresif Sınıflandırma	83.33%	84.24%
Destek Vektör Makinesi	87.50%	88.03%
Rassal Orman	85.20%	86.11%
AdaBoost	86.12%	86.67%
XGBoost	88.33%	88.48%
LSTM	90.72%	90.84%

Tablo 8’de, politika veri setine uygulanan algoritmaların verdiği doğruluk değerleri gösterilmektedir. Passive Agresif sınıflandırma %83.33’lük doğruluk oranında, Destek Vektör Makinesi %87.5’lik doğruluk oranında, Rassal Orman %85.2’lik bir doğruluk oranında, AdaBoost algoritması %86.12, XGBoost algoritması %88.33 ve LSTM

algoritması %90.72'lik doğruluk oranlarında yalan haber tespitinde bulunmuştur. Doğruluk oranlarına bakıldığında en yüksek oranı derin öğrenme algoritmalarından biri olan LSTM algoritmasının verdiği görülmüştür. LSTM algoritmasından sonra en yüksek doğruluk oranlarını XGBoost ve Destek Vektör makinesi algoritmaları vermiştir. En düşük oranı Pasif Agresif algoritması vermiştir. Algoritmaların verdiği oranlar yüksek olduğundan dolayı aşırı uyma olup olmadığını kontrol etmek için çapraz doğrulama tekniği uygulanmıştır. Çapraz doğrulama tekniği uygulandıktan sonra test ve doğrulama verilerinde yapılan tahmin oranlarının birbirine yakın olduğu görülmüştür. Sonuçlara bakılarak aşırı öğrenme olmadığı doğrulanmıştır.

Tablo 9

Veri setinde kullanılan algoritmaların ortalama kare hatalarının karşılaştırılması.

	Ortalama Kare Hatası (MSE)
Pasif Agresif Sınıflandırma	16.67%
Destek Vektör Makinesi	12.50%
Rassal Orman	14.80%
AdaBoost	13.88%
XGBoost	11.67%
LSTM	9.28%

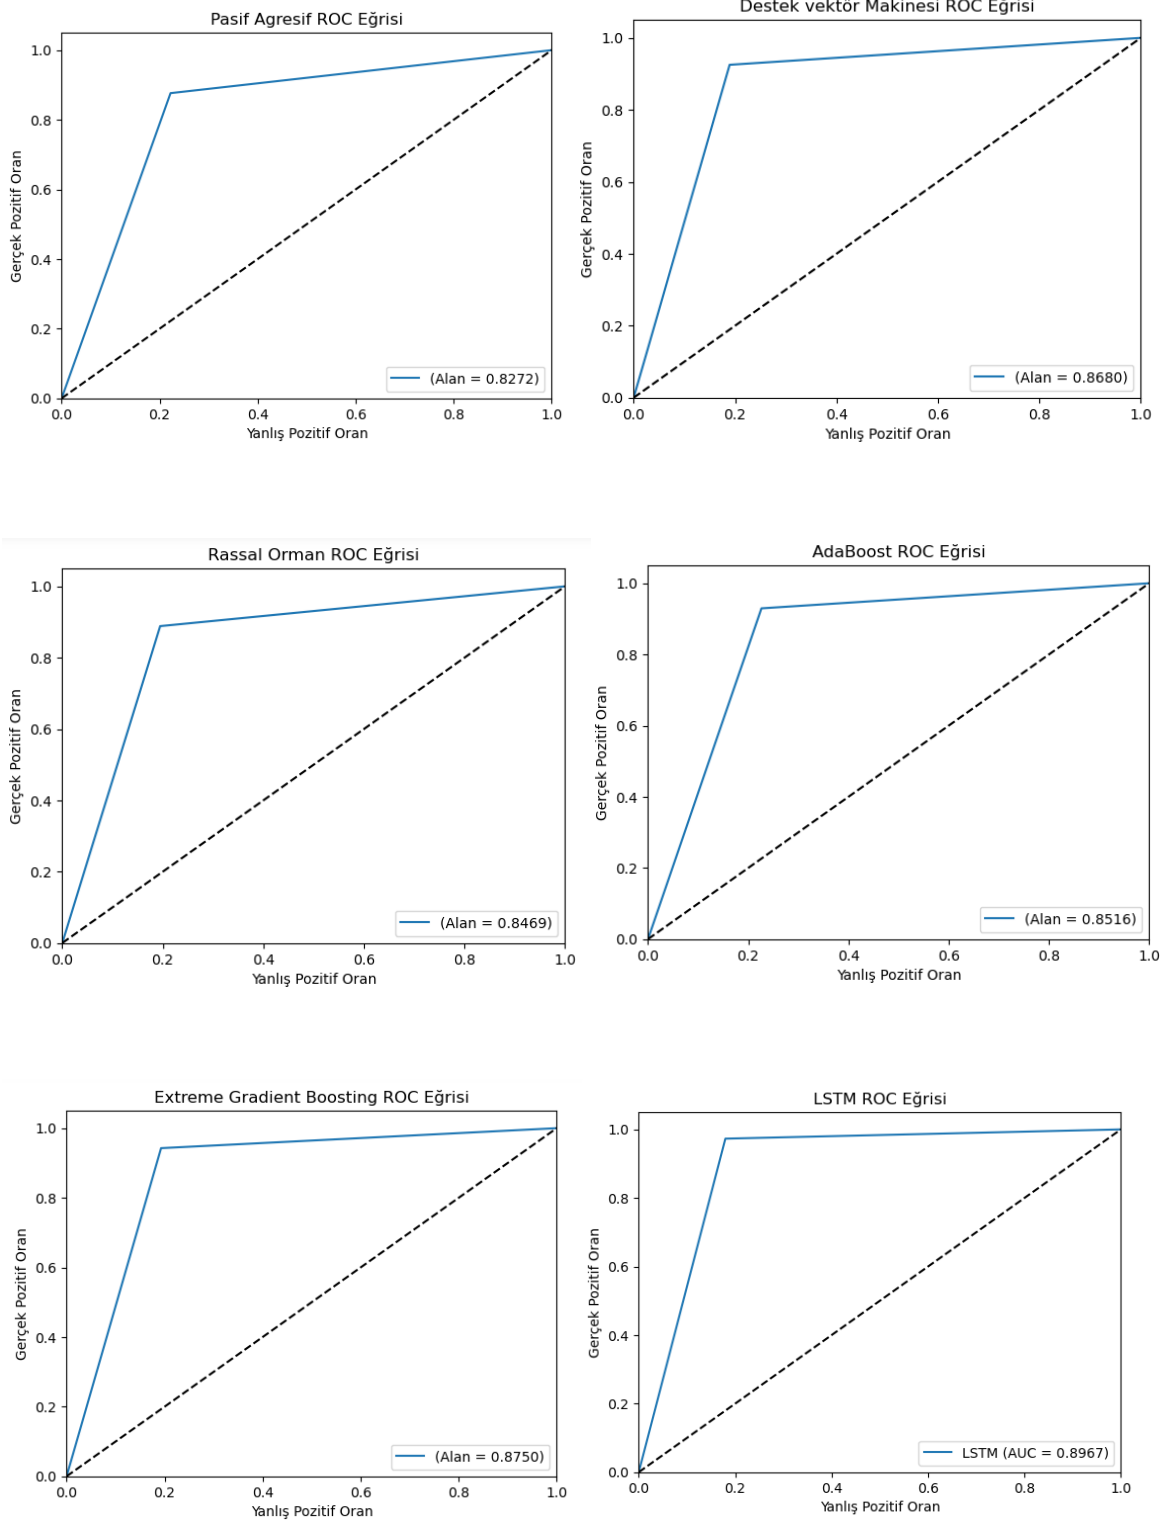
Tablo 9'da; en düşük hata oranını %9.28'lik bir oranla LSTM algoritması, en yüksek hata oranını %16.67'lik bir oranla Pasif Agresif algoritması vermiştir.



Şekil 21. Politika, Toplumsal Olaylar ve Kültür-sanat haberlerinden oluşan veri setine uygulanan modellerin karmaşıklık matrisleri.

Şekil 21’de, her bir modelin karmaşıklık matrisleri gösterilmektedir. Değerlere bakıldığında en yüksek performansı Destek Vektör Makinesi, XGBoost ve LSTM algoritmaları vermiştir. Destek Vektör makinesi, 1427 adet yalan haberin 270 tanesini gerçek olarak sınıflandırmıştır. 1830 adet gerçek haberin 137 tanesini yalan olarak sınıflandırmıştır. XGBoost algoritması, 1427 adet yalan haberden sadece 275 tanesini gerçek olarak sınıflandırmıştır. 1830 adet gerçek haberin sadece 105 tanesini yalan olarak sınıflandırmıştır. LSTM algoritması, 1403 adet yalan haberin 252 tanesini gerçek olarak sınıflandırmıştır. 1852 adet gerçek haberin sadece 50 tanesini yalan olarak sınıflandırmıştır.





Şekil 22. Politika, Toplumsal Olaylar ve Kültür-sanat haberlerinden oluşan veri setine uygulanan modellerin ROC eğrileri.

Şekilde 22’te, modellerin ROC eğrilerine bakıldığında en yüksek AUC oranlarını LSTM, Destek Vektör Makinesi ve XGBoost algoritmaları vermiştir. En düşük AUC oranını, %82.72’lik bir oranla Pasif Agresif algoritması vermiştir.

Yapılan çalışmada kullanılan algoritmaları, diğer çalışmalarda kullanılmış olan veri setleri üzerinde uygulamak için çevrimiçi ortamda araştırma yapılmıştır. Ancak diğer çalışmalarda kullanılmış olan veri setleri internette erişime açık olmadığı için karşılaştırma yapılamamıştır.



BEŞİNCİ BÖLÜM

SONUÇ VE ÖNERİLER

Günümüzde yalan haber negatif etkilerinden dolayı çok büyük bir sorun haline gelmiştir. Teknolojinin gelişip yaygınlaşmasıyla birlikte paylaşılan bir gönderi, çevrimiçi ortamlarda içeriği doğrulanmadan çok hızlı yayılmaktadır. Hızlı yayılan yalan haberler çok geniş kitlelere tespit edilemeden ulaşmaktadır. Yalan haberler ulaştıkları kişilerde ya da toplumlarda panik, korku, endişe, kaos, kargaşa gibi olumsuz etkilere neden olmaktadır. Bu durum, yalan haberlerin yayılmasının önüne geçilebilmesi için çözümler aranmasına ve çok sayıda çalışma yapılmasına neden olmuştur. Yine de bilgi akışının ve yayılımının kontrol edilebilmesi imkânsız olacaktır.

Bu çalışmada, yalan haberin tespit edilerek yayılmasını önleyen, otomatik bir Chrome uzantısı geliştirilmiştir. Çalışmada; politika, toplumsal olaylar, kültür-sanat ve bu üç veri setinden alınan verilerle oluşturulan veri seti kullanılmıştır. Veri madenciliği, doğal dil işleme, makine öğrenmesi algoritmaları, çevrimiçi öğrenme algoritması, yükseltme algoritmaları, derin öğrenme algoritması kullanılmıştır. Modellerin doğruluk oranları, çapraz doğrulama tekniği uygulandıktan sonra elde edilen doğruluk oranları, karmaşıklık matrisleri ve ROC eğrileri birbirleriyle karşılaştırılmıştır. Ayrıca diğer çalışmalarda kullanılan farklı modeller de veri setine uygulanmış ve diğer çalışmalarda elde edilen doğruluk oranlarıyla karşılaştırılmıştır. Kullanılan veri setlerine, doğal dil işleme teknikleri uygulanarak özellik seçimiyle elde edilen veriler vektör matrislerine çevrilmiştir. Yalan haber tespiti için; çevrimiçi öğrenme algoritması olan Pasif Agrasif, denetimli öğrenme algoritmalarından Rassal Orman ve Destek Vektör Makinesi, güçlendirme algoritmalarından AdaBoost ve XGBoost algoritması, derin öğrenme algoritmasından LSTM algoritması dört veri setine uygulanmıştır. Genel olarak dört veri setinde en yüksek doğruluk oranını LSTM algoritmasının verdiği görülmüştür. LSTM algoritmasından sonra performansı en yüksek olan algoritmalar; XGBoost, AdaBoost ve Destek Vektör Makinesi algoritmalarıdır. Çalışmada, oluşturulan Chrome uzantısının farklı türdeki yalan haberleri yüksek bir oranda tahmin edebilmesi için, üç farklı veri setinden alınan haberlerden oluşan veri seti için model oluşturulmuştur. Son veri setinde, Pasif agresif sınıflandırma %83.33, SVM algoritması %87.5, Rassal Orman algoritması %85.2, AdaBoost algoritması %86.12, XGBoost algoritması %88.33 ve LSTM algoritması %90.72'lik doğruluk oranında yalan haber tahmini yapmıştır.

Makine öğrenmesi modeli olarak LSTM algoritması seçildikten sonra, model Python projesinde kullanılmak üzere diske kaydedilmiştir. Chrome uzantısı; Spyder programında HTML, CSS, Javascript, XMLHttpRequest, Python programlama dili kullanılarak oluşturulmuştur. Kullanıcılar Chrome uzantısında bulunan metin kutusuna, kontrol etmek istedikleri haberi girerek yalan ya da gerçek olduğunu uzantı popup'ında görebilmişlerdir. Kullanıcıya istediği haberi kontrol edebilme özgürlüğü sunulması, bu çalışmayı diğer çalışmalardan ayırt etmektedir.

Çalışmada, makine öğrenmesi algoritmaları ve doğal dil işleme teknikleri bir arada kullanılarak yalan haberler yüksek oranda tespit edilmiştir. Bu çalışmayla yalan haberler ve yalan haberlerin olumsuz etkilerinin önüne geçilmesi amaçlanmıştır. Bunun için kullanıcıların yararlanabileceği tarayıcı uzantısı geliştirilmiştir. Geliştirilen Chrome uzantısıyla; yalan haberler kısa sürede tespit edilecek, yayılması önlenecek ve sebep olduğu olumsuz etkilerin önüne geçilmiş olacaktır.

Yalan haber tespiti yapan Chrome uzantısı, ileride geliştirilerek daha iyi performans göstermesi sağlanabilir. Kullanıcı arayüzünde, kontrol edilen haberin yalan ya da gerçek olduğuna dair sonuç verilmektedir. Yapılan tespitle birlikte, neden yalan ya da gerçek olduğuna dair bir bilgi notu eklenebilir. Böylece yapılan tespit bilgi notuyla desteklenerek, kullanıcının döndürülen sonuca daha fazla güven duyması sağlanmış olur. Tespit edilen haberin yüzde kaçlık bir oranla gerçek ya da yalan olduğu kullanıcı arayüzünde verilebilir. Chrome uzantısı sadece İngilizce dilini desteklemektedir. Farklı diller eklenerek, uzantının daha geniş bir kitle tarafından kullanması sağlanabilir. Bu gibi farklı özellikler ileride geliştirilmek üzere tarayıcı uzantısına eklenebilir.

KAYNAKÇA

- Akca, M., F. (2020, 4 Ocak). Deep Learning Türkiye. Erişim adresi: <https://medium.com/deep-learning-turkiye/nedir-bu-destek-vekt%C3%B6r-makineleri-makine-%C3%B6%C4%9Frenmesi-serisi-2-94e576e4223e>
- Al Asaad, B. ve Erascu, M. (2018). “A Tool for Fake News Detection”. *2018 20th International Symposium on Symbolic and Numeric Algorithms for Scientific Computing (SYNASC)*. doi:10.1109/synasc.2018.00064
- Aldwairi, M. ve Alwahedi, A. (2018). “Detecting Fake News in Social Media Networks”. *Procedia Computer Science, 141, 215–222*. doi:10.1016/j.procs.2018.10.171
- Azar, A. T., Elshazly, H. I., Hassanien, A. E. ve Elkorany, A. M. (2014). “A random forest classifier for lymph diseases”. *Computer Methods and Programs in Biomedicine, 113(2), 465–473*.
- Bahad, P., Saxena, P. ve Kamal, R. (2019). “Fake News Detection using Bi-directional LSTM-Recurrent Neural Network”. *Procedia Computer Science, 165, 74–82*. doi:10.1016/j.procs.2020.01.072
- Becker, D. A. (2021). “Using Mobile Apps to Combat Fake News”. *Journal of Electronic Resources in Medical Libraries, 18(1), 55–60*. doi:10.1080/15424065.2021.1887787
- Botnevik, B., Sakariassen, E. ve Setty, V. (2020). “BRENDA: Browser Extension for Fake News Detection”. *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*. doi:10.1145/3397271.3401396
- Bovet, A. ve Makse, H. A. (2019). “Influence of fake news in Twitter during the 2016 US presidential election”. *Nature Communications, 10(1)*. doi:10.1038/s41467-018-07761-2
- Bulut, F. (2016). “AdaBoost ile Kalp Krizi Risk Tespiti”. *CBÜ Fen Bil. Dergi., Cilt 12, Sayı 3, 459-472*.
- Castelo, S., Almeida, T., Elghafari, A., Santos, A., Pham, K., Nakamura, E. ve Freire, J. (2019). “A Topic-Agnostic Approach for Identifying Fake News Pages”. *Companion*

- Cengil, E. ve Çınar, A. (2020). “Göğüs Verileri Metrikleri Üzerinden Kanser Sınıflandırılması”. *DÜMF Mühendislik Dergisi 11-2 (2020) : 513-519.*
- Collins, B., Hoang, D. T., Nguyen, N. T. ve Hwang, D. (2020). “Trends in combating fake news on social media – a survey”. *Journal of Information and Telecommunication, 1–20.*
- Conroy, N. J., Rubin, V. L. ve Chen, Y. (2015). “Automatic deception detection: Methods for finding fake news”. *Proceedings of the Association for Information Science and Technology, 52(1), 1–4.* doi:10.1002/pr2.2015.145052010082
- Crisci, C., Ghattas, B. ve Perera, G. (2012). “A review of supervised machine learning algorithms and their applications to ecological data”. *Ecological Modelling, 240, 113–122.* doi:10.1016/j.ecolmodel.2012.03.001
- Cui, L., Shu, K., Wang, S., Lee, D. ve Liu, H. (2019). “dEFEND”. *Proceedings of the 28th ACM International Conference on Information and Knowledge Management - CIKM '19.* doi:10.1145/3357384.3357862
- Della Vedova, M. L., Tacchini, E., Moret, S., Ballarin, G., DiPierro, M. ve de Alfaro, L. (2018). “Automatic Online Fake News Detection Combining Content and Social Signals”. *2018 22nd Conference of Open Innovations Association (FRUCT).* doi:10.23919/fruct.2018.8468301
- Elen, A., Baş, S. ve Közkurt, C. (2022). “An Adaptive Gaussian Kernel for Support Vector Machine”. *Arabian Journal for Science and Engineering (2022) 47:10579–10588.*
- El Naqa, I. ve Murphy, M. J. (2015). “What Is Machine Learning?”. *Machine Learning in Radiation Oncology, 3–11.* doi:10.1007/978-3-319-18305-3_1
- Güven, C, T. (2020). “Yapay Zekâ Yöntemleri Kullanılarak Akıllı Ev Sistemi Geliştirilmesi”.
- Gavcar, E. ve Metin, H., M. (2021). “Hisse Senedi Değerlerinin Makine Öğrenimi (Derin Öğrenme) ile Tahmini”. *Ekonomi ve Yönetim Araştırmaları Dergisi, 10(2).*

- Hand, D. J. (2007). "Principles of Data Mining". *Drug Safety*, 30(7), 621–622. doi:10.2165/00002018-200730070-00010
- Hao, X., Zhang, G. ve Ma, S. (2016). "Deep Learning". *International Journal of Semantic Computing*, 10(03), 417–439. doi:10.1142/s1793351x16500045
- Jain, A. ve Kasbe, A. (2018). "Fake News Detection". *2018 IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS)*. doi:10.1109/sceecs.2018.8546944
- Jakkula, V. (2006). "Tutorial on Support Vector Machine (SVM)". *School of EECS, Washington State University, Pullman 99164*. 13 s. course.ccs.neu.edu
- Jiang, T., Li, J. P., Haq, A. U., Saboor, A. ve Ali, A. (2021). "A Novel Stacking Approach for Accurate Detection of Fake News". *IEEE Access*, 9, 22626–22639. doi:10.1109/access.2021.3056079
- Jorge, J. ve Paredes, R. (2018). "Passive-Aggressive online learning with nonlinear embeddings". *Pattern Recognition*, 79, 162–171.
- Kara, A. (2019). "Global Solar Irradiance Time Series Prediction Using Long Short-Term Memory Network". *Gazi Üniversitesi, Fen Bilimleri Dergisi, Part C: Tasarım ve Teknoloji*, 7(4): 882-892.
- Kelle, A., C. ve Yüce, H. (2022). "MQTT Trafikinde DoS Saldırılarının Makine Öğrenmesi ile Sınıflandırılması ve Modelin SHAP ile Yorumlanması". *Journal of Materials and Mechatronics: A*, 2022, 3(1), 50-62.
- Kesarwani, A., Chauhan, S. S. ve Nair, A. R. (2020). "Fake News Detection on Social Media using K-Nearest Neighbor Classifier". *2020 International Conference on Advances in Computing and Communication Engineering (ICACCE)*. doi:10.1109/icacce49060.2020.9154
- Kiranmayee, B. V., Suresh, C. ve SreeRakshak, S. (2021). "Classification of the Suicide-Related Text Data Using Passive Aggressive Classifier". *Sentimental Analysis and Deep Learning pp 439–449*. doi:10.1016/j.ecolmodel.2012.03.001

- Klyuev, V. (2018). "Fake News Filtering: Semantic Approaches". *2018 7th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO)*. doi:10.1109/icrito.2018.8748506
- Liu, C., Sheng, Y., Wei, Z. ve Yang, Y.-Q. (2018). "Research of Text Classification Based on Improved TF-IDF Algorithm". *2018 IEEE International Conference of Intelligent Robotic and Control Engineering (IRCE)*. doi:10.1109/irce.2018.8492945
- Liu, Y., Sun, C. ve Jiang, S. (2019). "A Reduced Gaussian Kernel Least-Mean-Square Algorithm for Nonlinear Adaptive Signal Processing". *Circuits Syst Signal Process* 38, 371–394 (2019). doi :10.1007/s00034-018-0862-0
- Lu, J., Zhao, P. ve Hoi, S. C. H. (2016). "Online Passive-Aggressive Active learning". *Machine Learning*, 103(2), 141–183.
- Paka, W. S., Bansal, R., Kaushik, A., Sengupta, S. ve Chakraborty, T. (2021). "Cross-SEAN: A cross-stitch semi-supervised neural attention model for COVID-19 fake news detection". *Applied Soft Computing*, 107, 107393. doi:10.1016/j.asoc.2021.107393
- Panov, P. ve Džeroski, S. (2007). "Combining Bagging and Random Subspaces to Create Better Ensembles". *Advances in Intelligent Data Analysis VII*, 118–129.
- Paschalides, D., Christodoulou, C., Orphanou, K., Andreou, R., Kornilakis, A., Pallis, G. ve Markatos, E. (2021). "Check-It: A plugin for detecting fake news on the web". *Online Social Networks and Media*, 25, 100156. doi:10.1016/j.osnem.2021.100156
- Patankar, A., Bose, J. ve Khanna, H. (2019). "A Bias Aware News Recommendation System". *2019 IEEE 13th International Conference on Semantic Computing (ICSC)*. doi:10.1109/icosc.2019.8665610
- Paul, S., Joy, J. I., Sarker, S., Shakib, A.-A.-H., Ahmed, S. ve Das, A. K. (2019). "Fake News Detection in Social Media using Blockchain". *2019 7th International Conference on Smart Computing & Communications (ICSCC)*. doi:10.1109/icsc.2019.8843597
- Pérez-Rosas, V., Kleinberg, B., Lefevre, Mihalcea, A. ve Mihalcea, R. (2017). "Automatic Detection of Fake News". *Conference: 27th International Conference on Computational Linguistics Volume: 27*.

- Pisner, D. A. ve Schnyer, D. M. (2020). "Support vector machine". *Machine Learning*, 101–121. doi:10.1016/b978-0-12-815739-8.00006-7
- Panchar, R. (2021, 4 Ağustos). "What is REST API vs. Web API (vs SOAP API)?". Erişim adresi: <https://www.rlogical.com/blog/what-is-rest-api-vs-web-api-vs-soap-api>
- Reis, J. C. S., Correia, A., Murai, F., Veloso, A., Benevenuto, F. ve Cambria, E. (2019). "Supervised Learning for Fake News Detection". *IEEE Intelligent Systems*, 34(2), 76–81. doi:10.1109/mis.2019.2899143
- Ruchansky, N., Seo, S. ve Liu, Y. (2017). "CSI". *Proceedings of the 2017 ACM on Conference on Information and Knowledge Management-CIKM '17*. doi:10.1145/3132847.3132877
- Rusk, N. (2016). "Deep learning". *Nature Methods*, 13(1), 35–35. doi:10.1038/nmeth.3707
- Schapire, R. E. (2013). "Explaining AdaBoost". *Empirical Inference*, 37–52. doi:10.1007/978-3-642-41136-6_5
- Shu, K., Mahudeswaran, D. ve Liu, H. (2018). "FakeNewsTracker: A tool for fake news collection, detection, and visualization". *Computational and Mathematical Organization Theory*. doi:10.1007/s10588-018-09280-3
- Singhal, S., Shah, R. R., Chakraborty, T., Kumaraguru, P. ve Satoh, S. (2019). "SpotFake: A Multi-modal Framework for Fake News Detection". *2019 IEEE Fifth International Conference on Multimedia Big Data (BigMM)*. doi:10.1109/bigmm.2019.00-44
- Singh Tomar, G., Chaudhari, N. S., Barbosa, J. L. V. ve Aghwariya, M. K. (Eds.). (2020). "Algorithms for Intelligent Systems". *International Conference on Intelligent Computing and Smart Communication 2019*. doi:10.1007/978-981-15-0633-8
- Shi, T., Zhu, J. (2014). "Online Bayesian Passive-Aggressive Learning". *Proceedings of the 31st International Conference on Machine Learning, PMLR 32(1):378-386*.
- Tai, L. ve Liu, M., (2015). "Deep-learning in Mobile Robotics - from Perception to Control Systems: A Survey on Why and Why not". *Journal Of Latex Class Files, Vol. 14, No. 8*.

- Vo, N. ve Lee, K. (2018). “The Rise of Guardians”. *The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval-SIGIR '18*. doi:10.1145/3209978.3210037
- Vyas, P., Chauhan, A. ve Liu, J. (2021). “An LSTM Based Approach for the Classification of Customer Reviews: An Exploratory Study”. *Conference: AMCIS 2021 Proceedings*.
- Yang, F., Pentyala, S. K., Mohseni, S., Du, M., Yuan, H., Linder, R. ve Hu, X. (Ben). (2019). “XFake: Explainable Fake News Detector with Visualizations”. *The World Wide Web Conference on - WWW '19*. doi:10.1145/3308558.331411



