



**HIZLANDIRILMIŞ MAKİNE ÖĞRENMESİ
ALGORİTMALARI İLE TÜRKÇE SAHTE HABER
TESPİTİ**

Elif YILDIRIM

**2022
YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ**

**Tez Danışmanı
Prof. Dr. Oğuz FINDIK**

**HIZLANDIRILMIŐ MAKİNE ÖĐRENMESİ ALGORİTMALARI İLE
TÜRKÇE SAHTE HABER TESPİTİ**

Elif YILDIRIM

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliđi Anabilim Dalında
Yüksek Lisans Tezi
Olarak Hazırlanmıştır**

**Tez Danışmanı
Prof. Dr. Ođuz FINDIK**

**KARABÜK
Ađustos 2022**

Elif YILDIRIM tarafından hazırlanan ‘‘HIZLANDIRILMIŐ MAKİNE ÖŐRENMESİ ALGORİTMALARI İLE TÜR KÇE SAHTE HABER TESPİTİ’’ baŐlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduĐunu onaylarım.

Prof. Dr. OĐuz FINDIK

.....

Tez DanıŐmanı, Bilgisayar MühendisliĐi Anabilim Dalı

Bu çalıŐma, jürimiz tarafından Oy BirliĐi ile Bilgisayar MühendisliĐi Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiŐtir.09/08/2022

Ünvanı, Adı SOYADI (Kurumu)

İmzası

BaŐkan : Prof. Dr. OĐuz FINDIK (KBÜ)

.....

Üye : Dr. Öğr. Üyesi Kasım ÖZACAR (KBÜ)

.....

Üye : Prof. Dr. Mustafa Servet KIRAN (KTÜN)

.....

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Yüksek Lisans derecesini onamıŐtır.

Prof. Dr. Hasan SOLMAZ

.....

Lisansüstü Eğitim Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Elif YILDIRIM

ÖZET

Yüksek Lisans Tezi

HIZLANDIRILMIŞ MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE TÜRKÇE SAHTE HABER TESPİTİ

Elif YILDIRIM

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı:

Prof. Dr. Oğuz FINDIK

Ağustos 2022, 69 sayfa

İnternetin hızla yayılmasıyla insanların haber alma kaynakları da değişmektedir. Televizyon ve gazete gibi geleneksel medya platformlarının yerine twitter ve instagram gibi sosyal medya platformlarının kullanımı artmaktadır. Bu artış ile haberlerin doğruluğunun araştırılmadan paylaşılmasına sahte haberlerin yayılmasına neden olmaktadır. Bilinçsiz sosyal medya kullanımından dolayı sahte haberler kısa sürede yayılmaktadır. Sahte haberler, insanları aldatmaya yönelik yapılan gerçek dışı haberlerdir. Sosyal medya platformlarının çoğunda sahte haber tespiti uzmanlar tarafından yapılmaktadır. Yoğun trafiğe sahip platformlarda uzmanların haberleri inceleme süresi uzadığından, sahte haberler yayılmaktadır. Böylece sahte haberlerin kısa sürede tespit edilmesi önemlidir. Yapılan bu çalışmanın amacı, literatürde eksik olan Türkçe sahte haberleri tespit etmek ve uzmanlara kolaylık sağlamaktır. Literatürde bulunan Sahte Haber Tespiti çalışmalarının çoğu İngiliz diline aittir.

Türkçe gibi sondan eklemeli diller için Sahte Haber Tespiti konusunda az sayıda çalışma bulunmaktadır. Bu tez çalışması kapsamında makine öğrenmesi alanında topluluk yaklaşımı kullanılarak sahte haber tespiti için çözüm geliştirilmiştir. Önerilen modelde Boosting yöntemlerinin türleri olan Catboost, Adaboost, Gradient Boosting, Light GBM ve XGBoost algoritmaları kullanılmıştır. Bu algoritmalar, hiper parametre ayarları sayesinde yüksek performans göstermesi ve modele kolayca uyum sağlamaları nedeniyle tercih edilmiştir. Sonuç olarak, yaygın bir şekilde kullanılan performans değerlendirme metrikleri ile önerilen modelin performansı doğrulanmıştır. Önerilen modellerden Boosting Algoritmalarının literatürde kullanılan diğer algoritmalara göre daha iyi sonuçlar verdiği gözlemlenmiştir.

Anahtar Sözcükler : Sahte haber tespiti, Boosting algoritmaları, Makine öğrenmesi, Veri analizi, Yapay zekâ.

Bilim Kodu : 92416

ABSTRACT

Master Thesis

FAKE NEWS DETECTION IN TURKISH WITH ACCELERATED MACHINE LEARNING ALGORITHMS

Elif YILDIRIM

**Karabük University
Institute of Graduate Programs
Department of Computer Engineering**

Thesis advisor:

Prof. Dr. Oğuz FINDIK

August 2022, 69 pages

With the rapid spread of the Internet, people's sources of information are also changing. The use of social media platforms is increasing instead of traditional media platforms. With this increase, the sharing of the news without investigating the accuracy of the news causes the spread of fake news. Due to the unconscious use of social media, fake news spreads in a short time. Fake news is fake news made to deceive people. In most of the social media platforms, fake news detection is done by experts. Fake news spreads as it takes longer for experts to review news on high-traffic platforms. The aim of this study is to identify the missing Turkish fake news in the literature and to provide convenience to the experts. Most of the Fake News Detection studies found in the literature belong to the English language. There are few studies on Fake News Detection for agglutinative languages such as Turkish. Within the scope of this thesis, a solution has been developed for fake news detection by using the

community approach in the field of machine learning. In the proposed model, Catboost, Adaboost, Gradient Boosting, Light GBM and XGBoost algorithms, which are the types of Boosting methods, are used. These algorithms have been preferred due to their high performance. As a result, the performance of the proposed model was validated with widely used performance evaluation metrics. It has been observed that Boosting Algorithms from the proposed models give better results than other algorithms used in the literature.

Keywords: Fake news detection, Boosting algorithms, Machine learning, Data analysis, Artificial intelligence.

Science Code: 92416

TEŐEKKÜR

Bu tez alıŐmasının planlanmasında, araŐtırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteęini esirgemeyen, engin bilgi ve tecrübelerinden yararlandıęım, yönlendirme ve bilgilendirmeleriyle alıŐmamı bilimsel temeller ışığında şekillendiren sayın hocam Prof. Dr. Oęuz FINDIK'a sonsuz teşekkürlerimi sunarım. Sevgili aileme ve özellikle de eşim Mehmet YILDIRIM'a manevi hiçbir yardımı esirgemedен yanımda oldukları için tüm kalbimle teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iii
ABSTRACT.....	v
TEŞEKKÜR.....	vii
İÇİNDEKİLER	viii
ŞEKİLLER DİZİNİ.....	x
ÇİZELGELER DİZİNİ	xi
BÖLÜM 1	1
GİRİŞ	1
BÖLÜM 2	3
TÜRKÇE SAHTE HABER TESPİTİ.....	3
2.1. SAHTE HABER.....	3
2.1.1. Metinsel Aldatma ve Sahte Haber Kavramı	3
2.1.2. Sahte Haberin Karakteristiği, Etkileri ve Çeşitleri	6
2.1.3. Sahte Haberle Mücadele ve Zorlukları	11
2.1.4. Sahte Haber Tespit Çalışmaları	13
2.2. TÜRKÇE DOĞAL DİL İŞLEME VE SAHTE HABER ANALİZ YAKLAŞIMLARI.....	16
2.2.1. Türkçe Doğal Dil İşleme ve Metin Madenciliği.....	16
2.2.2. Sahte Haber Analiz Yaklaşımları	20
2.2.2.1. Dilbilimsel Yaklaşımlar	21
2.2.2.2. Ağ (Network) Yaklaşımları	22
2.2.3. Türkçe DDI’de Karşılaşılan Zorluklar.....	23
2.3. ÇEVİRİM İÇİ HABER KAYNAKLARI VE SOSYAL MEDYA	25
2.4. DİJİTAL KÜTÜPHANECİLİK VE SAHTE HABER	26

	<u>Sayfa</u>
BÖLÜM 3	29
MAKİNE ÖĞRENMESİ TEMELLİ SAHTE HABER TESPİTİ	29
3.1. MAKİNE ÖĞRENMESİ.....	30
3.2. KELİME YERLEŞTİRME TEKNİKLERİ VE METİNLERİN VEKTÖRLERE ÇEVİRİLMESİ.....	33
3.2.1. Word2Vec Modeli	33
3.2.2. N-Gram Modeli	35
3.2.3. Öznitelik Seçimi ve Çıkarımı	36
3.2.4. SMOTE Tekniği	36
3.2.5. Çapraz Doğrulama/Geçerleme (Cross Validation).....	37
3.3. BOOSTING YÖNTEMLERİ ÇEŞİTLERİ.....	37
3.3.1. CatBoost Algoritması	37
3.3.2. LightGBM Algoritması	39
3.3.3. XGBoost Algoritması	40
3.3.4. Gradient Boosting Algoritması.....	44
3.3.5. Adaboost.....	45
3.4. LİTERATÜR.....	45
3.5. ÖNERİLEN MODEL.....	48
3.5.1. Veri Seti	48
3.5.2. Önerilen Model.....	50
3.5.3. Katkı/özgünlük Özeti ve Sınırlaması.....	51
3.5.4. Bulgular	52
3.6. PERFORMANS ÖLÇÜM METRİKLERİ.....	56
3.6.1. Modelin Performansının Değerlendirilmesi İçin Kullanılan Metrikler	56
BÖLÜM 4	58
SONUÇLAR	58
KAYNAKLAR	60
ÖZGEÇMİŞ	69

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Dilbilimin temel analiz seviyeleri.....	17
Şekil 3.1. Yapay zekâ, makine öğrenmesi ve derin öğrenme kavramları.....	32
Şekil 3.2. CBOW ve Skip-Gram modelleri [81].....	34
Şekil 3.3. Çapraz doğrulama uygulama adımları [88].....	37
Şekil 3.4. En uygun karar sınırları [2].....	41
Şekil 3.5. XGBoost'un standart GBM'yi optimize etme yolları [90].....	43
Şekil 3.6. Kullanılan veri kümesinin gösterimi.....	49
Şekil 3.7. Sahte ve gerçek haberlerin yüzdesel gösterimi.....	49
Şekil 3.8. Sahte haber sınıflandırılması için önerilen model.....	50
Şekil 3.9. Önerilen modelin geliştirilmiş hali.....	51
Şekil 3.10. Sahte haber veri kümesinde sınıflandırıcıların performans analizi.....	55

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 3.1. TF-IDF kelime vektörüne dayalı performans değerlendirme çıktıları...	53
Çizelge 3.2. Word2Vec kelime vektörüne dayalı performans değerlendirme çıktıları.	53
Çizelge 3.3. k-Kat çapraz doğrulama kullanılarak elde edilen doğruluk değerleri....	54
Çizelge 3.4. Voting classifier ile en iyi sonuç gösterimi.	55

BÖLÜM 1

GİRİŞ

Dijital çağın çok hızlı gelişmesiyle birlikte, günümüzde yazılı haber medyalarının çevrimiçi yayın modellerine evrilmiştir. Buna bağlı olarak sosyal medya aracılığı ile tüketen-üretken platformlar haline gelmeleri, farklılık ve hacimlilik kapsamında muazzam bir büyüklükte, bir haberin veri akışına sebep olabilmektedir. Bu üretken ve dağılım kolaylığı ile gerçek içeriğin yanı sıra, uydurma ve sahte içeriklerin de dolaşımı hız kazanmıştır. İletişim teknolojilerinde yaşanmış olan bu hızlı dönüşüm ve değişim, bireylerin maruz kaldığı haberleri ve bu haberler ile birlikte gelen veri akışlarını savunmasız bırakmıştır. Her geçen gün nerede ise, haber veya yeni bilgi, birçok kez doğruluğu onaylanmamış bir biçimde sayısız sosyal medya kullanıcılarına çeşitli platformlardan sunulabilmektedir. Öyle ki; bireylerin çevrim içi olarak karşılaşmış olduğu haberler, birçok kez hiçbir doğrulama arayışına girilmeden, yanlış/sahte bilginin içeriğinin “(fake/fraudulent information and content)” büyük bir hız ile yayılmasına sebep olmaktadır. Bu yayılımın kişiler ve toplumların üstünde öfke, önyargı, panik ve korku gibi negatif etkiler oluşturmaktadır. Genel bakış açısı ile toplumsal ve kişisel etkilerine ek olarak, sosyal medya platformlarının da şirketlerin ticari yönden itibar kaybının yaşanılmasından toplum olarak ayrılmaya kadar olan ülke içerisinde ve uluslararası krizin tetiklenmesine, ticari ve politik faaliyetin manipüle edilmesinde, toplumda güvensiz ortamın yaratılmış olmasına kadar birden fazla negatif etki gözlemlenmiştir. Son dönemlerde sahte haberlerin tespiti, sosyal mühendislik unsurundan faydalanılarak adeta asimetrik bir saldırı aracı haline dönüşmeye başlamıştır. Bu sorun ile çözüm bulma arayışının sonucunda, son beş sene içinde başta bilgisayar bilimleri olmak suretiyle, birden fazla disiplinde merak uyandıran Türkçe sahte haberin tespiti, disiplinler arası bir araştırma alanı ortaya çıkmasına neden olmuştur.

Haber içerikleri genel olarak başta metin olmak suretiyle “görsel, ses ve video vb.” bileşenlerden oluşmaktadır. Çevrimiçi ortamlarda verilerin yayılma hızları, boyutu, farklılığı vb. göz önüne alındığında, haberin gerçekliğini tespit edecek kapsayıcı bir sistematik yaklaşım geliştirilmesi oldukça zor bir görevdir. Bu kapsamda haberi oluşturan bileşenlerin içerisinde en baskın tür olan metin içeriğinin analizi de büyük bir öneme sahiptir. Bu metinlerin içeriklerinin analizi için öncelikle başvuru noktası doğal dil işleme (DDİ) disiplini olduğu bilinmektedir. En genel anlamı ile devamlı ve gelişen teknolojilerin birçok yönden dünyayı küresel bir köy haline getirmekte olduğu öne sürülmüştür. Fakat dil unsurunun halen toplumsal farklılıklarını barındıran kültürel bir öğenin varlığını sürdürdüğü gözlemlenebilmiştir. DDİ alanındaki araştırmacıların kendi dilinde araştırmalar yapması beklenir iken, özellikle de “Sahte Haber Tespiti” hususunda incelemelerde bulunan araştırmacıların büyük bir bölümü İngilizce dilini çalışmış olduğu gözlemlenmiştir. İnternet kullanımının artması ile yaygınlaşan sahte haberler dünyada önemli problem haline gelmiştir. Sahte haber yayılma sebepleri politik, ekonomik, kültürel anlaşmazlıktır. Haber hızla yayılır ve insanların kandırılmasına sebep olur. Böylece hem devlete hem de insanların birbirlerine olan inancı ortadan kaybolmaktadır. Bu çerçevede dilimizde “sahte haber tespit” araştırmalarının ve bu kapsamda elde edilebilecek bilgi birikimlerinin aktif savunmada kullanılacak milli bir güç çarpanı olarak değerlendirmekteyiz. Bu tez çalışmasında “boosting algoritmaları ile Türkçe sahte haber tespiti ve kullanılan algoritmaların karşılaştırılması” literatür kapsamında değerlendirilecektir.

BÖLÜM 2

TÜRKÇE SAHTE HABER TESPİTİ

2.1. SAHTE HABER

Sahte (yalan) haber, gerçek kimliğini kullanmadan kışkırtıcı kullanıcılar tarafından propaganda, provokasyon veya insanları aldatma amacıyla dağıtılan mesajlardır. Günümüzde çok sayıda kullanıcı sahte haber yayabilmektedir. Yayılan haberler, kişilerin ve/veya grupların amaçlarına göre değişmektedir.

2.1.1. Metinsel Aldatma ve Sahte Haber Kavramı

Aldatma; Buller ve Burgoon [1] belirtmiş olduğu gibi, kuram göndericinin yanlış bir inancı, bilgileri ya da sonucu alıcıya bilinçli ya da bilinçsiz bir şekilde iletmesi olarak tanımlamışlardır. Tarihsel yönden değerlendirdiğimizde metinsel aldatma ve sahte haber kavramının tarihinin çok eskilere kadar dayandığı görülmektedir. Somut olarak kanıtlanması oldukça zor olsa da yalan, çarpıtma ya da aldatma, insanların birbirleriyle temasa geçtiği ilk zamanlara kadar uzadığı belirtilmektedir [1,2].

Aldatmanın metinsel ortama uyarlanması zamanla metinlerde aldatma kavramını ortaya çıkarmıştır. Bu çalışma bağlamında “Metin Aldatmacası”, fiziksel veya çevrimiçi olarak sunulan sahte bir belge değil, yazılı ve çevrimiçi dolandırıcılık olgusunu belirten kavram şeklinde belirtilmiştir. Sahte haberlerin sebep olduğu negatif durumlar göz önünde bulundurulduğunda, yüz yüze iletişimde yalan söyleyebilmek ve aldatmaktan daha yıkıcı bir etkisinin olduğu söylenilebilir. Bu yönden bireylerin görsel ve yazılı iletişimde yüz yüze iletişime göre daha fazla savunmasız oldukları söylenebilmektedir.

Bu bağlamda, metinsel aldatmanın, başta dilsel ipuçları olmak üzere farklı farklı yöntemle tespit edilebileceği, bir kısmı ilerleyen bölümlerde referans gösterilen çeşitli bilimsel çalışmalara konu olmuştur [3, 4]. Yazılı iletişimin gelişmesinde paralel olarak metinsel aldatma birden fazla alanda kendisini gösterebilmiştir. Alan yazında yapılan metin madenciliği araştırmaları, metin aldatmasını farklı metin sınıflandırma sorunlarıyla ilişkilendirmiştir. Metin aldatma çalışmalarının alanları sözlü iletişimin yazıya geçirilmesi, bilgisayarlı iletişim, habercilik, hukuk, güvenlik ve bilimsel metinler olarak ortaya çıkmıştır. Sözlü iletişimin yazıya geçirilmesinde deneysel veriler, müşteri hizmetleri konuşmaları, anket ve röportajlar olarak ele alınırken, bilgisayarlı iletişim alanında; çevrim içi iletişim, elektronik postalar, sosyal medya platformlarını incelemektedir. Hukuk, güvenlik ve bilimsel metinlerde ise davalar, adli bilim, intihal tespit programı ve belge sahteciliği konuları işlenmektedir. Habercilik alanında sosyal medya ile internetin kötüye kullanılması, sosyal olaylar, politika, eleştiri, hiciv yazıları gibi çeşitli sahte haberler ve alanlarında çalışma yaptığı bilinmektedir [2].

Haber, Türk Dil Kurumun Güncel Türkçe Sözlüğünde "bir olay, olgu, nasihat hakkında bilgi", "iletişim veya yayın yoluyla verilen bilgiler" ve "bilgi" terimleriyle tanımlanmaktadır. Haberler, halkın bilgi edinmesi içgüdüsünde ve merakına cevap verebilen doğal bir olgudur. Buna karşı halen etki yönünden değerlendirilmesi yapıldığında, basit bir bilgiyi yayma faaliyetlerinden çok daha fazlası olduğu apaçiktir [2].

Son beş senede “yalan haber, teyit, post-truth” vb. yeni kuramların yapılandırılması ve tanımlanması zorlaşmıştır. İletilerin hangi eklerle kullanıldığı, sunuluş biçimi, yöntemleri, iletilerde kullanılan dil ve hatta seçilen sözcükler gibi pek çok etken, iletilerin kime ve neye göre doğru ya da yanlış olduğunu belirlemeyi zorlaştırmaktadır. Üstelik haber dağıtımının teknolojinin de yardımıyla hızlanması ve yoğunlaşması, insanlara haberin kalitesini sorgulama fırsatı bile vermemektedir. Bu kapsamda “sahte haber” kavramının özellikleri, etkileri, kökeni, teknolojik gelişimi ve tespiti yönünden birden fazla disiplinden araştırmacının ilgisini çekmeyi başarmıştır. Bütün bu problemlerin tezi kapsamında tartışılmıştır ve sahte haberin tespit edilmesi için bilgisayar destekli sayısal çözümlere odaklanıldığı görülmektedir. Sahte haber

tespiti doğa bilimleri ve sosyal bilimleri etkileyen kapsamlı bir konuda oldukları için, birden fazla alt araştırma alanlarına kısaca değinilmiştir. Disiplinler arası kesişimler ise ölçülü bir biçimde değinilmeye çalışılmıştır. Sahte haber; başka bir deyişle sözde/yalan haber, geleneksel alışlagelmiş haber araçları (yazılı ve basılı olabilir) ve sosyal medya araçları vasıtasıyla bilerek veya bilmeyerek insanları yanıltmak ya da aldatmak için üretilen haber türleridir. Pek çok bilimsel makale, sahte haberin tanımını, göze çarpan özellikleriyle birlikte sağlar. Egelhofer'in [5] çalışmasına dayalı olarak çeşitli araştırmalarda yapılan yalan haber tanımlarını detaylı olarak ele alınacak olunursa;

1. Kasıtlı oluşturulmuş ve teyit edilebilir şekilde yanlış olan ve okuyucuları yanlış yönlendirebilecek haber makaleleridir [6]. 1, 2, 3
2. Tamamen yanlış veya bilinçli bir şekilde haber içeriğine yanıltıcı öğeler içeren haberlerdir [7] . 1,3
3. Gerçekmiş gibi hazırlanan ve yayınlanan sahte haber öyküleridir [8]. 1, 2
4. İlk olarak 2016 ABD Başkanlık Seçimlerinde ortaya çıkan öne çıkan yeni bir siyasi yanlış bilgilendirme biçimi [9]. 1
5. Sahte bir haber tartışmasının altında yatan varsayım, gerçek habermiş gibi yazılmış olmasıdır (...). Oysa sahte haberler aldatma niyeti taşır, bu da okuyucuyu doğru olduğuna inandırır [10]. 1, 2, 3
6. Bu terim yaygın olarak gerçeğe dayalı bir haber hikâyesi gibi görünmek için yapılan yanlış veya yanıltıcı bilgilere atıfta bulunur [11]. 1, 2
7. Legal kaynaklardan gelmiş gibi sunulan uydurma hikâyelerdir [12]. 1,2

Tanımlarda vurgulanan özellikler: (1) *gerçekçi değil*, (2) *gazetecilik/haber/basın formatı*, (3) *Aldatma kastı*” haber özellikleridir. Bu araştırmaların yanı sıra çeşitli makalelerde de tanımlara rastlanılması mümkündür [6, 7]. Araştırmamızda yalan haberin kuramsal tanımlarından ziyade, sorunların çözülmesi için gereken matematik modellemeye odaklanılmıştır. Bu yaklaşımın ana sebebi, kuramın nasıl tanımlanması gerektiği hususunda bir fikir birliğinin oluşmasına rağmen, problemin tanımlanmasında ortak bir noktaya ulaşılabacağına dair inancımız yüksektir. Bu bağlamda, Shu'nun [8] çalışmasındaki probleme benzer şekilde kurulan matematiksel modelin evrensel olarak geçerlidir. Sonuç olarak;

1. Herhangi bir haberi "h" olarak tanımlanmış olduğunu varsayalım. Mesajların kaynak (K), mesajların ana metni (M) olmak üzere iki asıl bileşeni olduğunu ve bu bileşenlerin bazı özellikler ve alt bileşenler taşıdığını ve bazı mesajların da sosyal hayatta belirli etkileşimlere sahip olduğu bilinmektedir.
2. Yani; bu yazar, yayın kaynağı, zaman, kaynak adı vb. bilgileri içerir. Aynı şekilde mesaj metninin ve ek bileşenlerinin metin bilgileri, başlığı, sesi, görüntüsü ve videosu vb. parçalardan oluşmaktadır.
3. Bu aynı zamanda haberin sosyal bağlamında okuyucu, gönderi, paylaşım ve ağ davranışı hakkında bilgileri de içerir.
4. Buna göre, temel bir sahte haber tespit modelinde, fonksiyon/model F, kaynak tarafından yayılan haberleri değerlendirir. Örneğin modelde $FKh(Mh)$ olarak Mh 'de (Mh =metin+başlık+kategorik veri) dolandırıcılık tespit ettiğinde, bunu True değilse Fake olarak işaretler. Literatürde yalan haberleri sınıflandıran hemen hemen tüm modeller, bu bileşenlerin farklı kombinasyonlarını farklı yöntemlerle ele almaktadır.

2.1.2. Sahte Haberin Karakteristiği, Etkileri ve Çeşitleri

Yapısındaki özellikleri dikkate aldığımızda; haberi oluşturan ana unsurların bazı araştırmalarda ifade edilmiş olduğu gibi “haber metni” olduğu söylenmektedir. Mesajdaki metni tamamlayan bileşenlerin videoları, sesleri ve görüntüleri eklenmektedir. Bazı durumlarda, bu bileşenler metnin başına bile eklenebilmektedir. Bir diğer önemli unsur ise yapısal olarak haberin oluşmasını ve okuyucuya sunulmasını sağlayan haber kaynağıdır. Son olarak, bütüncül bir bakış açısıyla, “haber okuyucunun habere tepki vermesindeki ve haberin yayılmasındaki rolü” yukarıdaki unsurlardan ayrılamaz. Bu kapsamda yalan haberlerin tespit edilebilmesi için bu unsurların dikkatli bir şekilde incelenmesi gerekmektedir [9].

Yalan haberler genellikle hem üretim hem de yayma açısından bilinçli ya da bilinçsiz saiklerle ortaya çıkar. Etkisi, niteliği ve kapsamı açısından farklı çalışmalarda farklı değerlendirilse de tüm çalışmaların ortak görüşü yalan haberlerin toplum üzerinde olumlu bir etkisinin rapor edilmediğidir [10]. Sahte haberin özellikleri, türlerine göre

değişmesiyle beraber, bazı çarpıcı özellikleri de bulunmaktadır. Bu özellikler aşağıdaki gibi sıralanabilir [10]:

1. Sahte Haberlerde kullanılan dil gösterişli, genellikle gayri resmi ve daha fazla okuyucuya ulaşmak için tasarlanmıştır.
2. Paylaşılması kolay bir şekilde sunulmaktadır.
3. Etkileyici (dikkat çekici) bir tarz kullanılmaktadır.
4. Zaman, yazar, tarih vb. mesajı kontrol edilmelidir, damga bilgisi eksik veya yanlış olabilmektedir.
5. Bir sonraki bölümde ayrı ayrı ele alınan belirli kelimelerin genel görünümü gözlenir. Başka bir deyişle, kullanılan dilin belirli bir cümle veya kelime için basit, dar bir çerçevede tekrarlandığını görülebilmektedir.
6. Sahte haber kaynakları ve sahte haber yayan hesaplar düzenli olarak kapatılıp farklı adres ve kimliklerle yeniden ortaya çıkabilir.
7. Sahte haberler, özellikle sahte içerikli, genellikle kasıtlı olarak oluşturulmaktadır.
8. Özellikle kamuoyunu etkileyen yalan haberler, doğru olmadığı bilinse dahi haberlerden olumsuz etkilenebilir.

Yalan haber; “kuruluşlara, kişilere, kurum ve devletlere” birden fazla yönden zarar vermektedir ve bunlar turizm, siyaset, ekonomi, toplumsal kutuplaşma vb. alanlarda kullanılmıştır. Birçok alanda dolaylı ve doğrudan etkileri gözlemlendiği görülmektedir. Bu yönden kişilerin diğer kişilere, kurumlara, olaylara, devletlere ve örgütlere bakış açılarını değiştiren bir silah haline geldiği değinilmektedir. Sahte haberlere yönelik birden fazla araştırma, sahte haberlerin etkilerini dolaylı ve doğrudan görüldüğü uluslararası olaylardan bahsedilmektedir. Aşağıda, yakın dünya tarihinde, değişen kapsam ve büyüklükteki sahte haberlere neden olan, katalize eden veya bunlarla ilişkilendirilen birkaç önemli vaka listelenmiştir [10];

1. 2000'li yılların başında, Irak'ın kitle imha silahları ürettiğine dair haberler ve bu silahlarla birçok ülkeye saldıracağına dair manipülatif haberler nedeniyle bölgedeki durum daha karmaşık hale geldi [10],

2. Sri Lanka ve Myanmar ülkeleri, etnik azınlıklara yönelik şiddet kışkırtıcı haberlere yol açtı [11],
3. Arap Baharı ayaklanmasını ateşleyen seçkin askerler tarafından desteklenen yalan haberler [19],
4. Ukrayna-Rusya krizi [12],
5. Boston Maratonu bombalamasından sonra sosyal medyada yanlış bilgiler dolaşmaya devam ediyor [13],
6. 2016 Başkanlık seçimleriyle ilgili Sahte Amerikan hikayeleri [14],
7. Pizzagate skandalı ve komplo teorileri [15],
8. Brexit tartışmaları ve propagandası [16],
9. Dezenformasyon ve yanıltma(botlar) sosyal medya hesap operasyonlarının haberleri [17],
10. Cambrid'in Facebook olayının işletmelere verdiği zarar [18],
11. Afrika da bulunan mülteciler hakkında özellikle yabancı basında yanlış bilgi ve duygu sömürüsü [19],
12. İnternette dolaşan mültecilerle ilgili söylentiler toplumu kutuplaştırması,
13. Yalan haberler (5G baz istasyonlarının olduğu iddiaları gibi) COVID19'u (koronavirüs) yaymakta toplumun rahatsız edilmesi.

Yalan haberler, yukarıda bahsedilen olayların dışında, toplumsal ve bireysel birçok olayı doğrudan veya dolaylı olarak etkilemektedir.

Tüm olumsuz etkilerinin yanı sıra insanların gerçekliğe ve dünyaya bakış açısının sarsılması mevcut durumun farklı bir sosyolojik sonucu olduğunu göstermektedir. Sahte haberler, özellikle bilgisayar bilimlerinde nispeten yeni bir çalışma alanı olduğu için, birçok farklı kaynaktan sahte haber türleri hakkında birçok farklı görüş vardır. Bu bakımdan üzerinde anlaşmaya varılmış bazı çeşitlerin olduğu söylenemez. Yalan haberin birden fazla altyazı ile çeşitlendirilmiş olması en büyük etkendir ve bunların farklı amaçlar ile oluşturulmasıdır. Rashkin ve arkadaşlarının yapmış oldukları araştırmalarından, sahte haberin bilgi kalitesini ve oluşturma amaçlarına göre kümelenmişlerdir. Diğer bir araştırmada ise, Meel ve Vishwakarma sahte haber kategorilerinin sunulmuş olması ve sahte haberi diğer bazı farklı türler ile örtüşen ayrı bir başlık altında anlatmıştır. Alan yazında yalan haberin tanımlanmasındaki zorluk,

yalan haberin türlere ayrılmış olmasında ya da hangi haber türünün yalan haber kapsamında girdiğinin belirlenmiş olmasında da kendini göstermiştir. Sahte haber türlerinin yayılma hızını ve risk seviyelerine göre dağılımlarını ele aldığımızda ise;

Yanılıcı Manşetler: Manşet içerik bilgisinin altında hiçbir ilgisi olmayan yalan haberdir. Haber başlıklarının öncelikle bakış açısı ve fikir oluşturma çalışmalarında kullanıldığını ve haberin önemli bir parçası olduğunu görüyoruz [21].

Tıklama Tuzakları: Genellikle reklam yönlendirmeleri içeren, farklı haber dışı içerikler sunan ve kullanıcıyı herhangi bir kazanç için, web sitede biraz daha uzun süre tutabilme için genel olarak, alakasız olan bir sahte haber çeşididir. Okuyucuların haber sitelerine olan güvenlerini sarsan önemli bir unsur olarak kabul edilmektedir [21].

Asparagas Habercilik (Yellow journalism): Duyulduğunda veya okunduğunda heyecan yaratan sansasyonel ve yalan haberler, insanlara dokunur ve genellikle hiçbir kanıt içermemektedir [22].

Yanlı Kurgu (Biased fiction): Buna taraflı, genellikle politik kurgu haberleri denir. Genellikle mevcut bir gerçek dünya olayını saptırarak yaratılır. Bu tür mesajların sosyal medyada paylaşılmasında toplumsal kutuplaşmanın izleri var [23].

Sahte Hesaplar (Sockpuppets): Sahte hesap, bot hesabı veya günlük dilde "trol" olarak tanımlanan hesaplar tarafından gerçekleştirilen sahte mesaj veya etkinliklerin türüne verilen isimdir [24].

Şaka, latife tarzı mizah haberleri (Hoax, tidbits, humour): Var olmayan bir gerçeğin veya durumun abartılması hakkında eğlence ve mizah amaçlı yalan haberlerdir. Genellikle platformda ve yayınlandığı yerde yayın bildiriminde gerçek dışı olarak bildirilir. Hiciv kanıtının yanı sıra, literatürde de tartışılan çalışmalar bulunabilir [25].

Hiciv, parodi (Satire, parody): Eleştiri, ima veya düpedüz mizahi ifadelerle süslenmiş bir haber biçimidir. Dolaylı ifadeler ve benzetmeler sıklıkla kullanılır. Hiciv

tanımak çok zor bir iştir, çünkü hicivli bir metinde kelimelere ve ifadelere farklı gizli/metaforik anlamlar yüklenir. Yalan haber tespitinin yanı sıra literatürde sadece hiciv tespitine odaklanan çalışmalar da bulunmaktadır [26].

Partizan haber (Extreme bias): Aşırı önyargılı ve objektif olmayan sahte haberlerdir. Birçok yönden, taraflı kurgu, haberlerle ortak bir zemini paylaşmaktadır [26].

Komplo Teorileri (Conspiracy theory): Kamuoyunu etkileyen önemli bir konuda toplumda şüphe uyandırmayı amaçlayan, gerçeklerden farklı yalan haberdır. İnanılmasa bile toplumu bozma potansiyeli açısından olumsuz etkileri bulunmaktadır [26].

Nefret Söylemi ve Haberleri (Hate news and speeches): Genellikle siyasi saiklerle beslenen seçim mitingleri, meclis oturumlarının (genellikle belirli bir bölümü) konuşmalarıyla ilgili haberlerdir. "Deep fake" olarak bilinen teknolojinin kullanımı ile içerik manipülasyonunda kullanıldığı da gözlemlenebilmektedir [27].

Uydurma haber (Newspeak, Make-up): Birçok işle bağlantısı bulunmayan ve kısa bir süre zarfı içinde işlenmiş olan haberlerdir. Kasıtlı olarak hazırlanmış olduğu ve kötü niyetli olduğu belirtilmektedir [28].

Dedikodu haberler (Rumours): Söylentiler biçiminde yayımlanmış olan ve genel olarak insanlarda çelişki bırakan haber türüdür. Masallar, rivayetler ve tevatür biçimde anlatılmaktadır. Bu tip yalan haberler yayılım gösterdikçe, içeriği de değişim gösterebilir. Söylentilerin yayılmış olması, metinsel aldatma araştırmaları vb. uzun süre çalışılır. Bu yönden yalan haberlerin tespit edilmesi ve dedikodu tespiti vb. alan yazında çeşitli şekillerde ele alındıkları görülmüştür [28].

Yanlış bilgilendirme (Misinformation): Kurumsal gerçek bir olayın ve bireyin olmasına karşılık içeriğinde yalan ve yanlış bilgiler barındıran haber olarak tanımlanmaktadır. Yanıltıcı ve yanlış bilgiler içeren bu tip mesajların genellikle kasıtlı bulunmamaktadır [28].

Provokatif haber (Provocative news): Özellikle de kriz zamanında doğru bilgiye ulaşılmamasının zorlaştığında, ortaya çıkan kışkırtıcı haberlerdendir. Bu tip haberlere en çok sosyal medya ortamlarından rastlanılmıştır [28].

Şehir Efsaneleri (Urban legends): Belirli aralıklar ile tekrar eden ve çok hızlı yayılan, fakat toplumun geneli tarafından şüphe ile karşılanmış olduğu için, potansiyeli düşük olan haber çeşididir [29].

Tanımsız sosyal medya hesapları (Social media bots): Sahte haber üretmekte olan ya da dağıtan sahte hesaplardır. Sahte grupları ve profilleri yönetmeye ilişkin kötü niyetli girişimlere denilmektedir. Belli bir haber çeşidinden ziyade bütün yalan habere etki edebilen bir aktör olarak değerlendirilmektedir [29].

Manipülasyon (Manipulation, deepfake): İnsanları etkileyebilmek ve manipüle edebilmek için üretilen yalan haberdir. Kuram olarak tek bir mesajdan ziyade sürekli bir yönlendirme süreci bulunmaktadır. Birkaç basit ifade ile video içeriklerindeki oynamaya kadar birçok farklı şekilde kendini gösterebilmektedirler [30].

Propaganda: Hedef kitlelerin belli bir konu ilgili inançlarını ve motivasyonlarını etkileyebilmek ya da yönlendirme yapabilmek için, manipüleyle iç içe bir sürece ifade etmektedir [31].

2.1.3. Sahte Haberle Mücadele ve Zorlukları

Tüm insanların etkileyici ve ilginç bilgiyi yayma istekleri, yalan haberin sayısının artış göstermesine neden olmaktadır. Şüphesiz ki günümüzde sanal alemin hızlı yaygınlaşması ile, bu eğilimin en kolay uygulanacağı ortamlar çevrimiçi metinlerin bulunmuş olduğu çevrimiçi haber siteleri ve sosyal medya platformlarıdır. Bu durumun çatışmaya yol açması ve savaşı zorlaştırmasının temel nedenlerinden biri, yalan haberlerin gerçek haberlerden çok daha hızlı yayılması ve daha fazla etkileşime sahip olmasıdır [32,33].

Eleştirel etkisi son yıllarda artan yalan haberler konusunda toplumda genel bir farkındalık olduğu söylenebilir. Ancak önceki bölümlerde de açıklandığı gibi bu farkındalığın somut çözümlere katkısı çok azdır. Akademik çalışmaların yanı sıra son yıllarda sahte haberlerle mücadele konusunda uluslararası yarışmalar, konferanslar, paneller ve seminerler düzenlenmektedir. Genel olarak yalan haberlerle mücadelenin üç farklı şekilde çalıştığını söyleyebiliriz. Bunlar [33]:

1. Okuyucu Farkındalığı,
2. Web Sitesi ve Haber İnceleme Kuruluşları,
3. Otomatik Tespit Araçları ve Sistemleri.

Birinci strateji okur farkındalığı, yalan habere karşı bireysel ve toplumsal farkındalığı ifade eden bir kalkan olarak tanımlanabilir. Bu farkındalığın toplumsal anlamda somut çabalara dönüştüğü de gözlemlenmektedir. Sahte haberin doğası ve bireylerin sansasyonel bilgileri yayma teşvikine dayalı akıllı tasarımı sebebiyle, bu tip stratejiler sahte haber ile mücadelede kontrolü elinde tutabilmek için, yeterli değildir. Bazı çalışmalar, insanların/kullanıcıların yalanları tespit etmesinde ya da haberlerin yanlış mı yoksa doğrumu olduğu karar vermede iyi olmadığını göstermiştir. Aynı zamanda, insanlar bu açıklamaları yapar iken, tarafsız olması gerekmektedir. Yani; insanlar özellikle de siyasi görüşleri içeren tartışmalı konularda, kendi görüşleriyle çelişen gerçekleri sıklık ile görmezden gelmektedirler [38].

İkinci strateji olarak tanımlayacağımız haber doğrulama kuruluşu ve web siteleri, yoğun birey emeği ile yürütülmekte olan mücadele yöntemidir. Günümüze gelindiğinde, mesaj doğrulama kuruluşları [39], start-up'lar ve amaca yönelik projeler, bu yöntemleri hem çevrimdışı hem de çevrimiçi kullanmaya çalışırken ortaya çıkmıştır. Ancak, büyük bir çoğunluk ile manuel olarak çalıştırılmış olan bu sistemlerin, devamlı olarak üretilen sayıda dijital içeriği kaldırmamaktadır. Bu yüzden; spor, siyaset, hiciv vb. için dijital haber içeriği alt kümelerle odaklanabilir. Yanlış bir bilginin yayılma hızı göz önüne serildiğinde, bu alt kümelerden de benzer problemler ortaya çıkmıştır. Bu sebeple, otomatik ve doğrulanmış sistemler en son çare olarak ortaya çıkmaktadır.

Üçüncü stratejide ise, yapay zekâ teknolojileriyle birlikte birçok verimli gerçeğin otomatik olarak doğrulayabilmek ya da sahte haberi tespit edebilmek için tasarlanmış olan sistemdir. Sahte haberin daha hızlı yayılmış olduğu “Google, Twitter ve Facebook” vb. sosyal medya platformları, itibarlarını koruyabilmek için akademik çalışmaların geliştirilmesine teşvikler sağlamıştır. Yapay zekâ ile birlikte insan analizleri kullanılmaya başlanmıştır. Aynı zamanda, bazı önemli olay ve durumlarda hesapların içeriklerini engelledikleri, aynı zamanda işaretledikleri görülmektedir [39, 43].

Günümüzde yapılan birçok çalışmada çeşitli yöntemlerin ve otomatik çözümlerin uygulanabilir hale getirilmesiyle, önemli araştırmalar da yapılmıştır [16, 40-42]. Problemlerin çözülmesi için, önemli adımlar atılmış olsa da araştırmaya açık birçok alan halen bulunmaktadır. Mesaj doğrulama kuruluşlarında ve orada çalışmakta olan bireylerin sayılarındaki artışlar, henüz “uygun (optimal)” çözümlerin bulunamadığının önemli bir göstergesi olarak karşımıza çıkmaktadır [39, 43].

2.1.4. Sahte Haber Tespit Çalışmaları

Sosyal medya ve İnternet'teki geleneksel medya sunumu, sahte haberleri yaymanın iki ana yoludur. Bu nedenle, tüm çalışmalar bu yayılma ortamlarına dayalı olarak çözümler bulmaya ve stratejiler geliştirmeye çalışır. Sahte haber tespit çalışmalarının ortaya çıkışı ve gelişimi; Sosyal bilimlerle ilgili olarak yalan haberleri ortaya çıkaran sosyal/sosyolojik nedenleri ve çözümlerini incelemek, sayısal bilimlerle ilgili olarak ise matematiksel modeller, algoritmalar ve sistematiği olmak üzere iki ana çerçevede incelemek mümkündür.

Sahte haber kavramı, sosyal etkisinin hissedilmesiyle son 4-5 yılda popülaritesini artırdı. Öyle ki, 2017 senesinde Collins sözlüğü kavramı senenin en fazla kullanılan terimlerinden birisi olarak listelemiştir. ABD başkanlık seçimlerinden sonra birçok çalışmaya yansıdığı üzere “sahte haber” kavramının daha fazla popüler bir kuram haline geldiğinden ve bu alanlardaki akademik araştırmaların da aynı doğrultuda ivme kazanmış olduğu görülmüştür [6]. Söz konusu seçimlerde yalan haberlerin yayılmasında başta Facebook olmak üzere sosyal medyanın büyük etkisi olduğu tespit

edildi [44]. Grondahl ve Asokan [45], bilgi teknolojisi (BT) departmanlarından arařtırmacıların artan ilgisini, sahte haberleri tespit etmede uzman olmayanların nispeten düşük performansına bağlamıřtır. Bu sebep, alıřmacıların hesaplamalı özmler bulmaya motive etmiřtir.

Sorunlara bilgisayar tabanlı özmlere dayalı olarak yaklařan alıřmaların metinsel kopya tespiti alıřmalarında kullanılan nicel yaklařımlara dayandıęı görlmektedir. Ayrıca problem klasik metin sınıflandırma problemlerinden birkaç noktada farklılık göstermektedir. Örnek verilecek olunursa eęer, klasik metinlerin sınıflandırılmasında yařanan sorunlarda kullanılan kitle kaynak yöntemleri kullanılarak, gerekleřtirilmiř olan etiketlenmenin bu sorunlara karřı aynı ölçde katkı saęlayacaęı söylenmemektedir. Sorun ise, gerek ve sahte mesajlarda yazan yazarın tespit edilmesine benzeyen, dięer taraftan ise aę bilgilerinin kullanılması yönünden spam tespit sorunlarına benzetilmektedir [15].

Bu alandaki önc alıřmalardan birinde, sahte haberleri tespit etme yaklařımları Conroy ve dięerleri tarafından kapsamlı bir řekilde tartıřıldı [46]. Bu bağlamda en önemli yaklařımlar; Dil ve Aę Yaklařımları. Ayrıca kaynak güvenilirlięi, semantik analiz ve hibrit yaklařımlar bařta olmak üzere farklı yaklařımların kullanıldıęı görlmektedir.

Bilim dünyasında arařtırmacılar tarafından en yaygın bir biçimde kullanılan yaklařımlardan birisi de, dilsel yaklařımlar olarak bilinmektedir. Örnek verecek olursak eęer; Markowitz ve Hancock'un arařtırmalarında “N-gram, kelime türü (POS, konuşmanın parası)” vb. yöntemlere dayalı olan dilsel yaklařımların kullanıldıęı belirtilmektedir. Dilsel yaklařımlarda kullanılan dięer bir arařtırmada ise problem “Baęlamdan Baęımsız Dilbilgisi (CFG)” kullanılarak, kural tabanlı söz dizimsel analizler ile ele alınmıřtır. Literatürde kullanılan bazı alıřmalarda ise, dilsel yaklařımlar dięer yaklařımdan tamamlayıcısı olarak kullanıldıęı tespit edilmiřtir [46]. Semantik yaklařımlar ile dilsel yaklařımların keřiřmiř olduęu noktalarda, söylem temeline dayalı “retorik” belirlenmesinde birtakım arařtırmalarda kullanılmıřtır. Rubin, yapmıř olduęu arařtırmasında yapı ve tutarlılık yönünden gerek ve yanıltıcı hikayelerin arasındaki sistematik farklılıkları tanımlayabilmek için, analitik bir

kapsamda ele alarak, retorik yapı teorisi kullanmıştır. Benzer bir biçimde, söylem düzeylerine odaklanan diğer bir araştırmada ise, vektör alanları modelleyiciler olarak “İngilizce” iletiler için retorik yapıları kullanmışlardır.

Bazı araştırmacılar, derin öğrenme tekniklerinin karmaşık mimarisinin geliştirilemeyeceğine işaret ederek [31], poz algılama konusundaki çalışmalarında geleneksel makine öğrenimi yöntemlerini kullanmış, bazı araştırmacılar ise derin öğrenme tekniklerini uygulamış ve geleneksel makine öğreniminin bazı eksiklikleri, öğrenme tekniklerini tanımlamaktadır. Derin öğrenmenin kullanılmış olduğu araştırmalarından birinde ise, yazarlar sahte haberlerin bir alt alanı olan müstehcen haberleri tespit edebilmek için kişilik ve duygusal özelliklere odaklanmış, önceden yapılmış “Evrşimsel Sinir Ağı”na dayanan bir model geliştirmişlerdir.

Sahte haber tespiti; haber içeriğinin ana unsuruna baktığımızda, haber büyük ölçüde metin tabanlı olmasına rağmen zaman içinde değişen sunumlarla birlikte artık metne ek olarak ses, görüntü ve video unsurlarıyla zenginleştirilmiştir. Bu yönden haberin bütün bileşenleriyle değerlendirildiği çalışmalara ihtiyaç vardır. Ruchansky, çalışmasında [16] bu ihtiyaca yönelik hibrit bir model önermiştir. Bu tür çalışmalar, zaman içinde değişebilen meta verilerin dikkatli bir analizini göstermektedir.

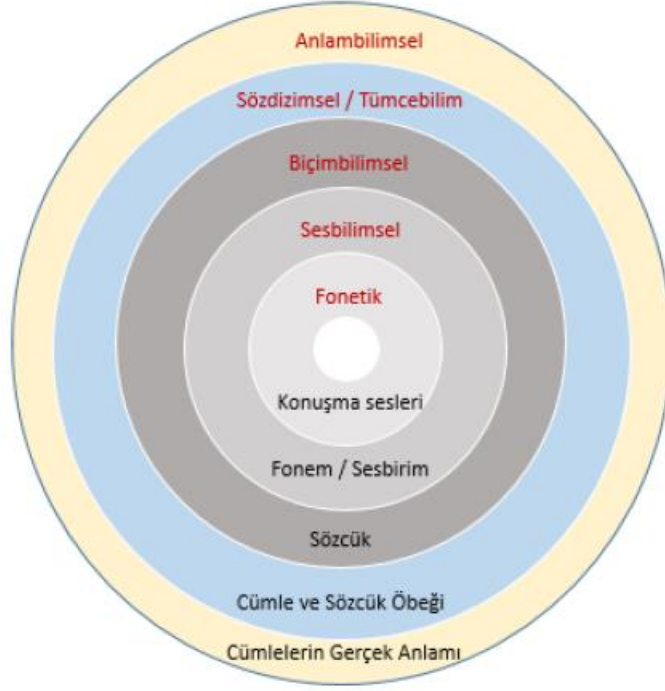
Bu tip verilerin toplanılmasının ve etiketlenmesinin zaman alması, sıkıcı bir sürecin olduğu düşündüğümüzde, çalışmaların hepsinin halka açık İngilizce veri kümelerinin kullanılması hiç de şaşırtıcı değildir. Bu kapsamda, DDI alanında çalışma yapan araştırmacılar ana dilinde çalışmadıklarını ve mevcut veri setiyle çalışmalarının sınırlı olduğu anlamına gelmiştir. Çalışmayla ilgili bir diğer konu da çalışma alanının makine öğrenmesi problemlerine (spor, siyaset, vb.) daraltılmasının nispeten daha etkin ve verimli sonuçlar vermeleridir. Bu ayrıca sahte haberin tespit edilmesi için geçerli olmaktadır. Netice olarak belli bir alanda ders başarısı olsa da bütün alt alanı kapsamına alan bir sistem sunulamamaktadır.

2.2. TÜRKÇE DOĞAL DİL İŞLEME VE SAHTE HABER ANALİZ YAKLAŞIMLARI

2.2.1. Türkçe Doğal Dil İşleme ve Metin Madenciliği

Doğal Dil İşleme, literatürde sıklıkla kullanılan İngilizce terimi ile, doğal dillerin kanonik yapıyı dikkate alarak yeniden üretilmesi ve çözümlenmesi için, matematiksel bir model oluşturmak amaçlanan disiplinler arasındadır. Yapay zekâ ve dilbilim bir alt kategorileri olarak da tanımlanmış olan bu disiplinler, bilgisayar bilimlerinde ana disiplinleri biri olmasının yanı sıra “psikoloji, robotik, matematik, psikoloji vb.” birden fazla çeşitli disiplin ile etkileşim içerisinde olmaktadır [50].

Dil, uzun bir sürede evrilen ve devamlı gelişen karmaşık bir yapıya sahip yaşamakta olan bir olgudur. Dil zamanı ile özellikle eski kelimelerin ortadan kalkmasıyla ve yeni kelimenin eklenmesi biçiminde değişirken, dilin yapısal özelliklerin büyük bir ölçüde değişmesi istikrarlı bir yapıya sahip olduğunu göstermektedir. Doğal diller, bireylerin arasındaki iletişimde temelini oluşturmuş olduğu, birden fazla sosyal ve kültürel kuramın anahtar unsuru olarak görülebilmektedir. Bu kavramlardan ilki millet kavramıdır. İyi bir örnek, ülke adlarının çoğunlukla o ülkede kullanılan dilden türetilmesidir. Bu doğrultuda kütüphaneler, dillerin yapısı ve terimleri toplumdan topluma değişen birçok farklılık içermektedir. Bu bağlamda “doğal dil”in yani insanların konuştuğu dilin makine işleminde bu farklılıkları dikkate alan dile özgü çalışmaların yapılması gerekmektedir. Dilbilim; Alt aşamalarda, yani DDI çalışmalarında da sıklıkla kullanılan farklı analiz seviyelerinde işlenir. Bu alt aşamalar Şekil 2.2’te şematik olarak gösterilmiş ve aşağıda kısaca açıklanmıştır.



Şekil 2.1. Dilbilimin temel analiz seviyeleri.

Fonetik, bireylerin diğer bireyler ile konuşur iken kullanmış olduğu seslerin incelenmesi ile ilgilenmektedir. Fonetik analiz özellikle işitsel girdi çalışmalarında kullanılır. Tonlamalar, kelime telaffuzları, gürültüler ve seslendirme varyasyonları ile büyük bir sıklık ile analiz edilen konuların arasında yer almaktadır. Bu kapsamda DDİ'deki araştırmaların ses ve metin olmak suretiyle 2 ana girdiye odaklandığını belirtmemiz yerinde ve isabetli olmaktadır. Fonoloji, benzer biçimdeki konuşmalardaki sesin ve belli konuşma seslerinin “fonemler”in işlevini incelemektedir. Dili oluşturan ses çağrışımı ile de ilgilenmektedirler.

Morfolojik analizin ana çalışma alanı, dilin en küçük anlamlı parçaları olan morfemlerdir. Kelimeleri, diğer kelimelerle olan ilişkilerini, nasıl oluştuklarını, kelimelerin kök, kök, sonek gibi yapılarını analiz etmektedir. Dildeki kelimenin yapısını “(kök-ek-kök)” incelemekte olan katmandır. Dilimizin sondan eklemeli dil yapısı göz önüne alındığında, bu analiz biçimsel olarak karmaşık bir yapıya sahip dillerde sıklıkla karşılaşılan morfolojik belirsizlik sorunu açısından da oldukça önemlidir [50].

Bütün dillerin, morfolojik kurallarıyla beraber herhangi bir dilin gramerlerini oluşturmakta olan ana söz dizimsel kuralları bulunmaktadır. Sözdizimsel analiz, cümlenin, insanların ve deneyimlerin anlamlı bir biçimde iletişim kurabilmek için kullanmış olduklarını incelenmesidir ve özetle cümle yapılarını inceleyen katmandır. Dilbilgisel yapı çözümlemesi olarak da adlandırılabilen bu çözümlemede dil kuralları cümle düzeyinde işlenmektedir.

Semantik/semantik analiz, cümlelerin genel olarak tam anlamı ile neleri ifade etmiş olduğunu incelemektedir. Kelimeler birçok dil ile birlikte fazla anlama sahip olduğundan, bu analizlerin ana araştırma alanları, bu anlamların gerçek dünya nesnelere ya da kavramlarını temsil ettiği durum olarak belirtilmektedir [50].

Doğal dil problemleri, bu analiz seviyelerine ek olarak, sözlük analizi (duygu analizi), dil analizi (söylem analizi), kelime türü bulma (POS, konuşmanın parçası) vb. ara analizleri kullanır [51,52]. Bu noktada literatürde yaygın olarak kullanılan konuşma bölümü analizi (POS) veya konuşma bölümü belirleme/etiketleme (POS etiketleme) bir metni oluşturan öğelerin işlevini/doğasını belirten bir etikettir. (sıfat, isim, fiil, zarflar vb.). Söylem/söylem analizi, metnin içeriğinin ötesinde gerçek karşılığı bulmakla ilgilidir. Metni kimin ifade ettiğini, neye dayandığını ve hangi amaca dayandığını inceleyerek doğru anlamı bulmaya çalışır [53]. Bu analizin sıklıkla yazar tespit problemlerinde kullanılmış olduğu tespit edilmiştir. Duygu analizlerinde bu 2 analiz vb. Türkçe ile ilgili olduğu müddetçe popülerliği olan bir araştırma alanı olarak kabul edilmektedir. Özellikle de 2'nci aşamada sözlüğün oluşturulma metodolojisinde, duygu durum analiz araştırmalarında yaygın bir biçimde kullanılmış olan bir yaklaşım türüdür. Dolayısıyla ile, araştırmamızda izlenilmiş olan süreç kapsamında, duygu durum analizinde sözlük kullanılan araştırmalar ile terminolojik ve metodolojik benzerlikler yer almaktadır.

DDİ, dolaylı ve doğrudan olarak birçok araştırma alanındaki sorunların çözülmesinde çalışabilmektedir [51, 52, 53]. Bunlardan bazıları aşağıdaki gibidir:

1. Metin ve içerik sınıflandırması,
2. Metin etiketleme, seslendirme,

3. Duygu analizi,
4. Ad varlık tanıma (NER),
5. Makine çevirisi,
6. Metinden bilgi çıkarma,
7. Semantik analiz,
8. Soru ve Cevap makineleri,
9. Metin Özeti,
10. Konuşma ve Karakter Tanıma,
11. İmla ve İmla Denetimi,
12. Diller Arası Çeviri,
13. Konuşma Oluşturma ve Tanıma.

DDİ disiplininde ortaya çıkmış olan bazı problemler aşağıda yer alan başlıklar ile ifade edilebilmektedir [51, 52, 53]:

1. Dilin biçimsel yapısına uymayan içerikler de içerebilir.
2. Sözcüksel ve morfolojik analiz gibi farklı düzeylerde belirsizlik sorunları.
3. Aynı ifadenin farklı bağlamlarda farklı terimlerle kullanılmasından kaynaklanan anlamsal belirleme ve eş anlamlı/zıt anlamlı sözcüklerin belirlenmesi sorunu.
4. Aynı varlığa atıfta bulunan tüm ifadeleri bulmanın zorluğu olarak ifade edilebilecek olan bağıntıları çözme sorunu.
5. Mecazi ve dolaylı anlamı olan atasözleri, deyimler vb. örüntülerin yarattığı anlam farklılıkları.
6. Kullanılan terimlerin ima, eleştiri, argo, alay ve hiciv vb. ima edilen anlam ve kavram kargaşası.
7. Sonlu Durum Otomatları (FSA) ile dilleri modellemede yaşanan zorluklar ve farklı kurallara sahip farklı dillerin yapısı nedeniyle ortak bir kurallar dizisi oluşturamama.
8. İngilizce dışında birçok dilde gelişmiş dil kaynakları, kütüphaneler ve araçlar eksikliği.
9. Ön bilgi gerektiren metinlerin analizi.
10. Lehçe farklılıkları nedeniyle ses verisi kod çözme sorunu.

DDI ile birbirine girmiş ve metin tabanlı arařtırmalarda yaygın bir biçimde kullanılmakta olan diđer bir disiplin ise, metin madenciliđi olarak belirtilmektedir. Metin madenciliđinde bir bakıma veri madenciliđinden kaynak verilerin metin olduđu arařtırma alanı bulunmaktadır. Genel anlamı ile metin madenciliđi, düzensiz olan metinlerde örtük bilgilerin çıkarılmasını ve metinlerin düzenlenerek yapılandırılmış bir biçimde işlenmesini amaç edinen bir süreç olarak tanımlanabilmektedir. Başka bir ifade ile, yapılandırılmayan metin verisinin yapılandırılan bir şekle dönüřtürülmüş olmasıdır. Bu işlenmiş ve organize edilmiş veriler analiz edilerek metinlerde yer alan bağlamlar, örüntüler ve hatta hipotezler çıkarılabilir [54].

Özetleme, metinlerden konu çıkartmak, özetlemek, metinlerin kümelenmiş olması, duygu analizleri, varlık ilişki modellerinin oluşturulması, iş zekâları, bilgi erişimi, kayıtların yönetimi vb. arařtırmalarda metin madenciliđinin yöntemleri yaygın bir biçimde kullanılmıştır. DDI; “veri madenciliđi, metin madenciliđi, makine öğrenimi ve yapay zekâ” vb. disiplinlerinden örtüşen yöntem ve tekniklerin kullanılması ile birbirlerine tamamlamış olduđu, bu arařtırmalarda olduđu gibi birden fazla arařtırmada da bu kapsamda beraber kullanmış olduđu söylenebilmektedir. Birden fazla arařtırmada DDI ile beraber metin madenciliđinin kullanıldıđı tespit edilmiştir. Buradaki ana temel farklar; metin madenciliđinden daha fazla istatistiksel sonuçların ve metinlere odaklanarak ilerlemiş olduđu, DDI arařtırmalarının ise yapay zeka yöntemleri ile kullanılarak bu bölümlerin başında tanımlanmış olan dilsel analizlere odaklanılarak ilerlemiş olduđunu söyleyebiliriz. Bu kapsamda, arařtırma doğrultusunda hem metin madenciliđinde hem de DDI analizlerinin ve tekniklerinin birbirinden farklı kullanıldıđı belirtilmiştir [54].

2.2.2. Sahte Haber Analiz Yaklaşımları

Sahte haber tespiti ve metin aldatma üstüne yapılan arařtırmada [46], Conroy ve arkadaşları aşağıdaki 2 ara başlık altında özetlemiřtirler:

1. Dilbilimsel Yaklaşımlar
2. Ağ (Network) Yaklaşımları

Bu yaklaşımlara ana yaklaşım olarak kaynak analizini eklemek mümkündür. Ek olarak, Bölüm 2.2.1'de açıklanan veri sunumu, bağlantılı veriler, sosyal medya davranışı ve diğer NDI analiz seviyeleri, ana yaklaşımdan eşlenmiş olan alt yaklaşımlar olarak eklenebilmektedir. Araştırmalardaki genel eğilimlerin, birden çok yaklaşım ve teknik bir arada kullanılabilir. Bu analizlere ek olarak, yalan haber konusu özellikle toplumsal bağlamda fikir ve yayılmaya dayalı modellemede grafik temelli muhakemelere oldukça açıktır [54].

2.2.2.1. Dilbilimsel Yaklaşımlar

Yalan söylemede kullanılan beden dili gibi, aldatma ve yalan haberde kullanılan metin dili de yalan ve aldatmacanın ipuçlarını barındırmaktadır. Elbette bilinçli olarak yalan haber metinleri oluşturanlar, haberleri olabildiğince doğru bir şekilde iletmek istemektedirler. Metinsel sınıflandırma sorunlarında, çoğunluk ile kullanılan geleneksel dil bilimsel analiz teknikleri şu şekilde özetlenebilmektedir [55]:

1. Kelime Torbası – kelime sayıları (countvectorizer), tf-idf, kelime ve harflere dayalı n-gram sayımları, Word2Vec gibi metin verilerini vektörlere dönüştüren çeşitli metin oluşturma yöntemleri ve çeşitli sayma yöntemleri,
2. Konuşma bölümlerinin kullanımı (POS), bağlamdan bağımsız dilbilgisi kurallarının kullanılması,
3. Fonksiyon kelimelerinin kullanımı,
4. Kelime kümeleme, birlikte oluşum matrisi, kelime filtreleme,
5. Gizli anlamın indekslenmesi, anlamsal uzayın kullanılması,
6. Noktalama işareti, kelime, cümle, ters cümle, harf, sonek, cümlelerde ortalama kelime ve harf, kelimelerde ortalama harf ve ek sayısı vb. üslup özelliklerinin (stilometri) kullanımı ve istatistik bilgisi. Örneğin bu çalışmada sayı tabanlı öznitelikler kullanılırken görece uzun veya kısa haberler dikkate alınarak ortalama alma hesaplamaları (μ) kullanılmıştır.

Bu tekniklerin ve çeşitli türevlerinin, öznitelik odaklı makine ve derin öğrenme yöntemlerinin ve diğer güvenilirlik analiz yöntemlerinin başta yukarıda bahsedilen veri/metin gösterim yöntemleri olmak üzere sahte haber tespit çalışmalarında

kullanıldığı görülmektedir. Aynı zamanda duygu analizleri “retorik ve semantik” analizlerin üstüne yapılmış olan araştırmalara esas olarak sözdizimsel analizlerin başlığı altında özetlenebilmektedir. Özellikle de morfolojik ve sözdizimsel analizlerin yapılmış olduğu araştırmalarda ise dile özgü DDI kitaplıkların ve araçların gelişme durumları ön plana çıktığı belirtilmektedir [46].

Tamamen dilsel yaklaşımları kullanan çalışmalarda önerilen bazı modellerin, bağlamsal bilgiyi dikkate almamasına rağmen kesinlik/doğruluk açısından nispeten iyi performans gösterdiği ortaya çıktı. Bununla birlikte, bazı çalışmalar bu yaklaşımı tek başına kullanmanın eksikliklerini vurgulamıştır. Örnek verecek olursak eğer, Conroy ve diğerleri, özellikle de gerçek zamanlı izleme gerektiren bütün incelemeler gibi ticari konularda da dilsel yaklaşımların genelleşemeyeceğini savunmuşlardır [46]. Bu yönden yalan haberin tespit edilmesinde büyük bir sıklık ile, hibrit modelin ve dolayısı ile çeşitli yaklaşımların bir arada kullanılmış olduğu ifade etmektedirler [56]

2.2.2.2. Ağ (Network) Yaklaşımları

Facebook, mikroblog, Whatsapp, Instagram, Twitter, vb. gerçek zamanlı içeriklerin üretilmiş olduğu sosyal medya platformlarının, mesajlaşma ortamlarının ve çevrimiçi ortamların daha yoğun kullanılması ile yalan haberin yayılmasının hızlanmış olduğu aşikardır. Bu mecralardaki metin özelliklerinin geleneksel medyada kullanılmış olan haber metinlerinde çeşitli özellikler taşımasıyla ve sosyal ağların karmaşık olması sebebiyle, ağ yayılmasına dayalı olan yaklaşımların ağırlıklı olarak sosyal ağ verilerinde kullanıldığı araştırmalarda kullanılmaktadır. Sorunların örüntü ya da trend analizi gerektiren özelliklerden dolayı, sosyal ağa analizleri ve çizgi teorileri üstüne çalışan çalışmacılarına konuya ilişkin ilgi göstermiş olduğu söylenilebilir.

Bilgi ağlarının kullanımı, kanıtlanabilir verileri doğrulamak için bağlantılı veri analizinde önemli bir kaynaktır. Bunun için İnternet ağındaki her bir bilgi parçasını anlamlı bir şekilde modelleyerek ve birbirleriyle olan ilişkilerini göstererek bir tür ontoloji ve veri tabanlarının oluşmasını sağlayan çalışmalar (Dbpedia, Freebase, GDELT vb.) kullanılabilir. Varlık Adı Tanımlama problemlerinde kullanılan bilgi

ağlarının yanı sıra aktörler, nesnelere, yerler, olaylar vb. Bilgiye erişim, yalan haberlerin erken tespiti için önemli ipuçları içerebilir [56].

Ayrıca, sahte haber içeriği üreten kaynaklar artık bu içeriği sahte hesaplar ve profiller aracılığıyla üretiyor. Bu, özellikle gerçek ve sahte içeriği tespit etmek için sosyal medya kimlik doğrulamasını çok önemli hale getirdi. Son zamanlarda sosyal medya platformlarında hesapların veya paylaşımların etiketlenmesi, toplumun bazı kesimleri tarafından desteklenirken, başkaları tarafından iletişim özgürlüğünü kısıtladığı için eleştirilmiştir [57].

Ağ yaklaşımı, söylenti yayma gibi ağ bilgisi gerektiren çalışmalarda yaygın olarak kullanılan yaklaşımlardan biridir. Bu çalışmalardan birinde Zhang ve arkadaşlarının tweetleri; Mesajlar, yaratıcılar ve mesaj konusu ile ilgili olarak incelenen derin yayılma ağı modeli kullanılarak incelenmiştir. Aynı şekilde, güvenilirliğiyle değerlendirmeye odaklanılan araştırmalarda çeşitli ağ yapısı kullanılmaktadır. Çevrimiçi sosyal ağların yapısının ve kullanıcılarına yönelik ilişkileri modelleyebilmek için, kullanılan ölçeklenebilir grafikler oluşturucuların çalışmacılara büyük bir kolaylık sağladığı bilinmektedir. Fakat, bu sentetik modeller gerçek dünya ile hangi ölçüde, modelleyebileceği diğer bir problemdir [57].

Genel anlamı ile hem ağ temelli hem de dilsel yaklaşımda kullanılmış olan yaklaşımların belli bir yerde ve sınırlı alanlarda verimli neticeler elde ettiğini söyleyebiliriz. Fakat geniş ve kapsamlı bir ilgi alanında başarılı olunması için, hibrit modellerinde yaşama geçirilmesi gerekmektedir. Bu araştırmalarda göz önünden kaçan ve üstünde durulması gereken husus, karmaşık mimariler kullanılmış olduğunda çözümlerin genellenebilir ve uygulanabilir olmasıdır. Özellikle de ağ yaklaşımında, gerçek zamanlı verilerin değişken doğasıyla çok dikkatli bir biçimde ele alınması gerekmektedir [58].

2.2.3. Türkçe DDI’de Karşılaşılan Zorluklar

Türk dili “Ural-Altay” dil ailesine sonradan eklenmeli bir dil olarak bilinmektedir. Türkçe, doğal dil işleme için ilginç zorlukları ortaya koymaktadır. Aynı zamanda,

sondan eklemeli biçim birimlerinin cümle ve yapısal öğelerin esnek bir biçimde yer değiştirmesiyle, dilimizin biçimsel yönden zengin kılmaktadır. Dilimizdeki iki ana etken yapım ekleridir. Geçmiş olduğu kelimenin yüklemine ve anlamını türüne göre değiştirmektedir. Çekim ekleri kelimelerin anlamını değiştirmeden kelimenin cinsini değiştirebilmektedir. Bu yapıyla, dilimiz DDI araştırmalarında kullanıldığında, öncelikli olarak dil bilimsel bir analizin yapılması gerekmektedir [58, 59].

Dilimizde DDI araştırmalarında karşılaşılmış olan sorunlardan birisi de kelime anlam ayrımı kuramı temelinde bir kelimenin diğerinden fazla anlamının olduğu bir durumdur. Bu zorlayıcı durumlar, genel bir sözlük oluşturulduğunda hissedilmese de ilerleyen dönemlerde yapılabilecek araştırmalara özgü sözlükler oluşturularak, bu durum dikkat ile ele alınması gerekli olan bir konudur. Dilimizde çeşitli anlam bozukluğu olan kelimeler bulunmaktadır. Bu sorun genellikle metin bütünlüğü içinde anlam açıklığa kavuşturularak çözülmeye çalışılmıştır. Bu doğrultuda Türkçe için çeşitli anlam açıklama çalışmaları bulunmaktadır [58, 59]. Örneğin: “Karahisar kalesinin yapılma amacı savunmaya yöneliktir.” cümlesinde bulunan “kale” kelimesi savunma amacıyla yapılmış, kalın, burçlu ve mazgalı yapıyı ifade ederken yani tarih terimi iken, “Bugün yapılan maçta kale de kim savunma yapacak?” cümlesindeki “kale” kelimesinin metindeki anlamı futbol terimidir.

Özellikle de Türkçe ’de duygu sözlüğü oluşturmak ve duygu tahlili araştırmalarında gözlemlenene eş anlamlı veya zıt zenginliğinde kaynaklanmış olan bir zorluğun olduğu ortaya çıkmıştır. Çünkü, Türkçede, tam eş anlamlı ya da zıt anlamlı kelimeler olmasa da birbirlerine yakın anlamlar taşıyan birçok istisnai durum bulunmaktadır. Bu sorunların çözülmesinde, çeşitli anlamsal sınıflandırmalar büyük önem kazanmaktadır. Dilimizde bir başka zorlayıcı olan özellik ise, “morfolojik” belirsizlik problemidir. Özetle bu, “morfolojik” analizi bulunan kelimelerin ham hali ile anlam belirsizliği yönünden birden çok “morfolojik” analize sahip olduğu anlamına gelmektedir. Aynı zemberekte olduğu gibi, “morfolojik” ayrıştırıcılar kelimelerin cümle içerisinde anlamsal olarak çeşitli kullanım sebebiyle “morfolojik” yönden birden fazla sonuç verebilmektedir. Doğru sonucu seçebilmek için, buradaki “morfolojik” belirsizleştiricilerin ismi verilen yöntemlerde kullanılmaktadır. Fakat, bu

yöntemlerin tam anlamı ile bir başarının getireceğini söyleyebilmemiz doğru olmamaktadır. Bu sonuçlar, dilin yapısal zenginliği ile de bağlantılabilmektedir [60].

Türkçede bazı problemlerin çözümünde karşılaşılan bir diğer problem ise B. duygu analizi ve makine çevirisi, seyreklik sorunu, sözcüklerin morfemlerin birbiri ardına bir araya gelmesiyle oluşturulduğu sondan eklemeli yapıdan kaynaklanmaktadır. Özetle, kök-ek kombinasyonları dikkate alındığında incelenen bütüncü ne kadar büyük olursa olsun Türkçe gibi dillerde (tam listeleme hipotezi) [84] olabilecek tüm kelimeleri listelemenin mümkün olmadığı söylenebilir. Problemin çözümüne odaklanan bazı çalışmalarda Arısoy ve ark. [66] başka bir yöntemin (alt sözcük birimleri) kullanılmasını önermiş ve başka bir çalışmada Can [65] tarafından Uzun Kısa Süreli Bellek Ağları (LSTM) ile kök çözme yöntemi kullanılmıştır. Sosyal ağlarda daha sonra Türkçeye giren veya biçimsel değeri olmayan yabancı kökenli kelime ve kısaltmaların sık kullanımı ve ASCII kodlarında yer alan durumlarda, göreceli kısa metinlerden yola çıkılarak sosyal medyanın belirlenmesini zorlaştıran bir diğer unsurdur.

2.3. ÇEVİRİM İÇİ HABER KAYNAKLARI VE SOSYAL MEDYA

Alan yazında farklı biçimlerde tanımlanmış olan haber, doğasında var olanı bilme, çevresinde olup biteni anlamak ve toplumu bilgilendirme organı olarak tanımlanabilir. Dijitalleşmeyle, sosyal medya bileşenlerinin içerikleri ve bu içeriklerin en önemlisinden birisi de haberin kapsamının hangi ölçüde değişmiş olduğudur. Özellikle de sosyal medyanın insanı etkileme olanağı ve gücünün her geçen gün artış göstermesiyle beraber, yazılı medya olarak da bilinen geleneksel haber medyaları ve özelliklerinin de ana akım haber medyalarının çevrimiçi ortamlarda yerini aldığı gözlemlenmiştir. Günümüzde nerede ise, bütün haber ajansları ve büyük basın, gazeteler de çevrimiçi içerikler üretmektedir. Bu kapsamda geleneksel medya “radyo, televizyon, yazılı basın vb. oluşturulmaktadır. Dijital medya kaynaklarının kullanımının artış göstermesiyle beraber, kitle iletişim araçlarının öneminin etkileri azalmıştır [66].

İnternet gazeteciliği üzerine çığır açan yayınlardan birinde İnternet gazeteciliği kategorilere ayrılmıştır. Ana akım haber medyası bu kategorilerin başında gelir. Ana

akım medya, bu çalışma bağlamında, baskın medyadan daha fazla kişinin eriştiği, alternatif medyanın tam tersi anlamda kullanılan, açık ve imza bilgisine (yazar, zaman, yer, kişi vb.) Etik ilkelerle ilgili haberleri sunarken verilen mesajların başka bir deyişle, popüler geleneksel medyanın çevrimiçi haber siteleridir. Çevrimiçi haber kuruluşlarının, izleyicilerini büyütmek ve varlıklarını sürdürmek için okuyucularını/izleyicilerini/kullanıcılarını meşgul etmesi ve etkilemesi gerekir. Bu açıdan gazetecilik çalışmalarında hedef kitlenin beklentileri dikkate alınmalıdır. Tersine, sosyal medya her ne kadar kontrolden uzak yapısıyla her kullanıcıyı bir muhabire dönüştürse ve güvenilirliği defalarca sorgulansa da giderek daha baskın bir haber kaynağı haline geliyor. Örneğin Twitter, sosyal medyaya yansıyan bir “manşete dayalı gazetecilik” biçimi olarak görülebilir. Bu göstergeler, sosyal medyayı kısa sürede çevrimiçi gazetecilikte varlığını kanıtlamak için daha aktif kullanabileceğini göstermektedir. Her ne kadar bazı sosyal medya platformları yalan haberlere karşı önlem alsın da internet ortamının doğasına aykırı olarak yasaklama eylemi yapılması blokajlara, tepkilere ve ticari kayıplara neden olmuştur. Ayrıca bu kurum ve platformların insanlar gibi ön yargılı ve ön yargılı olma potansiyeli ne yazık ki onları çözümün merkezinden uzaklaştırıyor [67].

2.4. DİJİTAL KÜTÜPHANECİLİK VE SAHTE HABER

Bu bölüm, modelimizi ve sahte haberleri sadece sayısal olarak değil sosyolojik açıdan da otomatik olarak tespit eden diğer tüm sistemleri tamamladığına inandığımız ve yapabileceğini tahmin ettiğimiz dijital (dijital) kütüphaneciliğin konuyla bağlantısı hakkındadır. Bu bağlamda bütüncül bir bakış açısıyla yararlanılabileceği açıklanmıştır. Kütüphane yönetimi; Tarih boyunca insanların en önemli kültür varlıklarından biri olarak bilgi üretiminin, erişiminin ve alışverişinin sağlandığı sürekli hareket halinde olmuştur. Ayrıca “kütüphane”, yani bilginin saklandığı yer, eski çağlardan beri toplum tarafından saygı duyulan, gerçek bilgilere erişimi çağrıştıran sosyal bir kuramdır. Günümüze geldiğinde geleneksel ortamların yerini dijitalleşme sürecinde uyum sağlayarak dijital alanlarda ve dinamik faaliyetler sürdürülmektedir. Tarihsel yönden kazanmış olduğu prestijin halen korunmuş olduğu söylenilebilir.

Elbette her zaman güvenilir bilgi kaynakları olarak bilinen kütüphaneler de yalan haberlerden etkileniyor. Dünyanın her yerindeki kütüphanelerin dijitalleşme ve kullanıcılarına dijital içerik sunma sürecinden geçtiği düşünüldüğünde, dijital kütüphanelerin kullanıcılarına sunduğu büyük miktardaki içeriği anında kontrol etmek çok zordur. Bu nedenle yalan ve/veya yanlış bilgi ve haberlerin yer alması doğaldır. Dijital kütüphaneciliğe büyük önem veren birçok medya/bilgi okuryazarlığı çalışması bulunmaktadır.

Kattimani ve diğerleri [68] tarih boyunca kütüphanelerin kendisini yeniden konumlandırması gerektiğini ve bir rol oynanmasında başarılı olduğu belirtmiştir. Benzer bir biçimde, Connaway ve diğerleri [68] gazeteciler, kütüphaneciler ve arşivler gibi bilgi profesyonellerinin toplumdaki haberlere yönelik ilgili hizmet ve ürünlerin uygun bir biçimde yararlanmış olmasına yardımcı olmasındaki kilit rollerine işaret edebilmektedir. Fakat, bilgi kirliliğinin de zirve yapmış olduğu günümüzde ise, "Kütüphane ve Bilgi Bilim Topluluğu (LIS)" çalışmacıları arasında sahte haberlerin mücadele ile dijital kütüphaneciliğin özel rolleri kapsamında bir fikir birliğinin olmadığı görünmektedir.

Çağdaş akademik araştırmalar, başlangıçta sadece bir pazarlama ve savunuculuk aracı olarak görülen yalan haberlerin, günümüzde başta bilişim olmak üzere birçok farklı disiplinden araştırmacıların ilgisini çeken toplumsal bir tehdit olduğunu göstermektedir. Bu çözüm arayışında kütüphane araştırmacıları tarafından incelenen konular arasında yerini almıştır. Kavramsal çerçeveler çizen çok sayıda çalışma bu konuda çeşitli açıklamalarda bulunmuştur. Bu çalışmalardan birinde; Sullivan, 2016 ABD başkanlık seçimlerinden sonra kütüphane ve bilgi bilimi camiasının sahte bilgilerin çoğalmasından ciddi şekilde etkilendiğini belirtiyor [90]. Aynı çalışma, yalan haber ve kütüphanecilik arasındaki ilişkinin tam olarak kurulmadığını ve konunun iyi anlaşılmadığını da ortaya koydu.

Dünyanın her yerindeki kütüphaneler dijital içerik hizmetlerine geçerken, bilgi profesyonellerinin rehberliğinde hileli ve yanıltıcı içeriğin yayılmasını önleyecek mekanizmalar uygulamalıdır. Kütüphane ve bilgi bilimi, sorunu çözmek için uygun stratejileri belirlemek için "dijital kütüphaneler" ve "sahte haberler" arasındaki

bağlantıya daha somut bakmalıdır. Daha önce de belirttiğimiz gibi, bu, birçok yaklaşımı tek bir potada eritmek için kolektif bir çaba gerektirir. Bu doğrultuda dijital kütüphanelerin kaliteli haber hizmetleri sunma zamanının geldiğine inanıyoruz. Bu bağlamda gerçek bilgi/haber denilince akla ilk gelen kütüphaneler, bilgiyi değerlendirmede uzman sayabileceğimiz kütüphaneciler ve dijital kütüphaneciliğin çerçevemizde hizmet olarak yer alması gerektiğini değerlendirmiştir [73].

BÖLÜM 3

MAKİNE ÖĞRENMESİ TEMELLİ SAHTE HABER TESPİTİ

Günümüzde insanlar istem dışı olarak makine öğrenmesi, arařtırmalarına destek vermektedirler. Gündelik olarak çekilen fotoğraf, video, sosyal medya üstünden yapılan yorumlar, video izleme platformlarından izlenen videolar, hastanelerde yapılan testler, online alışveriş sitelerinde yapılan tüm işlemler vb. arařtırmalar daha sonrasında makine öğrenme modellerinde kullanılmak şartı ile yapılan işlemler vb. arařtırmalar daha sonrasında makine öğrenmesinde kullanılmak üzere veri tabanlarını oluşturmaktadır. Devamlı olarak üretilmekte olan bu verilerin büyük bir çoğunluğu, istatikselsel veri olarak kalmaktadır ve çeşitli amaçlar için kullanılabilir [2]. Veri bilimi o kadar önemli bir noktaya gelmiştir ki, “NASA” uzaya göndermek için yetiřtirmiş olduđu astronotların yanı sıra veri bilimi üstünde yapılan arařtırmalar yapabilmek için “R veya Python” programlarının dilline hâkim veri bilimciler yetiřtirmektedirler [3]. Makine öğrenmesi, istatikselsel ve matematikselsel yöntemler kullanılarak öğrenme gerçekleřtiren ve mevcut veriler ile çıkarımda bulunabilen, bu çıkarımların sayesinde bilinmeyen ile ilgili tahminlerde bulunan yöntemlerin genel adıdır. Makine öğrenme yöntemleri ilgili ne kadar çok veri ile eğitilir ise, modelin doğru tahmin etme olasılıkları da artış göstermektedir. Makinelerin yapmış olduđu doğru çıkarımlar ile ilgili verilen iyi örnek olarak “Google”nin geliřtirmiş olduđu “DeepMind’in Go” şampiyonunu yenmesi gösterilebilmektedir [4]. Aynı zamanda “DeepMind”in yapmış olduđu işlemler bireylerin geçmişte yapmış olduđu hamleleri deneyimleyerek çıkarımda bulunabilmektedir.

Makine öğrenme modeli oluşturulur iken öğrenmenin yeterliliği önemlidir. Yani gelen veriler için doğru tahminlerde bulunduğu büyük bir öneme sahiptir. Örnek verecek olursak eğer, kredi kartında sahtekarlığın tespit edilebilmesi için oluşturulmuş olan bir modelde, kullanılan yöntem ile doğru sonuç üretilmesi amaçlanmıştır. Burada karşılaşılmış olan en büyük sorunlardan birisi karar sınıfına ait veri dağılımının dengeli oluşumudur. Model oluşturulur iken, karar sınıflarına ait azınlık veri gurubu eğitim veri seti içinde düşük seviyede veya hiç bulunmayacaktır. Bu durumda birçok kez zaman modelinin performansını ölçerken, yanılgıya düşmesine neden olmaktadır.

3.1. MAKİNE ÖĞRENMESİ

Makine öğrenimi ve derin öğrenme, şu anda lisans ve lisansüstü bilgisayar mühendisliği eğitiminde bir ders olarak öğretilen çok geniş konulardır. Bu bölüm, bu konuları mümkün olan en açıklayıcı ve genel şekilde ele almaktadır. Bu iki konunun anlatılmış olduğu bir ortamda yapay zekâ kuramlarından bahsedilmez ise, anlatım eksik kalmaktadır. Bu sebeple, bu bölümde yapay zekâ kuramları, makine öğrenmesi ve ana yaklaşımları olan derin öğrenme ele alınacak, haber tespit probleminde kullanımı anlatılacaktır. Bazı ifadelerin ve kavramların anlaşılmasını kolaylaştırmak için teknik ve kavramsal tanımlamalar ve açıklamalar yapılmıştır. En genel tanımıyla yapay zekâ, "bir bilgisayarın veya bilgisayar kontrollü bir robotun, akıllı canlılara benzer çeşitli faaliyetleri gerçekleştirme yeteneği" olarak özetlenebilir [74].

Literatürde sıklıkla "AI, Yapay Zekâ" olarak anılan yapay zekanın günümüzde çok sayıda çalışması, projesi ve uygulama alanı bulunmaktadır. Günümüzde kullanılan en önemli kuramlardan birisi olan "yapay zekâ" başlı başına incelenecek çok kapsamlı bir alandır. Canlılarda, özellikle de insanlarda gözlemlenebilen ve akıllı davranışlar olarak nitelendirilmekte olan davranışların sergileyen bir sistemdir. Diğer birçok disiplinde olduğu gibi, doğal dilin işlenmesinde de en geniş bir uygulama alanı kendisine bulmuştur. Zaman içindeki evrim yönünden, yapay zekâ kavramı "Alan Turing'in "Turing Testi" ve daha sonra John McCarthy tarafından 1950'lerde bir akademik konferansta bir kavram olarak tanıtılmıştır. Daha sonra da çok geniş bir kapsama ve alan haline getirerek geliştirmiştir. Yapay zekâ 1980'li yıllara kadar kuramsal bir kapsamda güncelliğini korumuş olsa da sürdürülebilir teknolojiler ile

pratik hayattaki yansımaların ve teknik boyutun 1970’li senelerinin sonuna doğru gerçekleşmiş olduğu söylenebilmektedir. Yapay zekâ kavramı ile; derin öğrenme, makine öğrenmesi vb. 2000’li senelerin başı ile daha geniş genel kullanıma sahip olan teknik birer kavram olmaktan çıkarak, üstün teknolojilerin gelişmesini ifade edebilen toplumsal birer olguya everildiğini söyleyebiliriz. Günümüzde birçok kurum ve kişi, bu konuya yönelik güncel referansları konuşmaları, kuramın önem kazandığı, devamlı olarak gündem olduğu anlamına gelmektedir [75].

Makine öğrenimi uzun süreli veri madenciliği, istatistik vb. olmuştur. Araştırmaların gerisinde kalsa bile, kullanılmış olan algoritmaların evrimi ve ticari rekabet ortamlarının zeminine döşenen ticari rekabet ortamlarının bir sonucu olarak, 1980’li yıllarda ortaya çıktığı görülmektedir. Bu tip araştırmaların başı 1990’lı senelerin başında gelmiştir. Senelerce ve özellikle de 2000’li senelerin başında oldukça yoğun bir biçimde kullanılmıştır ve halen kullanılmaya devam etmektedir. Bu yönden makine öğrenimi, yapay zekanın birer alt alanı olan ve teknik görüntüleri olarak görülebilmektedir. 2010’lı senelerde geliştirilmiş olan derin öğrenme algoritmaları ve sistemleri, çok büyük ve farklı veriler ile çalışmakta olan, birden çok katman yapısıyla kullanılmış olan ve yüksek hesaplama gücü gerektiren sorunlara odaklanan sistemlerin başında gelmektedir. Bu özellikleri ile derin öğrenme keskin çizgiler ile makine öğreniminden ayırt edilmesi oldukça güçtür. Fakat, daha güçlü bilgisayarlar ile daha karmaşık sorunların üstünden geldiği için, derin öğrenme popülaritesi artış göstermektedir. Yapay zekanın kapsayıcı olarak tanımlanmış olduğu Şekil 3.1’de sunulan resim; Yapay zekâ, makine öğrenimi ve derin öğrenme kavramlarının ve gelişim tarihinin bir özetidir [76].



Şekil 3.1. Yapay zekâ, makine öğrenmesi ve derin öğrenme kavramları.

Makine öğrenimi, istatistiksel ve matematiksel yöntemlerin tarihsel verilerden ve bilgilerde çıkarımlar yapabilmek için, bilgisayarlarda kullanılarak tahminler yapan sistemin modellenmiş olmasıdır. Alan yazında makine öğrenimi için geliştirilen birçok yöntem, algoritma ve kütüphane yer almaktadır. Makine öğrenim problemleri, geri bildirimler ve öğrenmeler ile şekillenmiş olan 3 temel öğrenme yaklaşımı kullanılarak ele alınmaktadır. Bu yaklaşımlar kısa bir şekilde aşağıda açıklanmaktadır [77]:

Denetimli Öğrenme (Supervised Learning): Bu öğrenme yaklaşımında, algoritmalar öğrenilenlerden etiketlenmiş verileri kullanarak tahminler yapar. Eğitimde kullanılacak veriler ve bu verilerin kategorisi, etiketi vb. sınıf bilgileri önceden bilinmektedir. Denetimli öğrenmede, var olan bilgiyi kullanarak öğrenen sistem, yeni veri/durumlar için tahminlerde bulunur.

Denetimsiz Öğrenme (Unsupervised Learning): Denetimli öğrenmede olduğu gibi önceden etiketlenmiş eğitim verileri yoktur. Öğrenme mantığı, veriler arasındaki çeşitli ilişkileri/ilişkileri tanımak ve eğitilmemiş verileri kullanarak dar içerikleri/değerleri/anlamları vb. analiz etmekten oluşur. Gruplar halinde toplama, kümeleme olarak işlemeye dayanır. Yeni gelen veri/durumlar, algoritma tarafından oluşturulan en uygun gruba atanır. Denetimsiz öğrenme olarak da adlandırılrsa da, çalışma boyunca "denetimsiz öğrenme" olarak kullanılmaktadır. Genel; Kümeleme,

Birliktelik Kuralı Madenciliği ve Boyutsallık Azaltma olmak üzere üç temel yöntemle incelenebilir.

Takviyeli Öğrenme (Reinforced Learning): Bu yöntem yukarıda bahsetmiş olduğumuz 2 yönteme göre farklıdır. Bu yöntemde öğrenme mantığı, çevremizden gelen geri bildirimlerin mekanizmalarına dayandırılmaktadır. Hedef olarak olası durumlara yönelik ulaşım ulaşılmadığının kontrol edilmesi gerekmektedir. Sistem kullanmış olduğu “ödül ve ceza” yöntemiyle devamlı olarak, pekiştirici bir öğrenme işlevini hedeflenmiştir [78].

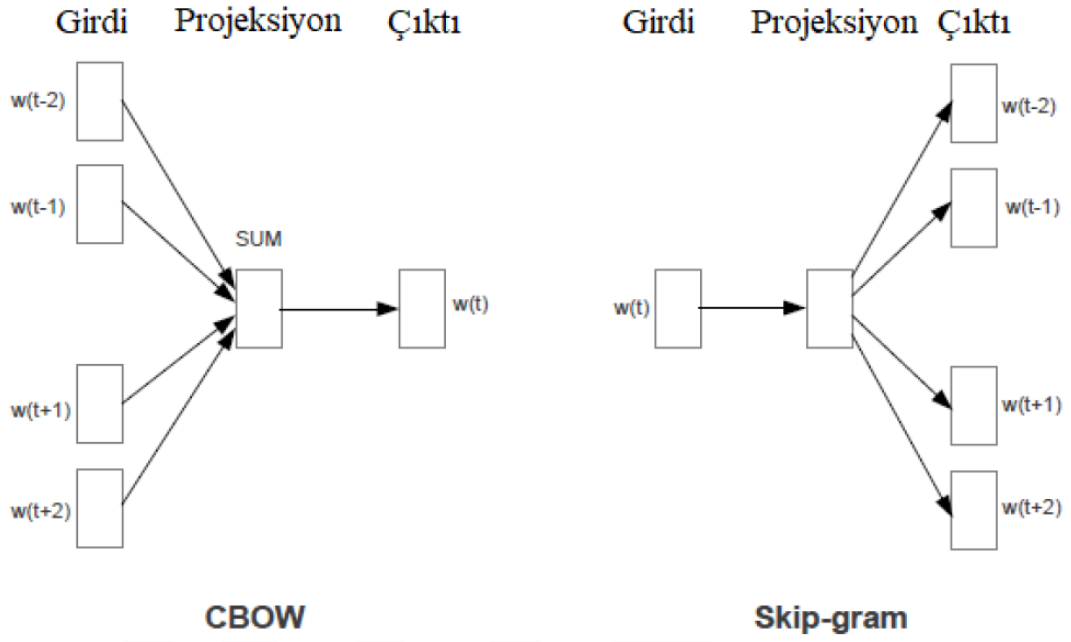
3.2. KELİME YERLEŞTİRME TEKNİKLERİ VE METİNLERİN VEKTÖRLERE ÇEVİRİLMESİ

3.2.1. Word2Vec Modeli

Mikolov ve ark. Her kelimenin vektör temsilini öğrenmek için yeni geliştirilen Skip-Gram ve CBOW modellerini kullanarak kelime vektör dönüşümü ile kelime temsiline gerçekleştiren Word2Vec modelini geliştirdi [79].

Word2Vec modeli doğrusal olmayan dönüşümleri önler ve bu nedenle eğitimi son derece verimli hale getirir (Ren ve diğerleri 2016) Sözlükteki milyonlarca kelimedenden ve milyarlarca kelime içeren çok büyük veri setlerinden gömülü kelime vektörlerinin öğrenilmesine izin verir [80].

Kelime vektörleri oluşturmak için en yaygın kullanılan modellerden biri olan Word2Vec, Şekil 3.2'de gösterildiği gibi Skip-Gram (SG) ve Continuous Bag-of-Words (CBOW) olarak adlandırılan iki model ile uygulanmaktadır [81].



Şekil 2.2. CBOW ve Skip-Gram modelleri [81].

1. CBOW, çevreleyen bağlam kelimelerini kullanarak hedef kelimeyi tahmin etmek için eğitilmiştir, örn. $w_i - 2$, $w_i - 1$, $w_i + 1$, $w_i + 2$ girdilerini alarak w_i hedef kelimesini tahmin eder (Güvenç 2016).
2. Skip-Gram modelinin pedagojik amacı, bir cümle veya belgede çevreleyen kelimeleri tahmin etmek için yararlı olan kelime temsillerini bulmaktır ((Mikolov ve diğerleri 2013b).
3. Mikolov'a göre, Atla-gram nadir kelimelerde daha yavaştır, ancak küçük eğitim verileriyle iyi çalışır. Bu nedenle çalışmamızda küçük veri setimizde kullanılmak üzere Word2Vec modelinin varsayılan değeri olan Skip-gram'ı seçilmiştir.

Python programlama dilinde Gensim kütüphanesi sayesinde Word2Vec modelini kullanarak, İngilizce veri seti eğitilerek 300 boyutlu GoogleNews-Vectors-negative 3 milyon kelime koleksiyonu oluşturuldu. Word2Vec yöntemini eğitirken. Türkçe veri seti için Boğaziçi Üniversitesi tarafından geliştirilen 416051 kelime 300 boyutlu bir "Wiki-tr" derlemi kullanılmıştır.

3.2.2. N-Gram Modeli

N-gram, n uzunluğunda bir kelime dizisidir. İfade paketinde, metin bir kelimeler topluluğu olarak kabul edilir ve kelimelerin sırası kabul edilmez. Örneğin, BOW yaklaşımında "Ayşe, Betül'den daha güzel" ve "Betül, Ayşe'den daha güzel" özdeştir. Bu, metinde büyük bir bilgi kaybına neden olur. N-gram modelinin kullanılması, öznitelik sözcük kümelerinin öznitelik olarak kullanılması yoluyla bilgi kaybını azaltır [82].

Kelime seviyesindeki n-gram modeli, kelime çantası modeli ile yöntem olarak aynıdır (her iki modelde de nitelikler kelimelerdir), ancak ön işleme aşamasında n-gram modeli ayrıştırma dışında hiçbir işlem yapmaz. Ayrıca karakter seviyeli n-gram modelinde minimum string uzunluğu ikiden az olmamalıdır (unigramlar çıkarılmaz) [83]. N-gramlar da bulunan “n” kontrol edilen kelime sayısını ifade etmektedir. Genellikle unigram (n=1), bigram (n=2) ve trigram (n=3) kullanılan modellerdir. Metinde tüm bağımsız sözcüklerden bir araya gelerek oluşan unigrams, n-gram'lara yaklaşmak için en basit modeli sağlamaktadır. Bigram kalıbı, bir çift bitişik kelimeyi ifade etmektedir. Her kelime çifti tek bir bigram oluşturur. En büyük gram, n bitişik kelimeyi birleştirerek benzer şekilde oluşturulabilir.

Daha büyük n-gramlar, kelime konumunun daha iyi anlaşılmasına izin verdikleri için bağlamı yakalamada tartışmasız daha etkilidir. Gram modeli aşağıdaki örnek metin kullanılarak açıklanmıştır:

Metin: “Bugün okullar tatil olduğu için mutluyum.”

Unigrams: “Bugün”, “okullar”, “tatil”, “olduğu”, “için”, “mutluyum”.

Bigrams: “Bugün okullar”, “okullar tatil”, “tatil olduğu”, “olduğu için”, “için mutluyum”

Trigrams: “Bugün okullar tatil”, “okullar tatil olduğundan”, “tatil olduğu için”, “olduğu için mutluyum”.

3.2.3. Öznitelik Seçimi ve Çıkarımı

Öznitelik çıkarımı ve seçimi, makine öğrenme yöntemlerini kullanabilmek için verilerin en uygun özelliklerinin tespit edilmesi işlemidir. Bu durum, birden fazla gerçek dünya sorunlarından kolaylık ile bulunmayan birer süreçtir ve yakın analiz gerektirmektedir. Veri madenciliği ile ilgili yapılan araştırmalarda olduğu gibi, ön işlemlerde ve “veri filtreleme/temizleme” işlemlerinden sonra uygulanmaktadır. Bu sorunlarda, göze çarpan niteliklerin, veri tablo şekline dönüşmüş olduğu “(tablo/matris olarak)” her satırı tanımlayabilen sütunlar olarak ifade edilebilmektedir. Kullanılacak olan alt öznitelikler ve normal öznitelikler, bu sütunlardan en uygun olanların seçilmesinde, özniteliklerin arasındaki ilişkilerden veya bu ilişkilere dayandırılan hesaplamalardan kaynaklanabilecek, yeni özniteliklerin kullanılması hali olabilmektedir. Verideki sistemin tahminlerini etkilemeyen ve nispi olarak daha az etkin olan bazı özelliklerin kaldırılma işlemlerine özellik seçimi denilmektedir. Bu işlemler sistemlerin herhangi bir ek hesaplama yükünü de yükleyebilmek ve sistemin performanslarını arttırabilmek için gerekli kılmaktadır. Özellikle de seçimleri ayrıca aşırı bir öğrenmenin oluşmasını engellemektedir [84].

3.2.4. SMOTE Tekniği

Smote tekniği, TR_FN kaydında hedef sınıf, yanlış olarak işaretlenmiş bir değeri mesaj gövdesine atayan sınıftır. Bölüm 3.2.4, TR_FN veri kümesinin dengesiz bir hedef sınıf dağılımına sahip bir veri kümesi olduğundan bahsetmiştir. Bu açıdan verilerin doğrudan dengesiz veri kümelerinde kullanılması durumunda, veri kümesinde de performans değerleri için çelişkili sonuçların ortaya çıkması olasıdır. Dengesiz veri problemini çözmek için veri setindeki örnek yapısını düzenleyen teknikler (yetersiz örnekleme, aşırı örnekleme, SMOTE vb.) kullanılmaktadır. Örneğin TR_FN veri seti ham verilerle işlendiğinde, gerçek haberlerin neredeyse tamamı doğru tahmin edilirken, yalan haberlerin çoğu yanlış tahmin ediliyordu. Bu problem SMOTE tekniği (Sentetik Azınlık Aşırı Örnekleme Tekniği) ile aşılmıştır. SMOTE tekniğinde, azınlık sınıfı örneklerin "k" komşuları dikkate alınarak sentetik örnekler üretilir [87].

3.2.5. Çapraz Doğrulama/Geçerleme (Cross Validation)

Aldığımız sistem verilerin çoğunu yanlış tahmin ettiğinde, sistem aşırı öğrenme nedeniyle genelleştirme kabiliyetini kaybettiğinde buna "eksik öğrenme" veya "ezberleme" denir. Bu tür sonuçlardan kaçınmak ve tutarlı modeller oluşturmak için çapraz doğrulama kullanılır. Oluşturduğumuz veri setinin aslında bağımsız verilerle nasıl çalıştığını test etmek demektir. Eğittiğimiz modelin yeni verilere, aşırı öğrenme, eksik öğrenme ve varyans-yanlılık çatışmaları gibi sorunlara genelleştirilip genelleştirilemeyeceğini belirlemeye hizmet eder. Veri setimiz rastgele 10(k) gruba ayrıldı ve makine öğrenme modelleri için 10 kat çapraz doğrulamaya (10 kat çapraz doğrulama) tabi tutuldu. Şekil 3.3'te görüldüğü gibi graplardan biri test, diğerleri eğitim seti olarak kullanılmıştır. 10 grup modeli bu şekilde tekrar ederek eğitmiştir [88].

	Bölüm 1	Bölüm 2	Bölüm 3	Bölüm 4	Bölüm 5	Bölüm 6	Bölüm 7	Bölüm 8	Bölüm 9	Bölüm 10
Aşama 1	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
Aşama 2	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
Aşama 3	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
Aşama 4	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
Aşama 5	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
Aşama 6	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim
Aşama 7	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim
Aşama 8	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim
Aşama 9	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim
Aşama 10	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test

Şekil 3.3. Çapraz doğrulama uygulama adımları [88].

3.3. BOOSTING YÖNTEMLERİ ÇEŞİTLERİ

3.3.1. CatBoost Algoritması

Sıralı Yükseltme ve kategorik değişkenleri işlemek için geliştirilen yenilikçi algoritma olan Catboost ile sunulan iki önemli algoritmik gelişme olarak belirtilmiştir. Her iki teknik de mevcut gradyan geliştirme algoritmalarında tahmin yanlılığıyla mücadele etmek için geliştirilmiştir. Hedefe ulaşmada yaşanan kayıp ve kayıpların tahminin sapmasından kaynaklandığı tespit edilmiştir. Bu problemin detaylı bir analizi yapıldı

ve oluşturulan Catboost algoritmasının problemi etkin bir şekilde çözdüğü ortaya çıktı. CatBoost, gradyan artırma karar ağaçlarının mevcut en son uygulamalarından (XGBoost ve LightGBM) daha iyi performans gösterir. Catboost, tahmini kaydırmayı önlemek için sıralı artırma yöntemini kullanır. Türetilmiş Sıralı Yükseltme, hedefe ulaşırken kayıpları önlemek için standart gradyan artırma algoritmasının değiştirilmiş bir versiyonudur. Tahmin kayması, bulmaya çalıştığımız değişkendeki tahmin değeri (örneğin GPA veya ev fiyatları) veri setindeki değere yaklaştığında ve gerçek değerden saptığında meydana gelir. Tahmin edilen değer ile gözlenen değer arasındaki fark artık olarak tanımlanır. Catboost algoritması temel olarak artık kaymaları önlemeye çalışır [88].

Kategorik Değişkenlerin Prosesi: Makine öğrenimi algoritmaları kategorik değişkenleri tanımlayamaz. Bu nedenle, kategorik değişkenler sayısal değerlere dönüştürülmelidir. Standart algoritmalarda kategorik değişkenleri önceden işlerken sorunlar ortaya çıkar. Bunun için ortak bir çözüm, tüm nominal değerleri ikili kukla değişkenlere (bir sıcak kodlama) dönüştürmektir. Ancak, bu özellik kümenizi hızla büyütebilir/patlayabilir [88].

Gradyan arttırılmasında kategorik değişkenlerin kullanılmasını en verimli ve en etkin yollarından birisi de kategorileri hedef istatistiksel verilere dönüştürmektir. Hedef istatistiklerin kendini basit bir istatistiksel modeldir. Aynı zamanda hedef kayıplarına ve tahmin değişikliğine sebep olabilmektedir. Catboost, nominal bir değişkenin (ör. uyruk) her bir kategorisi (ör. Hollandalı, Alman, Belçikalı) için hedefe dayalı bir istatistik hesaplar. Bu hesaplama için izlenen adımlar şunlardır [88]:

1. Kategorik bir özellik başlar (örneğin, milliyet). Buna x denir.
2. Rastgele seçilen bir satırda (eğitim veri setindeki k satırı), bu kategorik özellik (örn. düzeyi) rastgele bir sayı ile değiştirilir (örneğin Hollandaca 5).
3. Bu sayı (bizim örneğimizde 5) genellikle kategori düzeyine göre hedef değişkene (hedef değişken tahmin edilecektir) dayanmaktadır. Başka bir deyişle, hedef sayı, beklenen sonuç değişkenine dayanmaktadır.
4. Split özneliği iki eğitim veri seti oluşturmak için kullanılır: ilk set tüm kategorileri içerir (örn. Almanca, Fransızca, Hintçe, vb.). Bu kategoriler, 3.

adımında hesaplanan hedef değişkenlerden daha büyüktür. Diğer grup ise daha az veya daha küçük hedeflerden oluşuyor.

3. adımda bulunan sayı sadece random bir değişken değil, aynı zamanda hedefe dayalı bir istatistiğe (TBS) dayanmaktadır. Hedefe dayalı istatistikler dört farklı şekilde hesaplanabilir: Açgözlü, Uzak Duran, Bir Dışarıda Bırakılan ve Sıralı. Catboost tarafından sipariş edilen TBS'yi kullanır. Sıralı TBS yaklaşımı, geçmişin geleceği etkilediği varsayımına dayanmaktadır. Catboost'ta, odak satırından önceki satırların sırası rastgele belirlenir ve hedef istatistiği (TBS) hesaplamak için kullanılır. Bu birkaç kez tekrarlanır (Kategori verileriyle çalışmaya başlayın: Catboost, n.d.). 3. adımdaki sayı yalnızca rastgele bir değişken değil, aynı zamanda hedefe dayalı bir istatistiğe (TBS) dayanmaktadır. Hedefe dayalı istatistikler dört farklı şekilde hesaplanabilir: Açgözlü, Uzak Duran, Bir Dışarıda Bırakılan ve Sıralı. Catboost tarafından sipariş edilen TBS'yi kullanır. Sıralı TBS yaklaşımı, geçmişin geleceği etkilediği varsayımına dayanmaktadır. Catboost'ta, odak satırından önceki satırların sırası rastgele belirlenir ve hedef istatistiği (TBS) hesaplamak için kullanılır [88].

3.3.2. LightGBM Algoritması

Light Gradient Boosting (LightGBM) algoritmasında, karar ağaçlarını kullanmakta olan diğer bir gradyan arttırma modeli bulunmaktadır. Analiz süreçlerinde diğer karar ağaçları dikey bir şekilde adlandırılır iken, LightGBM yapraklar arasında yatay olarak dallanır. Karar ağacı, en büyük delta değerine sahip yapraktan dallanmaya devam etmektedir. Diğer gradyan artırma modelleriyle karşılaştırıldığında LightGBM, hızlı işleme, daha büyük verileri işleme ve daha az bilgisayar belleği (RAM) ile analiz gerçekleştirme gibi avantajlara sahiptir. LightGBM modelinin bir diğer avantajı da kategorik değişkenlerle verileri sayısal olarak analiz etmek için tek-sıcak kodlama gibi işlemler gerektirmemesidir. LightGBM, büyük veri kümelerinde daha iyi sonuçlar verir, çünkü veri kümesindeki diğer modellere göre fazla takmaya daha kolay izin vermektedir. Çeşitli veri seti üstünde yapılan araştırmalarda “LightGBM” modelinin veri öğrenme sürecinde, diğer modellere göre 20 kat daha çok hızlı olduğu görülmüştür [85].

3.3.3. XGBoost Algoritması

Extreme Gradient Boosting'in kısaltması olan XGBoost, gradyan artırma ve karar ağacı algoritmasına dayanan bir makine öğrenme modelidir. XGBoost algoritması orijinal versiyonu 2002 senesinde "Friedman" tarafından geliştirildiği bilinmektedir. Daha sonrasında, "Washington Üniversitesi"nden 2 araştırmacı olan "Tianqi Chen ve Carlos Guestrin" tarafından "2016 SIGKDD (Bilgisayar Makinelerinin Bilgi Keşfi ve Veri Madenciliği için Özel İlgi Grubu Derneği" konferansında bir makale olarak sunulmuştur ve makine öğrenimi de bundan sonra popüler olmuştur [89].

XGBoost herkes tarafından bilinen bir algoritmadır. Büyük bir çoğunluk ile "Kaggle" araştırmalarında tercih edilmektedir. Sağlık, enerji ve finans vb. pratiklerde uygulama alanı bulmuşlardır. Bu diğer algoritmalar göre performans ve hız yönünden oldukça avantajlıdır. Aynı zamanda XGBoost, diğer algoritmalara göre yüksek tahmin gücü bulunmaktadır ve diğer algoritmalarından on kat daha hızlı olduğu belirtilmektedir. Tüm bunlara ek olarak XGBoost genel performansların iyileşmesini sağlayan, fazla takmamayı ve fazla öğrenmeyi azaltan bir dizi düzenleme içermektedir [89].

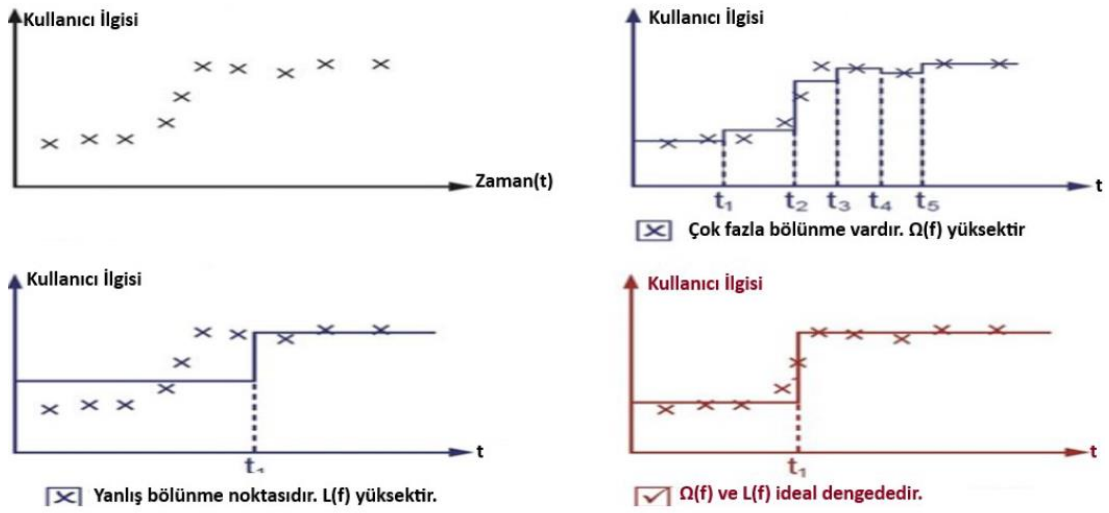
Gradient Boost, çok güçlü bir sınıflandırıcı oluşturabilmek için bir dizi zayıf sınıflandırıcıyı güçlendirmesi ile birleştiren, bir topluluk yöntemi olarak bilinmektedir. Güçlü bir öğrencinin, kolay öğrencilerden başlayarak yinelemeli olarak eğitilmektedir. Hem gradyan hem de XGBoost aynı prensibi takip etmektedir. Arasındaki temel farklar, uygulamanın ayrıntılarında yatmaktadır. XGBoost, farklı düzenleme tekniği kullanarak ağaçların karmaşıklığının kontrol ederek, daha verimli ve etkin bir performans elde etmektedir [89].

XGBoost açık kaynaklı bir yazılım kütüphanesi olup,

1. Komut satırı arayüzü (CLI),
2. C ++ (kütüphanenin yazıldığı dil),
3. Python arayüzü ve scikit-learning'de bir model,
4. R arayüzü ve "caret" paketindeki bir model,
5. Julia,

6. Scala gibi Java ve JVM dilleri,
7. Hadoop.

Şekil 3.4.'teki grafikler ise; Girişler birinci diyagramda gösterilmektedir, ikinci diyagramda çok fazla bölme noktası olduğundan düzenlilik yüksektir, üçüncü diyagramda yanlış bölme noktası tarafından kesildiği için kayıp fonksiyonu yüksektir ve son olarak dördüncü diyagramda, düzenleştirme ve kayıp fonksiyonlarının dengede olduğu görülebilir.



Şekil 3.4. En uygun karar sınırları [2].

Bir XGBoost modelini eğitirken iyi sonuçlar elde etmek için önemli bir faktör parametre ayarlamadır. Modeli; İki adımdan oluşur: ilk olarak XGBoost'un genel olarak ne kadar iyi performans gösterdiğini gözlemlemek için bir temel model geliştirilir ve ardından sonuçları temel modelle karşılaştırarak parametre ayarlama kullanılarak ikinci bir model eğitilir. Parametre ayarlama yaklaşımı, genel Gradyan Artırma Makinesininkine benzer. İlk olarak, eğitimi hızlandırabilmek için daha verimli bir öğrenme oranı kullanılmaktadır. Daha sonrasında ağaca özgü parametreler ayarlandıktan sonra ve son olarak öğrenme oranı düşürülmektedir. Bunun ardından, optimal sınıflandırıcıların kümesini elde edebilmek için eğitilmektedir [90].

XGBoost, Gradient Boosting Machines gibi zayıf öğrenenler kullanır ve zayıf öğrenenler, gradyan iniş yöntemiyle desteklenir. XGBoost çoğu algoritmadan üstün olsa da GBM'lere göre avantajı özellikle hem algoritmik hem de sistem optimizasyonundaki (donanım ve yazılım) iyileştirmelerden kaynaklanmaktadır [90].

XGBoost, paralelleştirme yoluyla sıralı karar ağaçlarını çok daha hızlı oluşturur. Bunu yapabilme yeteneği, çekirdek öğrenciler oluştururken iç ve dış döngüler arasında geçiş yapabilmesidir. Normalde, dış döngüler karar ağacının yapraklarını oluştururken, iç döngüler özellikleri hesaplar. Ancak paralelleştirme sınırlıdır, çünkü dış döngüler, iç döngüler tamamlanmadan tamamlanamaz, yani öznitelikler hesaplanmadan ağacın yaprakları oluşturulamaz. Algoritmanın işlem süresini azaltmak için tüm örnekler bir arada ele alınarak algoritmadaki giriş sayısı belirlenir [91].

XGBoost, düzenlileştirmeye sahip olduğu için aşırı öğrenmeyi veya aşırı uyumluluğu azaltmaya yardımcı olur. Ayrıca yüksek esnekliği sayesinde bu algoritma, kullanıcıların modele yeni bir boyut katan kriterleri değerlendirmesine ve en uygun amaç fonksiyonunu tanımlamasına olanak tanımaktadır [92].

XGBoost'un bir diğer faydası ise; herhangi bir kullanıcının yükseltme süreçlerinin her yinelenmesinin doğrulanabilmesine ve böylesine tek bir araştırmada tam anlamı ile, en uygun yükseltme yineleme sayılarının azalmasına izin verilmesi kolaydır [93].

Çapraz doğrulama, ile makine öğrenme testinin hatasını daha iyi tahmin edebilmek için, modelin seçilmesinde kullanılan birer tekniktir.

XGBoost, Sparsity Awareness ile kayıp gözlem değerleri otomatik olarak artış göstermektedir. Gerçek veri setinde birçok yerde yaygın olan bu durum içinde, işlevsel olarak oldukça kullanışlıdır. Eksik gözlem sebebiyle, bütün örneğin atılması, veri kümelerinin boyutunu etkilemektedir. XGBoost algoritması, eksik değerleri tahmin edebilmek için “enterpolasyon” kullanmaktadır [94].

XGBoost'un bir başka avantajı da derin öncelikli aramadır. Bu algoritmada ağaç yapılarını arayabilmemiz için, kullanılmış olan bir algoritma türüdür. Aramaya başladığı andan itibaren, düğümlerde ulaşabileceği en derin düğüme gitmektedir. Daha derin düğüm yok ise, geri sarmaktadır ve derin düğümler ile öncelik vererek devam etmektedir. Daha basit bir ifade ile, bu algoritmalarından önce alt düzey komşuları aramaktadırlar. XGBoost'un bu faydaları Şekil 3.4.'te basitçe gösterilmiştir.



Şekil 3.5. XGBoost'un standart GBM'yi optimize etme yolları [90].

XGBoost için kullanılan bazı parametreler aşağıdaki gibi sıralanır.

1. Max_depth: Ağacın derinliğini kontrol eder.
2. Eta: Öğrenme oranını kontrol eder. 0 ile 1 aralığında değer alır. Genellikle 0.01-0.3 arasında iyi sonuç verir.
3. Nthread: Paralel hesaplamayı etkinleştirir.
4. Nround: Gereken maksimum yineleme sayısını kontrol eder.
5. Gamma: Aşırı öğrenmeyi engeller.
6. Subsample: Bu, her bir ağacı eğitmek için kullanılan eğitim örneklerinin rastgele seçilen kısmıdır.
7. Colsample_bytree: u, her bir ağacı eğitmek için kullanılan niteliklerin rastgele seçilmiş bölümüdür. Her bir ağacı oluştururken sütunların alt örnek oranını ifade

eder. Alt örnekleme, oluşturulan her ağaç için bir kez gerçekleştirilir. Başka bir deyişle, bir ağaca sunulan özelliklerin (değişkenlerin) sayısını kontrol eder. 0 ile 1 aralığında değerler alır.

8. Colsample_bynode: Her düğüm için sütunların alt örnek oranını belirtir. Alt örnekleme, her yeni bir bölünmede yeniden değerlendirilir.

XGBoost parametrelerinin en uygun değerlerinin seçilmesi, performans kriterleri için iyi sonuçlar elde etmeyi amaçlar. XGBoost algoritmasını farklı parametrelerle kullanmak mümkündür. XGBoost algoritmasının son zamanlardaki yaygın kullanımı, literatürdeki sağlık, biyolojik, finans ve çevresel alanlardaki çalışmalar incelenerek ve benzer çalışmalarla karşılaştırılarak değerlendirilmiştir.

3.3.4. Gradient Boosting Algoritması

Extreme Gradient Boosting (XGBoost) algoritması, gradyan artırma algoritmasının performans ve sonuçların çalışma hızı açısından geliştirilmiş bir versiyonudur. Makine öğrenimi problemlerini çözmek için kullanılan bir dizi algoritmadır. Az miktarda kaynakla milyonlarca örneği çözebilen verimli bir algoritmadır. 2014 yılında Tianqi Chen tarafından geliştirilmiş ve açık kaynaklı makine öğrenme algoritmalarını içeren DMLC (Distributed Machine Learning Community) adlı kütüphaneye eklenmiştir [95].

XGBoost algoritması, çok fazla veriyi kısa zamanda analiz edebilmektedir. Ayrıca diğer algoritmalara kıyasla az işlem gücü harcadığı ve geçici depolama (RAM) kullandığı için birçok makine öğrenmesi ve veri analizi problemini çözerken tercih edilen algoritma olmuştur. Örnek verilecek olunursa, Avrupa Nükleer Araştırma Merkezi (CERN), Büyük Hadron Çarpıştırıcısı tarafından üretilen 3 petabaytlık (PB, 1024 terabayt) yıllık veriyi analiz etmek için XGBoost algoritmasını kullanmıştır [96].

Light Gradient Boosting (LightGBM) algoritması, karar ağaçlarını kullanan başka bir gradyan artırma modelidir. Analiz sürecinde diğer karar ağaçları dikey olarak dallanırken, LightGBM yapraklar arasında yatay olarak dallanır. Karar ağacı, en büyük delta değerine sahip yapraktan dallanmaya devam eder. Diğer gradyan artırma

modelleriyle karşılaştırıldığında LightGBM, hızlı işleme, daha büyük verileri işleme ve daha az bilgisayar belleği (RAM) ile analiz gerçekleştirme gibi avantajlara sahiptir. LightGBM modelinin bir diğer avantajı da kategorik değişkenlerle verileri sayısal olarak analiz etmek için tek-sıcak kodlama gibi işlemler gerektirmemesidir. LightGBM, büyük veri kümelerinde daha iyi sonuçlar verir, çünkü veri kümesindeki diğer modellere göre fazla takmaya daha kolay izin verir. Farklı veri setleri üzerinde yapılan çalışmalarda LightGBM modelinin veri öğrenme sürecinin diğer modellere göre 20 kat daha hızlı olduğu tespit edilmiştir [96].

3.3.5. Adaboost

Ensemble algoritmalarına ait olan bu yöntemle veri seti, torbalama yönteminde olduğu gibi rastgele parçalara ayrılmaktadır. Her parça farklı bir algoritma kullanılarak öğrenilir ve test edilir. Test sonucunda yanlış tahmin edilen veri parçaları farklı bir algoritma kullanılarak yeniden öğrenilir ve tekrar test edilir. Sistem her seferinde doğru tahmin ettiği sonuçları alarak yoluna devam etmektedir [96].

3.4. LİTERATÜR

Mustapha ve Saeed 2016 yılında yaptıkları çalışmada, farklı veri kümelerini tahmin etmek için Random Forest (RF), Lineer Support Vector Machines (LSVM), Radial Basis Function Neural Network (RBFN), Naive Bayes (NB) algoritmaları ve XGBoost'u yedinci biyolojik aktiviteye uygulamışlardır. Deneysel sonuçlar, XGBoost'un heterojen verilerde %94.47 doğruluktan homojen verilerde %98.49'a kadar değişen etkileyici doğruluk ürettiğini göstermiştir [97].

Chen et al. 2017 yılında yayınladıkları çalışmada büyük veri setinin radar verici veri setinde Support Vector Machines, Weighted-XGBoost ve Gboost algoritmalarını kullanmış ve Weighted-XGBoost'ta %98.3 doğru sınıflandırma oranı ile en iyi sonucu elde etmiştir [98].

2017 çalışmasında, Fitriah ve ark. Beynin farklı bölgelerindeki elektriksel aktiviteyi ölçmeyi ve aktiviteyi görsel bir iz gibi kaydetmeyi mümkün kılan elektroensefalografi

(EEG) kullanarak felç tespiti. Bu çalışmada, temel bileşen analizi uygulanırken XGBoost ile uygulanmadığında XGBoost'un doğru sınıflandırma oranları karşılaştırılmıştır. Dokuz çift kanal için elde edilen sonuçlarda temel bileşen analizini kullanmanın hem test hem de eğitim veri setlerinde doğru sınıflandırma oranını arttırdığını bulmuşlardır [99].

Priyadarshini, 2017 yılında yaptığı çalışmada XGBoost algoritmasını kullanarak diabetes mellitus tahminini elde etmeyi amaçladı. Modelin performansı XGBoost parametreleri kullanılarak değerlendirildi. İlk yinelemeden sonra modelin doğruluğu %77 idi, ancak birçok yinelemeden sonra modelin doğruluğu kademeli olarak %77'den %90'a yükselmiştir [100].

Choi et al. Anlık uykululuğu izlemek ve her duruma özgü anlık dalga değişikliklerini yakalayarak uyanıklık, uyuşukluk veya uyku arasında ayırım yapmak için 2018 çalışmasında elektroensefalografiyi (EEG) kullandı. EEG'nin kısa bir zaman çerçevesini kullanarak hipersomniyi tespit etmek için önerilen yeni yöntemde, makine öğrenimi amacıyla uykululuğu etiketlemek için önce psikomotor farkındalık görevinin ve elektrokülografi tekniklerinin faydalarını birleştirdiler. Ayrıca, EEG'nin kısa bölümünden özellik çıkarmak için Çok Amaçlı Güç Spektral Yoğunluğu (MPSD) ve bir makine öğrenme sınıflandırıcısı olan XGBoost kullanıldı [101].

Mitchell ve diğerleri, 2018 çalışmalarında, gradyan artırma algoritmasının diğer bölümleri için özellik kümelerine ve paralel algoritmalara dayalı önemli ölçüde daha hızlı ve daha verimli bir bellek karar ağacı algoritması sundular. XGBoost GPU algoritmasının, uçtan uca gradyan artırma hattını çalıştırmak için GPU üzerinde karar ağacı oluşturma, nicel üretim, tahmin ve gradyan hesaplama algoritmaları uygulayarak büyük bir veri setinde yüksek doğruluk ve düşük çalışma süresi ve bir öğrenme görevi gösterdiğini bulmuşlardır [106].

Wang ve Guo, 2019'da yayınladıkları ECG-PPG'ye dayalı fizyolojik özellik füzyonu ve XGBoost sınıflandırmasını kullanarak öğrencilerin bilişsel yük algısı için veriye dayalı bir çerçeve geliştirmek için çalıştı. İlk olarak, doğrusal öznitelik bağımlılık modellemesini kullanan bir öznitelik birleştirme şeması ve önceden işlenmiş EKG ve PPG sinyallerinden kalp hızı değişkenliğini ve darbe değişkenliğini tahmin ederek ve

ardından bu deęişkenlerden öznitelikler çıkararak XGBoost sınıflandırıcısını kullanan bir bilişsel stres durumu sınıflandırma şeması öneriyorlar. Destek Vektör Makineleri, k-En Yakın Komşu, Karar Ağaçları, Rastgele Orman, XGBoost algoritmalarını kullanarak en iyi sonucu %97,2 ile XGBoost ile elde etmişlerdir [108].

Zhang et al. 2019 yılında yayınladıkları çalışmada rulman yatağı arıza teşhisine XGBoost algoritmasını uygulamışlardır. XGBoost'u diğer ağaç algoritmaları olan Random Forest, Adaboost ve Gradient Boosting Decision Tree ile karşılaştırdılar ve sonuç olarak XGBoost algoritmasının doğruluk ve zaman açısından diğer algoritmalarından üstün olduğunu gösterdiler [110].

2019 yılında yayınlanan çalışmalarında Chang ve ark. hastanın tespit indeksine göre, bir hastanın kan basıncı kategorisinin kümeleme algoritması kullanılarak belirlenebileceğini ve XGBoost yöntemiyle kombinasyon halinde hastanın hipertansiyona bağlı farklı semptomlara sahip olmasının muhtemel olduğunu belirtiyor. Yeni bir hastada, kümeleme algoritmasını kullanarak kategoriye belirledikten sonra, doktorun bu araştırmanın sonuçlarına dayanarak olası semptomları tahmin edebileceğini belirttiler. Bu çalışmada Çin'deki 531 hipertansif hastadan 334'ü eğitim verisi, 197'si test verisi olarak kabul edilmiş ve XGBoost yöntemi uygulanmış ve %98.48'lik doğru kümeleme sınıflandırma oranını elde etmişlerdir [111].

Chen et al. 2019 çalışmasında HIV-1 tropizmini tahmin etmek için XGBoost ve gizli Markov modellerini kullandı. Bu çalışmada, her iki algoritma için beş farklı veri seti uygulamışlardır. Performans metrikleri arasında özgüllük, doğru sınıflandırma oranı, Matthew korelasyon katsayısı (MCC) ve eğrinin altındaki alan (AUC) açısından XGBoost en iyi sonuçları elde etti [112].

Guo et al. 2019 çalışmalarında, ergenlerin giyilebilir koşu takibinde kullanılabilecek makine öğrenimi tabanlı bir fiziksel uygunluk değerlendirme modelini, 14 yaşındaki kadınlardan ve 288 erkekten PPG sinyallerinin toplandığı aktivite tabanlı deneysel bir paradigmaya uyguladılar. Akıllı bantlardan PPG sinyalleri toplama. Bu özelliklere göre Random Forest, k-en yakın komşu, destek vektör makineleri, karar ağaçları ile çalıştırılan erkek ve dişiler için sırasıyla %98,1 ve %96,4 doğru sınıflandırma oranları

ile erkek ve diři doğru sınıflandırma oranları en iyisidir. Gradient Boost Karar Ağaçları ve XGBoost Algoritmaları XGBoost sonucu sağladı [113].

Hosni'nin 2019 çalışması, kötü amaçlı yazılımdan koruma sistemlerinin yanıt verme hızını ve performansını iyileştirmek için ve birden çok kötü amaçlı yazılım türüyle uğraşırken bu süreci otomatikleştirme ihtiyacını açıkça göstermektedir. Beş öğrenme algoritması, kötü amaçlı dosya sınıflandırma performansı açısından istatistiksel olarak karşılaştırıldı. Burada tartışılan algoritmalar ve metrikler arasında XGBoost, %99.5'lik Doğruluk Puanı performans ölçümleriyle en iyi performansı gösterdi [114].


3.5. ÖNERİLEN MODEL

3.5.1. Veri Seti

Yapılan araştırmada, internet sitelerinde paylaşımı yapılan Türkçe haberler toplanılarak, doğruluđu teyit edilmesinin ardından, daha önce de literatürde yer alan Türkçe veri setleri eklenmiştir. Haberlerdeki doğrulukların kontrol edilebilmesi için “Teyit.org” sitesinden faydalanılmıştır. Bu sitede “IFCN (International Fact-checking Network)” sertifikasına sahip olan haber doğrulama sitesi olarak bilinmektedir [13] Şekil 3.5'te kullanılmış olan veri seti hakkında bilgiler yer almaktadır. Kullanılmış olan veri seti “3007” satırdan ve 2 sütundan oluşmaktadır.

	Body	Label
0	\nPazar sabahı Donald Trump, kendi partisinin ...	1
1	LONDRA (Reuters) - Aktör Bryan Cranston, Londr...	1
2	Geçtiğimiz hafta Bay Corker, Bay Trump'ın danı...	1
3	MEKSİKA ŞEHİRİ (Reuters) - Mısır'ın Cheiron Hol...	1
4	Las Vegas çekimleri başlarken performans sergi...	1
...
95	Matt Agorist tarafından\nBirkaç dakika önce, M...	0
96	Perşembe Gecesi Futbol Oyunlarına Bir Bakış\n(...	0
97	Telif hakkı Getty Images Image caption Futbol,...	1
98	Seattle Üniversitesi ve Fred Hutchinson Kanser...	0
99	Maria Kasırgası nedeniyle hasar gören binalar,...	1

Şekil 3.6. Kullanılan veri kümesinin gösterimi.

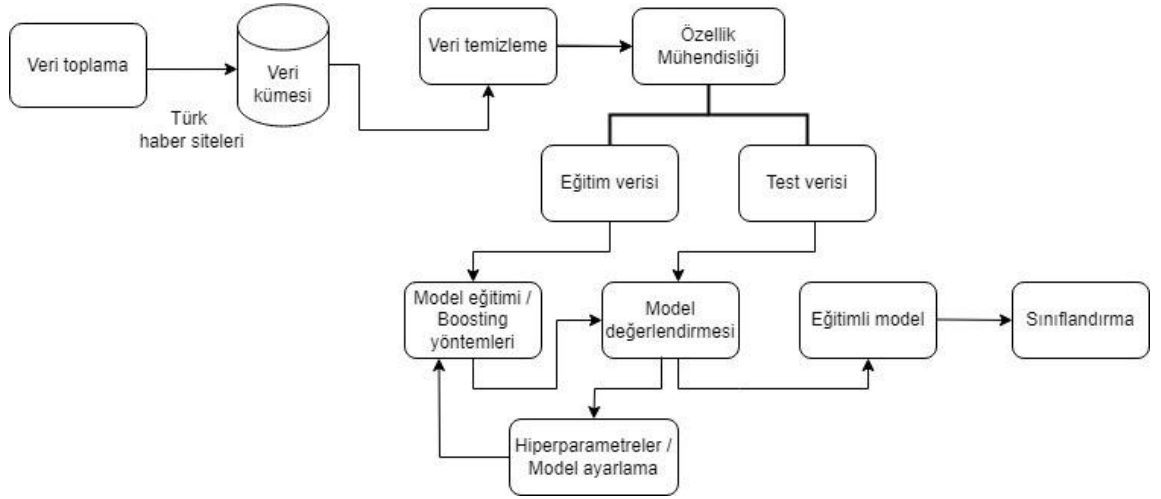


Şekil 3.7. Sahte ve gerçek haberlerin yüzdesel gösterimi.

Denetimli makine öğrenme yöntemlerinin yapımı için, verilerin etiketli olması gereklidir. Bu nedenle toplanılan veriler sahte veya gerçek olarak etiketlenmektedir. Veri setinde kullanılması için de 1399 tane sahte haber, 1591 tane gerçek haber etiketlenmiştir. Şekil 3.7'de kullanılmış olan veri seti sahte ve gerçek haberlerin dağılımı verilmektedir.

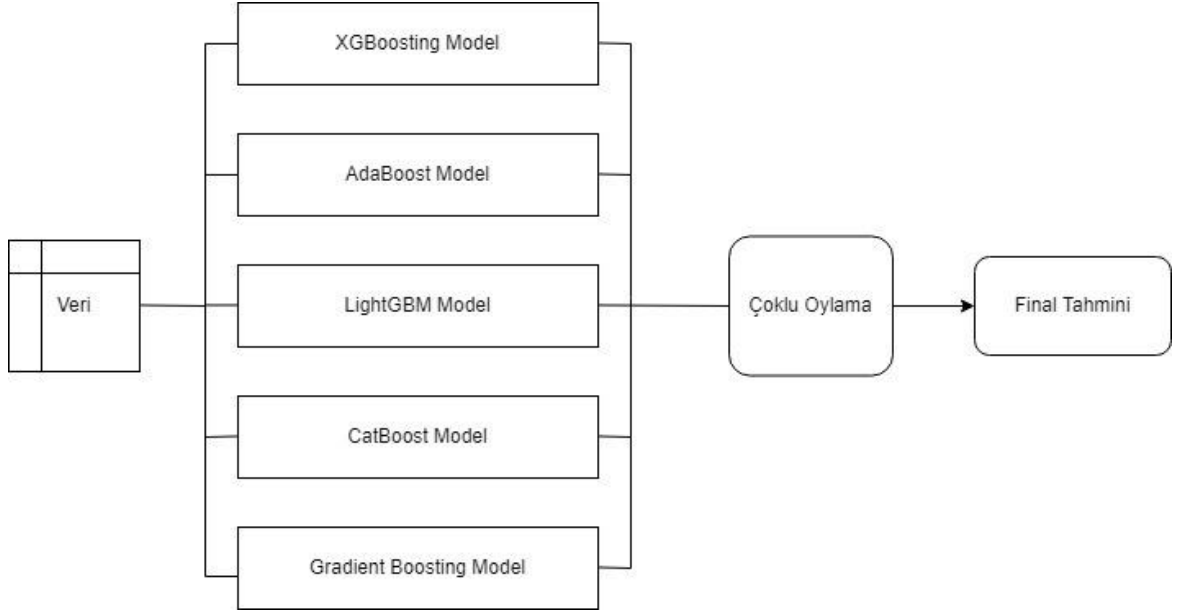
3.5.2. Önerilen Model

Önerilen model, Şekil 3.7’de gösterildiği gibi, Türkçe haber sitelerinin tamamında alınan haberlerin sahte ya da gerçek etiketi ile sınıflandırabilmek için, birbirinden farklı “Boosting Yöntemleri” tanıtılarak mevcut literatürün genişletilmesi sağlanmıştır.



Şekil 3.8. Sahte haber sınıflandırılması için önerilen model.

Şekil 3.8’de yer alan modele ek olarak, birçok çeşitli bağımsız model topluluğundan öğrenilen ve yüksek olasılıklara dayanan bir çıktığı sınıfı tahmin eden oylama teknikleri olan “soft voting tekniği” kullanılarak model üstündeki etkisi Şekil 3.9’da yer alan akışa göre takibi yapılmıştır.



Şekil 3.9. Önerilen modelin geliştirilmiş hali.

3.5.3. Katkı/özgünlük Özeti ve Sınırlaması

Öncelikli katkımız “Sahte Haber Tespiti” sorunu için çözüm önerileri olarak sunulmakta olan model “Boosting” yöntemlerinden elde edilmiş sonuçların neticesinde meydana gelmektedir. Deneysel kapsamda 5 farklı makine öğrenim algoritmalarına dayalı olarak oluşumu gerçekleştirilmiştir ve “CatBoost, AdaBoost, XGBoost, LightGBM ve Gradient Boosting Algoritmaları” ile Türkçe haberlerin üstünde çalışılmamıştır. Literatürde yer alan çözüm önerileri ile bu araştırmada olduğu “ML Tabanlı veya Yapay Sinir Ağı” tabanlı olarak çözümü sağlanmıştır. Kullanılan ML modelleri “SVM, k-NN, Random Forest” vb. algoritmaları ile sınırlıyken, bu araştırmada çeşitli algoritmaların denemesi yapılmıştır. Elde edilen sonuçlar, performans değerlendirme metrikleri ile doğrulaması yapılmıştır. Başarının artırılması için, en iyi modeli ortaya çıkarabilmek için “Soft voting” işlemi yapılmaktadır. 2’nci katkımız ise, Türkçe haber sitesinde haberler toplanılarak literatürde bulunan veri setlerine eklemeler yapılmıştır. Açık kaynak olarak da veri setinden faydalanılmıştır.

3.5.4. Bulgular

Sahte haber sorunları günümüzde internetin yaygınlaşmasına bağlı olarak sosyal medya platformlarının herkes tarafından kullanımının yaygınlaşmasına bağlı olarak ortaya çıkmıştır. Sosyal medya kullanıcılarının herhangi bir haberi paylaşma özgürlüğü bulunduğundan ve uzmanlar bu haberlerin sayısının çok fazla olduğundan bahsetmesi sebebiyle, manuel olarak sahte haber tespitleri yetiştirilmemektedir. Sahte haberlerin tespiti yapılmaya kadar, internette yaygınlaşmaktadır. Haberin doğrulukları araştırılmadan, buna inan bireyler mağduriyet yaşamaktadırlar. Sahte haberin yayılmasındaki en büyük amaç, bireylerin arasında güvensiz ortamların oluşturulması, bireyleri kandırmaya çalışmak ve art niyetli davranışlar göstermektedir. Bunların engelleyebilmek için de “Sahte Haber Tespit Sistemleri” geliştirilmeye başlanmıştır. Türkçe haber sitesinden alınan haberlerin hepsi “teyit.org” web sayfasından kontrol edilerek sahte ve gerçek etiketi ile etiketlenmiştir. Veriler ön işleme yapılmasının ardından, metinsel ifadelerin vektörel ifadeler dönüştürülmesiyle, ilk olarak “Tf-Idf ve Word2Vec vektör uzay modellerinden” yararlanılmıştır. İkinci olarak tercih edilen ve kelimeleri vektör uzayında ifade etmeye çalışan Word2vec modeli oluşturulmuştur. Bunun ardından veri setleri “%70 eğitim seti, %30 test seti” ayrılarak kullanılmaktadır. Sahte haberlerin tespit edilebilmesinde “Boosting Yöntemlerinden” faydalanılmıştır. Bulunan değerler literatürde yapılmış olan çalışmalardaki değerlere göre, daha iyi sonuçlar göstermektedir. Bunun nedeni olarak da “optimal hiper parametreler” bulunmuş olduğu için, modellerin daha iyi sonuçlar gösterdiği görülmektedir. Genel olarak da “XGBoost” modeli diğer modellere göre daha iyi sonuçlar vermektedir. Ama daha önce de belirtmiş olduğumuz gibi, yumuşak oylama yapılarak daha iyi sonuçların alındığı kanıtlanmıştır. Değerlendirmede, çoğunluk oylama tekniğiyle kişisel öğrenme tekniklerine kıyas ile, daha kabul edilir sonuçların elde edildiği doğrulanmaktadır. Yukarıda bahsetmiş olduğumuz sınıflandırmalarda kullanılarak, daha doğru sonuçlara ulaşılması için, çoğunluk oylama teknikleri kullanılarak, çok modelli bir sahte haber tespit sistemi yapılmıştır. Aşağıda bulunan çizelgede görülmüş olduğu üzere, değerlendirme “Çoğunluk Oylama tekniğinin” kişisel öğrenme tekniğine kıyas ile daha fazla kabul edilir sonuçları elde ettiğini doğrulamaktadır.

Çizelge 3.1. TF-IDF kelime vektörüne dayalı performans değerlendirme çıktıları.

Sınıflayıcı		Kesinlik	Duyarlılık	F1-score	Doğruluk
LightGBM	0	0.95	0.95	0.96	0.94
	1	0.96	0.99	0.97	0.94
CatBoost	0	0.95	0.96	0.93	0.95
	1	0.96	0.99	0.96	0.95
AdaBoost	0	0.94	0.97	0.95	0.96
	1	0.94	0.97	0.96	0.96
GBDT	0	0.95	0.93	0.95	0.96
	1	0.94	0.96	0.96	0.97
XGB	0	0.95	0.95	0.97	0.97
	1	0.96	0.97	0.97	0.97

Çizelge 3.2. Word2Vec kelime vektörüne dayalı performans değerlendirme çıktıları.

Sınıflayıcı		Kesinlik	Duyarlılık	F1-score	Doğruluk
LightGBM	0	0.92	0.87	0.89	0.89
	1	0.86	0.91	0.89	0.89
CatBoost	0	0.88	0.88	0.89	0.88
	1	0.86	0.87	0.86	0.88
AdaBoost	0	0.84	0.83	0.84	0.83
	1	0.81	0.82	0.84	0.83

GBDT	0	0.87	0.82	0.85	0.85
	1	0.81	0.86	0.84	0.85
XGB	0	0.89	0.88	0.89	0.89
	1	0.87	0.88	0.89	0.89

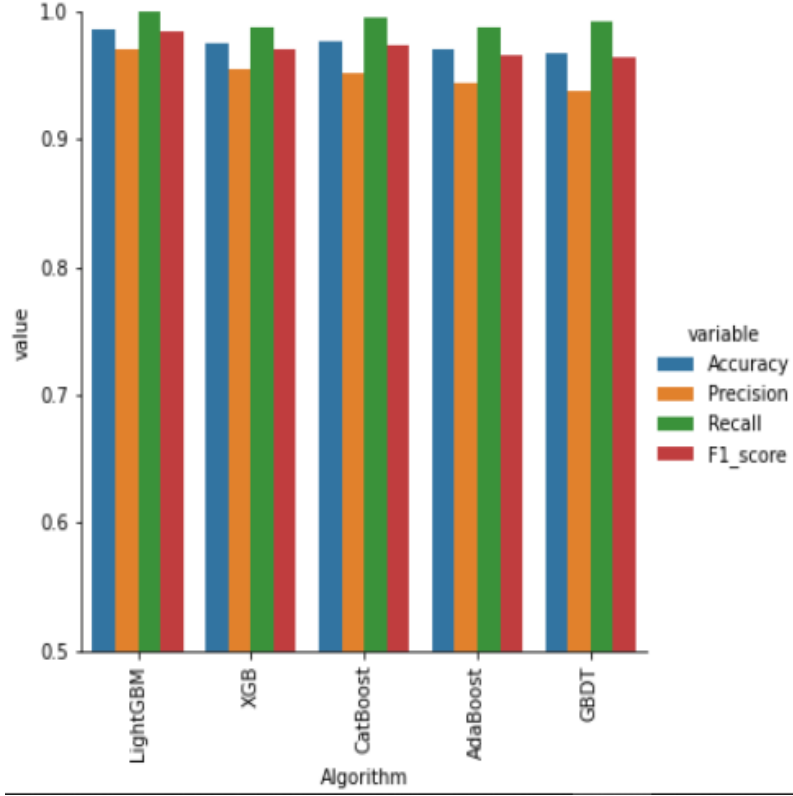
Yapılan tez çalışmasında bulunan sonuçlarda, literatürde yer alan sonuçlara göre, daha başarılı sonuçlar vermektedir. Yapılan araştırmada veri setleri çeşitli olduğu, ihmal edilmemesi gerekmektedir. Kategorilere göre elde edilen başarı oranları Çizelge 3.2’de verilmiştir. TF-IDF için en iyi başarı oranlarını veren XGBoost Algoritmasıdır. Word2Vec için en iyi başarı oranlarını veren XGBoost Algoritması Çizelge 3.3’te verilmiştir. Çalışmanın sonucunda TF-IDF ve Word2Vec ile elde edilen vektör modellerinin sınıflandırma başarı oranlarının birbirine çok yakın olduğu izlenmiştir.

Çizelge 3.3. k-Kat çapraz doğrulama kullanılarak elde edilen doğruluk değerleri.

k	LightGBM	CatBoost	AdaBoost	GBDT	XGB
k=1	0.83	0.86	0.88	0.82	0.85
k=2	0.91	0.85	0.83	0.82	0.87
k=3	0.88	0.88	0.80	0.88	0.86
k=4	0.84	0.84	0.85	0.85	0.89
k=5	0.89	0.83	0.87	0.87	0.82
k=6	0.86	0.80	0.81	0.86	0.87
k=7	0.84	0.84	0.84	0.84	0.90
k=8	0.82	0.85	0.92	0.89	0.92
k=9	0.89	0.90	0.76	0.84	0.94
k=10	0.80	0.87	0.78	0.82	0.92

Çizelge 3.4’te her bir algoritma onar kez çalıştırılmaları sonucunda elde edilen değerlerin ortalamaları tablo halinde gösterilmiştir. Sınıflandırma işlemi için uygulanan beş farklı algoritma doğruluk oranlarına (accuracy) göre karşılaştırılmıştır. Algoritmaların başarı oranları, verinin büyüklüğüne, düzenli olup olmadığına, test ve eğitim kümesinde bulunan veri miktarlarına, seçilen kelime ağırlıklandırma yöntemlerine bağlı olarak değişiklik göstermektedir. Fakat bu tezde uygulanan yöntemler, literatürde Türkçe sahte haber tespiti için daha önce kullanılmamış olan

Boosting yöntemleri kullanılmış olup ayrıca tezde kullanılan veriye en uygun olanı seçilerek belirlenmiştir.



Şekil 3.10. Sahte haber veri kümesinde sınıflandırıcıların performans analizi.

Şekil 3.10’da verilen görselde, araştırmada yer alan performans ölçüm metrikleri bütün veri kümesinde öğrenme algoritmalarının ortalama performanslarının grafiksel bir temsilidir.

Çizelge 3.4. Voting classifier ile en iyi sonuç gösterimi.

Accuracy	Precision	Recall	F1_score
0.983	0.966	0.976	0.986

3.6. PERFORMANS ÖLÇÜM METRİKLERİ

DDİ adımlarında ve seçilmiş olan yapay zekâ temelinde algoritmalarının başarılarını değerlendirebilmek için, farklı test ve eğitim yöntemleri kullanılmıştır [32]. Uygulanmış olan test ve eğitim yöntemleri algoritmaların performanslarının değerlendirebilmek için, karmaşıklık matrisleri kullanılarak, farklı performans değerlendirme metriklerinin hesaplaması yapılmıştır. Çizelge 3.6'da performans değerlendirmeleri için hesaplanmış olan karmaşıklık metrikleri ve matematiksel denklemlerle beraber sunulmaktadır.

3.6.1. Modelin Performansının Değerlendirilmesi İçin Kullanılan Metrikler

Eğitilmiş olan modellerin değerlendirmesinde kullanılmış olan yöntemler, performans değerlendirme metrikleridir. Modelin bu değerlendirme sonuçlarına göre, karşılaştırma yapmasını sağlamaktadır. Genel olarak 2'li sınıflandırmalar için oluşturulmuş olan matrislerin kullanılması ile elde edilmektedir [32].

1. **Doğruluk (Accuracy):** Pozitif ve negatif sınıflarına ait olan doğru sınıflandırılmış verilerin tüm verilere oranıdır. Denklem (3.1)' de doğruluk değerinin hesaplanması verilmiştir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.1)$$

2. **Duyarlılık (Recall):** Pozitif sınıfa ait olan doğru sınıflandırılmış verilerin pozitif sınıfa ait tüm verilere oranına duyarlılık denir. Denklem (3.2)' de duyarlılık değerinin hesaplanması verilmiştir.

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (3.2)$$

3. **Kesinlik (Precision):** Pozitif tahminleme yapılan değerlerin gerçekte ne kadarının pozitif olduğunu yani pozitif sınıfa ait olan doğru sınıflandırılmış verilerin

pozitif olarak etiketlenmiş tüm verilere oranına kesinlik denir. Denklem (3.3)'te kesinlik deęerinin hesaplanması verilmiştir.

$$Kesinlik = \frac{TP}{TP+FP} \quad (3.3)$$

4. **F1 Ölçütü (F1-Score):** Performans deęerlendirme ölçütlerinden duyarlılık ve kesinlięin harmonik ortalamasıdır. Denklem (3.4)'te F1 ölçütünün hesaplanması verilmiştir.

$$F1 \text{ Ölçütü} = 2x \frac{Accuracy \times Precision}{Accuracy+Precision} \quad (3.4)$$

BÖLÜM 4

SONUÇLAR

Türkçe sahte haber tespitinde ve kullanılan algoritmaların karşılaştırılmasında, nispeten yeni araştırmalara başlayan bir konu olmasına karşılık, birden fazla disiplinde kesişim alanına iren önemli bir konu olması sebebiyle, son birkaç sene içinde oldukça farklı ve fazla akademik araştırmalar yapılmaya başlanmıştır. Yapay zeka ve DDİ disiplinleriyle doğrudan ilişkisi olan bilgisayar merkezli sayısal çözümleri düşündüğümüzde, çeşitli dillere özgü olarak geliştirilmiş olan projelerin, uygulamaların ve kütüphanelerin vb. yenilikçi girişimler ile beraber, akademik araştırmaları ve pratik hayattaki uygulamaların artacağını düşünmekteyiz. Bu yönden çeşitli karakterler içeren ve köklü dilimize ait bir eli parmağını geçmeyecek kadar az bir araştırmanın bulunması, çalışmacıların dikkate alması gereken bir husus olduğunu değerlendirmekteyiz. Dünyada bu alanda yapılan gelişmeler özellikle de metin tabanlı çözümlerin dile özgü kaldığı ve kendi dilini çalışmak isteyen çalışmacılar için, yeni ufukların yaratılacağı ön görülmüştür. Dil kütüphanelerinin ve kaynaklarının gelişmesi uzun bir zaman almaktadır. Kümülatif ve kolektif bir araştırma yapılması gerekmektedir.

Türkçe sahte haber kavramı ve konusu, belli bir araştırma alanı olarak bir konu olmasına karşılık, birden fazla disiplinin kesişmiş olduğu geniş bir havuz barındırmıştır. Bütün insanlığı etkisi altına alan sebepleri ve sonuçların konusu ise çok daha fazla cazip hale getirmektedir. Bu nedenle boosting algoritmalarının yardımı ile sahte haber tespiti yapılırken, alt alanlara bölünüp çalışılması gerekmektedir. Boosting algoritmaları sahte haberin otomatik tespitinde en iyi bilgisayar merkezli sayısal çözüm aracıdır.

DDİ ile ilgili diğerk sorunlarında büyük bir sıklık ile yaşanmış olduđu yenilikçi çözümler geliştiren dil ile sınırlı kalma durumunda, dil kaynaklarını esas alan sahte haberin tespiti hususunda kendini gösterebilmektedir. Bu yüzden dilimiz içinde, dile özgü araştırmalar konusunda, kendini gösterebilmektedir. Bu sebeple, Türkçe dili için sahte haber tespiti araştırmalarının devam etmesi gerekir.

Günümüzde bireylerin en fazla ihtiyaç duymuş olduđu konulardan birisi de doğru bilgilere ulaşabilme ihtiyacı gelmektedir. Kurumlar, kişiler, toplumlar, örgütler vb. için sahte haberler açık bir tehditte dönüşmüştür. Bu yönden sahte haber ile mücadele edebilmek için, bir güvenlik sorunu olarak değerlendirilmesi gerekmektedir. Bu kapsamda, alanımızdaki çeşitli disiplinlerde yapılacak olan araştırmaların geliştirilmesi, toplumumuzun ve devletimizin sahte haberdeki bilgi kirliliğinin korunabilmesi için, önemli katkılar sağlayabilecektir. Sonuç olarak, dijital kütüphanecilik ekseninden önerilen çatılar çerçevesinde araştırmaların günümüzde yayılan haberlerin doğruluğunu araştırmaya yetişemediği ve otomatik tahmin sistemine gerek duyduğu ortaya çıkmıştır. Yapılan çalışmada “Türkçe Sahte Haber Tahmini” yapılarak insanların mağduriyetinin azaltılmasına daha güvenilir ortam hazırlanması hedeflenmiştir. Çalışmada elde edilen çalışmalar literatüre katkı sağlamış, başarılı sonuçlar elde edilmiştir. Böylece dünya genelinde bu alanda öncü olma fırsatını da yaratmıştır.

KAYNAKLAR

1. Buller, D. B. and Burgoon, J. K., “Interpersonal deception theory”, *Communication theory*, 6(3): 203-242 (1996).
2. Weir, W., “History’s Greatest Lies”, Beverly, *Fair Winds Press*, Massachusetts, 28-41 (2009).
3. Gupta, S. and Skillicorn, D. B., “Improving a textual deception detection model”, *Proceedings of the 2006 conference of the Center for Advanced Studies on Collaborative research*, 29-es 2006.
4. Fuller, C., Biros, D., Twitchell, D., Burgoon, J., and Adkins, M., “An analysis of text-based deception detection tools”, *AMCIS 2006 Proceedings*, 418 (2006).
5. Egelhofer, J. L. and Lecheler, S., “Fake news as a two-dimensional phenomenon: a framework and research agenda”, *Annals of the International Communication Association*, 43: 97-116 (2019).
6. Tandoc, E. C., Lim, Jr, Z. W. and Ling, R., “Defining “fake news” A typology of scholarly definitions”, *Digital journalism*, 6: 137-153 (2018).
7. Lazer, D. M., Baum, M. A., Benkler, Y., Berinsky, A. J., Greenhill, K. M., Menczer, F. M., Metzger, J., Nyhan, B., Pennycook, G. and Rothschild, D., “The science of fake news”, *Science*, 359: 1094-1096 (2018).
8. Shu, K., Sliva A., Wang S., Tang J., and Liu, H., “Fake news detection on social media: A data mining perspective”, *ACM SIGKDD explorations newsletter*, 19: 22-36 (2017).
9. Ruchansky, N., Seo, S. and Csi Y. Liu, “A hybrid deep model for fake news detection”, *Proceedings of the 2017 ACM on Conference on Information and Knowledge Management*, 797-806 (2017).
10. Adams, J.S., “Internet Journalism and Fake News”, *Cavendish Square Publishing*, LLC, 2018.
11. Taub, M. Fisher, “Where countries are tinderboxes and Facebook is a match”, *New York Times*, 21 (2018).
12. Douai, “Global and Arab media in the post-truth era: Globalization, authoritarianism and fake news”, *IEMed: Mediterranean Yearbook*, 124-132 (2019).

13. Khaldarova, I. and Pantti, M., “Fake news: The narrative battle over the Ukrainian conflict”, *Journalism Practice*, 10(7): 891-901 (2016).
14. Starbird, K., Maddock, J., Orand, M., Achterman, P. and Mason, R.M., “Rumors, false flags, and digital vigilantes: Misinformation on twitter after the 2013 boston marathon bombing”, *IConference 2014 Proceedings*, (2014).
15. Barbera, P., “Explaining the spread of misinformation on social media: evidence from the 2016 US presidential election”, *Symposium: Fake News and the Politics of Misinformation*. APSA, 2018.
16. Gillin , J., “How Pizzagate went from fake news to a real problem for a DC business”, *PolitiFact*, (2016).
17. Narayanan, V., Howard, P.N., Kollanyi, B., and Elswah, M., “Russian involvement and junk news during Brexit”, *The computational propaganda project. Algorithms*, automation and digital politics. <https://comprop.oii.ox.ac.uk/research/working-papers/russia-andbrexit>, (2017).
18. Ferrara, E., “Disinformation and social bot operations in the run up to the 2017 French presidential election”, *arXiv preprint arXiv:1707.00086*, (2017).
19. Ireton, C. and Posetti, J., “Journalism, fake news & disinformation: handbook for journalism education and training”, *UNESCO Publishing*, 2018.
20. Mertoğlu U., Sever, H. ve Genç, B., “Savunmada Yenilikçi bir Dijital Dönüşüm Alanı: Sahte Haber Tespit Modeli”, 9. *Savunma Teknolojileri Kongresi*, ODTÜ, Ankara, 2018.
21. Chaudhry, A.K. and Baker, D. P., “Thun-Hohenstein, Stance detection for the fake news challenge: identifying textual relationships with deep neural nets”, *CS224n: Natural Language Processing with Deep Learning*, (2017).
22. Masood, R., Aker, A., “The Fake News Challenge: Stance Detection using Traditional Machine Learning Approaches”, *KMIS*, 126-133 (2018).
23. Tacchini, E., Ballarin, G., Della Vedova, M.L., Moret, S., and de Alfaro, L., “Some like it hoax: Automated fake news detection in social networks”, *arXiv preprint arXiv:1704.07506*, (2017).
24. Vosoughi, S., Roy, D. and Aral, S., “The spread of true and false news online”, *Science*, 359:1146-1151 (2018).
25. Mandalios, J., “RADAR: An approach for helping students evaluate Internet sources”, *Journal of Information Science*, 39: 470-478 (2013).
26. Blakeslee, S., “The CRAAP test, LOEX Quarterly”, 31(4): (2004).

27. Rubin, V.L. and Conroy, N., “Discerning truth from deception: Human judgments and automation efforts”, *First Monday*, 17 (2012).
28. Pérez-Rosas, V., Kleinberg, B., Lefevre, A., and Mihalcea, R., “Automatic detection of fake news”, *arXiv preprint arXiv:1708.07104*, (2017).
29. Vosoughi, S., Roy, D., and Aral S., “The spread of true and false news online”, *Science*, 359 1146-1151 (2018).
30. J.P. Friesen, T.H. Campbell, A.C. Kay, “The psychological advantage of unfalsifiability: The appeal of untestable religious and political ideologies”, *Journal of personality and social psychology*, 108(3): 515-529 (2015).
31. Pavleska, T., Školkay, A., Zankova, B., Ribeiro, N., and Bechmann, A., “Performance analysis of fact-checking organizations and initiatives in Europe: a critical overview of online platforms fighting fake news”, *Social media and convergence*, 29 (2018).
32. Tacchini, E., Ballarin, G., Della Vedova, M.L., Moret S., and de Alfaro, L., “Some like it hoax: Automated fake news detection in social networks”, *arXiv preprint arXiv:1704.07506*, (2017).
33. Vosoughi, S., Roy, D., and Aral, S., “The spread of true and false news online”, *Science*, 359: 1146-1151 (2018).
34. Mandalios, J., “RADAR: An approach for helping students evaluate Internet sources”, *Journal of Information Science*, 39: 470-478 (2013).
35. Blakeslee S., “The CRAAP test”, *LOEX Quarterly*, 31(4): (2004).
36. Rubin, V. L. and Conroy, N., “Discerning truth from deception: Human judgments and automation efforts”, *First Monday*, 17 (2012).
37. Pérez-Rosas, V., Kleinberg, B., Lefevre, A., and Mihalcea, R., “Automatic detection of fake news”, *arXiv preprint arXiv:1708.07104*, (2017).
38. J.P. Friesen, T.H. Campbell, A.C. Kay, “The psychological advantage of unfalsifiability: The appeal of untestable religious and political ideologies”, *Journal of personality and social psychology*, 108(3): 515-529 (2015).
39. Pavleska, T., Školkay, A., Zankova, B., Ribeiro, N., and Bechmann, A., “Performance analysis of fact-checking organizations and initiatives in Europe: a critical overview of online platforms fighting fake news”, *Social media and convergence*, 29 (2018).
40. Lahlou, Y., El Fkihi, S. and Faizi, R., “Automatic detection of fake news on online platforms: A survey”, *2019 1st International Conference on Smart Systems and Data Science (ICSSD)*, IEEE, 1-4 (2019).

41. Janze C., Risius M., “Automatic Detection of Fake News on Social Media Platforms”, *PACIS*, 261 (2017).
42. Granskogen, T., “Automatic Detection of Fake News in Social Media using Contextual Information”, Master's thesis, *NTNU*, 2018.
43. Graves, L. and Cherubini, F., “The rise of fact-checking sites in Europe”, 2016.
44. Zannettou, S., Sirivianos, M., Blackburn, J. and Kourtellis, N., “The web of false information: Rumors, fake news, hoaxes, clickbait, and various other shenanigans”, *Journal of Data and Information Quality (JDIQ)*, 11: 1-37 (2019).
45. Gröndahl, T. and Asokan, N., “Text Analysis in Adversarial Settings: Does Deception Leave a Stylistic Trace”, *ACM Computing Surveys (CSUR)*, 52: 1-36 (2019).
46. Markowit D.M., and Hancoc, J.T., “Linguistic obfuscation in fraudulent science”, *Journal of Language and Social Psychology*, 35: 435-445 (2016).
47. S. Feng, R. Banerjee, Y. Choi, “Syntactic stylometry for deception detection”, *Proceedings of the 50th Annual Meeting of the Association for Computational Linguistics* , 2: 171-175 (2012).
48. Rubin, V.L., Conroy, N.J., and Chen, Y., “Towards news verification: Deception detection methods for news discourse”, *Hawaii International Conference on System Sciences*, 5-8 2015.
49. Poria, S., Cambria, E., Hazarika, D. and Vij, P., “A deeper look into sarcastic tweets using deep convolutional neural networks”, *arXiv* preprint arXiv:1610.08815, (2016).
50. Küçük, D. ve Arıcı, N., “Doğal Dil İşlemede Derin Öğrenme Uygulamaları Üzerine bir Literatür Çalışması”, *Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi*, 2: 76-86 (2018).
51. Liddy, E. D., “Natural Language Processing. Encyclopedia of Library and Information Science”, *M. Drake (Eds)*, 2, New York, 2001.
52. Kurdi, M. Z., “Natural language processing and computational linguistics 2: Semantics”, *Discourse and Applications*, John Wiley & Sons, New Jersey, USA, 2017.
53. Doyuran L., “Medyatik Bir Çalışma Alanı Olarak Eleştirel Söylem Çözümlemesi (Televizyon Dizileri Örneğinde)”, *Erciyes İletişim Dergisi*, 5: 301-323 (2018).
54. Chaudhry, A. K., Baker, D. and Thun-Hohenstein, P., “Stance detection for the fake news challenge: identifying textual relationships with deep neural nets”, *CS224n: Natural Language Processing with Deep Learning*, (2017).

55. Masood, R. and Aker, A., “The Fake News Challenge: Stance Detection using Traditional Machine Learning Approaches”, *KMIS*, 126-133 (2018).
56. Braşoveanu, A.M. and Andonie, R., “Semantic fake news detection: a machine learning perspective, International Work-Conference on Artificial Neural Networks”, *Springer*, 656-667 (2019)
57. Tsikerdekis, M., and Zeadally, S., “Online deception in social media”, *Communications of the ACM*, 57: 72-80 (2014).
58. Zhang, J., Cui L. and Y. Fu, F.B. “Gouza, Fake news detection with deep diffusive network model”, *arXiv* preprint arXiv:1805.08751, (2018).
59. Oflazer, K. ve Saraçlar, M., “Turkish and its challenges for language and speech processing”, *Springer*, Cham, Switzerland, 1-19 (2018).
60. Kutlu, M. ve Cicekli, I., A hybrid morphological disambiguation system for turkish , *Proceedings of the Sixth International Joint Conference on Natural Language Processing*, 1230-1236 (2013).
61. Sak, H., Güngör, T. ve Saraçlar, M., “Morphological disambiguation of Turkish text with perceptron algorithm”, *International Conference on Intelligent Text Processing and Computational Linguistics*, Springer, 107-118 (2007).
62. Bilgin, O., “Frequency effects in the processing of morphologically complex Turkish words”, Master’s thesis, Boğaziçi University, İstanbul, 2016.
63. Akyürek, E., Dayanık, E. ve Yuret, D., “Morphological analysis using a sequence decoder”, *Transactions of the Association for Computational Linguistics*, 7: 567-579 (2019).
64. Sak, H., Güngör, T. ve Saraçlar, M., “Resources for Turkish morphological processing”, *Language resources and evaluation*, 45: 249-261 (2011).
65. Burcu, C., “LSTM Ağları ile Türkçe Kök Bulma”, *Bilişim Teknolojileri Dergisi*, 12: 183-193 (2019).
66. Arisoy, E., Can, D., Parlak, S., Sak, H. ve Saraçlar, M., “Turkish broadcast news transcription and retrieval”, *IEEE Transactions on Audio, Speech and Language Processing*, 17: 874-883 (2009).
67. Ünür, E., “Geleneksel Medya'nın Sosyal Medyayı Nasıl Kullandığına İlişkin Bir İnceleme: Dizilerin Twitter Kullanımı”, *Turkish Journal of Social Research/Turkiye Sosyal Arastirmalar Dergisi*, 20 (2016).
68. Kattimani, S., Kumbargoudar, P. and Gobbur, D.S., “Training of the library professionals in digital era: key issues”, (2006).

69. Connaway, L.S., Julien, H., Seadle, M. and Kasprak, A., "Digital literacy in the era of fake news: Key roles for information professionals", *Proceedings of the Association for Information Science and Technology*, 54 (2017) 554-555.
70. Sullivan, M., "Libraries and Fake News: What's the Problem? What's the Plan?", *Communications in Information Literacy*, 13: 91-113 (2019).
71. Finley, W., McGowan, B. and Kluever, J., "Fake news: An opportunity for real librarianship", *ILA reporter*, 35: 8-12 (2017).
72. Association, A. L., "Resolution on access to accurate information", *Retrieved February*, 10: 2018 (2017).
73. Rochlin, N., "Fake news: belief in post-truth", *Library Hi Tech*, 35: 386-392 (2017).
74. Wardle, C. and Derakhshan, H., "Information disorder: Toward an interdisciplinary framework for research and policy making", *Council of Europe report*, 27 (2017).
75. İnternet: "Artificial Intelligence: Definition, Examples, and Applications, Encyclopedia Britannica, <https://www.britannica.com/technology/artificial-intelligence> (2022).
76. Gambus, P. and Shafer, S. L., "Artificial intelligence for everyone", *Anesthesiology: The Journal of the American Society of Anesthesiologists*, 128: 431-433 (2018).
77. Mohri, M., Rostamizadeh, A. and Talwalkar, A., "Foundations of Machine Learning", *MIT Press, London*, England, 2018.
78. Mikolov, T., Sutskever, I., Chen, K., Corrado, G. S., and Dean, J. "Distributed representations of words and phrases and their compositionality". *In Advances in neural information processing systems*, 3111-3119 (2013).
79. Ren, Y., Wang, R., and Ji, D., "A topic-enhanced word embedding for twitter sentiment classification.", *Information Sciences*, 369: 188-198 (2016).
80. Nakov, P., Ritter, A., Rosenthal, S., Sebastiani, F., and Stoyanov, V., "SemEval-2016 task 4: Sentiment analysis in Twitter". *In Proceedings of the 10th International Workshop on Semantic Evaluation*, 1-18 (2016).
81. Grave, E., "Pre-trained word vectors". Machine learning methods in natural language processing, Yüksek Lisans Tezi, *İnönü Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul (2013).
82. Fürnkranz, J., "A study using n-gram features for text categorization.", *Austrian Research Institute for Artificial Intelligence*, 3: 1-10 (1998).

83. Çoban, Ö. “Metin Sınıflandırma Teknikleri ile Türkçe Twitter Duygu Analizi”. Yüksek Lisans Tezi, *Atatürk Üniversitesi Fen Bilimleri Enstitüsü*, Erzurum (2016).
84. Kaynar, O. Arslan, H., Görmez, Y. ve Işık, Y. E., “Makine Öğrenmesi ve Öznitelik Seçim Yöntemleriyle Saldırı Tespiti”, *Bilişim Teknolojileri Dergisi*, 11: 175-185 (2018).
85. Chawla, N. V., Bowyer, K. W., Hall, L. O. and Kegelmeyer, W. P., “SMOTE: synthetic minority over-sampling technique”, *Journal of artificial intelligence research*, 16: 321-357 (2002).
86. Cawley, G. C. and Talbot, N.L., “On over-fitting in model selection and subsequent selection bias in performance evaluation”, *The Journal of Machine Learning Research*, 11: 2079-2107 (2010).
87. Dikker, J., “Boosted Tree Learning for Balanced Item Recommendation In Online Retail”, Master Thesis, *Eindhoven University of Technology, Business Information System*, Netherlands, (2017)
88. Patrous, Z. S. “Evaluating XGBoost For User Classification By Using Behavioral Features Extracted From Smartphone Sensors”, Master Thesis, *KTH Royal Institute of Technology*, School of Computer Science and Communication, Sweden, (2018).
89. İnternet: Singh, A. Analytics Vidhya. <https://www.analyticsvidhya.com/blog/2018/06/comprehensive-guide-to-forensemble-models/>. (2019).
90. İnternet: Morde, V. Medium. <https://towardsdatascience.com/https-mediumcom-vishalmorde-xgboost-algorithm-long-she-may-rein-edd9f99be63d> (2019).
91. Dixit, A., “Ensemble Machine Learning. Birmingham”, *UK.: Packt Publishing Ltd* (2017).
92. Chen, X., Wang, Z.-X., and Pan, X. M., “HIV-1 Tropism Prediction by the XGBoost and HMM Methods”, *Scientific Reports*, 9(9997): (2019).
93. Sundaram, R. B. (2018, September 06). Understanding the Math behind the XGBoost Algorithm. Retrieved March 02, 2019, from <https://www.analyticsvidhya.com/blog/2018/09/an-end-to-end-guideto-understand-the-math-behind-xgboost/>
94. Mustapha, I. B., & Saeed, F. (2016). Bioactive Molecule Prediction Using Extreme Gradient Boosting. *Molecules*, 21 (983), 2-11.
95. Chen, X., Wang, Z.-X., and Pan, X.M., “HIV-1 Tropism Prediction by the XGBoost and HMM Methods”, *Scientific Reports*, 9(9997): (2019).

96. Fitriah, N., Wijaya, S. K., Fanany, M. I., Badri, C. and Rezal, M., "EEG Channels Reduction Using PCA to Increase XGBoost's Accuracy for Stroke Detection.", *International Symposium on Current Progress in Mathematics and Sciences 2016 (ISCPMS 2016)*, Indonesia: American Institute of Physics (2017).
97. Priyadharshini, P., "Prediction of Diabetes Mellitus Using XGBoost- Gradient Boosting.", *International Journal of Advances in Science Engineering and Technology*, 5 (4): 2-4 (2017).
98. Choi, H., Kim, S., Oh, J. E., Yoon, J., Park, J. A. and Yun, C., "XGBoost-Based Instantaneous Drowsiness Detection Framework Using Multitaper Spectral Information of Electroencephalography." *2018 ACM International Conference on Bioinformatics, Computational Biology, and Health Informatics*, 111-121 (2018).
99. Dhaliwal, S. S., Nahid, A.-A., & Abbas, R. "Effective Intrusion Detection System Using XGBoost." *Information*, 9 (149): 2-24 (2018).
100. Dimitrakopoulos, G. N., Vrahatis, A. G., Plagianakos, V. and Sgarbas, K. "Pathway Analysis Using XGBoost Classification in Biomedical Data". *10th Hellenic Conference on Artificial Intelligence (SETN'18)*, Rio Patras, Greece: Association for Computing Machinery (2018).
101. Ji, X., Tong, W., Liu, Z. and Shi, T. "Five-Feature Model for Developing the Classifier for Synergistic vs. Antagonistic Drug Combinations Built by XGBoost.", *Frontiers in Genetics*, 10(600): (2019).
102. Merembayev, T., Yunussov, R. and Yedilkhan, A., "Machine Learning Algorithms for Stratigraphy Classification on Uranium Deposits", *13th International Symposium "Intelligent Systems" (INTELS'18)*, Elsevier B.V., 46-52 (2019).
103. Mitchell, R., Adinets, A., Rao, T. and Frank, E., "XGBoost: Scalable GPU Accelerated Learning", *Cornell University, arXiv*, 2018.
104. Nagata, M., Takai, K., Yasuda, K., Heracleous, P. and Yoneyama, A., "Prediction Models for Risk of Type-2 Diabetes Using Health Claims.", *Proceedings of the BioNLP 2018 Workshop*, Melbourne, 172-176 (2018).
105. Wang, C., & Guo, J., "A Data-Driven Framework for Learners' Cognitive Load Detection Using ECG-PPG Physiological Feature Fusion and XGBoost Classification.", *2018 International Conference on Identification, Information and Knowledge in the Internet of Things, IIKI 2018*. 147, 338-348 (2019).
106. Yu, J., Shi, S., Zhang, F., Chen, G. and Cao, M., "PredGly: Predicting Lysine Glycation Sites for Homo Sapiens Based on XGBoost Feature Optimization.", *Bioinformatics*, 35, 2749-2756 (2018).

107. Zhang, C. and Yunqian, M., “Ensemble Machine Learning Methods and Applications.”, *New York, USA: Springer Science+Business Media*, (2012).
108. Chang, W., Liu, Y., Xiao, Y., Xu, X., Zhou, S. and Lu, X., “Probability Analysis of Hypertension-Related Symptoms Based on XGBoost and Clustering Algorithm.”, *Applied Sciences*, 9(1215): 2-14 (2019).
109. Chen, T. and Guestrin, C., “XGBoost: A Scalable Tree Boosting System”, *KDD '16 Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, New York, USA, 785-794 (2016).
110. Internet: “Understanding the Math behind the XGBoost Algorithm.”, <https://www.analyticsvidhya.com/blog/2018/09/an-end-to-end-guide-to-understand-the-math-behind-xgboost/> (2018).
111. Mustapha, I. B. and Saeed, F., “Bioactive Molecule Prediction Using Extreme Gradient Boosting.”, *Molecules*, 21(983): 2-11 (2016).
112. Chen, X., Wang, Z.-X. and Pan, X.-M., “HIV-1 Tropism Prediction by the XGBoost and HMM Methods.”, *Scientific Reports*, 9 (9997): (2019).
113. Guo, J., Yang, L., Bie, R., Yu, J., Gao, Y. and Shen, Y., “An XGBoost-Based Physical Fitness Evaluation Model Using Advanced Feature Selection and Bayesian Hyper-Parameter Optimization For Wearable Running Monitoring.”, *Computer Networks*, 151: 166-180 (2019).
114. Hosni, H., “Machine Learning Approach For Malware Multiclass Classification.”, *BRAINS 2019- 1st Blockchain, Robotics, AI for Networking Security Conference*. Rio de janeiro, Brazil (2019).
115. Ji, C., Zou, X., Hu, Y., Liu, S., Lyu, L. and Zheng, X., “XG-SF: An XGBoost Classifier Based on Shapelet Features for Time Series Classification.”, *IJKI 2018: International Conference on Identification, Information and Knowledge in the Internet of Things for 2018*, 24-28 (2019).

ÖZGEÇMİŞ

Elif Yıldırım, ilk ve orta öğrenimini Ankara’da tamamladı. Uluğbey Anadolu Lisesi Fen Bilimleri Bölümü’nden mezun oldu. 2014 yılında Bilgisayar Mühendisliği Bölümü’nde öğrenime başlayıp 2019 yılında “Onur Öğrencisi” olarak mezun oldu. Sekiz ay özel bir firmada yazılım geliştirici olarak çalıştı. Bununla birlikte 2019 yılında Karabük Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda yüksek lisans öğrenimine başladı ve 2022 yılında mezun oldu.