



**TÜRKÇE DOĞAL DİL İŞLEME VE DERİN ÖĞRENME YÖNTEMLERİ
KULLANARAK SOSYAL MEDYADA HALK SAĞLIĞI TAKİBİ**

Doğan KÜÇÜK

**DOKTORA TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ARALIK 2023

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Doğan KÜÇÜK

27/12/2023

TÜRKÇE DOĞAL DİL İŞLEME VE DERİN ÖĞRENME YÖNTEMLERİ
KULLANARAK SOSYAL MEDYADA HALK SAĞLIĞI TAKİBİ

(Doktora Tezi)

Doğan KÜÇÜK

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Aralık 2023

ÖZET

Günümüzde sosyal medyanın birçok farklı alan için önemli bir veri kaynağı olduğu bilinmektedir. Bu alanlardan biri de halk sağlığı, özellikle de halk sağlığının otomatik takibidir. Öte yandan, yapay zekâ alanında da çok hızlı ve derin etkisi olan gelişmeler yaşanmaktadır. Yapay zekânın kapsamındaki ana yöntemler makine öğrenmesi modelleri ile birlikte günümüzde derin öğrenme modelleridir. Yine doğal dil işleme alanı ve duygu analizi, duruş tespiti ve varlık ismi tanıma gibi alt alanları da yapay zekânın kapsamına girmektedir. Bu tez çalışmamızda; halk sağlığının otomatik takibi için sosyal medya iletileri üzerinde duygu analizi, duruş tespiti ve varlık ismi tanıma için geleneksel makine öğrenmesi yöntemleri ve derin öğrenme yöntemleri kullanılmıştır. Türkçe için işaretlenmiş tweet veri kümeleri üzerinde karşılaştırmalı değerlendirme sonuçları sunulmuştur. Derin öğrenme tabanlı modellerin daha yüksek başarımlar elde ettiği gözlenmiştir. Tezimiz kapsamında ayrıca söz konusu problemleri çözen yaklaşımları kullanan bir halk sağlığı izleme ve karar destek sistemi de önerilmiştir. Tez çalışmamız, doğal dil işlemenin önemli problemlerinin ortak veri kümeleri üzerinde makine öğrenmesi ve derin öğrenme modelleri kullanarak çözülmesi, bu süreçte Türkçe doğal dil işleme için veri kümeleri oluşturulması ve önerilen sistemin halk sağlığı uzmanları ve karar vericileri tarafından kullanılabilir olması nedeniyle oldukça önemlidir ve bu açılarından ilgili literatüre kayda değer katkılarda bulunmaktadır.

Bilim Kodu : 92432

Anahtar Kelimeler : Doğal dil işleme, sağlık bilişimi, derin öğrenme, makine öğrenmesi, duygu analizi, duruş tespiti, Türkçe, sosyal medya

Sayfa Adedi : 81

Danışman : Prof. Dr. Nursal ARICI

PUBLIC HEALTH MONITORING ON SOCIAL MEDIA USING TURKISH NATURAL
LANGUAGE PROCESSING AND DEEP LEARNING METHODS

(Ph. D. Thesis)

Doğan KÜÇÜK

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

December 2023

ABSTRACT

Today, social media is known to be an important source of data for many different fields. One of these fields is public health, especially the automatic monitoring of public health. On the other hand, there are rapid and profound developments in the field of artificial intelligence. The main methods within the scope of artificial intelligence are machine learning models and, particularly, deep learning models today. Additionally, subfields such as natural language processing and sentiment analysis, stance detection, and named entity recognition are also within the scope of artificial intelligence. In our thesis, traditional machine learning methods and deep learning methods were used for sentiment analysis, stance detection, and named entity recognition on social media posts for the automatic monitoring of public health. Comparative evaluation results were presented on annotated tweet datasets for Turkish. It has been observed that deep learning-based models achieve higher performance. Furthermore, within the scope of our thesis, a public health monitoring and decision support system utilizing the approaches solving the aforementioned problems was proposed. Our thesis is highly significant as it involves solving important natural language processing problems using machine learning and deep learning models on common datasets, creating datasets for Turkish natural language processing during this process, and making the proposed system usable by public health experts and decision-makers; hence it contributes significantly to the relevant literature in these aspects.

Science Code : 92432

Key Words : Natural language processing, health informatics, deep learning, machine learning, sentiment analysis, stance detection, Turkish, social media

Page Number : 81

Supervisor : Prof. Dr. Nursal ARICI

TEŞEKKÜR

Tez çalışmam süresince bana rehberlik eden değerli danışmanım ve hocam Prof. Dr. Nursal ARICI'ya en içten teşekkürlerimi sunarım. Kendisinin değerli önerileri, yönlendirmeleri, yardımları ve desteği olmadan bu tez çalışmasını tamamlamak mümkün olmayacaktı.

Tez izleme komitemin değerli üyeleri olan Prof. Dr. Pınar KARAGÖZ ve Doç. Dr. İbrahim Alper DOĞRU hocalarıma çok teşekkür ederim. Tez izleme komite toplantılarında ilettikleri değerli öneriler ve geri bildirimler ile tez çalışmamı iyileştirme fırsatı buldum. Ayrıca tez jürimin diğer değerli üyeleri Prof. Dr. Ahmet COŞAR ve Doç. Dr. Hüseyin POLAT hocalarıma da yorumları ve katkıları için çok teşekkür ederim.

Doktora eğitimim sırasında ders alma fırsatı bulduğum Gazi Üniversitesi Teknoloji Fakültesi Bilgisayar Mühendisliği Bölümü'ndeki değerli hocalarıma hepsine çok teşekkür ederim.

Tez çalışmam sırasında benden desteklerini esirgemeyen; başta annem ve babam olmak üzere, tüm aile üyelerime de çok teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	x
ŞEKİLLERİN LİSTESİ.....	xi
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ.....	1
2. LİTERATÜR TARAMASI	5
2.1. Sosyal Medya Üzerinde Halk Sağlığı Takibi	5
2.2. Twitter Üzerinde COVID-19 Salgınının Takibi.....	9
2.3. Duygu Analizi.....	10
2.4. Duruş Tespiti	16
2.5. Varlık İsmi Tanıma	18
2.6. Makine Öğrenmesi ve Derin Öğrenme	20
2.6.1. Makine öğrenmesi	20
2.6.2. Derin öğrenme.....	23
2.6.3. Transformer tabanlı modeller ve BERT	24
2.6.4. Üretken yapay zekâ modelleri ve ChatGPT	26
3. MATERYAL VE METOT	29
3.1. Veri Kümelerinin Oluşturulması	29
3.2. Duygu Analizi ve Duruş Tespiti Yaklaşımları	36

	Sayfa
3.2.1. Veri artırımı ile makine öğrenmesi yöntemlerinin kullanımı	36
3.2.2. BERT ve ChatGPT'nin kullanımı	39
3.3. Varlık İsmi Tanıma Yaklaşımı	40
4. ÖNERİLEN OTOMATİK HALK SAĞLIĞI TAKİBİ VE KARAR DESTEK SİSTEMİ.....	43
4.1. Genel Bilgiler.....	43
4.2. Halk Sağlığı İzleme ve Karar Destek Sistemi Modülleri.....	44
4.2.1. Veri toplama modülü.....	44
4.2.2. Duygu analizi modülü	44
4.2.3. Duruş tespiti modülü	45
4.2.4. Varlık ismi tanıma modülü.....	45
4.2.5. Veri tabanı modülü.....	45
4.2.6. Kullanıcı arayüz modülü	46
5. DEĞERLENDİRME VE TARTIŞMA	53
5.1. Değerlendirme Metrikleri	53
5.2. Değerlendirme Sonuçları	54
5.2.1. Makine öğrenmesi ve veri artırımı ile duruş tespiti ve duygu analizi değerlendirme sonuçları	54
5.2.2. BERT ve ChatGPT ile duruş tespiti ve duygu analizi değerlendirme sonuçları	56
5.2.3. Varlık ismi tanıma değerlendirme sonuçları	58
5.3. Tartışma	58
5.4. İleri Çalışma Konuları.....	60
6. SONUÇ VE ÖNERİLER.....	63
KAYNAKLAR	65

ÖZGEÇMİŞ	79
----------------	----



ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. 600 tweet’lik veri kümesinde en sık görülen 20 kelime ve sıklıkları.....	30
Çizelge 3.2. 230 tweet’lik veri kümesinde en sık görülen 20 kelime ve sıklıkları.....	31
Çizelge 3.3. 300 tweet’lik veri kümesinde en sık görülen 20 kelime ve sıklıkları.....	32
Çizelge 3.4. İşaretli veri kümelerinden örnek tweet’ler ile duygu ve duruş işaretleri ...	35
Çizelge 3.5. Varlık ismi tanıma yaklaşımında kullanılan hedef terimlerden örnekler...	41
Çizelge 5.1. Duruş tespiti ve duygu analizi sınıflayıcılarının veri kümesinin ilk hali ve artırılmış hali üzerindeki 10-kat çapraz doğrulama sonuçları (F-Oranı cinsinden).....	55
Çizelge 5.2. Duruş tespiti ve duygu analizi sınıflayıcılarının ilk ve genişletilmiş veri kümelerini eğitim amacıyla kullandıktan sonraki değerlendirme sonuçları (F-Oranı cinsinden)	55
Çizelge 5.3. VADER aracı ile kullanılan dört sınıflayıcının test veri kümesi üzerindeki duygu analizi değerlendirme sonuçları (F-Oranı cinsinden)....	56
Çizelge 5.4. Testlerde kullanılan BERT tabanlı model ile ChatGPT’nin (* ile belirtilen) değerlendirme sonuçları ve diğer modeller ile karşılaştırılmaları (F-Oranı cinsinden).....	57

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Geri-çevrim (back-translation) tabanlı veri artırımı örneği	22
Şekil 2.2. Temel dönüştürücü (transformer) mimarisi	25
Şekil 2.3. BERT modelinin mimarisi.....	26
Şekil 2.4. ChatGPT'nin güncel arayüz görüntüsü	27
Şekil 3.1. 600 tweet'lik Türkçe veri kümesinden oluşturulan kelime bulutu	29
Şekil 3.2. 230 tweet'lik Türkçe veri kümesinden oluşturulan kelime bulutu	31
Şekil 3.3. 300 tweet'lik Türkçe veri kümesinden oluşturulan kelime bulutu	32
Şekil 3.4. Duruş tespiti için işaretleme talimatları	33
Şekil 3.5. 600 tweet'lik veri kümesindeki duygu ve duruş sınıflarının dağılımı	34
Şekil 3.6. 300 tweet'lik veri kümesindeki duygu ve duruş sınıflarının dağılımı.....	35
Şekil 3.7. Duygu analizi ve duruş tespiti için kullanılan yaklaşımlar.....	36
Şekil 3.8. Önerilen veri artırım yöntemi ve makine öğrenmesi testlerinin yapılması akış diyagramı	37
Şekil 4.1. Önerilen sistem mimarisi	43
Şekil 4.2. Kullanıcı arayüz modülü – Giriş ekranı.....	47
Şekil 4.3. Kullanıcı arayüz modülü – Veri analizi ana ekranı	48
Şekil 4.4. Kullanıcı arayüz modülü – Duygu analizi analiz ekranı	48
Şekil 4.5. Kullanıcı arayüz modülü – Duruş tespiti analiz ekranı	49
Şekil 4.6. Kullanıcı arayüz modülü – Varlık ismi tanıma analiz ekranı	49
Şekil 4.7. Kullanıcı arayüz modülü – Eğitilmiş model ile varlık ismi tanıma ekranı.....	50
Şekil 4.8. Kullanıcı arayüz modülü – Veri temizliği ekranı	51
Şekil 5.1. ChatGPT'nin iki farklı tweet için ürettiği duruş ve duygu çıktı metinleri	59

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklamalar
AbSA	Aspect-based Sentiment Analysis
ADE	Adverse Drug Events
API	Application Programming Interface
ARFF	Attribute-Relation File Format
BERT	Bidirectional Encoder Representations from Transformers
Bi-LSTM	Bidirectional Long Short-Term Memory
CNN	Convolutional Neural Network
COVID-19	Novel Coronavirus Disease-2019
CRF	Conditional Random Fields
CSV	Comma-Separated Values
GPT	Generative Pre-trained Transformer
KNN	K Nearest Neighbors
LDA	Latent Dirichlet Allocation
LIWC	Linguistic Inquiry and Word Count
LLM	Large Language Model
LSTM	Long Short-Term Memory
MERS	Middle East Respiratory Syndrome
MLP	Multilayer Perceptron
NLG	Natural Language Generation
NLTK	Natural Language Toolkit
RNN	Recurrent Neural Network
SVM	Support Vector Machine
TFRC	TensorFlow Research Cloud
TPU	Tensor Processing Unit
VADER	Valence Aware Dictionary and sEntiment Reasoner
WEKA	Waikato Environment for Knowledge Analysis

1. GİRİŞ

Problem durumu / Konunun tanımı

Halk sağığı; günümüzde tüm insanlar ve devletler için önemli bir kavram olarak ortaya çıkmaktadır. En bilinen tanımlarından birine göre *halk sağığı*, “*organize topluluk çabaları yoluyla hastalığı önleme, yaşamı uzatma ve fiziksel sağığı ve verimliliği geliştirme bilimi ve sanatıdır....*” (Winslow, 1920:30). Özellikle yakın geçmişte yaşanan ve etkileri halen süregelen COVID-19 (Novel Coronavirus Disease-2019) salgını, halk sağığının korunmasının ve sürdürülebilirliğinin önemini bir kez daha ortaya çıkarmıştır.

Devletler ve toplumlar için halk sağığının takibi, halk sağığının amacına ulaşmasının kayda değer araçlarından biridir. Halk sağığı profesyonelleri tarafından gerçekleştirilecek uygun halk sağığı takibi yöntemleri ile halk sağığını geliştirmeye yönelik tahminler yapılarak ardından alınacak koruyucu ve önleyici tedbirler vakitlice uygulanabilecektir.

Halk sağığı takibi geleneksel olarak resmi hastane kayıtları üzerinde yapılagelmiştir (Yao, Bi ve Chen, 2018). Ancak günümüzde internet üzerinde anlık olarak oluşturulmakta olan büyük boyutlu metin biçimindeki veriler de halk sağığı takibi için önemli bir kaynak olma potansiyeli taşımaktadır. Bu verilerin kaynakları arasında çevrimiçi forum siteleri, haber sitelerinin yorum kısımları ile birlikte, son ve güncel olarak sosyal medya ağları (platformları) sayılabilmektedir. Özellikle Twitter ve benzeri sosyal medya ağları; yaygınlıkları ve anlık ileti yayınlama yetenekleri dolayısıyla çevrimiçi halk sağığı takibi için çok uygun platformlardır (Culotta, 2014; Zhou, Zhang, Yang ve Wang, 2018).

Halen etkileri devam etmekte olan COVID-19 salgını döneminde Twitter gibi sosyal medya ağları aracılığı ile yayınlanan iletilerde; insanların salgınla ve salgına ilişkin konularla ilgili (kapanma, maske kullanımı, sosyal/fiziksel mesafe kuralları, aşılar, uzaktan çalışma, uzaktan eğitim vb.) duygu ve düşüncelerini hızlı bir şekilde ifade ettikleri görülmektedir (Alkhaldi ve diğerleri, 2022; Burzyńska, Bartosiewicz ve Rękas, 2020; Cascini ve diğerleri, 2022).

Şüphesiz, COVID-19 salgını sırasında hem geleneksel medyada hem de sosyal medyada en çok tartışılan ve hakkında farklı fikirlerin ortaya atıldığı konulardan biri de COVID-19 aşılardır. Bu nedenle, özellikle COVID-19 aşıları konusunda insanların fikirlerinin, duygu ve duruşlarının (*aşı taraftarı, aşı karşıtı* gibi) sosyal medya üzerinden otomatik analizi konusunda kayda değer çalışmalar yapılmıştır. Bu çalışmalardan bazıları yapay zekâ yöntemlerinin sosyal medyada aşı hakkındaki iletiler üzerinde uygulanması hakkında iken (Aljedaani, Saad, Rustam, de la Torre Díez ve Ashraf, 2022; Boucher ve diğerleri, 2021; D'Andrea, Ducange, Bechini, Renda ve Marcelloni, 2019; Saleh ve diğerleri, 2021;), bazıları ise ilgili araştırmalarda kullanılabilecek veri kümeleri sunmaktadır (Chen, Lerman ve Ferrara, 2020; DeVerna ve diğerleri, 2021; Haouari, Hasanain, Suwaileh ve Elsayed, 2020; Hayawi, Shahriar, Serhani, Taleb ve Mathew, 2022; Hou, van der Putten ve Verberne, 2022; Mu ve diğerleri, 2023; Qazi, Imran ve Ofli, 2020; Qorib, Oladunni, Denis, Ososanya ve Cota, 2023).

Öte yandan; sosyal medyada sağlıkla ilgili takip ve analiz yapılırken “*bilgi salgını*” olarak da bilinen “*infodemik*” kavramı da dikkate alınmalıdır. Özellikle COVID-19 salgını döneminde önem kazanan bu kavram; Calamusa ve diğerlerinin (2020) ilgili çalışmasında, bilginin istenmeyen sonuçlar doğuracak şekilde ve kontrolsüz olarak yayılması anlamında kullanılmıştır ve COVID-19 salgınının ilk evresinde İtalya’da sosyal medya üzerinde yayılan bir bilgi salgınına vurgu yapılmıştır. Genel olarak “*bilgi salgını*” Dünya Sağlık Örgütü tarafından da “*bir hastalığın ortaya çıkması esnasında görülen; yanlış veya yanlış yönlendirici bilgiler de içeren (dijital veya fiziksel çevredeki) çok fazla bilgi*” olarak tanımlanmaktadır (URL1).

Araştırmanın amacı

Bu tez çalışmamızın amacı; halk sağlığı ile ilgili Türkçe sosyal medya metinleri üzerinde çeşitli doğal dil işleme problemlerini çözmek üzere makine öğrenmesi ve derin öğrenme yaklaşımlarının kullanılması ve ayrıca bu çözümlere dayalı bir sosyal medyada halk sağlığı izleme ve karar destek sisteminin geliştirilmesidir.

Çalışma kapsamına alınan doğal dil işleme problemleri; duygu analizi, duruş tespiti ve varlık ismi tanıma problemleridir.

Makine öğrenmesi yöntemleri olarak *destek vektör makineleri (support vector machines)*, *lojistik regresyon*, *rasgele orman (random forest)* ve *torbalama (bagging)* yöntemlerinin kullanılması amaçlanırken, derin öğrenme yöntemi olarak güncel *dönüştürücü (transformer)* tabanlı derin öğrenme modellerinin kullanılması amaçlanmaktadır.

Çalışma kapsamında ayrıca; sağlıkla ilgili ve özellikle güncel COVID-19 salgınıyla ilgili sosyal medya metinlerinden oluşan veri kümelerinin oluşturulması da amaçlanmaktadır. Bilindiği üzere, ilgili literatürde Türkçe doğal dil işleme için gerekli işaretli veri kümeleri çok azdır. Bu yönüyle tez çalışmamız bu açığı kapatmak amacıyla da literatüre katkı vermektedir. Çalışmamız kapsamında alınan sonuçlar ile ileri çalışmalar kapsamında yapılacak çalışmalar aynı veri kümeleri üzerinde test edilebilecek ve farklı yöntemler karşılaştırılabilecektir.

Araştırmanın önemi

Tez çalışmamız aşağıdaki nedenle literatüre katkı sağlamaktadır ve bu nedenle önem arz etmektedir:

- Güncel COVID-19 salgını gibi geniş ölçekli halk sağlığı olayları esnasında toplumların karşı karşıya kalacağı zararları en aza indirmek için halk sağlığının hızlı ve etkin şekilde takip edilmesi gerekmektedir. *Sosyal medya*, geleneksel medyaya göre daha hızlı ve daha yaygın şekilde bilgi paylaşımını mümkün hale getirmekte, bu yolla da güncel sağlık bilgileri ile toplumların sağlıkla ilgili olaylara bakış açısının hızlı şekilde tespit edilmesini ve halk sağlığını korumak için bu bilgilere dayalı olarak karar verilmesi sağlanabilmektedir. Çalışmamız kapsamında Türkçe sosyal medya metinlerinin otomatik analizine dayalı olarak bir halk sağlığı izleme ve karar destek sistemi prototipi gerçekleştirilmiştir.
- Tez çalışmamız kapsamında Türkçe sosyal medya metinleri üzerinde birden çok önemli doğal dil işleme problemine çözüm önerileri sunulmakta ve test sonuçları sunulmaktadır. Söz konusu problemler duygu analizi, duruş tespiti ve varlık ismi tanıma problemleridir. Bunların her biri başlı başına birer araştırma konusuyken ve literatürdeki birçok çalışmada sadece bu problemlerden biri üzerinde çalışılmışken, tez çalışmamız bünyesinde bu problemlerin üçüne birden çözümler önerilmiştir ve bu çözümlerin performans sonuçları değerlendirilmiştir.

- Günümüzde, doğal dil işleme araştırma alanlarında yaygın kullanılan kural-tabanlı yöntemlerin yerini yakın dönemde makine öğrenmesi yöntemleri, sonrasında da derin öğrenme yöntemleri almıştır. Tez çalışmamız kapsamında; sağlıkla ilgili sosyal medya metinleri üzerinde doğal dil işleme problemlerinin çözümü için makine öğrenmesi ve derin öğrenme yöntemleri kullanılmış ve karşılaştırmalı sonuçlar sunulmuştur.
- Doğal dil işleme alanında; İngilizce, İspanyolca, Çince gibi yaygın kullanılan diller üzerinde birçok çalışma yapılmış olmasına ve bu diller için birçok kapsamlı sözcüksel kaynak ile işaretli veri kümesi hazır olarak bulunmasına rağmen, Türkçe gibi diller için aynı durum söz konusu değildir. Çalışmamız hem Türkçe sosyal medya çözümlemesi (analizi) için önemli bir çalışmadır hem de çalışma kapsamında kayda değer işaretli veri kümeleri oluşturulmuştur. Bu yönüyle tez çalışmamız Türkçe doğal dil işleme literatürüne önemli bir katkı oluşturmaktadır.
- Tez çalışmamızda kapsamında; halk sağlığı takibi için sosyal medyanın kullanımı, özellikle güncel COVID-19 salgınıyla ilgili sosyal medyanın kullanımı ve COVID-19 aşılı ile ilgili duygu analizi ve duruş tespiti konularında geniş bir literatür taraması sunulmuştur. Bu literatür taramasının bu güncel alanlarda çalışacak araştırmacılar için faydalı bir kaynak olduğu değerlendirilmektedir.

Sınırlılıklar

Çalışmamız Türkçe doğal dil işleme alanı için önemli bir çalışma olmakla birlikte; tek bir dil üzerinde çalışılmış olması da çalışmamızın sınırlılıklarından birini oluşturmaktadır. İleri çalışmalar kapsamında; birden çok dilde (multi-lingual) veri içeren kümeler üzerinde de testler yapılması planlanmaktadır.

Çalışmamızın bir diğer sınırlılığı da modellerin eğitim ve test aşamalarında kullanılan veri kümelerinin boyutlarıdır. Yine ileri çalışmalar bünyesinde bu kümelerin genişletilmesi ve genişletilmiş veri kümeleri üzerinde testlerin tekrarlanması planlanmaktadır.

2. LİTERATÜR TARAMASI

Bu bölümde, tez çalışmamızla ilgili literatür taranırken ilk alt bölümde sosyal medya üzerinde halk sağlığı takibi ile ilgili çalışmalar incelenmiştir. İkinci alt bölümde, ilgili yayınlarda en fazla kullanılan sosyal medya platformu olan Twitter üzerinde halk sağlığı takibine odaklanan çalışmalar sunulmuştur. Ardından sırasıyla; tezimiz kapsamında ele alınan doğal dil işleme problemleri olan duygu analizi, duruş tespiti ve varlık ismi tanıma problemleriyle ilgili literatür tez çalışmamızla ilgili olduğu ölçüde verilmiştir. Son olarak da tezimiz kapsamında kullanılan yöntemleri oluşturan makine öğrenmesi ve derin öğrenme yaklaşımları genel hatlarıyla açıklanmıştır.

2.1. Sosyal Medya Üzerinde Halk Sağlığı Takibi

Twitter üzerinde halk sağlığı amacıyla; 2013 yılında varolan Twitter veri kümelerini ve tweet'lerdeki yaygın kelime gruplarını filtrelemek için Wikipedia'yı kullanan bir çalışma sunulmuştur (Parker, Wei, Yates, Frieder ve Goharian, 2013).

Lee, Agrawal ve Choudhary'nin (2013) ilgili çalışmasında grip ve kanserle ilgili Twitter iletilerinin otomatik tespiti ve gerçek zamanlı izlenmesi için bir sistem geliştirilmiştir.

Yine konuyla ilgili olarak 2014 yılında Twitter üzerinde anahtar kelime tabanlı bir yaklaşımla halk sağlığıyla ilgili tweet'lerin sınıflandırılmasını amaçlayan bir çalışma yapılmıştır (Velardi, Stilo, Tozzi ve Gesualdo, 2014).

Stoové ve Pedrana'nın (2014) çalışmasında Twitter verilerinin geleneksel verilerle birlikte halk sağlığı takibi yapılmasında kullanılabileceği vurgulanmıştır.

Ancak Google vb. arama motorları ve Twitter vb. sosyal medya platformları ticari uygulamalar olduklarından bunlardan elde edilen verilerin gerçek olguları yansıtamayabileceği, sosyal medyanın iletilerinin gerçek dışı bilgilerin yayılması ve toplumun yönlendirilmesi amaçlarıyla kötüye kullanılabileceği de literatürde vurgulanmaktadır (Lazer, Kennedy, King ve Vespignani, 2014).

Derin öğrenme yöntemlerinden Multilayer Perceptron (MLP) kullanan bir yaklaşımla Twitter'da salgınların takibini ve salgınların zamansal ve mekânsal modellenmesini amaçlayan bir diğer çalışma 2015'te gerçekleştirilmiştir (Zhao ve diğerleri, 2015).

Genel olarak halk sağlığı takibinde sosyal medyanın kullanımı hakkında Fung, Tse ve Fu'nun (2015) çalışmasında; sosyal medyanın geleneksel yöntemlerin yanında tamamlayıcı nitelikte bilgi sağlamak üzere kullanılabileceği ifade edilmiştir. Yine aynı çalışmada; sosyal medyanın daha çok kriz anlarındaki tıbbi ihtiyaçların hızlı tespitinde faydalı olacağı değerlendirilmiştir.

Kendra, Karki, Eickholt, Gandy (2015) tarafından tamamlanan çalışmada Twitter'da yayınlanmış antibiyotiklerle ilgili tweet'ler tespit edilerek bunlar makine öğrenmesi yöntemleri kullanılarak sınıflandırılmıştır.

Halk sağlığı takibi için geleneksel tıbbi veri kaynaklarını, arama motorlarında yapılan aramaların geçmişini ve sosyal medyayı kullanan makine öğrenmesi tabanlı bir yaklaşım Santillana ve diğerleri (2015) tarafından tanıtılmıştır.

Kapp, Hensel ve Schnoring'in (2015) çalışmasında; Twitter'ın halk sağlığı araştırmacılarının ilgili araştırma sonuçlarını yayınlamada ve bu yolla bu araştırma sonuçlarının karar alıcılara ulaştırılmasında uygun bir kaynak olduğu ifade edilmiştir.

Genel halk sağlığı ile ilgili önemli bir konu da ilaçların istenmeyen yan etkilerinin ve bu yan etkilerin birbirleriyle etkileşiminin tespiti, değerlendirilmesi ve önlenmesidir. Bu yöndeki çalışmalar *farmakovijilans* konusunun alanını oluşturmaktadır ve farmakovijilans için de sosyal medyanın ve doğal dil işleme tekniklerinin kullanımı konusunda yapılmış çalışmalar mevcuttur (Abacha ve diğerleri, 2015; Nikfarjam, 2016; Sarker ve diğerleri, 2015).

Byrd, Mansurov ve Baysal'ın (2016) çalışmasında griple ilgili yayınlanan tweet'lerin anahtar kelime tabanlı bir yöntemle otomatik ve gerçek zamanlı olarak belirlenebileceği ve çıktıların haritalar üzerinde görselleştirilebileceği gösterilmiştir.

Gkotsis ve diğerlerinin (2017) ilgili çalışmasında *Reddit* adlı sosyal medya aracındaki iletilerde akıl hastalığını gösteren bulgular olup olmadığını belirlemek üzere derin

öğrenmeye dayalı bir yaklaşım tanıtılmıştır.

İlgili bir diğer çalışmada; Twitter'ın halk sağlığı takibinde çift yönlü iletişim için kullanılabileceği vurgulanmıştır (Rabarison ve diğerleri, 2017).

İlgili bir derleme çalışmasında; sağlık bilişimi (health informatics) için derin öğrenme yöntemlerini uygulayan çalışmalar incelenmiştir (Ravi ve diğerleri, 2017).

Güney Kore'de 2015'te yaşanan ve MERS-CoV adlı virüsün sebep olduğu Middle East Respiratory Syndrome (MERS) adlı hastalığın salgını hakkında insanların duygusal tepkileri sosyal medya üzerinde makine öğrenmesi teknikleri kullanılarak analiz edilmiştir (Choi ve diğerleri, 2017).

Seltzer, Horst-Martz, Lu ve Merchant (2017) tarafından Instagram sosyal medya platformu üzerinde Zika virüs hakkındaki paylaşımlar (resimler) incelenmiş ve sonuç olarak çeşitli istatistikler raporlanmıştır.

Öte yandan; toplumların sağlığını tehdit eden yaygın salgınlarla ilgili olarak bazı çalışmalarda sağlıkla ilgili kuruluş ve/veya kişilerin sosyal medya iletileri dikkate alınmıştır. Örneğin; Guidry, Jin, Orr, Messner ve Meganck (2017) tarafından sunulan çalışmada Ebola salgını ile ilgili olarak Dünya Sağlık Örgütü, ABD'nin Hastalık Kontrol ve Önleme Merkezleri (Centers for Disease Control and Prevention - CDC) ve Sınır Tanımayan Doktorlar (Médecins Sans Frontières - MSF) adlı kuruluşların sosyal medya iletileri incelenmiştir.

Sosyal medya platformlarından özellikle Twitter'ın sağlık iletişimi için en popüler kaynaklardan biri olduğu ve sağlık iletişimin iyileştirilmesi için kullanılabileceği ancak çok miktarda yanlış bilginin yayılması ve bilgi kaynaklarının güvenilirliğinin tartışmalı olması gibi risklerin de göz önünde bulundurulması gerektiği vurgulanmaktadır (Pershad, Hangge, Albadawi ve Oklu, 2018).

Thiébaud ve Thiessard'ın (2018) ilgili çalışmasında da; sosyal medyanın oldukça güncel bilgiler içermesi nedeniyle halk sağlığı takibi ve tahminini hızlandırılabilceği ileri sürülmüştür.

Tıbbi metinlerde sınıflandırma ve kavram normalizasyonu için kaynakların ve yöntemlerin sunulduğu “Sağlık için Sosyal Medya Madenciliği – Social Media Mining for Health (SMM4H) 2017” adlı etkinliğin ayrıntıları Sarker ve diğerleri (2018) tarafından sunulmuştur.

İtalya’da 2016-2017 ile 2017-2018 dönemlerinde gerçekleşen mevsimsel grip vakalarının Twitter üzerinden tespit edilmesi hakkında Comito, Forestiero ve Pizzuti (2018) tarafından gerçekleştirilen çalışmada; Twitter’den çıkarılan bilgiler ile resmi kayıtların uyumlu olduğu ifade edilmiştir.

Unger ve diğerlerinin (2018) çalışmasında gençlerin Twitter’da tütün ile ilgili iletileri analiz edilmiş ve sonuç olarak Twitter’da konuyla ilgili ileti yayınlamakla tütün kullanımı arasında bir ilişkinin mevcut olduğu ifade edilmiştir.

Wiemken ve diğerleri (2018) tarafından gerçekleştirilen çalışmada; bulaşıcı hastalıkların tespiti amacıyla, Twitter’ın anomali ve ani ortaya çıkış tespit yöntemleri ile istatistiksel bir yöntem karşılaştırılmış ve sonuçlar sunulmuştur.

Wakamiya, Kawai ve Aramaki’nin (2018) çalışmasında Twitter’da grip vakalarının takibine odaklanılmıştır ve 7 milyon Japonca tweet’te grip vakalarının tespiti için doğal dil işlemeye dayalı bir yöntem tanıtılmıştır.

Tweet’lerin halk sağlığı ile ilgili olup olmadıklarının bir derin öğrenme metodu olan LSTM ile belirlendiği bir yaklaşım Jiang ve diğerleri (2018) tarafından sunulmuştur.

Jordan ve diğerleri (2018) Twitter üzerinde 2010-2017 yılları arasında gerçekleştirilen halk sağlığı takibi ve tahmini alanlarındaki çalışmaları derlemişlerdir.

Wakamiya, Morita, Kano, Ohkuma ve Aramaki’nin (2019) çalışmasında; sekiz tip hastalık belirtisi içeren İngilizce, Japonca ve Çince tweet’lerde gerçekten hastalıklardan bahsedilip bahsedilmediğinin sınıflandırılmasına hakkındaki *MedWeb* isimli akademik yarışmayla ilgili bilgiler verilmiştir.

Twitter ve Pubmed makale özetleri üzerinde salgın tespiti yapılan ilgili bir diğer çalışmada (Khatua, Khatua ve Cambria, 2019) kelime vektörleri ile ağaç sınıflayıcısı yöntemine dayalı bir yaklaşım sunulmuş, 2014’teki Ebola salgını ile 2015’te Zika salgını verileri kullanılmıştır.

Yine halk sađlığı ile tweet'lerin otomatik tespitine ilişkin Doan ve diđerlerinin (2019) alıřmasının ise; metin ayrıştırma (parsing) ile birlikte sözlüksel-sözdizimsel kuralların kullanıldığı bir dođal dil işleme alıřması olarak sunulmuřtur.

Du, Michalska, Subramani, Wang ve Zhang'ın (2019) alıřmasında saman nezlesi (polen alerjisi) vakalarının Twitter üzerinde tespiti için derin öğrenme tabanlı yöntemler kullanılmıştır.

Benis, Chatsubi, Levner ve Ashkenazi'nin (2021) ilgili alıřmasında; COVID-19 salgını esnasında, Twitter üzerinde yayınlanan mesajlarda (tweet'lerde) yer alan terimlerin analiz edilmesi yoluyla grip ve ařılar konusunda insanların yaklařımlarının nasıl deđişim gösterdiği araştırılmıştır. Bu yolla, halk sađlığı politikalarının iyileştirilmesine katkı verilmesi amaçlanmıştır.

Tez alıřmamız kapsamında gerçekleřtirdiđimiz bir derleme alıřmamızda (Küçük, Arıcı ve Küçük, 2021); sosyal medyada halk sađlığının takibine ilişkin 2013-2020 yılları arasında yapılan alıřmalar sunulmuř ve karşılaştırılmıştır.

2.2. Twitter Üzerinde COVID-19 Salgınının Takibi

Jahanbin ve Rahmanian'ın (2020) alıřmasında; COVID-19 ile ilgili tweet'lerin sınıflandırılması amacıyla bulanık kural-tabanlı evrimsel (fuzzy rule-based evolutionary) bir yaklařım kullanılmıştır.

İtalyanca Twitter ve Facebook iletileri üzerinde COVID-19 ařılılarıyla ilgili sohbetlerin takibi için geliştirilen bir sistem Pierri ve diđerleri (2021) tarafından geliştirilmiş ve sunulmuřtur.

Yan, Law, Nguyen, Cheung ve Kong (2021) tarafından Kanada'da gerçekleştirilen alıřmada; COVID-19 ařılılarıyla ilgili Reddit yorumları üzerinde duygu tanıma (emotion recognition) testleri; rasgele orman regresyonu (random forest regression) algoritması kullanılarak yapılmıştır. Bu alıřmada duygu türleri olarak *kızgınlık*, *korku*, *mutluluk* ve *üzüntü* kullanılmıştır ve şehir bazında daha lokal alıřmalar yapılarak insanların görüşlerinin daha iyi öğrenilebileceđi ifade edilmiştir.

Bir diğerk çalışmada beş farklı ülkeden (Hindistan, ABD, Brezilya, İngiltere ve Avusturalya) COVID-19 aşısı ile ilgili tweet'ler üzerinde duygu tanıma gerçekleştirilmiştir (Chopra, Vashishtha, Pal, Tyagi ve Sethi, 2021). Aşılama ile ilgili tereddütlerin ülkeden ülkeye farklılık gösterdiği saptanmıştır.

Monselise, Chang, Ferreira, Yang ve Yang'ın (2021) ilgili çalışmasında da COVID-19 aşısıyla ilgili tweet'ler üzerinde BERT gibi derin öğrenmeye dayalı metotlar dahil çeşitli metotlarla duygu tanıma gerçekleştirilmiştir. Çalışmada beş farklı duygu dikkate alınmış, en yaygının korku, ikinci en yaygının ise mutluluk olduğu gözlemlenmiştir.

Al-Laith ve Alenazi'nin (2021) çalışmasında; COVID-19 salgısını sırasında Twitter'da insanların salgınla ilgili kaygılarını ve duygularını izleyen ve bu duygularla da hastalık belirtilerini eşleştiren bir sistem sunulmuştur.

Zhang ve diğerleri (2021) COVID-19 salgını döneminde artış gösteren depresyon vakalarıyla ilgili Twitter verilerini içeren geniş bir veri kümesi tanıtmış; derin öğrenme modelleri kullanılarak Twitter'da depresyon takibi yapılabileceğini ifade etmiştir.

Guntuku ve diğerlerinin (2020) çalışmasında yine COVID-19 döneminde Twitter üzerinde yapılan paylaşımlarda; akıl sağlığı ile ilgili (stres, endişe, gelecek kaygısı gibi) ve COVID-19 belirtileriyle ilgili ifadeler incelenmiştir ve istatistikler çıkarılmıştır.

2.3. Duygu Analizi

Duygu analizi (görüş madenciliği), duyuşsal hesaplama (affective computing) bir problemdir ve farklı çalışmalarda çeşitli şekillerde tanımlanmıştır (Cambria, Das, Bandyopadhyay ve Feraco, 2017; Liu, 2010; Medhat, Hassan ve Korashy, 2014; Mäntylä, Graziotin ve Kuutila; 2018; Pang ve Lee, 2008).

Bazı çalışmalar; duygu tanıma, öznellik algılama ve *polarite tespiti* (polarity detection) problemlerinin hepsinin duygu analizinin alt görevleri olduğunu ifade etmektedir (Zhang, Wang ve Liu, 2018).

Yine de ilgili birçok çalışmada; duygu analizi, bir metin parçasının *pozitif* (positive), *negatif*

(negative), *nötr* (neutral) veya *hiçbiri* (none) olarak sınıflandırılması olarak tanımlanan polarite (aynı zamanda yönelim veya değerlik olarak da adlandırılır) tespitine eşdeğer kabul edilir (Cambria, Das, Bandyopadhyay ve Feraco, 2017).

Duygu analizinin önemli bir alt problemi de *özellik-tabanlı* veya *hedef-tabanlı duygu analizidir* (Aspect-based Sentiment Analysis - AbSA). Özellik-tabanlı duygu analizinde, sadece metne bir duygu analizi sınıfı etiketi atanması yerine, metinde yer alan (genellikle bir varlığın) özelliklerine yönelik duygu analizi yapılmaktadır ve söz konusu özellikler için ayrı sınıf etiketleri atanmaktadır (Nazir, Rao, Wu ve Sun, 2020). Özellik-tabanlı duygu analizi problemi, genel duygu analizinin önemli bir alt problemi olduğu için burada değinilmiştir ancak tez çalışmamızın kapsamında yer almadığından bu problemle ilgili kısım bu bölümde açıklandığı kadarıyla sınırlı tutulmuştur.

Duygu analizi ile yakından ilişkili bir diğer problem de *duygu tanıma* (emotion recognition) problemidir. Duygu tanıma; polarite yerine, verilen metinde ifade edilen duygu (*mutluluk, üzüntü, öfke, nefret* vb.) tespit edilmeye çalışılmaktadır (Gaïnd, Syal ve Padgalwar, 2019; Küçük ve Arıcı, 2021; Küçük ve Arıcı, 2022b; Saxena, Khanna ve Gupta, 2020).

Duygu tanıma problemi, mevcut tez çalışmamızın kapsamına girmese de; ilgili literatürde duygu analizi ve duruş tespitiyle birlikte sıklıkla ele alındığından, tez kapsamındaki literatür taramamızda duygu tanımayla ilgili çalışmalara da yer verilmiştir.

Bu bölümün kalan kısmında halk sağlığıyla ilgili sosyal medya iletileri üzerinde duygu tespiti konusundaki çalışmalar derlenmiştir.

Hussain ve Sheikh'in (2021) çalışmasında; Twitter üzerinde yapılacak ilgili duygu analizi çalışmalarının, COVID-19 aşılarının yaygınlaştırılmasına yönelik politikaların oluşturulmasında faydalı olacağı vurgulanmıştır.

COVID-19 aşlarıyla ilgili Avustralya'dan atılan tweet'ler üzerindeki bir çalışmada (Kwok, Vadde ve Wang, 2021) hem duygu analizi (*pozitif* ve *negatif* sınıflarıyla) hem de 8 farklı duygu dikkate alınarak duygu tanıma yapılmıştır. Çalışmada, herkese açık doğal dil işleme araçları kullanılmıştır. Çalışmada pozitif duyguların yeterince fazla olmadığı ve bu tip sonuçların ilgili kamu kurumları tarafından kullanılması gerektiği vurgulanmıştır.

İlgili bir diğer çalışmada; k-ortalama (k-means) kümeleme algoritması kullanılarak COVID-19 aşısı konusundaki tweet'ler üzerinde duygu analizi gerçekleştirilmiştir (Wang ve Kwok, 2021).

Shamrat ve diğerleri (2021) tarafından yürütülen ilgili bir diğer çalışmada, değişik COVID-19 aşısı türleri ile ilgili tweet'ler üzerinde (*pozitif*, *negatif* ve *nötral* sınıflarıyla) duygu analizi yapılmıştır ve KNN makine öğrenmesi yöntemi kullanılmıştır. Çalışmada, her bir aşı türü için ayrı ayrı sınıf yüzdeleri verilmiştir.

Ansari ve Khan'ın (2021) çalışmasında, Türkiye dahil birçok ülkeden yayınlanan (COVID-19 aşısıyla ilgili) tweet'ler üzerinde TextBlob aracı ile duygu analizi yapılmış, çalışma sonucunda negatif duyguların daha yaygın olduğu görülmüştür.

Sv, Tandon ve Hinduja'nın (2021) çalışmasında da Hindistan'da COVID-19 aşılarının yan etkileriyle ilgili tweet'ler üzerinde TextBlob aracı ile duygu analizi denemeleri yapılmış, tweet'lerin %78'inden fazlasında yaygın duygunun pozitif veya nötral olduğu gözlemlenmiştir. Benzer şekilde Sv, Ittamalla ve Deepak'ın (2021) çalışmasında yine Hindistan'da COVID-19 aşısıyla ilgili tweet'ler üzerinde duygu analizi yapılmıştır.

Ali ve diğerlerinin (2021) ilgili çalışmasında 2021 yılında ABD'den yayınlanan COVID-19 aşısı hakkındaki tweetler üzerinde zamansal ve mekansal duygu analizi, hazır bir duygu analizi aracı kullanılarak gerçekleştirilmiştir.

Liu, Li ve Liu'nun (2021) çalışmasında da COVID-19 aşısı hakkındaki tweet'ler üzerinde değişik makine öğrenmesi yöntemleriyle duygu analizi gerçekleştirilmiştir. Lojistik regresyon, rasgele orman ve SVM ile *öğrenme aktarımı* (*transfer learning*) yöntemleri kullanılmış ve çalışmanın sonuçlarının eğitim programları tarafından COVID-19 aşısının kabulünü artırmak için kullanılabileceği vurgulanmıştır.

Takip eden bir diğer çalışmada (Liu ve Liu, 2021); VADER (Valence Aware Dictionary and sEntiment Reasoner) duygu analizi aracı (Hutto ve Gilbert, 2014) ile COVID-19 aşısıyla ilgili Liu, Li ve Liu'nun (2021) çalışmasındaki tweet veri kümesi üzerinde duygu analizi gerçekleştirilmiştir. Bu tweet'lerin 42.8%'inin *pozitif*, 30.3%'ünün *negatif* olarak sınıflandırıldığı görülmüştür.

VADER aracı ile duygu analizi gerçekleştirilen bir diğer ilgili çalışmanın (Xu, Liu, Luo, Xu, ve Wang, 2021) sonucunda, yeni ortaya çıkan COVID-19 vakalarının sayısı gibi farklı faktörlerin insanların duygularını etkilediği ortaya konmuştur.

Sattar ve Arifuzzaman'ın (2021) çalışmasında da TextBlob ve VADER (Hutto ve Gilbert, 2014) araçları kullanılarak; COVID-19 aşısıyla ilgili tweet'ler üzerinde duygu analizi gerçekleştirilmiş ve tweet'lerin çoğunluğunun *pozitif* olarak sınıflandırıldığı görülmüştür.

Batra ve diğerleri (2021) tarafından gerçekleştirilen çalışmada; Hindistan, Pakistan, İsveç, Norveç, ADB, Kanada ülkelerinden yayınlanan ve COVID-19 ile ilgili tweet'ler üzerinde duygu analizi testleri yapılmıştır. Çalışmada, birbirine komşu ülkelerde aşırı benzer tepkilerin verildiği belirtilmiştir.

ABD ve İngiltere'den, COVID-19 aşlarıyla ilgili (Facebook ve Twitter'dan) toplam 300.000 sosyal medya metni üzerinde Hussain ve diğerleri (2021) tarafından yürütülen bir çalışmada derin öğrenme tabanlı duygu analizi gerçekleştirilmiştir. Her iki ülkedeki sosyal medya metinlerinde de pozitif duygunun daha yaygın (%55'in üzerinde) olduğu gözlenmiştir.

Villavicencio, Macrohon, Inbaraj, Jeng ve Hsieh'in (2021) ilgili çalışmasında COVID-19 aşlarına ilişkin İngilizce ve Filipince tweet'ler üzerinde Naïve Bayes yaklaşımı ile duygu analizi gerçekleştirilmiştir.

Endonezya'da gerçekleştirilen ilgili bir diğer çalışmada da (Ritonga, Ihsan, Anjar ve Rambe, 2021) COVID-19 aşlarına ilişkin tweet'ler üzerinde Naïve Bayes yöntemi ile duygu analizi yapılmıştır.

Güney Kore'de gerçekleştirilen ilgili bir diğer çalışmada, bir ay boyunca COVID-19 aşlarıyla ilişkili tweet'lerdeki duygu değişimleri analiz edilmiştir (Shim ve diğerleri, 2021).

Öte yandan; Müller ve Salathé'nin (2020) çalışmasında makine öğrenmesi algoritmalarının yaşadığı *kavram kayması (concept drift)* probleminin, pandemi sırasındaki sosyal medya iletilerinde duygu analizine etkisi incelenmiştir. Kavram kayması; genel olarak, belirli bir eğitim veri kümesinde eğitilmiş makine öğrenmesi algoritmalarının test aşamasında daha

güncel verilerle test edildiklerinde başarımlarının düşmesi olarak tanımlanabilir (Müller ve Salathé, 2020).

Melton, Olusanya, Ammar ve Shaban-Nejad (2021) tarafından tamamlanan çalışmada ise bu kez COVID-19 aşılılarıyla ilgili Reddit platformunda yayınlanan iletiler üzerinde duygu analizi gerçekleştirilmiş ve iletilerde pozitif duygunun negatiften daha yaygın olduğu vurgulanmıştır.

Jawad ve diğerleri (2021), COVID-19 aşılılarıyla ilgili olarak Twitter üzerinde hem duygu analizi hem de duygu tanıma işlemlerini sözlük tabanlı yöntemler kullanarak gerçekleştirmiştir. Söz konusu çalışmada, duygu analizi sınıfları olarak *pozitif* ve *negatif*; duygu tanıma sınıfları olarak ise *öfke*, *güven*, *korku*, *üzüntü*, *sevinç*, *şaşkınlık*, *iğrenme* ve *beklenti* kullanılmıştır.

ABD’de COVID-19 aşılılarına ilişkin olarak Twitter üzerinde duygu analizinin gerçekleştirildiği bir diğer çalışmada (Karami, Zhu, Goldschmidt, Boyajieff ve Najafabadi, 2021); duygu analizi için mevcut araçlardan VADER (Hutto ve Gilbert, 2014), LIWC (Linguistic Inquiry and Word Count) ve Brandwatch kullanılmıştır ve en iyi sonuçların Brandwatch tarafından elde edildiği gözlemlenmiştir.

Kaggle.com adresinde bulunan COVID-19 hakkındaki bir tweet kümesi üzerinde üç sınıflı (*pozitif*, *negatif*, *nötr*) duygu analizi Singh, Imam, Wibowo ve Grandhi (2022) tarafından gerçekleştirilmiştir. LSTM ve *dikkat* (*attention*) mekanizması kullanan yöntemin SVM ve rasgele orman gibi yöntemlere kıyasla daha iyi sonuçlar verdiği (F-oranı: %75,67) belirtilmiştir.

Marcec ve Likic (2022); çeşitli COVID-19 aşılıları hakkındaki tweet’ler üzerinde sözlük tabanlı bir yöntemle duygu analizi gerçekleştirmiştir.

Ye, Hai, Wang, Wei ve Song (2022), BERT modelini kullanarak COVID-19 aşılılarına ilişkin tweet’ler üzerinde duygu analizi gerçekleştirmişlerdir. Aynı çalışmada; kullanılan veri kümesi üzerinde *pozitif* duygunun daha yaygın olduğu da ifade edilmiştir.

Zulfiker, Kabir, Biswas, Zulfiker ve Uddin (2022) tarafından Bangladeş’te COVID-19

aşıları hakkındaki İngilizce tweet'ler üzerinde iki sınıflı (*pozitif, negatif*) duygu analizi gerçekleştirilmiştir. SVM ve karar ağaçları gibi makine öğrenmesi yöntemleri ile LSTM, Bi-LSTM ve CNN gibi derin öğrenme yöntemleri arasından Bi-LSTM ile en iyi sonuç (F-oranı: %88,89) elde edilmiştir.

Niu ve diğerleri (2022) COVID-19 aşılıları hakkındaki Japonca tweet'leri Amazon'un duygu analizi API'sini kullanarak analiz etmişlerdir.

Nezhad ve Deihimi'nin (2022) çalışmasında; İran'da COVID-19 aşılıları hakkındaki Farsça tweet'ler üzerinde CNN-LSTM mimarisi tabanlı bir duygu analizi modeli uygulanmıştır.

Başka bir çalışmada Hindistan'da COVID-19 aşılıları hakkındaki tweet'ler üzerinde duygu analizi testleri yapmıştır. Bu çalışma kapsamındaki testlerde sözlük tabanlı ve makine öğrenmesi tabanlı modellerin benzer sonuçlar verdikleri gözlenmiştir. (Paliwal, Parveen, Afshar Alam, Ahmed, 2022)

Güney Kore'de yayınlanan COVID-19 aşılılarına ilişkin sosyal medya metinleri üzerinde Bayes sınıflandırma yöntemiyle yapılan duygu analizi sonucunda; salgının ilk evrelerinde nötr duygunun, sonraki evrelerinde ise pozitif duygunun hâkim olduğu gözlenmiştir (Choi, Lee ve Paek, 2022).

Genel olarak; bu alanda yapılan çalışmaların birçoğunda (Chandrasekaran, Desai, Shah, Kumar, Moustakas, 2022; Hu ve diğerleri, 2021; Huangfu, Mo, Zhang, Zeng, He, 2022; Liu ve Liu 2021; Sattar ve Arifuzzaman, 2021; Yin, Song, Yang, Li, 2022; Yousefinaghani, Dara, Mubareka, Papadopoulos, Sharif, 2021) duygu analizi için VADER aracının (Hutto ve Gilbert, 2014) kullanıldığı gözlemlenmiştir.

Duygu tanıma konusuna ilişkin olarak ise Xue ve diğerlerinin (2020) çalışmasında COVID-19 hakkındaki Twitter iletileri üzerinde Latent Dirichlet Allocation (LDA) metodu kullanılarak duygu tanıma işlemi gerçekleştirilmiştir. Chou ve Budenz'in (2020) ilgili çalışmasında, duygu tanıma konusunda yapılacak çalışmaların özellikle toplumdaki aşı tereddüdü ile mücadele etmeye yönelik stratejilerin belirlenmesinde faydalı olacağı vurgulanmıştır.

Kaur, Kaul ve Zadeh'in (2020) çalışmasında COVID-19 ile ilgili tweet'ler üzerinde TextBlob aracı ile duygu analizi, aynı zamanda da IBM Tone Analyzer adlı araç (URL2) ile duygu tanıma işlemi gerçekleştirilmiştir.

Stella, Vitevitch ve Botta'nın (2021) çalışmasında; aşılara ilgili İngilizce ve İtalyanca tweet'lerdeki perspektifleri ve duyguları tespit etmek amacıyla, metin ve görüntü verileri üzerinde bilişsel ağlar (cognitive networks) ile görüntü işleme teknikleri kullanılmıştır.

Lyu, Han ve Luli (2021) aşıyla ilgili tweet'ler üzerinde R programlama dilinde geliştirilmiş hazır bir duygu analizi aracı (URL3) ile duygu analizi yapmışlar, aynı zamanda NRC Duygu Sözlüğü (Emotion Lexicon) adlı kaynağı (URL4) kullanarak da duygu tanıma yapmışlardır.

2.4. Duruş Tespiti

Duruş tespiti, ilgili çalışmalarda yaygın olarak *duruş analizi* veya *duruş tahmini* olarak da bilinir. Duygu analizi ile ilgili olmasına rağmen, duruş analizi/tespiti, bir hedefe yönelik pozisyon veya duruşun araştırılması anlamında farklı bir problemdir (Küçük ve Can, 2020; Mohammad, Kiritchenko, Sobhani, Zhu ve Cherry, 2016). Duruşun hedefi; bir varlık, bir fikir veya bir olay gibi herhangi bir kavram olabilir. Yaygın duruş sınıfları arasında *tarafında* (favor), *karşısında* (against) ve *hiçbiri* (neither/none) yer alır.

Duruş analizi genellikle insanların tartışmalı konularda, seçimlerde veya referandumlarda adaylara veya konulara karşı tutumlarını belirlemek için yapılır (Küçük ve Can, 2020). Bununla birlikte; bazı çalışmalarda duygu analizi ve duruş tespiti problemlerinin birlikte ele alındıkları ve hem duygu hem de duruş etiketleri ile işaretlenmiş veri kümelerinin oluşturulduğu görülmektedir (Mohammad, Sobhani ve Kiritchenko, 2017; Küçük ve Arıcı, 2022a).

Yakın dönemde yapılan çalışmalarda (Zhang, Ding ve Jing, 2022); ChatGPT gibi transformer tabanlı üretken yapay zekâ modellerinin duruş tespiti problemini çözmede başarılı olduğu ifade edilmiştir.

Bu bölümün kalan kısmında halk sağlığıyla ilgili sosyal medya iletileri üzerinde duruş tespiti konusundaki çalışmalar derlenmiştir.

Bu konudaki ilk çalışmalardan birinde (Zhang ve diğerleri, 2017) insanların tamamlayıcı ve alternatif tıp konusuna ilişkin duruşları belirlenmeye çalışılmıştır.

Twitter’da COVID-19 aşılara yönelik ilk çalışmalardan birinde (D’Andrea ve diğerleri, 2019), İtalyanca tweet’ler üzerinde aşılarla yönelik duruş tespiti, farklı makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak gerçekleştirilmiştir. Duruş sınıfları olarak *aşının tarafında*, *aşının tarafında değil* ve *nötral*’in kullanıldığı bu çalışmada SVM modeli ile en iyi başarıya ulaşıldığı ifade edilmiştir.

COVID-19 aşılarının ilk açıklandığı dönemde, aşıyla ilgili tweet’ler üzerinde, aşılarla karşı duruş tespiti gerçekleştiren bir çalışmada (Cotfas ve diğerleri, 2021); tweet’lerin çoğunun *nötral* duruşa sahip olduğu, aşılarda ‘*tarafında*’ olan tweet’lerin ‘*karşısında*’ olan tweet’lere göre fazla oldukları görülmüştür.

Twitter’da COVID-19 aşısı konusunda yapılan bir diğer duruş tespiti çalışmasında; *aşı-taraftarı*, *aşı-karşıtı* ve *nötral* sınıfları kullanılmıştır (Scannell ve diğerleri, 2021). Bu çalışmada yaklaşık 1.000 adet tweet üzerinde testler yapılmıştır ve ilgili çalışmaların sonuçlarının ulusal aşı kampanyalarında kullanılabileceği belirtilmiştir.

Glandt, Khanal, Li, Caragea ve Caragea (2021), COVID-19 ile ilgili okul kapanmaları ve maske takılması gibi önlemlerle ilgili tweet’ler üzerinde farklı derin öğrenme yöntemleri ile duruş tespiti yapmış, BERT modeli en iyi sonuçları vermiştir, ayrıca toplamda 6133 tweet işaretlenmiştir.

Nyawa, Tchunte ve Fosso-Wamba (2022) tarafından toplam 20.000 tweet COVID-19 aşısına karşı ‘*tereddütlü*’ ve ‘*tereddütlü değil*’ olarak işaretlenmiş ve bu sınıflara göre tweet sınıflandırma testleri yapılmıştır. LSTM derin öğrenme yöntemi diğer birçok makine öğrenmesi (SVM, KNN, rasgele orman) ve RNN gibi derin öğrenme yöntemlerine göre daha iyi sonuçlar vermiştir (F-oranı: %80).

Alqurashi (2022) tarafından COVID-19 salgını sırasında uzaktan eğitime yönelik olarak

Arapça tweet'ler (4348 adet) üzerinde iki sınıflı (*tarafında*, *karşısında*) duruş tespiti testleri gerçekleştirilmiştir. Bu çalışmada rasgele orman, SVM, Adaboost, multinomial naïve Bayes, CNN ve LSTM yöntemleri denenmiş, SVM yönteminin en iyi başarımı (F-oranı: %85,9) gözlemlenmiştir.

Miao, Last ve Litvak (2022) COVID-19 sırasında New York'taki kapanma politikası hakkındaki tweet'ler üzerinde üç sınıflı (*tarafında*, *karşısında*, *hiçbiri*) duruş tespiti gerçekleştirmiştir. Çalışmada; SVM, BERT ve LSTM yöntemleri test edilmiş ve LSTM'in en iyi sonuçları (F-oranı: %63) verdiği tespit edilmiştir.

Twitter kullanıcılarının COVID-19 öncesi ve sonrasında aşılara karşı tavırlarını tespit etmek amacıyla gerçekleştirilen bir diğer güncel çalışmada (Poddar, Mondal, Misra, Ganguly ve Ghosh, 2022) ilgili tweet kümeleri üzerinde duruş tespiti ('*aşı taraftarı*', '*aşı karşıtı*', '*nötral*') gerçekleştirilmiştir. SVM, FastText ve BERT versiyonları test edilmiş, en iyi sonuç (F-oranı: %82,5) CT-BERT versiyonu tarafından elde edilmiştir. Bu çalışmada; ayrıca insanların pandemi öncesi ve sonrasında duruşlarının nedenleri de belirlenmeye çalışılmıştır (COVID-19 salgını sonrası aşılarda çok acele geliştirilmesi, etkisiz olduğu düşüncesi gibi...).

Zhu, Fang, Pergola, Procter ve He (2022), COVID-19 aşılarda hakkındaki tweet'ler üzerinde semi-supervised bir yaklaşımla duruş tespiti yapmıştır. Yöntem olarak bir oto-kodlayıcı (auto-encoder) mimarisi kullanılmış, bu mimari üzerinde semi-supervised bir yöntem ile tuning yapılmıştır.

Sauvayre, Vernier ve Chauvière (2022) COVID-19 aşılarda hakkında Fransızca tweet'ler üzerinde BERT modelini kullanarak duruş tespiti yapmışlardır. Çalışmaları kapsamında 1851 tweet toplayıp işaretlemişlerdir.

Duruş tespiti için COVID-19 aşılarda ilgili işaretlenmiş İspanyolca tweet'lerden oluşan bir veri kümesi Martínez, Blanco ve Lourenço (2023) tarafından sunulmuştur.

2.5. Varlık İsmi Tanıma

Varlık ismi tanıma, doğal dil işleme problemlerinden *bilgi çıkarımının* kapsamında yer almaktadır. En yaygın tanımı ile *varlık ismi tanıma*; doğal dildeki metinlerden insan ismi,

yer ismi, kurum ismi gibi önemli bilgilerin çıkarımıdır (Küçük ve Arıcı, 2016). Sıklıkla varlık ismi tanımının kapsamına doğal dildeki metinlerden tarih-zaman bilgileri ile parasal ifadelerin çıkarımı da dâhil edilmektedir (Sundheim, 1995).

Varlık ismi tanıma probleminin çözümüne yönelik öncül çalışmalar kural-tabanlı olmakla birlikte, daha güncel çalışmalar sırasıyla makine öğrenmesi ve derin öğrenme modellerine dayalı çalışmalardır (Li, Sun, Han ve Li, 2020).

Konuyla ilgili öncül çalışmalar; gazete haberleri gibi dilbilgisi ve yazım kurallarına daha uygun metinler üzerinde yapılmış iken, daha yeni çalışmalarda sosyal medya metinleri gibi dilbilgisi ve yazım kurallarına dikkat edilmeyen, kısaltmaların yaygın olarak kullanıldığı metinler üzerinde çalışılmıştır (Ritter, Clark ve Etzioni, 2011; Liu, Zhang, Wei ve Zhou, 2011).

Sağlık alanındaki metinlerde varlık ismi tanımada ise çoğunlukla alana özgü isimler ve terimler dikkate alınmaktadır. Dolayısıyla, sağlıkla ilgili varlık isimleri; hastalıkların, yan etkilerin, bakteri ve virüslerin, salgınların, aşı ve ilaçların, sağlıkla ilişkili kurumların (ilgili kamu kurumları, bakanlıklar ile ilaç firmaları vb.) ve yerlerin (hastaneler vb.) isimlerini kapsamaktadır.

Nikfarjam ve diğerleri (2015) tarafından gerçekleştirilen sağlık alanındaki varlık ismi tanıma çalışmasında, sosyal medya iletileri üzerinde ilaçların istenmeyen etkileri (adverse drug reactions), CRF (Conditional Random Fields) adlı makine öğrenmesi yöntemiyle tespit edilmeye çalışılmıştır.

Xia, Wang ve Fan (2017) tarafından sunulan ilgili bir diğer çalışmada; yine varlık ismi olarak ilaçların istenmeyen (olumsuz) etkileri (adverse drug events - ADE) dikkate alınmış ve derin öğrenmeye dayalı bir yöntemle bu isimlerin metinlerden çıkarılmasına yönelik deneyler yapılmıştır.

İlaçların istenmeyen etkilerinin varlık ismi olarak kabul edilerek, Twitter üzerinde bu amaçla varlık ismi tanıma işlemi yapılan bir diğer çalışmada (Cocos, Fiks ve Masino, 2017) yine derin öğrenme yöntemlerinden RNN modeli kullanılmıştır.

Magumba, Nabende ve Mwebaze'nin (2018) çalışmasında; Twitter'da hastalık isimlerinin otomatik çıkarımı için bir derin öğrenme yaklaşımıyla birlikte ontoloji kullanılmıştır.

Gorinski ve diğerleri (2019) tarafından gerçekleştirilen çalışmada; elektronik sağlık kayıtları üzerinde varlık ismi tanıma amacıyla kural-tabanlı yaklaşımlar ile makine öğrenmesi yaklaşımları karşılaştırılmıştır. Çalışmanın sonucunda; kural-tabanlı yaklaşımlar ile yüksek doğrulukta sonuçlar elde edildiği ancak henüz kuralların oluşturulamadığı durumlarda makine öğrenmesi yaklaşımlarının daha etkin olduğu vurgulanmıştır.

Yine ilgili bir diğer çalışmada da (Fan, Fan ve Smith, 2020) metinden ilaçların olumsuz etkilerinin tespiti ve çıkarılması için derin öğrenme yöntemleri kullanılmıştır.

Biyomedikal metinler üzerinde varlık ismi tanıma (BioNER) problemi için; Asghari, Sierra-Sosa ve Elmaghraby (2022) LSTM, RNN ve CRF yöntemlerine dayalı BİNER adlı metodu sunmuşlardır. BERT tabanlı BioBERT yöntemi ile karşılaştırma yapılmış ve BİNER'in değişik veri kümeleri üzerinde F-oranı bazında %3 ile %9 arasında daha iyi sonuçlar alabildiği görülmüştür.

Yine biyomedikal metinlerde varlık ismi tanıma için Chai ve diğerleri (2022) tarafından multi-task öğrenmeyi de kullanan hiyerarşik ortak bir transfer öğrenmesi yöntemi sunulmuştur. Beş veri kümesi üzerinde yapılan testler sonucunda üç veri kümesi üzerinde, önerilen yöntem BioBERT ve diğer yöntemlerden daha iyi sonuçlar elde etmiştir. Yöntemin elde ettiği en yüksek başarımlar %93,83'tür (F-oranı).

2.6. Makine Öğrenmesi ve Derin Öğrenme

Tez çalışmamız kapsamında makine öğrenmesi ve derin öğrenmesi modelleri kullanıldığından bu bölümde bu iki önemli konu hakkında ilgili literatüre dayalı özet bilgi sunulmaktadır.

2.6.1. Makine öğrenmesi

Makine öğrenmesi; yapay zekanın temelini oluşturan kavramlardan biridir ve bilgisayarların deneyimleri yoluyla giderek kendilerini iyileştirmelerini amaçlayan metotları kapsamaktadır

(Jordan ve Mitchell, 2015). Makine öğrenmesi algoritmaları (modelleri) resim ve video işleme, metin (veya doğal dil) işleme ve ses işleme alanlarındaki problemlerin çözümünde uzun yıllardır kullanılmaktadır.

Makine öğrenme algoritmaları (modelleri) genellikle denetimli (supervised) algoritmalar ve denetimsiz (unsupervised) algoritmalar olarak ikiye ayrılmaktadır. Bunlar dışında yarı-denetimli (semi-supervised) algoritmalar mevcut olduğu gibi, birden fazla modeli birleştiren topluluk (ensemble) öğrenmesi yöntemleri de mevcuttur.

Bir çok alanda kullanılmakta olan ve birçok alt türe ayrılan denetimli makine öğrenmesi algoritmaları eğitim (training) adı verilen bir süreç içerisinde işaretli veriler kullanılarak eğitilmektedirler, ardından da eğitim kümesinde bulunmayan veriler üzerinde test edilmektedirler. Dolayısıyla denetimli makine öğrenmesi algoritmaları test edilmeden bir eğitim aşamasına ihtiyaç duymaktadırlar.

En bilinen denetimli makine öğrenmesi algoritmaları arasında yapay sinir ağları, karar ağaçları, SVM (Support Vector Machine – Destek Vektör Makinesi), CRF (Conditional Random Fields – Şartlı Rasgele Alanlar) ile lojistik regresyon sayılabilir.

Denetimsiz makine öğrenmesi yöntemleri genellikle işaretlenmemiş veri kümeleri üzerinde verinin yapısıyla ilgili belirli varsayımlara göre çalışan algoritmalar (Jordan ve Mitchell, 2015). En bilinen denetimsiz makine öğrenmesi yöntemleri kümeleme algoritmaları bunlar arasında en bilinenlerinden biri de k-ortalama (k-means) algoritmasıdır.


Birden fazla makine öğrenmesi algoritmasını birleştiren topluluk öğrenmesi algoritmalarının en bilinenleri arasında ise rasgele orman (random forest) ile torbalama (bagging) algoritmaları sayılabilir.

Yaygın kullanılan denetimli makine öğrenmesi modellerinin karşı karşıya kaldıkları en önemli problemlerden birisi *eğitim verisinin yetersizliği/kıtlığı* (data scarcity) durumudur. Seçilen alanı modellemek için eğer makine öğrenmesi modeline yeterli büyüklükte ve sınıflara göre dengeli dağılmış bir eğitim veri kümesi sağlanamazsa, bu modelin test aşamasında yüksek performansa ulaşması mümkün olmayacaktır. Makine öğrenmesi

modellerinin sıklıkla karşılaştığı bu veri yetersizliği problemini çözebilmek için literatürde *veri artırımı* (*data augmentation*) adı verilen bir yöntem önerilmiştir.

Genel bir ifade ile; veri artırımı yöntemleri eğitim veri kümesinde mevcut olan verilerin bir miktar değiştirilerek tekrar bu kümeye eklenmesi yoluyla eğitim veri kümesinin artırılmasını amaçlamaktadır (Wei ve Zou, 2019). İlgili çalışmalarda yer verilen yaygın veri artırımı yöntemleri arasında kelimeleri eşanlamlısı ile değiştirme (synonym replacement), rasgele değiş-tokuş (random swap) ve geri-çevrim (back-translation) yöntemleri sayılabilir (Wei ve Zou, 2019). Örneğin eşanlamlısı ile değiştirme yönteminde; eğitim kümesindeki metin verileri içerisindeki kelimeler eşanlamlıları ile değiştirilerek bu değiştirilmiş veriler etiketleri korunarak tekrar veri kümesine eklenmektedir. Benzer şekilde, geri-çevrim tabanlı veri artırımı yöntemlerinde eğitim verisi içerisindeki metin verileri otomatik olarak farklı bir dile çevrildikten sonra elde edilen bu çeviri tekrar orijinal diline geri çevrilmekte, elde edilen çeviri metni, orijinal metnin etiketi ile veri kümesine eklenmektedir.

Geri-çevrim yoluyla veri artırımına bir örnek Şekil 2.1’de sunulmaktadır. Bu şekilde, orijinal dili İngilizce olan bir metin Fransızca’ya çevrildikten sonra tekrar İngilizce’ye geri çevrilmekte, bu nihai çeviri de veri kümesine eklenmektedir. Veri artırımı yöntemlerinin hem duygu analizi (Xiang ve diğerleri, 2021) hem de duruş tespiti (Li ve Caragea, 2021) problemlerinin çözümünde veri yetersizliği probleminin etkilerini azaltmak için kullanıldığı görülmektedir.



Şekil 2.1. Geri-çevrim (back-translation) tabanlı veri artırımı örneği (URL5)

2.6.2. Derin öğrenme

Derin öğrenme; genellikle makine öğrenmesi algoritmalarında kullanılan soyutlama katmanı sayılarına kıyasla çok daha fazla soyutlama katmanı kullanan öğrenme modellerini kapsamaktadır (Goodfellow, Bengio ve Courville, 2016). Günümüzde derin öğrenme alanında yaşanan hızlı gelişmeler, yapay zekanın hedeflerine daha önce olduğundan daha fazla oranda yaklaşıldığı şeklinde yorumlanmaktadır.

Doğal dil işleme problemlerinin çok büyük bir bölümünün çözümü için de yakın dönemlerden itibaren (özellikle son 10 yıldır) derin öğrenme modellerinin yaygın olarak kullanıldığı bilinmektedir (Küçük ve Arıcı, 2018). Literatürde yaygın olarak kullanıldığı görülen derin öğrenme modelleri aşağıda listelenmiş ve kısaca açıklanmıştır.

- *Recurrent Neural Networks (Yinelemeli Sinir Ağları) – RNN*: Genellikle, zaman serileri ve diğer sıralı veriler gibi bir dizi halinde gelen verileri işlemek için kullanılan derin öğrenme modelleridir. RNN'ler, girdi verilerini işlerken önceki zaman adımlarından gelen bilgiyi saklayabilen yapılardır. Bu özellik, bu derin öğrenme modelinin; dil modellemesi, metin üretimi, zaman serisi analizi gibi birçok alanda kullanılmalarını sağlar. RNN'lerin önemli bir dezavantajı uzun süreli bağımlılıkları etkili bir şekilde öğrenme konusunda zorluk yaşamalarıdır.
- *Long Short-Term Memory – LSTM (Uzun Kısa-Dönem Bellek)*: LSTM'ler, RNN'lerin daha gelişmiş bir versiyonudur ve özellikle uzun süreli bağımlılıkları daha etkili bir şekilde öğrenebilirler. Bunun temel sebebi, LSTM'lerin hafıza hücrelerine ve kontrol mekanizmalarına sahip olmalarıdır. Uzun süreli bağımlılıkları etkili bir şekilde öğrenme yetenekleri sayesinde, özellikle sıralı verilerle ilgili karmaşık modeller oluşturulmasında yaygın kullanılan derin öğrenme modellerindendir.
- *Convolutional Neural Networks – CNN (Konvolüsyonel Sinir Ağları)*: Özellikle görsel verilerde kullanılan derin öğrenme modellerindendir. Geleneksel sinir ağlarından farklı olarak CNN'ler, görüntü işleme gibi alanlarda büyük başarı elde etmişlerdir. CNN'lerin temel amacı, görsel veri içindeki özellikleri çıkarmak ve bu özellikleri hiyerarşik olarak öğrenmektir. Bu özelliklere örnek olarak kenarlar, desenler veya daha yüksek seviye özellikler verilebilir.

- *Transformer (Dönüştürücü) Tabanlı Yöntemler*: Tezimizin ilerleyen bölümlerinde tekrar ele alınacağı üzere, transformer tabanlı modeller özellikle büyük boyutlu metin verileri üzerinde başarılı sonuçlar elde etme potansiyeline sahip derin öğrenme yöntemleridir. RNN veya LSTM gibi sıralı yapılar yerine *dikkat* (attention) mekanizmasına dayanan bir yapıya sahiptir. Transformer'lardaki dikkat mekanizması, özellikle uzun mesafeli bağımlılıkların daha etkili bir şekilde öğrenilmesini sağlamaktadır. Bu nedenle de bu türdeki derin öğrenme modelleri; dil modelleme ve makine çevirisi (dilden dile çeviri) gibi görevlerde oldukça etkilidir.
- *Generative Adversarial Networks – GAN (Üretken Çekişmeli Ağlar)*: Özellikle yapay olarak veri üretmek için kullanılan etkili bir derin öğrenme modelidir. *Üretici ağ* ve *ayırt edici ağ* olmak üzere iki ana ağdan oluşmakta ve bu iki ağ, oyun teorisi prensibine dayalı olarak birbirleriyle rekabet etmektedirler. Üretici ağ, daha gerçekçi veriler üretmeyi öğrenirken, ayırt edici ağ, gerçek veriler ile üretilen veriler arasındaki farkı öğrenmeye çalışmaktadır.
- *Deep Reinforcement Learning (Derin Pekiştirmeli Öğrenme)*: Bu model, aksiyon alma ve karar verme yeteneklerini geliştirmek için derin öğrenme tekniklerini kullanır. Model, bir ajanın belirli bir ortamda farklı aksiyonları deneyerek, en büyük ödülü alma gibi belirli bir amaca ulaşmayı öğrenmesini amaçlar. Derin pekiştirmeli öğrenme algoritmaları, ajanın doğru aksiyonları seçmesi ve bu aksiyonların belirli bir amaca yönelik olarak en iyi şekilde öğrenilmesi için kullanılır. Bu modelin özellikle karmaşık karar verme problemlerinde, video oyunlarında ve robotik gibi alanlarda kullanıldığı ve yüksek başarımlar elde ettiği görülmektedir.


Önceki alt bölümlerde sunulduğu gibi; derin öğrenme yöntemleri, halk sağlığının sosyal medya üzerinde takibi için kullanılmaya başlanmıştır. Örnek bir çalışmada; sosyal medya üzerinde salgın takibi ve salgının gerçek-zamanlı modellenmesi için bir derin öğrenme algoritması olan MultiLayer Perceptron – MLP kullanılarak Simnest isimli bir sistem geliştirilmiştir (Zhao ve diğerleri, 2015).

2.6.3. Transformer tabanlı modeller ve BERT

Önceki bölümde de kısaca açıklandığı üzere, transformer tabanlı öğrenme modelleri ilk olarak Vaswani ve diğerlerinin 2017 tarihli çalışmasında tanıtılmıştır. Bu modeller; derin öğrenme tabanlı modellerdir ancak yineleme (recurrence) veya konvolüsyon (convolution)

yerine dikkat (attention) mekanizmasını kullanmaktadırlar. Bu öğrenme modellerinin temel mimarisi Şekil 2.2’de verilmiştir (Vaswani ve diğerleri, 2017).


Transformer tabanlı modellerin; otomatik çeviri ve doğal dil üretimi gibi birçok metin işleme problemi için başarılı sonuçlar verdiği gözlemlenmiştir.



Şekil 2.2. Temel dönüştürücü (transformer) mimarisi (Vaswani ve diğerleri, 2017)

BERT (Bidirectional Encoder Representations of Transformers) yaygın olarak kullanılan transformer tabanlı bir öğrenme modelidir (Devlin, Chang, Lee ve Toutanova, 2018). BERT mimarisi de ilgili çalışmasından alıntılanarak Şekil 2.3’te sunulmuştur (Devlin, Chang, Lee ve Toutanova, 2018).

BERT modelinde; *ön-eğitim (pre-training)* ve *fine-tuning (hassas ayar)* olarak anılan iki aşama yer almaktadır. BERT modelinin de farklı doğal dil işleme problemleri için kullanıldığı ve başarılı sonuçlara ulaştığı bilinmektedir.



Şekil 2.3. BERT modelinin mimarisi (Devlin, Chang, Lee ve Toutanova, 2018)

Literatürde İngilizce dışında değişik diller için de BERT modelleri sunulduğu görülmektedir. İlgili diller arasında İspanyolca (Cañete ve diğerleri, 2020), İtalyanca (Polignano, Basile, De Gemmis, Semeraro, Basile, 2019), Fransızca (Le ve diğerleri, 2019) ve Çince (Cui, Che, Liu, Qin, Yang, 2021) sayılabilir.

2.6.4. Üretken yapay zekâ modelleri ve ChatGPT


Üretken yapay zeka modelleri (generative artificial intelligence models); büyük boyutlu veriler üzerinde eğitildikten sonra özgün içerik üretebilen modellerdir (Gozalo-Brizuela ve Garrido-Merchan, 2023). Söz konusu üretken modeller; girdi ve çıktıları dikkate alınarak metinden-görüntüye (text-to-image), metinden-metne (text-to-text), metinden-koda (text-to-code) gibi alt sınıflara ayrılarak incelenmektedir (Gozalo-Brizuela ve Garrido-Merchan, 2023).

Metinden-metne türündeki üretken modellerden en bilinenlerinden biri OpenAI firması tarafından geliştirilmiş olan ChatGPT sistemidir (URL6). ChatGPT, “Chat Generative Pre-trained Transformer” ifadesinin kısaltılmış halidir ve önceki bölümde açıklanan derin öğrenme yaklaşımlarından transformer modeline dayalı bir sistemdir.

ChatGPT ve benzer sistemler amaçlandıkları şekilde metin türünde çıktı üretebilmek için, derin öğrenme yaklaşımına dayalı olmanın yanı sıra çok büyük boyutlardaki metin verileri üzerinde de eğitilmiş olduklarından genellikle (ayrıca) büyük dil modeli (Large Language Model – LLM) olarak da adlandırılmaktadır.

ChatGPT sohbete dayalı bir şekilde kullanıcılarla etkileşimde bulunmaktadır (Gozalo-Brizuela ve Garrido-Merchan, 2023).

Tezimiz kapsamında testleri yapılan ve başarımlar değerlendirilmesi gerçekleştirilen (GPT-3.5 eğitilmiş dil modeline dayalı) ChatGPT'nin 25 Eylül 2023'e ait güncel arayüz görüntüsü Şekil 2.4'te verilmiştir.



Şekil 2.4. ChatGPT'nin güncel arayüz görüntüsü (URL6)



bulunan kelimelerin sıklıklarına dayalı olarak üretilen kelime bulutu Şekil 3.1’de verilmiştir. Bu ilk veri kümesi çoğunlukla tezimiz kapsamındaki öğrenme modellerinin eğitim (training) aşamasında kullanılmıştır. Bu veri kümemizdeki en sık geçen 20 kelime Çizelge 3.1’de verilmiştir.

Çizelge 3.1. 600 tweet’lik veri kümesinde en sık görülen 20 kelime ve sıklıkları

<i>Kelime</i>	<i>Sıklık</i>	<i>Kelime</i>	<i>Sıklık</i>
aşı	544	kadar	25
yok	46	bile	24
değil	45	sağlık	23
drfahrettinkoca	41	olan	23
var	41	olun	22
saglikbakanligi	39	iyi	22
oldu	32	olmak	21
asi	30	zaten	21
aşısı	28	covid	20
sonra	27	artık	20

Ardından ikinci olarak; benzer şekilde Ocak 2021’de yayınlanmış tweet’lerden de benzer veri temizleme işlemi sonrasında COVID-19 aşılılarıyla ilgili 230 tweet elde edilmiştir. Bu 230 tweet’ten oluşan kümedeki tweet’lerin kelimelerinden oluşturulan veri bulutu ise Şekil 3.2’de sunulmuştur. Bu ikinci veri kümesi de tezimiz kapsamındaki öğrenme modellerinin test aşamasında kullanılmıştır. Bu veri kümemizdeki en sık geçen 20 kelime Çizelge 3.2’de verilmiştir.



Şekil 3.2. 230 tweet’lik Türkçe veri kümesinden oluşturulan kelime bulutu

Çizelge 3.2. 230 tweet’lik veri kümesinde en sık görülen 20 kelime ve sıklıkları

Kelime	Sıklık	Kelime	Sıklık
aşı	218	son	12
zorunlu	53	haftada	12
doz	18	milyon	12
insan	18	fazla	11
var	17	karşı	11
yok	17	değil	11
olmak	16	olan	11
drfahrettinkoca	15	aykırıdır	11
haklarına	14	uygulandı	11
kadar	12	vaka	10

Son olarak ise; yine Ocak 2021’de yayınlanan tweet’lerden aynı veri temizleme yönteminden sonra 70 tweet daha elde edilerek bir önceki aşamadaki 230 tweet’lik kümeye eklenerek, bu ikinci kümenin tweet sayısı 300’e çıkarılmıştır. Bu kümenin tweet’lerindeki kelimelerden oluşturulan kelime bulutu ise Şekil 3.3’te verilmiştir. Bu veri kümemizdeki en sık geçen 20 kelime Çizelge 3.3’te verilmiştir.



Şekil 3.3. 300 tweet'lik Türkçe veri kümesinden oluşturulan kelime bulutu

Çizelge 3.3. 300 tweet’lik veri kümesinde en sık görülen 20 kelime ve sıklıkları

<i>Kelime</i>	<i>Sıklık</i>	<i>Kelime</i>	<i>Sıklık</i>
aşı	279	olan	15
zorunlu	54	drfahrettinkoca	15
yok	26	son	14
var	23	haklarına	14
doz	21	karşı	13
insan	20	sağlık	13
olmak	19	karşıtı	13
olun	17	vaka	12
kadar	17	olmayan	12
değil	16	aykırıdır	12

Tweet veri kümeleri oluşturulduktan sonra verilerin işaretlenmesi aşamasına geçilmiştir.

Bu aşamada veriler üzerinde; tezimiz kapsamındaki üç farklı doğal dil işleme problemine (duygu analizi, duruş tespiti ve varlık ismi tanıma) ilişkin işaretlemeler yapılmıştır.

Duygu analizi işaretlemeleri esnasında üç temel sınıf kullanılmıştır: *pozitif*, *negatif* ve *hiçbiri*. Duruş tespiti problemi için de şu üç temel sınıf kullanılmıştır: *tarafında*, *karşısında* ve *hiçbiri*.

Duruş tespiti çalışmalarında bu alanda önemli bir çalışma olan Mohammad, Sobhani ve Kiritchenko (2017) tarafından gerçekleştirilen araştırmadaki işaretleme talimatları kullanılmıştır. Söz konusu talimatlar bu çalışmadan alıntılanarak Şekil 3.4'te verilmiştir.

Target of Interest: [target entity]
 Tweet: [tweet with query hashtag removed]

Q1: From reading the tweet, which of the options below is most likely to be true about the tweeter's stance or outlook towards the target:


- We can infer from the tweet that the tweeter supports the target
This could be because of any of reasons shown below:
 - the tweet is explicitly in support for the target
 - the tweet is in support of something / someone aligned with the target, from which we can infer that the tweeter supports the target
 - the tweet is against something / someone other than the target, from which we can infer that the tweeter supports the target
 - the tweet is NOT in support of or against anything, but it has some information, from which we can infer that the tweeter supports the target
 - we cannot infer the tweeters stance toward the target, but the tweet is echoing somebody else's favorable stance towards the target (in a news story, quote, retweet, etc.)
- We can infer from the tweet that the tweeter is against the target
This could be because of any of the following:
 - the tweet is explicitly against the target
 - the tweet is against someone / something aligned with the target entity, from which we can infer that the tweeter is against the target
 - the tweet is in support of someone / something other than the target, from which we can infer that the tweeter is against the target
 - the tweet is NOT in support of or against anything, but it has some information, from which we can infer that the tweeter is against the target
 - we cannot infer the tweeters stance toward the target, but the tweet is echoing somebody else's negative stance towards the target entity (in a news story, quote, retweet, etc.)
- We can infer from the tweet that the tweeter is neutral towards the target
The tweet must provide some information that suggests that the tweeter is neutral towards the target – the tweet being neither favorable nor against the target is not sufficient reason for choosing this
- There is no clue in the tweet to reveal the stance of the tweeter towards the target (support/against/neutral)

Şekil 3.4. Duruş tespiti için işaretleme talimatları (Mohammad, Sobhani ve Kiritchenko, 2017)

Şekil 3.4'teki duruş tespiti için tweet işaretleme talimatlarını özetleyecek olursak; işaretleycilere duruşun hedefi (target) ve tweet verildikten sonra; eğer tweet açık şekilde bu hedefi destekliyorsa veya tweet hedefle ilişkilendirilmiş bir nesne veya kişiyi destekliyorsa veya tweet hedeften farklı bir nesne veya kişiye karşıysa ve buradan tweet sahibinin hedefi desteklediğini çıkarabiliyorsak bu gibi durumlarda duruş işaretimiz *tarafında* olacak; benzer şekilde tweet açıkça hedefin karşısındaysa veya tweet hedefle ilişkilendirilmiş bir nesne veya kişinin karşısındaysa veya tweet hedefin dışında bir nesne veya kişiyi destekliyorsa ve buradan tweet sahibinin hedefin karşısında olduğunu çıkarabiliyorsak bu durumda duruş işaretimiz *karşısında* olacaktır. İlgili çalışmada (Mohammad, Sobhani ve Kiritchenko, 2017) başlangıçta bu iki temel sınıf etiketine ek olarak; *nötral* ve *hiçbiri* şeklinde iki ayrı sınıf

etiketi daha kapsama alınmış ise de işaretlemeler sonrası bu sınıflara ait verilerin azlığından dolayı bu iki etiket *hiçbiri* etiketi altında birleştirilmiş ve duruş sınıf etiketi sayısı tekrar üçe (*tarafında*, *karşısında*, *hiçbiri*) düşürülmüştür.


Yukarıda tanıtılan 600 tweet’lik ilk veri kümesi üzerindeki duygu analizi ve duruş tespiti işaretlemeleri sonrasındaki sınıf dağılımları pasta grafikleri biçiminde Şekil 3.5’te sunulmuştur. Sınıf dağılımları incelendiğinde; duruş tespiti bakımından sınıf dağılımının daha dengeli olduğu görülse de duygu analizi yönünden *negatif* sınıfın yüzdesinin yüksek olduğu, *pozitif* sınıfın yüzdesinin ise düşük olduğu görülmektedir. Buradan şu şekilde bir sonuç çıkarabilir: Twitter kullanıcıları, tweet’lerinde COVID-19 aşılarının tarafında veya karşısında olmalarından bağımsız olarak bu tweet’lerde kullanılan dil çoğunlukla pozitif bir dil değildir.



Şekil 3.5. 600 tweet’lik veri kümesindeki duygu ve duruş sınıflarının dağılımı

Yine yukarıda açıklanan şekilde topladığımız 300 tweet’lik veri kümemizin işaretlenmesinin ardından elde edilen sınıf dağılımları da pasta grafikler şeklinde Şekil 3.6’da verilmiştir.

Bu şekilde verilen grafikler incelendiğinde de (Şekil 3.5’teki grafiklere benzer şekilde); duruş tespiti kapsamındaki sınıfların dağılımlarının dengeli, duygu analizi sınıflarının dağılımlarının da dengesiz olduğu gözlemlenmektedir. Örneğin bu veri kümesinde *negatif* işaretli tweet’lerin oranı %55’ten fazla iken, *pozitif* olduğu belirtilen sınıfların oranı düşüktür (%10,7). Dolayısıyla, daha önce ifade ettiğimiz gibi, bu tweet veri kümesi bağlamında insanların duygularını genel olarak *pozitif olmayan* bir şekilde ifade ettikleri söylenebilir.



Şekil 3.6. 300 tweet’lik veri kümesindeki duygu ve duruş sınıflarının dağılımı

Yukarıda açıklanan işaretli tweet veri kümelerimizdeki örnek tweet’ler ile bunlar üzerinde yapılmış olan duygu ve duruş işaretlemeleri Çizelge 3.4’te verilmiştir.

Çizelge 3.4. İşaretli veri kümelerinden örnek tweet’ler ile duygu ve duruş işaretleri

Tweet	Duygu	Duruş
<i>Aşı gelsede olsak</i>	Hiçbiri	Tarafında
<i>ben asi yaptırmayı düşünmüyorum kimse kusura bakmasın. :)</i>	Pozitif	Karşısında
<i>Biraz negatif olabilirim bu konuda. Lâkin bu kadar kısa sürede aşı diye piyasaya sürülen maddelerin geniş kitleler üzerinde etkin olacağını düşünmüyorum.</i>	Negatif	Karşısında
<i>Türk Eczacıları Birliği’nden aşı açıklaması</i>	Hiçbiri	Hiçbiri
<i>Eski günleri çok özledik. İnsallah aşı ile birlikte yok olur.</i>	Pozitif	Tarafında
<i>Bırak hocam aşı karşıtları çeksin bedelini bize ne kendi düşen ağlamaz</i>	Negatif	Tarafında

Tez çalışmamızın başlangıç aşamasında Türkiye ve dünya genelindeki en popüler sosyal medya platformlarını (Twitter, Instagram ve Facebook) kapsam içerisine almak niyetinde olmamıza rağmen aşağıda detaylı olarak yer alan teknik kısıtlamalar ve gerekçeler nedeniyle tez çalışmamız kapsamında sosyal platformu olarak sadece Twitter’dan elde edilen veri setleri kullanılmıştır.


- Instagram ve Facebook’un Meta isimli aynı şirkete bağlı olması nedeniyle bu iki sosyal medya platformunun API kullanımını tek bir platformdan (URL9) ve aynı kurallar ile kullanıma açması,
- Instagram ve Facebook’un Twitter’ın aksine API kullanımını konusunda araştırmacılara herhangi bir esneklik sunmaması,
- Instagram ve Facebook’un ilgili API’ları kullanımını, bu API’lardan yararlanacak uygulamanın developer platformlarına yüklenmesini şart olarak ileri sürmesi nedeniyle

her tez çalışmasının olmazsa olmaz özelliklerinden olan “tez’in özgünlüğü” özelliğinin ihlal edilebileceği endişesi,

- Instagram ve Facebook platformlarından veri kümesi oluşturulabilmek için çeşitli web kazıyıcı (web scraper) kütüphanelerinden yararlanmak gibi yöntemler olmasına karşın bu yöntemlerin kullanılmasının etik açıdan tereddütlere neden olması.

3.2. Duygu Analizi ve Duruş Tespiti Yaklaşımları

Bu bölümde duygu analizi ve duruş tespiti problemlerinin her ikisi için de tezimiz kapsamında kullanılan yaklaşımlar detaylarıyla açıklanmıştır. Aşağıdaki alt bölümlerde sunulacağı üzere; ilk olarak geleneksel makine öğrenmesi yöntemleri, otomatik bir veri artırımı yöntemiyle birlikte kullanılmışlar, ikinci olarak da derin öğrenme modellerine dayalı BERT modeli ve ChatGPT aracı yine bu iki probleme uygulanmışlardır.



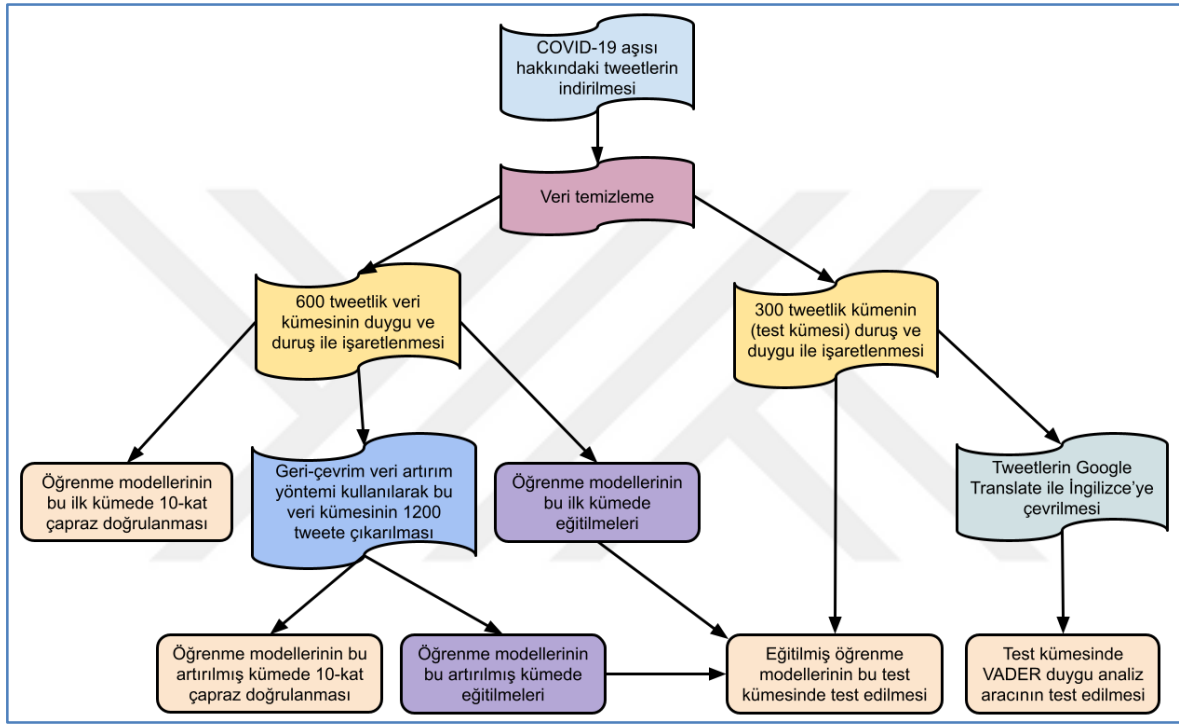
Şekil 3.7. Duygu analizi ve duruş tespiti için kullanılan yaklaşımlar

Aşağıdaki bölümlerde ayrıntıları verilen ve tezimiz kapsamında duygu analizi ve duruş tespiti yapmak amacıyla kullandığımız makine öğrenmesi ve derin öğrenme yöntemlerinin türleri özet olarak Şekil 3.7’de verilmiştir.

3.2.1. Veri artırımı ile makine öğrenmesi yöntemlerinin kullanımı

Tez çalışmamız kapsamında ilk olarak; makine öğrenmesi yöntemlerine dayalı bir yaklaşımla duygu analizi ve duruş tespiti testleri gerçekleştirilmiştir. Makine öğrenmesi yöntemlerinin sıklıkla karşı karşıya oldukları *veri yetersizliği (kıtlığı)* probleminden Bölüm

2’de bahsedilmişti. Yine aynı bölümde bu problemin çözümü için veri artırımı yöntemlerine başvurulduğu açıklanmıştı. Tezimiz kapsamında çeşitli makine öğrenmesi yöntemleri, bir otomatik veri artırımı tekniği ile birlikte kullanılmıştır. Bahsi geçen bu yaklaşımın akış diyagramı Şekil 3.8’de verilmiştir. Akış diyagramında; tweet’lerin indirilmesi, temizlenmesi ile duygu analizi ve duruş tespiti için işaretlenmeleri aşamaları daha önceki bölümlerde açıklanmıştı.



Şekil 3.8. Önerilen veri artırımı yöntemi ve makine öğrenmesi testlerinin yapılması akış diyagramı

Bölüm 2’de açıklandığı üzere; geleneksel makine öğrenmesi yöntemlerinin karşı karşıya olduğu problemlerden bir tanesi de veri kıtlığı problemidir ve bu problemi gidermek üzere literatürde çeşitli veri artırımı teknikleri önerilmekte ve uygulanmaktadır.

Biz de tez çalışmamız kapsamında; daha önce açıklanan ve işaretlenen veri kümelerimizden 600 tweet’lik ilk veri kümemizi eğitim amacıyla kullanmaya ek olarak bu veri kümesini geri-çevrim yöntemine dayalı veri artırımı yöntemi ile genişlettik. Veri kümesindeki 600 tweet önce Google Translate (URL10) otomatik veri çevrim aracı ile Türkçe’den İngilizce’ye çevrilmiş, ardından da İngilizce tweet çevirileri tekrar Türkçe’ye çevrilmiştir. En son elde edilen Türkçe tweet çevirileri de daha önce işaretleme aşamasındaki sınıf etiketleriyle birlikte ilk veri kümesine eklenerek 1200 tweet’ten oluşan işaretli bir veri kümesi

(artırılmış/genişletilmiş veri kümesi) elde edilmiştir. Böylelikle, eğitim kümesinin yetersizliğini ifade eden veri kıtlığı problemine bir dereceye kadar otomatik bir çözüm getirilmesi amaçlanmıştır.

Kullanılan makine öğrenmesi yöntemleri aşağıda listelenmiş ve kısaca açıklanmıştır:

- *Torbalama (Bagging)*: Bu makine öğrenmesi modeli, *topluluk öğrenmesi* (ensemble learning) kategorisine dahil bir modeldir. Sınıflandırma amaçlı topluluk öğrenmesi modellerinde birden fazla sınıflayıcı bulunmakta ve daha iyi sonuçlar elde etme amacıyla bunların sonuçları birleştirilmektedir. Birden fazla sınıflandırıcı kullanmasına rağmen, bagging modelindeki tüm sınıflandırıcılar aynı kategoriye aittir ve bizim durumumuzda bagging, karar ağacı sınıflandırıcısı kullanmaktadır. Bu nedenle bagging topluluk sınıflandırıcı modeli aynı zamanda literatürde *bagged karar ağaçları* (bagged decision trees) olarak da adlandırılmaktadır.
- *Lojistik Regresyon*: Kategorik bir sonucu tahmin etmek için kullanılabilen istatistiksel bir sınıflandırma modeli olarak adlandırılır ve metin işleme görevleri, özellikle duruş tespiti dahil olmak üzere yüksek performans elde etmek için rapor edilmiştir. Lojistik regresyon, sürekli bir sonucu tahmin eden *lineer regresyondan* farklıdır, çünkü ilki kategorik etiketler çıkaran denetimli bir sınıflandırma modelidir.
- *SVM*: optimize edilmiş *hiperdüzlem ayrımı* (hyperplane separation) konseptine dayalı geleneksel bir makine öğrenimi algoritmasıdır ve duruş tespiti ile duygu analizi gibi çeşitli metin analizi görevlerini içeren farklı uygulama alanlarında yaygın olarak kullanılmaktadır. Testlerimiz sırasında kullanılan SVM uygulamasında *polinom çekirdek* (polynomial kernel) kullanılmıştır.
- *Rasgele Orman (Random Forest)*: Yukarıda açıklanan torbalama (*bagging*) modeline benzer bir topluluk öğrenme modelidir. Rasgele orman, ayrı karar ağacı sınıflandırıcılarının sonuçlarını birleştirerek nihai sınıf etiketlerini çıkarmak için kullanılır. Bagged karar ağaçlarından farklı olarak, rasgele ormanda verinin ve özelliklerin rastgele alt kümeleri, temel karar ağaçlarının bölünme noktalarını belirlemek için kullanılır.

Tez çalışmamız kapsamında; yukarıda açıklanan modellerin mevcut olduğu WEKA (Waikato Environment for Knowledge Analysis) makine öğrenmesi kütüphanesi (Hall ve diğerleri, 2009) kullanılmıştır.

Yukarıda listelenen makine öğrenmesi yöntemleri için aşağıdaki öznitelikler (features) kullanılmıştır:

- Unigramlar
- Tweet’lerde hashtag bulunup bulunmaması
- Tweet’lerde emoticon bulunup bulunmaması

Eğitim ve test aşamalarında yukarıda listelenen öznitelikler tweet’lerden (bu amaçla geliştirilen bir yazılım parçası kullanılarak) çıkarılmış ve WEKA kütüphanesinin kabul ettiği ARFF (Attribute-Relation File Format) biçimindeki dosyalar oluşturulmuştur. Ardından bu dosyalar WEKA kütüphanesine girdi olarak verilerek ilgili makine öğrenmesi algoritmalarının eğitim ve test işlemleri gerçekleştirilmiştir.

Şekil 3.8’de gösterildiği üzere; bu dört makine öğrenmesi yönteminin eğitim veri kümesi olarak hem 600 tweet’lik ilk veri kümesinin hem de yukarıda açıklanan otomatik çeviriye dayalı veri artırım yöntemi ile genişletilmiş (1200 tweet’lik) veri kümesinin kullanıldığı testler ayrı ayrı gerçekleştirilmiştir. Bazı testlerde bu veri kümeleri üzerinde 10-kat çapraz doğrulama ile sonuçlar alınırken, bazı testlerde ise bu veri kümeleri eğitim amacıyla kullanılmakta ve testlerde (daha önce açıklanan) 300 tweet’lik diğer bir veri kümemiz kullanılmıştır. Tüm test sonuçları Bölüm 4.2’de sunulmuştur.

3.2.2. BERT ve ChatGPT’nin kullanımı

Duruş tespiti ve duygu analizi için ayrıca bir transformatör tabanlı bir derin öğrenme yaklaşımı olan BERT de kullanılmıştır. Yine günümüzde yaygın şekilde kullanılan üretken yapay zekâ modellerinden ChatGPT de tezimiz kapsamında ikinci bir derin öğrenme yöntemi olarak kullanılmıştır.

Çalışmamızda Türkçe metinler üzerinde eğitilmiş olan *BERTurk* (URL11) adlı BERT modeli kullanılmıştır. BERTurk, Türkçe Wikipedia’nın güncel bir yedeğini de içerecek şekilde toplam 4.404.976.662 kelimedenden oluşan 35 GB’lık Türkçe metin kümesi üzerinde

eğitilmiştir. Model, Google’ın TensorFlow Research Cloud (TFRC) altyapısı kullanılarak bir Tensör İşleme Ünitesi (Tensor Processing Unit - TPU) üzerinde 2M adımda eğitilmiştir. Duygu analizi ve duruş tespiti için kullanılan söz konusu BERT modelinin fine-tuning aşamasında hiper parametreler için değişik değerler denenmiştir. Sonuçta; batch boyutu olarak 16, öğrenme hızı olarak $4e-5$, epoch sayısı olarak 4 kullanılmıştır.

Veri ön-işleme aşamasında, etkisiz kelimeler (stopwords) tweet’lerden çıkarılmıştır. Tweet’leri kelimelere ayırmak için NLTK (Natural Language Toolkit) adlı python kütüphanesi (URL12) kullanılmıştır.

BERT modellerinin kullanıldığı testlerimizde altyapı olarak Simple Transformers isimli kütüphane (URL13) kullanılmıştır. Simple Transformers kütüphanesi ilgili Huggingface Transformers kütüphanesini (URL14) temel almaktadır. Simple Transformers kütüphanesi metin sınıflandırma (text classification), varlık ismi tanıma (named entity recognition), soru yanıtlama (question answering), dil modelleme (language modelling) vb. pek çok doğal dil işleme probleminde transformer tabanlı modellerin (BERT, RoBERTa gibi) kolay kullanımını desteklemektedir.

ChatGPT üzerindeki testler; testler sırasında ChatGPT’nin ücretsiz sürümü olan 24 Mayıs 2023 sürümü (URL15) üzerinde gerçekleştirilmiştir.

ChatGPT üzerinde testler gerçekleştirilirken, test kümesindeki COVID-19 aşılılarıyla ilgili her bir tweet arayüzden girdi olarak verilmiş ve duygu analizi için aşağıdaki soru sorulmuştur:

Bu metindeki duygu pozitif mi negatif mi yoksa hiçbir mi?

Benzer şekilde duruş tespiti için de ChatGPT’nin arayüzünde tweet girildikten sonra aşağıdaki soru sorulmuştur:

Bu metin aşı taraftarı mı karşıtı mı yoksa hiçbir mi?

3.3. Varlık İsmi Tanıma Yaklaşımı

İlk olarak; sağlıkla ilgili olarak hedef terimlerimiz belirlenmiştir. Söz konusu terimler maksimum iki kelimeden oluşmaktadır ve Çizelge 3.5’te bu terimlerden bazı örnekler sunulmuştur.

Çizelge 3.5. Varlık ismi tanıma yaklaşımında kullanılan hedef terimlerden örnekler

Terimler
Acil servis
Baş dönmesi
Boğaz iltihabı
Mide yanması
Kuş gribi
Kramp
Gastrit
Gıda zehirlenmesi
Diyabet

Genel sağlıkla ilgili yaklaşık 11.000 kelimeden oluşan toplam 650 tweet’lik yeni bir veri kümesi derlenerek, literatürde varlık ismi işaretlemeye sıklıkla kullanılan BIO yöntemi esas alınarak bu veri kümemiz işaretlenmiştir.

BIO yöntemi; temel olarak varlık isimlerine ait kelimelerin her birinin *başlangıç* (*beginning* – *B*), *içinde* (*inside* – *I*) ve *dışında* (*outside* – *O*) şeklinde işaretlenmesi esasına dayanmaktadır.


Tezimizin varlık ismi tanıma modülü kapsamında yine derin öğrenme (transformer) tabanlı BERT modeli kullanılmıştır. Yine Türkçe için *BERTurk* kullanılmış, yukarıda bahsi geçen ve sağlıkla ilgili tweet’lerden oluşan yaklaşık 11.000 kelimelik veri kümemiz ile *fine-tuning* (*hassas ayar*) yapılmıştır. BERT modelinde hassas ayar işlemi gerçekleştirilirken Bölüm 3.2.2’de de belirtilen Simple Transformers doğal dil işleme kütüphanesinden yararlanılmıştır.



4. OTOMATİK HALK SAĞLIĞI TAKİBİ VE KARAR DESTEK SİSTEMİ

4.1. Genel Bilgiler

Tez çalışmamız kapsamında halk sağlığı alanı için önerilen otomatik takip ve karar destek sisteminin genel mimarisi Şekil 4.1’de verilmiştir.



Şekil 4.1. Önerilen sistem mimarisi

Söz konusu sistem başlıca aşağıdaki modüllerden oluşmaktadır:

1. Veri Toplama Modülü
2. Duygu Analizi Modülü
3. Duruş Tespiti Modülü
4. Varlık İsmi Tanıma Modülü
5. Veri Tabanı Modülü
6. Kullanıcı Arayüz Modülü

Aşağıdaki alt bölümde bu modüllerin ayrıntıları sunulmaktadır. Sayılan sistem modüllerinin (MongoDB üzerine kurulan veri tabanı dışındaki) tümü Python programlama dili kullanılarak geliştirilmiştir. Python günümüzde en yaygın olarak kullanılan programlama

dillerinden biridir. Ayrıca makine öğrenmesi ve derin öğrenme kütüphanelerinin önemli bir kısmı Python programlama dili ile geliştirilmiş durumdadır.

Sistemin modülleri Python programlama dili ile geliştirildiğinden, sistem bünyesinde bu dilde yazılmış birçok kütüphane ve altyapı (Tweepy, Streamlit, Matplotlib, Pandas) da kullanılmıştır. Aşağıdaki ilgili bölümlerde bu kütüphanelerin de ayrıntıları sunulmaktadır.

Karar destek sistemi gerçekleştirilirken Python tabanlı açık kaynak kodlu Streamlit frameworkünden yararlanılmıştır. Streamlit, gelişmekte olan bir Web frameworkü olmasına rağmen özellikle veri analizi çalışmaları için sunduğu hazır bileşenler sayesinde gün geçtikçe popülerliği artmaktadır. Var olan pek çok Web frameworkünün aksine, Streamlit, grafik ve kelime bulutu gibi veri analizine yardımcı olacak gösterimleri Web arayüzünde hızlıca sunabilmektedir. Streamlit gelişmekte olan bir framework olduğu için şu anki sürümünde bazı yetersizlikleri de (link ekleme, biçimlendirme vb.) bulunmaktadır.

4.2. Halk Sağlığı İzleme ve Karar Destek Sistemi Modülleri

4.2.1. Veri toplama modülü

Bu modülün amacı; belirli sosyal medya platformlarından sağlıkla ilgili önceden belirlenmiş anahtar kelimeler kullanılarak sosyal medya iletilerinin otomatik bir şekilde toplanmasıdır. Bu modül periyodik olarak (saatte bir, 30 dakikada bir gibi) ve sürekli şekilde çalışarak halk sağlığı izleme ve karar destek sistemine girdi metinlerini sağlamaktadır. Sosyal medya platformlarından Twitter için (daha önceki bölümlerde açıklanan) Tweepy adlı Python kütüphanesi kullanılmaktadır.

Veri toplama modülü bünyesinde ayrı bir veri ön-işleme alt modülü bulunmakta, bu modül kullanılarak birbirinin aynı (fazlalık) sosyal medya iletileri ile Türkçe dışındaki dillerdeki iletiler otomatik olarak filtrelenmektedir.

4.2.2. Duygu analizi modülü

Duygu analizi modülü ile sistem bünyesinde toplanan her bir sosyal medya iletiindeki duygunun *pozitif*, *negatif* veya *hiçbiri* şeklinde sınıflandırılarak iletinin bu sınıf ile otomatik

olarak etiketlenmesi sağlanmaktadır. Ardından sistemin kullanıcı arayüz modülü vasıtasıyla bu çıktılar uygun şekilde görselleştirilerek (veri çerçevesi - data frame, grafik, kelime bulutu vb.) sistem kullanıcılarına sunulmaktadır.

4.2.3. Duruş tespiti modülü

Duruş tespiti modülü ile sistemde toplanan her bir sosyal medya iletisindeki duruşun, sistem yöneticileri tarafından önceden belirlenen hedef (target) halk sağlığı kavramlarına yönelik duruşları *tarafında*, *karşısında* veya *hiçbiri* şeklinde sınıflandırılarak ileti ile birlikte hedefin bu sınıf ile otomatik şekilde etiketlenmesi sağlanmaktadır. Ardından sistemin kullanıcı arayüz modülü vasıtasıyla bu çıktılar uygun şekilde görselleştirilerek (veri çerçevesi - data frame, grafik, kelime bulutu vb.) sistem kullanıcılarına sunulmaktadır.

4.2.4. Varlık ismi tanıma modülü

Varlık ismi tanıma modülü ile, veri toplama modülü ile elde edilen sosyal medya iletilerindeki halk sağlığı ile ilgili varlık isimlerinin (hastalıklar, virüs ve bakteri isimleri, belirtiler vb.) otomatik olarak çıkarılması sağlanmaktadır.

Bu modül daha önce açıklandığı üzere, yaygın halk sağlığı terimlerinden oluşturduğumuz bir “halk sağlığı terimleri” kaynağından da faydalanmaktadır. Bu terimler de diğer bilgilerle birlikte sistemin veri tabanı modülünde saklanmaktadır.

Varlık ismi tanıma modülünün çalıştırılması sonucunda elde edilen varlık isimleri, kullanıcı arayüz modülünde metin üzerinde uygun şekilde renklendirilmiş olarak gösterilmektedir.

4.2.5. Veri tabanı modülü

Çalışmamız kapsamında elde edilen tweet veri kümeleri ile bunlardan otomatik tespit edilen sınıflandırma sonuçları ve çıkarılan varlık isimleri, genel sistemin veri tabanı modülü bünyesinde saklanmaktadır.

Sistemin veri tabanı için MongoDB (URL16) veri tabanı yönetim sistemi kullanılmıştır.

MongoDB geleneksel SQL tabanlı veri tabanı yönetim sistemlerinden farklı olarak NoSQL olarak adlandırılan sistemlerdendir ve ayrıca doküman tabanlı bir sistem olduğu belirtilmektedir. NoSQL veri tabanlarında veriler tablolar şeklinde saklanmamaktadır. Bunun yerine, NoSQL veri tabanları anahtar-değer (key-value), doküman veya grafik veri tabanları gibi değişik yapılardan birinde olabilmektedir.

Günümüzde indeksleme, çoğaltma ve yük dengeleme gibi konulardaki önemli özelliklerinden dolayı yaygın bir kullanımı olan MongoDB NoSQL veri tabanı, sayılan nedenlerle tezimiz kapsamında geliştirilen sistemde veri tabanı olarak kullanılmıştır.

4.2.6. Kullanıcı arayüz modülü

Sistemin web-tabanlı kullanıcı arayüz modülü kapsamındaki ekranlar ile sistemin diğer modülleri tarafından toplanan veriler ile modüllerin otomatik gerçekleştirdiği işaretlemler (isimler ve sınıf etiketleri), farklı şekillerde görselleştirilerek halk sağlığı uzmanları ve karar alıcıların kullanımına sunulması planlanmaktadır. Böylelikle önerilen sistem; halk sağlığı takibi sağlmasına ek olarak, halk sağlığı uzmanları ve karar alıcıları için bir karar destek sistemi olma özelliği de göstermektedir.


Sistemin kullanıcı arayüz modülü Python tabanlı Streamlit altyapısı (URL17) kullanılarak geliştirilmiştir. Streamlit altyapısı veri analizine yönelik web-tabanlı uygulamaların Python programlama dili ile hızlı bir şekilde geliştirilmesini ve verilerin uygun şekillerde görselleştirilmesini sağlamaktadır.

Kullanıcı arayüz modülünde yer alan veri görselleştirme amaçlı grafikler için yine Python programlama dili ile yazılmış Matplotlib kütüphanesi (URL18) kullanılmıştır. Matplotlib kütüphanesi çizgi, çubuk, pasta, kutup (polar) grafiği gibi birçok farklı türde grafiği 2-boyutlu veya 3-boyutlu olarak çizdirilebilmesine imkân veren kapsamlı bir grafik kütüphanesidir.

Bu modül kapsamında kullanılmış olan Pandas isimli Python veri analizi kütüphanesi (URL19) sayesinde tablolar (veri çerçevesi – data frame) şeklinde görselleştirilen veriler virgülle ayrılan değerler (Comma-Separated Values – CSV) biçiminde .csv uzantılı dosyalar olarak dışarı aktarılabilir.

Sistemin kullanıcı arayüz modülü kapsamındaki ekranlar vasıtasıyla ayrıca kullanıcılar tarafından manuel veri işaretleme yapılabilmekte böylelikle yeni eğitim veri kümelerinin oluşturulması sağlanabilmektedir.

Şekil 4.2’de kullanıcı arayüz modülünün sisteme giriş ekranının örnek görüntüsü verilmiştir.



Şekil 4.2. Kullanıcı arayüz modülü – Giriş ekranı


Kullanıcı arayüz modülü içerisinde başlıca dört adet alt modül bulunmaktadır ve bu alt modüllerin isimleri sisteme giriş yapıldıktan sonra açılan ekranlarda sol panelde aşağıdaki şekilde listelenmektedir.

- Veri Analizi
- Eğitilmiş Modellerle Metin Sınıflandırma
- Veri İşaretleme
- Veri Temizleme

Genel sistemin kullanıcı arayüz modülünün sol panelinde her bir alt modül adı bir bağlantı şeklinde yer almaktadır ve istenen alt modül adına tıklanarak ilgili modülün ekranı açılmaktadır. Aşağıda söz konusu alt modüllerin açıklamaları, örnek ekran görüntüleriyle birlikte sunulmaktadır.


Sistemde işaretlenmiş sosyal medya metinlerindeki sınıf etiketlerinin dağılımlarının incelenebileceği “Veri Analizi” alt modülü ana ekranının örnek bir görüntüsü ise Şekil 4.3’te

verilmiştir. Bu ekran üzerinden kullanıcılar öncelikle istedikleri doğal dil işleme problemini (analiz yöntemini) seçmektedirler. Ardından ilgili probleme ait çıktıların gösterildiği ekran kullanıcılara görüntülenmektedir.




Şekil 4.3. Kullanıcı arayüz modülü – Veri analizi ana ekranı

Veri analizi ekranında yöntem olarak “Duygu Analizi” tercih edildiğinde açılan sistem ekranının örnek görüntüsü Şekil 4.4’te verilmiştir. Ekranda görüldüğü üzere, işaretli sosyal medya metinleri pasta grafik veya sütun grafik şeklinde görselleştirilmektedir.




Şekil 4.4. Kullanıcı arayüz modülü – Duygu analizi analiz ekranı

Benzer biçimde; Şekil 4.3'te verilen örnek ekran üzerinde veri analiz yöntemi olarak “Duruş Tespiti” seçildiğinde açılan ekrana ait örnek görüntü ise Şekil 4.5'te sunulmuştur. Burada da sistemde mevcut sosyal medya iletilerinin duruş etiketlerinin dağılımları pasta grafik ve sütun grafik olarak sunulmaktadır.



Şekil 4.5. Kullanıcı arayüz modülü – Duruş tespiti analiz ekranı

“Veri Analizi” ekranlarından sonuncusunun örnek ekran görüntüsü ise Şekil 4.6’da verilmiştir ve veri analizi yöntemi olarak “Varlık İsmi Tanıma” seçildiğinde açılan ekrandır. Sistemin veri tabanına kayıtlı sosyal medya metinlerinde mevcut varlık ismi etiketlerinin dağılımları pasta grafik ve sütun grafiği olarak ekranda yer almaktadır.



Şekil 4.6. Kullanıcı arayüz modülü – Varlık ismi tanıma analiz ekranı

Sistemin ikinci ana modülü olan “Eğitilmiş Modellerle Metin Sınıflandırma” ekranları yoluyla, eğitilmiş modeller kullanılarak sistemde daha önce yer almayan sosyal medya metinleri üzerinde işaretlemeler yapılmakta ve bu işaretlemelerin sonuçları sistem kullanıcılarına sunulmaktadır.

Örneğin, “Eğitilmiş Modellerle Metin Sınıflandırma” alt modülü ana ekranında veri analizi yöntemi olarak “Varlık İsmi Tanıma” seçildiğinde sistemin veri tabanında işaretlenmemiş şekilde bulunan sosyal medya iletileri üzerinde sistemde yer alan eğitilmiş varlık ismi modeli kullanılarak iletide yer alan varlık isimleri otomatik olarak tespit edilmektedir.


Sistemde eğitilmiş varlık ismi tanıma modeli ile yeni sosyal medya iletilerinde otomatik varlık ismi tanıma yapılmasını gösteren ekran görüntüsü Şekil 4.7’de verilmiştir.



Şekil 4.7. Kullanıcı arayüz modülü – Eğitilmiş model ile varlık ismi tanıma ekranı

Son olarak; sistemin kullanıcı arayüz modülünün “Veri İşaretleme” ve “Veri Temizliği” alt modülleri kapsamında da ilgili işlevlerin gerçekleştirilmesine yönelik ekranlar geliştirilmiştir.

Şekil 4.8’de “Veri Temizliği” ekranının örnek bir görüntüsü verilmiştir. Bu ekran vasıtasıyla kullanıcılar sosyal medya metinleri üzerinde isterlerse belirttikleri kriterlere göre veri temizliği işlemini gerçekleştirebilmektedirler.



Şekil 4.8. Kullanıcı arayüz modülü – Veri temizliği ekranı



5. DEĞERLENDİRME VE TARTIŞMA

Bu bölümün ilk alt bölümünde, değerlendirmelerde kullanılan metrikler formülleriyle birlikte açıklanmış, ikinci alt bölümde değerlendirme sonuçları sunulmuş, son alt bölümde ise elde edilen değerlendirme sonuçları tartışılmıştır.

5.1. Değerlendirme Metrikleri

Keskinlik (Precision), *Yakalama* (Recall) ve *F-Oranı* (F-Measure, F-Score); bu tezde odaklandığımız her üç araştırma problemi (duygu analizi, duruş tespiti ve varlık ismi tanıma) için de yaygın olarak kullanılan değerlendirme metrikleri arasındadır.

Aşağıda önce *Keskinlik* ve *Yakalama* metriklerinin formülü verilmiştir. Ardından da bu ikisinden hesaplanan F_{β} -Oranı metriğinin formülü sunulmuştur. Son olarak da F_{β} -Oranı metriğinde β değerinin 1 alınması ile elde edilen ve F1-Oranı olarak da bilinen F-Oranı metriğinin formülü verilmiştir.

$$Keskinlik = \frac{Doğru Pozitifler}{Doğru Pozitifler + Yanlış Pozitifler} \quad (5.1)$$

$$Yakalama = \frac{Doğru Pozitifler}{Doğru Pozitifler + Yanlış Negatifler} \quad (5.2)$$

$$F_{\beta} - Oranı = \frac{(\beta^2 + 1) * Keskinlik * Yakalama}{\beta^2 * Keskinlik + Yakalama} \quad (5.3)$$

$$F - Oranı = \frac{2 * Keskinlik * Yakalama}{Keskinlik + Yakalama} \quad (5.4)$$

Eş. 5.1’de verildiği üzere *keskinlik*; doğru pozitiflerin (doğru şekilde pozitif olarak sınıflanan pozitif örnekler), doğru pozitifler ile yanlış pozitiflerin (yanlış şekilde doğru olarak sınıflanan örnekler) toplamına oranıdır. Yine Eş. 5.2’de verildiği gibi *yakalama* ise doğru pozitiflerin, doğru pozitifler ile yanlış negatiflerin (yanlış şekilde negatif sınıflanan örnekler)

toplamına oranıdır. Eş 5.4.'te verilen *F-Oranı* ise keskinlik ile yakalamanın harmonik ortalamasına karşılık gelmektedir.

İlgili literatürde keskinlik, yakalama ve F-Oranı metriklerinin 100 ile çarpılarak, sonuçların yüzde (%) biçiminde verilmesi de yaygın olarak görülmektedir.

İlgili literatürdeki yaygın kullanımından dolayı, çalışmamız kapsamında yapılan değerlendirmelerde bu F-Oranı metriği yüzde (%) olarak kullanılmıştır.

5.2. Değerlendirme Sonuçları

5.2.1. Makine öğrenmesi ve veri artırımı ile duruş tespiti ve duygu analizi değerlendirme sonuçları

Bu alt bölümde; daha önce Bölüm 3.2.1'deki Şekil 3.8'de verilen test senaryolarına ait değerlendirme sonuçları sunulmuştur. Söz konusu testlerde farklı yaklaşımlar, farklı eğitim ve test veri kümesi kombinasyonları ile test edilerek ve elde edilen sonuçlar karşılaştırılarak; uygulamaya yönelik olarak en iyi sonuçların elde edildiği durumların belirlenmesi amaçlanmıştır.

Test senaryoları aşağıda listelenmiştir:

1. Makine öğrenmesi yaklaşımlarının 600 tweet'lik ilk veri kümesi üzerinde 10-kat çapraz doğrulaması
2. Makine öğrenmesi yaklaşımlarının 1200 tweet'lik genişletilmiş/artırılmış veri kümesi üzerinde 10-kat çapraz doğrulaması
3. Makine öğrenmesi yaklaşımlarının 600 tweet'lik ilk veri kümesi üzerinde eğitilip 300 tweet'lik ayık veri kümesinde test edilmesi
4. Makine öğrenmesi yaklaşımlarının 1200 tweet'lik genişletilmiş/artırılmış veri kümesi üzerinde eğitilip 300 tweet'lik ayık veri kümesinde test edilmesi
5. 300 tweet'lik test veri kümesi üzerinde otomatik makine öğrenmesi sonrası VADER (Hutto ve Gilbert, 2014) duygu analizi aracının test edilmesi

Yukarıdaki 1. ve 2. maddelerde belirtilen test senaryolarının değerlendirme sonuçları F-Oranı cinsinden Çizelge 5.1'de sunulmuştur. Ardından, 3. ve 4. maddelerdeki test

senaryolarının sonuçları ise yine bu metrik ile Çizelge 5.2.'de verilmiştir. Son olarak; 5. maddenin sonucu 4. maddenin sonuçları ile karşılaştırmalı olarak Çizelge 5.3'te verilmiştir. Çizelgelerde en yüksek F-Oranı değerleri koyu renkle gösteri gösterilmiştir.

Çizelge 5.1. Duruş tespiti ve duygu analizi sınıflayıcılarının veri kümesinin ilk hali ve artırılmış hali üzerindeki 10-kat çapraz doğrulama sonuçları (F-Oranı cinsinden)

<i>Sınıflayıcı</i>	<i>İlk Veri Kümesi</i> (600 tweet)		<i>Genişletilmiş Veri Kümesi</i> (1200 tweet)	
	<i>Duruş</i>	<i>Duygu</i>	<i>Duruş</i>	<i>Duygu</i>
	<i>Tespiti</i>	<i>Analizi</i>	<i>Tespiti</i>	<i>Analizi</i>
Bagging	%54,6	%62,0	%61,8	%67,0
Lojistik Regresyon	%51,4	%62,7	%56,7	%66,0
SVM	%61,5	%61,2	%89,3	%88,3
Rasgele Orman	%57,6	%50,0	%86,6	%76,5

Çizelge 5.2. Duruş tespiti ve duygu analizi sınıflayıcılarının ilk ve genişletilmiş veri kümelerini eğitim amacıyla kullandıktan sonraki değerlendirme sonuçları (F-Oranı cinsinden)

<i>Sınıflayıcı</i>	<i>İlk Veri Kümesi (eğitim)</i> <i>İkinci Veri Kümesi (test)</i>		<i>Genişletilmiş Veri Kümesi (eğitim)</i> <i>İkinci Veri Kümesi (test)</i>	
	<i>Duruş</i>	<i>Duygu</i>	<i>Duruş</i>	<i>Duygu</i>
	<i>Tespiti</i>	<i>Analizi</i>	<i>Tespiti</i>	<i>Analizi</i>
Bagging	%44,7	%57,5	%50,4	%59,0
Lojistik Regresyon	%44,5	%59,7	%45,8	%59,8
SVM	%51,1	%55,2	%53,0	%57,7
Rasgele Orman	%40,1	%35,1	%45,8	%47,7

Mevcut bir duygu analizi aracıyla karşılaştırma yapılabilmesini amaçlayan Çizelge 5.3'teki değerlendirmeler; dört makine öğrenmesi modeli için Çizelge 5.2'nin (yukarıda 4. maddede verilen durumdaki) son iki sütunundan duygu analizine karşılık gelen son sütununun sonuçlarını içermektedir. Diğer bir deyişle, modeller genişletilmiş 1200 tweet'lik veri

kümesinde eğitilmişler ve ardından test sonuçları 300 tweet'lik ikinci veri kümesi üzerinde elde edilmişlerdir.

Yine Çizelge 5.3'teki VADER duygu analizi aracının değerlendirme sonuçları da kıyaslama amacıyla yine 300 tweet'lik veri kümesi üzerinde elde edilmiştir. Tweet'ler VADER aracına girdi olarak verilmeden önce Google Translate ile önce İngilizce'ye çevrilmişlerdir.

Böylelikle, VADER'ın İngilizce için hazır ve Java ile yazılmış çalışabilir sürümü (URL20) adresinden indirilerek testlerimizde kullanılmıştır. VADER her bir girdi metni için bir skor hesaplamaktadır. Bu skorun değerlerine göre duygu analizi sınıfı belirlenmektedir. Çalışmamızda da VADER'in hesapladığı bu skorları sınıflara dönüştürmede aşağıdaki kurallar kullanılmıştır:

- Skor $\geq 0,05$ ise *pozitif*
- Skor $\leq -0,05$ ise *negatif*
- $-0,05 < \text{Skor} < 0,05$ ise *hiçbiri*

Çizelge 5.3. VADER aracı ile kullanılan dört sınıflayıcının test veri kümesi üzerindeki duygu analizi değerlendirme sonuçları (F-Oranı cinsinden)

Araç/Sınıflayıcı	Duygu Analizi
VADER	%52,3
Bagging	%59,0
Lojistik Regresyon	%59,8
SVM	%57,7
Rasgele Orman	%47,7

5.2.2. BERT ve ChatGPT ile duruş tespiti ve duygu analizi değerlendirme sonuçları

Makine öğrenmesi modellerinden bağımsız olarak; derin öğrenme modelleri kapsamına giren BERT modeli ve ChatGPT ile de farklı test senaryoları altında duygu analizi ve duruş tespiti testleri gerçekleştirilmiştir.

Söz konusu testler (önceki bölümlerde sunulan) 600 tweet'lik veri kümesi ile 230 tweet'lik veri kümesi kullanılarak gerçekleştirilmiştir. Bu testlerin sonuçları; geleneksel makine

öğrenmesi yöntemlerinden SVM ve rasgele orman yöntemlerinin sonuçları ile kıyaslamalı olarak Çizelge 5.4'te sunulmuştur.

Çizelge 5.4'te yer alan SVM ve rasgele orman algoritmalarının sonuçları 600 tweet'lik veri kümesi eğitim kümesi olarak, 230 tweet'lik küme de test veri kümesi olarak kullanılarak elde edilmiştir. Söz konusu değerlendirme sonuçları tezimiz kapsamında yayınladığımız ilgili çalışmamızdan (Küçük ve Arıcı, 2022a) alınarak sunulmuştur.

Makine öğrenmesi modelleri olan SVM ve rasgele orman; 600'lük kümeyi eğitim veri kümesi olarak, ardından da 230 tweet'lik kümeyi test kümesi olarak kullanmıştır (Küçük ve Arıcı, 2022a). ChatGPT'den ise arayüzü üzerinden 230 tweet'lik veri kümesindeki tweet'lerdeki duygu ve (aşırıya yönelik) duruşları beklenen sınıflar cinsinden döndürmesi istenmiştir.

Çizelge 5.4'te ayrıca, İngilizce tweet'ler üzerinde aşılara yönelik duruş tespitinin BERT modeli kullanılarak gerçekleştirildiği ilgili bir çalışmanın (Mu ve diğerleri, 2023) sonuçları da dahil edilmiştir. Bu çizelgede en yüksek F-Oranı değerleri koyu renkle gösterilmiştir.

Çizelge 5.4. Testlerde kullanılan BERT tabanlı model ile ChatGPT'nin (* ile belirtilen) değerlendirme sonuçları ve diğer modeller ile karşılaştırılmaları (F-Oranı cinsinden)

<i>Yaklaşım</i>	<i>Duygu Analizi</i>	<i>Duruş Tespiti</i>	<i>Türkçe Veri Kümeleri</i>
SVM (Küçük ve Arıcı, 2022a)	%55,65	%55,0	600 tweet'lik eğitim, 230 tweet'lik test kümesi
Rasgele Orman (Küçük ve Arıcı, 2022a)	%43,1	%49,5	600 tweet'lik eğitim, 230 tweet'lik test kümesi
*BERT Model	%64,64	%69,93	600 tweet'lik eğitim, 230 tweet'lik test kümesi
BERT Model (İngilizce tweet veri kümesi üzerinde) (Mu ve diğerleri, 2023)	–	%69,3	–
*ChatGPT	%57,83	%72,17	230 tweet'lik test kümesi

5.2.3. Varlık ismi tanıma değerlendirme sonuçları

Tezimiz kapsamında; sağlıkla ilgili sosyal medya metinleri üzerinde BERT modeli tabanlı varlık ismi tanıma modelimizin değerlendirme aşamasında önceki bölümlerde açıklanan keskinlik, yakalama ve F-Oranı metrikleri kullanılmıştır.

Anılan BERT tabanlı varlık ismi tanıma modelinin testlerinde, keskinlik sonucu olarak %65,63; yakalama sonucu olarak %81,62; F-Oranı sonucu olarak da %72,76 elde edilmiştir.

5.3. Tartışma

Geleneksel makine öğrenmesi yöntemleri kendi aralarında kıyaslandıklarında; duygu analizinde lojistik regresyonun, duruş tespitinde ise SVM'in en yüksek başarımlara ulaştıkları görülmüştür.

Torbalama (bagging) metodu hem duygu analizi hem de duruş tespiti problemi için ikinci en yüksek başarıma sahip olurken, rasgele orman metodu bu iki problemin çözümünde de en düşük sonuçları elde etmiştir.

Duygu analizi problemi özelinde; lojistik regresyon, bagging ve SVM modellerinin (hazır bir duygu analizi aracı olan) VADER'dan daha iyi sonuçlar elde ettiği, rasgele orman modelinin ise VADER'dan daha düşük bir sonuç elde ettiği gözlemlenmiştir.

Bu nedenlerle; eğer gerçek bir sistem içerisinde bu problemleri çözmek için bir makine öğrenmesi yöntemi kullanılması tercih edilirse, burada lojistik regresyon, SVM ve bagging yöntemlerinin dikkate alınması yerinde olacaktır. VADER aracı İngilizce metinler için geliştirilmiş bir duygu analizi aracıdır. Çalışmamızda makine çevrimi aracı ile Türkçe metinler İngilizce'ye çevrildikten sonra İngilizce metinler üzerinde kullanılmış olsa da; karşılaştırmalı sonuçlara göre tezimizde kullanılan ve yukarıda sayılan üç geleneksel makine öğrenmesi yöntemi VADER'dan daha yüksek başarımlar elde etmiştir.

Elde edilen tüm sonuçlar incelendiğinde ise hem duygu analizi hem de duruş tespiti problemlerinin çözümünde derin öğrenme yöntemlerinin, testlerimizde kullanılan

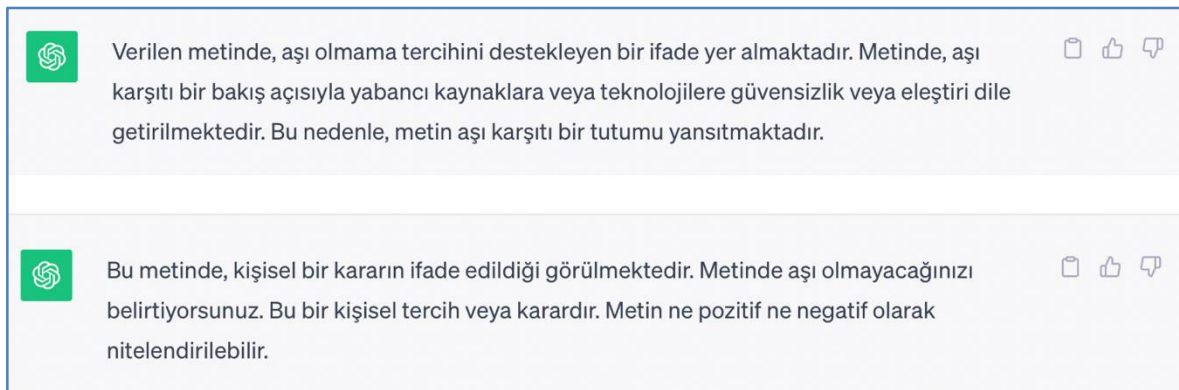
geleneksel makine öğrenmesi yöntemlerine göre daha yüksek başarımlar elde ettiği gözlemlenmiştir.

Duygu analizinde BERT modelinin (%64,64), duruş tespitinde ise ChatGPT'nin (%72,17) en yüksek başarımları sergiledikleri görülmüştür. BERT modeli duruş tespitinde de diğer modellere kıyasla iyi bir sonuç (%69,93) elde etmiştir ve bu sonuç İngilizce tweet'ler üzerinde duruş tespiti gerçekleştiren literatürdeki başka bir BERT tabanlı modelin (Mu ve diğerleri, 2023) sonucuna (%69,3) yakındır.

Tweet'ler hakkındaki duygu ve duruş soruları ChatGPT'ye ayrı ayrı sorulduğu halde, ChatGPT'nin duygu analizinde düşük başarımlar elde etmesinin önemli bir nedeni (kendi verdiği açıklamalara dayanarak) aş karşıtı olarak belirlediği tweet'leri *negatif* duygu ile, aş taraftarı olarak belirlediği tweet'leri ise *pozitif* duygu ile otomatik eşleştirmiş olması olabilir.

Bu durum, beklendiği üzere ChatGPT'nin üzerinde eğitildiği büyük boyutlu metin biçimindeki veri kümelerinin bakış açısından önemli ölçüde etkilendiği şeklinde yorumlanabilir.

Üretken (generative) bir modele dayalı olan ChatGPT'nin interaktif kullanıcı arayüzü yoluyla verdiği cevaplar için açıklamalar da üretmesi, diğer modellere kıyasla olumlu bir özellik olarak verilebilir. Şekil 5.1'de ChatGPT'den (farklı iki tweet için) sırasıyla duruş ve duygu sınıflandırması talep edildiğinde ürettiği çıktılar sunulmaktadır.



Şekil 5.1. ChatGPT'nin iki farklı tweet için ürettiği duruş ve duygu çıktı metinleri

Tez çalışmamız; ChatGPT'nin halk sağlığı ile ilgili sosyal medya iletileri üzerinde aynı anda

hem duygu analizi hem de duruş tespiti için kullanıldığı ilk çalışma olması açısından da önemlidir. Buna ek olarak, yukarıda da belirtildiği gibi, ilgili testlerimizde ChatGPT duruş tespiti problemi için en yüksek başarıyı sergilemiştir.

ChatGPT'nin duygu analizinde testlerinde de 600 tweet'lik veri kümesinde eğitilip 230 tweet'lik veri kümesinde test edilen SVM ve rasgele orman makine öğrenmesi modellerinden daha yüksek bir başarıyı elde ettiği görülmektedir.

Varlık ismi tanıma modülü sonuçlarının da F-Oranı cinsinden yaklaşık %73 gibi bir başarıya ulaştığı ve bunun da umut vadeden bir sonuç olduğu söylenebilir. Yaklaşık %82 olarak hesaplanan yakalama metriği sonucu değerlendirildiğinde, bu modülün varlık isimlerini kapsayıcılığının yüksek olduğu söylenebilir.

Varlık ismi tanıma modülünün yaklaşık %66 olarak hesaplanan keskinlik metriği sonucuna bakıldığında ise, modülün halk sağlığı varlık ismi olmayan kelimeleri veya kelime gruplarını da büyük oranda varlık ismi olarak işaretlediği; yani yanlış pozitif (varlık ismi olmayıp varlık ismi olarak işaretlenenler) sayısının yüksek çıktığı gözlemlenmiştir. Bu nedenle modülü iyileştirmek için yanlış pozitifleri azaltma yoluna gidilmesi gerektiği değerlendirilebilir.

5.4. İleri Çalışma Konuları

Tezimiz kapsamında gerçekleştirilen tüm çalışmaların tamamlanmasının ardından, ileri çalışma konuları olarak aşağıdaki maddeler değerlendirilebilir:

- Tezimiz kapsamında derlenen ve işaretlenen veri kümelerinin boyutları artırılabilir. Genişletilmiş veri kümeleri üzerindeki işaretlemelerin araştırma amacıyla açık hale getirilmesi sağlanabilir. Böylelikle, farklı yöntemlerin daha büyük veri kümeleri üzerinde test edilmeleri ve başarımlarının karşılaştırılması sağlanabilir.
- Benzer testlerin birden çok dilde (multi-lingual) metin içeren veri kümeleri üzerinde de gerçekleştirilerek, sosyal medya üzerinde halk sağlığı takibinin dünya genelinde gerçekleştirilebilmesi için farklı dillere özel ek veri analizi işlemlerinin gerekip gerekmediği tespit edilebilir.

- Tezimiz kapsamında kullanmadığımız ancak ilgili literatür taraması sonuçlarına göre sosyal medya metinleri üzerinde halk sağlığı takibini iyileştirme potansiyeline sahip farklı öğrenme yöntemleri ve geniş dil modelleri kullanılarak ilgili testler gerçekleştirilebilir. Bu sonuçlara göre en yüksek başarıyı elde eden yaklaşımlar önerdiğimiz halk sağlığı takibi ve karar destek sisteminin bünyesine katılabilir.
- Duygu tanıma (emotion recognition) problemi de geliştirilen sistemin kapsamına alınarak, bu problemin çözümüne yönelik olarak da ilgili modeller çalıştırılarak en iyi sonuçların hangi model/modeller tarafından elde edildiği gözlemlenebilir. Böylelikle sistemin içerisine yeni bir duygu tanıma modülü de eklenerek, her bir sosyal medya iletişisi için bu modülün çıktıları (*mutluluk, üzüntü, öfke, nefret* vb.) da sistem veri tabanında saklanabilir ve bu çıktılar da sistem kullanıcılarına (kullanıcı arayüzleri yoluyla) sunulabilir.
- Doğal dil işlemenin bir diğer problemi olan otomatik özetleme (summarization) problemine yönelik çözümler de önerilen halk sağlığı takibi ve karar destek sisteminin kapsamına dahil edilerek; sistemin otomatik olarak toplanan sosyal medya iletilerini ayrıca özetleyerek kullanıcılarına sunması sağlanabilir.
- Bir diğer potansiyel ileri araştırma konusu da önerilen halk sağlığı ve karar destek sistemine bir doğal dil üretim (Natural Language Generation – NLG) modülü eklenerek, bu modülün sistemin diğer otomatik çıktılarına dayanarak sistemin kullanıcısı olan halk sağlığı uzmanları ve karar alıcıları için Türkçe doğal dilde alınabilecek halk sağlığı önlemleri ve uyarılar üretmesinin sağlanmasıdır.
- Ayrıca, tezimiz kapsamında geliştirilen karar destek sistemi uygulamasının projelendirilerek sağlık alanında görev yapan uzmanların kullanımına sunulması amaçlanmaktadır.



6. SONUÇ VE ÖNERİLER

Halk sağığının korunması ve geliştirilmesi toplumların devamı ve refahı için son derece önemlidir. Sosyal medya metinleri de anlık bilgi sağılamaları ve yaygınlıkları dolayısıyla halk sağığı konusunda bilgi edinmek üzere karar alıcılar için önemli bir bilgi kaynağı teşkil etmektedir. Bu bilgi kaynağının otomatik analizi ile halk sağığı alanındaki karar alıcılar için önemli bir karar destek sistemi geliştirilmesi mümkün olabilecektir. Böylelikle de halk sağığı ile ilgili tedbirlere toplumların beklenti, düşünce ve duruşları dikkate alınarak ve hızlı bir şekilde karar verilmesi sağılanabilecektir.

Söz konusu metinler üzerinde çeşitli doğal dil işleme problemlerinin çözümü ile bu metinlerden otomatik olarak değerli bilgilerin çıkarımı mümkün olabilecektir.

Tez çalışmamız kapsamında; sağılıkla ilgili Türkçe sosyal medya iletileri üzerinde üç önemli doğal dil işleme probleminin (duygu analizi, duruş tespiti ve varlık ismi tanıma) çözümü amacıyla makine öğrenmesi ve derin öğrenme yöntemleri kullanılmış, elde edilen sonuçlar karşılaştırılmış ve elde edilen çözümlere dayalı olarak tam otomatik bir halk sağığı izleme ve karar destek sistemi geliştirilmiştir.

Gerçekleştirilen testler sonucunda, en iyi sonuçların transformer tabanlı bir derin öğrenme modeli olan BERT ve yine transformer ve derin öğrenme tabanlı bir üretken yapay zekâ aracı olan ChatGPT tarafından elde edildiğı gözlemlenmiştir. Elde edilen sonuçlar ile literatürde verilen sonuçlar genel olarak uyumludur.

Tez çalışmamız, ChatGPT'nin halk sağığı ile ilgili sosyal medya iletileri üzerinde duygu analizi ve duruş tespiti için kullanıldığı ilk çalışma olması açısından da değerlidir ve elde edilen sonuçlar da umut vericidir.

Testlerde kullanılmak üzere; halk sağığı ile ilgili Türkçe tweet'ler derlenmiş, daha sonra bu tweet'ler üzerinde temizleme işleminin ardından duygu analizi, duruş tespiti ve varlık ismi tanıma için işaretlenmiş ve böylelikle Türkçe tweet'lerden oluşan veri kümeleri elde edilmiştir. Türkçe metinler üzerinde doğal dil işleme araştırmalarının ilerlemesi amacına

hizmet etmeleri ve farklı doğal dil işleme problemlerini kapsamaları açısından söz konusu işaretli veri kümeleri önem arz etmektedir.

Çalışmamız kapsamında duygu analizi ve duruş tespiti için işaretlenen ve COVID-19 aşılılarıyla ilgili olan tweet’lerdeki duygu ve duruş sınıfları değerlendirildiğinde, duruş tespiti sınıflarının (*tarafında, karşısında, hiçbir*) görece dengeli olduğu ancak duygu analizi sınıflarından (pozitif, negatif, hiçbir) *negatif* sınıfın çok yaygın olduğu ve *pozitif* sınıfın ise oldukça az görüldüğü söylenebilir. Bu gözleme dayanarak, bizim veri kümelerimiz özelinde hem aşı taraftarlarının hem de aşı karşıtlarının *pozitif olmayan* bir dil kullandıkları ifade edilebilir.

Tez çalışmamız; üç önemli metin işleme probleminin aynı kapsamda çözülmesi, bu problemlere yönelik ortak işaretli veri kümelerinin oluşturulması, kullanılan yöntemlerin geleneksel makine öğrenmesi yöntemlerine ek olarak güncel derin öğrenme yöntemlerine de dayalı olması, karşılaştırma amacıyla bu problemler için mevcut araçların ve üretken yapay zeka modellerinin de test edilmiş olması, doğal dil işleme çalışmalarının sınırlı olduğu Türkçe dilindeki sosyal medya içerikleri üzerinde bu çalışmaların gerçekleştirilmiş olması ve halk sağlığı uzmanlarının kullanımı için prototip bir halk sağlığı izleme ve karar destek sisteminin geliştirilmiş olması nedenleriyle önem arz etmektedir.

İleri çalışmalar bünyesinde; veri kümelerimizin genişletilmesi, farklı yaklaşımların ve modellerin ortak veri kümeleri üzerinde test edilmesi ve bulguların mevcut sonuçlarla karşılaştırılması ve birden çok dilde metin içeren veri kümeleri üzerinde de benzer testlerin gerçekleştirilmesi sayılabilir.

Yine tezimizin ileri çalışmaları kapsamında; duygu tanıma (duyguların ve görüşlerin emojiyle ve kısaltılmış kelimelerle ifade edildiği durumların tespiti), otomatik özetleme ve doğal dil üretimi gibi birçok farklı doğal dil işleme problemine yönelik çözümler de önerilen halk sağlığı takibi ve karar destek sisteminin kapsamına alınabilir.

KAYNAKLAR

- Abacha, A. B., Chowdhury, M. F. M., Karanasiou, A., Mrabet, Y., Lavelli, A., and Zweigenbaum, P. (2015). Text mining for pharmacovigilance: Using machine learning for drug name recognition and drug–drug interaction extraction and classification. *Journal of Biomedical Informatics*, 58, 122-132.
- Al-Laith, A., and Alenezi, M. (2021). Monitoring people’s emotions and symptoms from Arabic tweets during the COVID-19 pandemic. *Information*, 12(2), 86.
- Ali, G. G., Rahman, M., Hossain, A., Rahman, S., Paul, K. C., Thill, J.-C., and Samuel, J. (2021). Public perceptions of COVID-19 vaccines: Policy implications from US spatiotemporal sentiment analytics. *Healthcare*, 9(9), 1110.
- Aljedaani, W., Saad, E., Rustam, F., de la Torre Díez, I., and Ashraf, I. (2022). Role of artificial intelligence for analysis of COVID-19 vaccination-related tweets: Opportunities, challenges, and future trends. *Mathematics*, 10(17), 3199.
- Alkhalidi, N. A., Asiri, Y., Mashraqi, A. M., Halawani, H. T., Abdel-Khalek, S., and Mansour, R. F. (2022). Leveraging tweets for artificial intelligence driven sentiment analysis on the COVID-19 pandemic. *Healthcare*, 10(5), 910.
- Alqurashi, T. (2022). Stance analysis of distance education in the Kingdom of Saudi Arabia during the COVID-19 pandemic using Arabic Twitter data. *Sensors*, 22(3), 1006.
- Ansari, M. T. J., and Khan, N. A. (2021). Worldwide COVID-19 vaccines sentiment analysis through Twitter content. *Electronic Journal of General Medicine*, 18(6).
- Asghari, M., Sierra-Sosa, D., and Elmaghraby, A. S. (2022). Biner: A low-cost biomedical named entity recognition. *Information Sciences*, 602, 184-200.
- Batra, R., Imran, A. S., Kastrati, Z., Ghafoor, A., Daudpota, S. M., and Shaikh, S. (2021). Evaluating polarity trend amidst the coronavirus crisis in peoples’ attitudes toward the vaccination drive. *Sustainability*, 13(10), 5344.
- Benis, A., Chatsubi, A., Levner, E., and Ashkenazi, S. (2021). Change in threads on Twitter regarding influenza, vaccines, and vaccination during the COVID-19 pandemic: Artificial intelligence–based infodemiology study. *JMIR Infodemiology*, 1(1), e31983.
- Boucher, J. C., Cornelson, K., Benham, J. L., Fullerton, M. M., Tang, T., Constantinescu, C., Mourali, M., Oxoby, R. J., Marshall, D. A., Hemmati, H., Badami, A., Hu, J., Lang, R. (2021). Analyzing social media to explore the attitudes and behaviors following the announcement of successful COVID-19 vaccine trials: Infodemiology study. *JMIR Infodemiology*, 1(1), e28800.
- Burzyńska, J., Bartosiewicz, A., and Rękas, M. (2020). The social life of COVID-19: Early insights from social media monitoring data collected in Poland. *Health Informatics Journal*, 26(4), 3056-3065.

- Byrd, K., Mansurov, A., and Baysal, O. (2016). *Mining Twitter data for influenza detection and surveillance*. International Workshop on Software Engineering in Healthcare Systems, 43-49.
- Calamusa, A., Tardelli, S., Avvenuti, M., Cresci, S., Federigi, I., Tesconi, M., Verani, M., Carducci, A. (2020). Twitter monitoring evidence of COVID-19 infodemic in Italy. *European Journal of Public Health*, 30(Supplement_5), ckaa165-066.
- Cambria, E., Das, D., Bandyopadhyay, S., and Feraco, A. (2017). Affective computing and sentiment analysis. *A Practical Guide to Sentiment Analysis*, 1-10.
- Cañete, J., Chaperon, G., Fuentes, R., Ho, J. H., Kang, H., and Pérez, J. (2020). *Spanish pre-trained BERT model and evaluation data*. Practical ML for Developing Countries Workshop at ICLR, 1-10.
- Cascini, F., Pantovic, A., Al-Ajlouni, Y. A., Failla, G., Puleo, V., Melnyk, A., Lontano, A., Ricciardi, W. (2022). Social media and attitudes towards a COVID-19 vaccination: A systematic review of the literature. *EClinicalMedicine*, 101454.
- Chai, Z., Jin, H., Shi, S., Zhan, S., Zhuo, L., and Yang, Y. (2022). Hierarchical shared transfer learning for biomedical named entity recognition. *BMC Bioinformatics*, 23, 1-14.
- Chandrasekaran, R., Desai, R., Shah, H., Kumar, V., and Moustakas, E. (2022). Examining public sentiments and attitudes toward COVID-19 vaccination: Infoveillance study using Twitter posts. *JMIR Infodemiology*, 2(1), e33909.
- Chen, E., Lerman, K., and Ferrara, E. (2020). Tracking social media discourse about the COVID-19 pandemic: Development of a public coronavirus Twitter data set. *JMIR Public Health and Surveillance*, 6(2), e19273.
- Choi, S., Lee, J., Kang, M. G., Min, H., Chang, Y. S., and Yoon, S. (2017). Large-scale machine learning of media outlets for understanding public reactions to nation-wide viral infection outbreaks. *Methods*, 129, 50-59.
- Choi, Y. J., Lee, J., and Paek, S. Y. (2022). Public awareness and sentiment toward COVID-19 vaccination in South Korea: Findings from big data analytics. *International Journal of Environmental Research and Public Health*, 19(16), 9914.
- Chopra, H., Vashishtha, A., Pal, R., Tyagi, A., and Sethi, T. (2021). Mining trends of COVID-19 vaccine beliefs on Twitter with lexical embeddings. *arXiv preprint arXiv:2104.01131*.
- Chou, W. Y. S., and Budenz, A. (2020). Considering emotion in COVID-19 vaccine communication: addressing vaccine hesitancy and fostering vaccine confidence. *Health Communication*, 35(14), 1718-1722.
- Cocos, A., Fiks, A. G., and Masino, A. J. (2017). Deep learning for pharmacovigilance: recurrent neural network architectures for labeling adverse drug reactions in Twitter posts. *Journal of the American Medical Informatics Association*, 24(4), 813-821.

- Comito, C., Forestiero, A., and Pizzuti, C. (2018). *Twitter-based influenza surveillance: an analysis of the 2016-2017 and 2017-2018 seasons in Italy*. International Database Engineering & Applications Symposium, 175-182.
- Cotfas, L. A., Delcea, C., Roxin, I., Ioanăș, C., Gherai, D. S., and Tajariol, F. (2021). The longest month: Analyzing COVID-19 vaccination opinions dynamics from tweets in the month following the first vaccine announcement. *IEEE Access*, 9, 33203-33223.
- Cui, Y., Che, W., Liu, T., Qin, B., and Yang, Z. (2021). Pre-training with whole word masking for Chinese BERT. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 29, 3504-3514.
- Culotta, A. (2014). *Estimating county health statistics with Twitter*. SIGCHI Conference on Human Factors in Computing Systems, 1335-1344.
- D'Andrea, E., Ducange, P., Bechini, A., Renda, A., and Marcelloni, F. (2019). Monitoring the public opinion about the vaccination topic from tweets analysis. *Expert Systems with Applications*, 116, 209-226.
- DeVerna, M. R., Pierri, F., Truong, B. T., Bollenbacher, J., Axelrod, D., Loynes, N., Torres-Lugo, C., Yang, K-C., Menczer, F., Bryden, J. (2021). *CoVaxxy: A collection of English-language Twitter posts about COVID-19 vaccines*. International AAAI Conference on Web and Social Media, 15, 992-999.
- Devlin, J., Chang, M. W., Lee, K., and Toutanova, K. (2018). BERT: Pre-training of deep bidirectional transformers for language understanding. *arXiv preprint arXiv:1810.04805*.
- Doan, S., Yang, E. W., Tilak, S. S., Li, P. W., Zisook, D. S., and Torii, M. (2019). Extracting health-related causality from Twitter messages using natural language processing. *BMC Medical Informatics and Decision Making*, 19, 71-77.
- Du, J., Michalska, S., Subramani, S., Wang, H., and Zhang, Y. (2019). Neural attention with character embeddings for hay fever detection from Twitter. *Health Information Science and Systems*, 7, 1-7.
- Fan, B., Fan, W., and Smith, C. (2020). Adverse drug event detection and extraction from open data: A deep learning approach. *Information Processing & Management*, 57(1), 102131.
- Fung, I. C. H., Tse, Z. T. H., and Fu, K. W. (2015). The use of social media in public health surveillance. *Western Pacific Surveillance and Response Journal: WPSAR*, 6(2), 3.
- Gaïnd, B., Syal, V., and Padgalwar, S. (2019). Emotion detection and analysis on social media. *arXiv preprint arXiv:1901.08458*.
- Gkotsis, G., Oellrich, A., Velupillai, S., Liakata, M., Hubbard, T. J., Dobson, R. J., and Dutta, R. (2017). Characterisation of mental health conditions in social media using informed deep learning. *Scientific Reports*, 7(1), 45141.

- Glandt, K., Khanal, S., Li, Y., Caragea, D., and Caragea, C. (2021). *Stance detection in COVID-19 tweets*. 59. Annual Meeting of the Association for Computational Linguistics and the 11. International Joint Conference on Natural Language Processing (Long Papers), 1.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep learning*. ABD: MIT Press.
- Gorinski, P. J., Wu, H., Grover, C., Tobin, R., Talbot, C., Whalley, H., Sudlow, C., Whiteley, W., and Alex, B. (2019). Named entity recognition for electronic health records: A comparison of rule-based and machine learning approaches. *arXiv preprint arXiv:1903.03985*.
- Gozalo-Brizuela, R., and Garrido-Merchan, E. C. (2023). ChatGPT is not all you need. A state of the art review of large generative AI models. *arXiv preprint arXiv:2301.04655*.
- Guidry, J. P., Jin, Y., Orr, C. A., Messner, M., and Meganck, S. (2017). Ebola on Instagram and Twitter: How health organizations address the health crisis in their social media engagement. *Public Relations Review*, 43(3), 477-486.
- Guntuku, S. C., Sherman, G., Stokes, D. C., Agarwal, A. K., Seltzer, E., Merchant, R. M., and Ungar, L. H. (2020). Tracking mental health and symptom mentions on Twitter during COVID-19. *Journal of General Internal Medicine*, 35, 2798-2800.
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., and Witten, I. H. (2009). The WEKA data mining software: an update. *ACM SIGKDD Explorations Newsletter*, 11(1), 10-18.
- Haouari, F., Hasanain, M., Suwaileh, R., and Elsayed, T. (2020). Arcov-19: The first Arabic COVID-19 Twitter dataset with propagation networks. *arXiv preprint arXiv:2004.05861*.
- Hayawi, K., Shahriar, S., Serhani, M. A., Taleb, I., and Mathew, S. S. (2022). ANTi-Vax: a novel Twitter dataset for COVID-19 vaccine misinformation detection. *Public Health*, 203, 23-30.
- Hou, Y., van der Putten, P., and Verberne, S. (2022). The COVMis-stance dataset: stance detection on Twitter for COVID-19 misinformation. *arXiv preprint arXiv:2204.02000*.
- Hu, T., Wang, S., Luo, W., Zhang, M., Huang, X., Yan, Y., Liu, R., Ly, K., Kracker, V., Bing, S., and Li, Z. (2021). Revealing public opinion towards COVID-19 vaccines with Twitter data in the United States: spatiotemporal perspective. *Journal of Medical Internet Research*, 23(9), e30854.
- Huangfu, L., Mo, Y., Zhang, P., Zeng, D. D., and He, S. (2022). COVID-19 vaccine tweets after vaccine rollout: sentiment-based topic modeling. *Journal of Medical Internet Research*, 24(2), e31726.

Hussain, A. and Sheikh, A. (2021). Opportunities for artificial intelligence-enabled social media analysis of public attitudes toward COVID-19 vaccines. *NEJM Catalyst Innovations in Care Delivery*, 2(1).

Hussain, A., Tahir, A., Hussain, Z., Sheikh, Z., Gogate, M., Dashtipour, K., Ali, A., Sheikh, A. (2021). Artificial intelligence-enabled analysis of public attitudes on Facebook and Twitter toward COVID-19 vaccines in the United Kingdom and the United States: Observational study. *Journal of Medical Internet Research*, 23(4), e26627.

Hutto, C. and Gilbert, E. (2014). VADER: A parsimonious rule-based model for sentiment analysis of social media text. *International AAAI Conference on Web and Social Media*, 8(1), 216-225.

İnternet: Infodemic. *Cipec*.URL1: https://www.who.int/health-topics/infodemic#tab=tab_1, Son Erişim Tarihi: 25.09.2023.

İnternet: Tone Analyzer. *Cipec*.URL2: https://cloud.ibm.com/docs/openwhisk?topic=openwhisk-pkg_tone_analyzer, Son Erişim Tarihi: 25.09.2023.

İnternet: Introduction to the Syuzhet Package. *Cipec*.URL3: <https://cran.r-project.org/web/packages/syuzhet/vignettes/syuzhet-vignette.html>, Son Erişim Tarihi: 25.09.2023.

İnternet: Mohammad, S. M., and Turney, P. D. NRC Emotion Lexicon. *Cipec*.URL4: <http://www.saifmohammad.com/WebDocs/NRCemotionlexicon.pdf>, Son Erişim Tarihi: 25.09.2023.

İnternet: Back Translation for Text Augmentation with Google Sheets. *Cipec*.URL5: <https://amitnness.com/2020/02/back-translation-in-google-sheets/>, Son Erişim Tarihi: 25.09.2023.

İnternet: ChatGPT. *Cipec*.URL6: <https://chat.openai.com/>, Son Erişim Tarihi: 25.09.2023.

İnternet: Twitter Developer Platform. *Cipec*.URL7: <https://developer.twitter.com/en/docs/twitter-api/tweets/search/introduction>, Son Erişim Tarihi: 25.09.2023.

İnternet: Tweepy. *Cipec*.URL8: <https://www.tweepy.org>, Son Erişim Tarihi: 25.09.2023.

İnternet: Meta for Developers. *Cipec*.URL9: <https://developers.facebook.com/>, Son Erişim Tarihi: 25.09.2023.

İnternet: Google Translate. *Cipec*.URL10: <https://translate.google.com/>, Son Erişim Tarihi: 25.09.2023.

İnternet: BERTurk. *Cipec*.URL11: <https://huggingface.co/dbmdz/bert-base-turkish-cased>, Son Erişim Tarihi: 25.09.2023.

İnternet: NLTK. *Cipec*.URL12: <https://www.nltk.org>, Son Erişim Tarihi: 25.09.2023.

İnternet: Simple Transformers. *Cipec*.URL13: <https://simpletransformers.ai>, Son Erişim Tarihi: 25.09.2023.

İnternet: Transformers. *Cipec*.URL14: <https://github.com/huggingface/transformers>, Son Erişim Tarihi: 25.09.2023.

İnternet: ChatGPT Release Notes. *Cipec*.URL15: <https://help.openai.com/en/articles/6825453-chatgpt-release-notes>, Son Erişim Tarihi: 25.09.2023.

İnternet: MongoDB. *Cipec*.URL16: <https://www.mongodb.com/>, Son Erişim Tarihi: 25.09.2023.

İnternet: Streamlit. *Cipec*.URL17: <https://streamlit.io>, Son Erişim Tarihi: 25.09.2023.

İnternet: Matplotlib. *Cipec*.URL18: <https://matplotlib.org>, Son Erişim Tarihi: 25.09.2023.

İnternet: Pandas. *Cipec*.URL19: <https://pandas.pydata.org>, Son Erişim Tarihi: 25.09.2023.

İnternet: VADER-Sentiment-Analysis in Java. *Cipec*.URL20: <https://github.com/apanimesh061/VaderSentimentJava>, Son Erişim Tarihi: 25.09.2023.

Jahanbin, K. and Rahmanian, V. (2020). Using Twitter and web news mining to predict COVID-19 outbreak. *Asian Pacific Journal of Tropical Medicine*, 13(8), 378.

Jawad, M. R., Qasim, M. A., Cazzato, G., Zahra, M. M. A., Kapula, P. R., Gherabi, N., and Jaleel, R. A. (2021). Advancement of artificial intelligence techniques based lexicon emotion analysis for vaccine of COVID-19. *Periodicals of Engineering and Natural Sciences*, 9(4), 580-588.

Jiang, K., Feng, S., Song, Q., Calix, R. A., Gupta, M., and Bernard, G. R. (2018). Identifying tweets of personal health experience through word embedding and LSTM neural network. *BMC Bioinformatics*, 19(8), 67-74.

Jordan, M. I. and Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.

Jordan, S. E., Hovet, S. E., Fung, I. C. H., Liang, H., Fu, K. W., and Tse, Z. T. H. (2018). Using Twitter for public health surveillance from monitoring and prediction to public response. *Data*, 4(1), 6.

Karami, A., Zhu, M., Goldschmidt, B., Boyajieff, H. R., and Najafabadi, M. M. (2021). COVID-19 vaccine and social media in the US: Exploring emotions and discussions on Twitter. *Vaccines*, 9(10), 1059.

Kapp, J. M., Hensel, B., and Schnoring, K. T. (2015). Is Twitter a forum for disseminating research to health policy makers?. *Annals of Epidemiology*, 25(12), 883-887.

- Kaur, S., Kaul, P., and Zadeh, P. M. (2020). Monitoring the dynamics of emotions during COVID-19 using Twitter data. *Procedia Computer Science*, 177, 423-430.
- Kendra, R. L., Karki, S., Eickholt, J. L., and Gandy, L. (2015). Characterizing the discussion of antibiotics in the Twittersphere: What is the bigger picture?. *Journal of Medical Internet Research*, 17(6), e154.
- Khatua, A., Khatua, A., and Cambria, E. (2019). A tale of two epidemics: Contextual Word2Vec for classifying Twitter streams during outbreaks. *Information Processing & Management*, 56(1), 247-257.
- Küçük, D. ve Arıcı, N. (2016). Türkçe için Wikipedia Tabanlı Varlık İsmi Tanıma Sistemi. *Politeknik Dergisi*, 19(3), 325-332.
- Küçük, D. ve Arıcı, N. (2018). Doğal dil işlemede derin öğrenme uygulamaları üzerine bir literatür çalışması. *Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi*, 2(2), 76-86.
- Küçük, D. and Arıcı, N. (2021). *Sentiment, stance, and emotion analysis on Twitter for COVID-19 vaccination: A brief survey*. International Conference on Informatics and Computer Science (ICI-CS2021).
- Küçük, D., Arıcı, N., ve Küçük, E. E. (2021). Sosyal medyada otomatik halk sağlığı takibi: Güncel bir derleme. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 10(2), 439-449.
- Küçük, D. and Arıcı, N. (2022a). Sentiment analysis and stance detection in Turkish tweets about COVID-19 vaccination. *Handbook of Research on Opinion Mining and Text Analytics on Literary Works and Social Media*, 371-387.
- Küçük, D. and Arıcı, N. (2022b). Sentiment, stance, and emotion analysis on Twitter for COVID-19 vaccination: A survey. *Artificial Intelligence Studies*, 5(1), 14-22.
- Küçük, D. and Can, F. (2020). Stance detection: A survey. *ACM Computing Surveys (CSUR)*, 53(1), 1-37.
- Kwok, S. W. H., Vadde, S. K., and Wang, G. (2021). Tweet topics and sentiments relating to COVID-19 vaccination among Australian Twitter users: Machine learning analysis. *Journal of Medical Internet Research*, 23(5), e26953.
- Lazer, D., Kennedy, R., King, G., and Vespignani, A. (2014). The parable of Google Flu: traps in big data analysis. *Science*, 343(6176), 1203-1205.
- Le, H., Vial, L., Frej, J., Segonne, V., Coavoux, M., Lecouteux, B., Allauzen, A., Crabbé, B., Besacier, L., Schwab, D. (2019). FlauBERT: Unsupervised language model pre-training for French. *arXiv preprint arXiv:1912.05372*.
- Lee, K., Agrawal, A., and Choudhary, A. (2013). *Real-time disease surveillance using Twitter data: demonstration on flu and cancer*. ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 1474-1477.

- Li, J., Sun, A., Han, J., and Li, C. (2020). A survey on deep learning for named entity recognition. *IEEE Transactions on Knowledge and Data Engineering*, 34(1), 50-70.
- Li, Y. and Caragea, C. (2021). *Target-aware data augmentation for stance detection*. Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 1850-1860.
- Liu, B. (2010). Sentiment analysis and subjectivity. *Handbook of Natural Language Processing*, 627-666.
- Liu, S., Li, J., and Liu, J. (2021). Leveraging transfer learning to analyze opinions, attitudes, and behavioral intentions toward COVID-19 vaccines: Social media content and temporal analysis. *Journal of Medical Internet Research*, 23(8), e30251.
- Liu, S. and Liu, J. (2021). Public attitudes toward COVID-19 vaccines on English-language Twitter: A sentiment analysis. *Vaccine*, 39(39), 5499-5505.
- Liu, X., Zhang, S., Wei, F., and Zhou, M. (2011). *Recognizing named entities in tweets*. Annual Meeting of the Association for Computational Linguistics: Human Language Technologies, 359-367.
- Lyu, J. C., Han, E. L., and Luli, G. K. (2021). COVID-19 vaccine-related discussion on Twitter: Topic modeling and sentiment analysis. *Journal of Medical Internet Research*, 23(6), e24435.
- Magumba, M. A., Nabende, P., and Mwebaze, E. (2018). Ontology boosted deep learning for disease name extraction from Twitter messages. *Journal of Big Data*, 5, 1-19.
- Mäntylä, M. V., Graziotin, D., and Kuutila, M. (2018). The evolution of sentiment analysis—A review of research topics, venues, and top cited papers. *Computer Science Review*, 27, 16-32.
- Marcec, R. and Likic, R. (2022). Using Twitter for sentiment analysis towards AstraZeneca/Oxford, Pfizer/BioNTech and Moderna COVID-19 vaccines. *Postgraduate Medical Journal*, 98(1161), 544-550.
- Martínez, R. Y., Blanco, G., and Lourenço, A. (2023). Spanish corpora of tweets about COVID-19 vaccination for automatic stance detection. *Information Processing & Management*, 60(3), 103294.
- Medhat, W., Hassan, A., and Korashy, H. (2014). Sentiment analysis algorithms and applications: A survey. *Ain Shams Engineering Journal*, 5(4), 1093-1113.
- Melton, C. A., Olusanya, O. A., Ammar, N., and Shaban-Nejad, A. (2021). Public sentiment analysis and topic modeling regarding COVID-19 vaccines on the Reddit social media platform: A call to action for strengthening vaccine confidence. *Journal of Infection and Public Health*, 14(10), 1505-1512.

- Miao, L., Last, M., and Litvak, M. (2022). Tracking social media during the COVID-19 pandemic: The case study of lockdown in New York State. *Expert Systems with Applications*, 187, 115797.
- Mohammad, S., Kiritchenko, S., Sobhani, P., Zhu, X., and Cherry, C. (2016). *Semeval-2016 task 6: Detecting stance in tweets*. International Workshop on Semantic Evaluation (SemEval-2016), 31-41.
- Mohammad, S. M., Sobhani, P., and Kiritchenko, S. (2017). Stance and sentiment in tweets. *ACM Transactions on Internet Technology (TOIT)*, 17(3), 1-23.
- Monselise, M., Chang, C. H., Ferreira, G., Yang, R., and Yang, C. C. (2021). Topics and sentiments of public concerns regarding COVID-19 vaccines: Social media trend analysis. *Journal of Medical Internet Research*, 23(10), e30765.
- Mu, Y., Jin, M., Grimshaw, C., Scarton, C., Bontcheva, K., and Song, X. (2023). VaxxHesitancy: A dataset for studying hesitancy towards COVID-19 vaccination on Twitter. *arXiv preprint arXiv:2301.06660*.
- Müller, M. and Salathé, M. (2020). Addressing machine learning concept drift reveals declining vaccine sentiment during the COVID-19 pandemic. *arXiv preprint arXiv:2012.02197*.
- Nazir, A., Rao, Y., Wu, L., and Sun, L. (2020). Issues and challenges of aspect-based sentiment analysis: A comprehensive survey. *IEEE Transactions on Affective Computing*, 13(2), 845-863.
- Nezhad, Z. B. and Deihimi, M. A. (2022). Twitter sentiment analysis from Iran about COVID 19 vaccine. *Diabetes & Metabolic Syndrome: Clinical Research & Reviews*, 16(1), 102367.
- Nikfarjam, A. (2016). *Health information extraction from social media*. Yayınlanmamış Doktora Tezi, Arizona State University, ABD.
- Nikfarjam, A., Sarker, A., O'connor, K., Ginn, R., and Gonzalez, G. (2015). Pharmacovigilance from social media: mining adverse drug reaction mentions using sequence labeling with word embedding cluster features. *Journal of the American Medical Informatics Association*, 22(3), 671-681.
- Niu, Q., Liu, J., Kato, M., Shinohara, Y., Matsumura, N., Aoyama, T., and Nagai-Tanima, M. (2022). Public opinion and sentiment before and at the beginning of COVID-19 vaccinations in Japan: Twitter analysis. *JMIR Infodemiology*, 2(1), e32335.
- Nyawa, S., Tchunte, D., and Fosso-Wamba, S. (2022). COVID-19 vaccine hesitancy: A social media analysis using deep learning. *Annals of Operations Research*, 1-39.
- Paliwal, S., Parveen, S., Afshar Alam, M., and Ahmed, J. (2022). *Sentiment analysis of COVID-19 vaccine rollout in India*. International Conference on ICT for Sustainable Development (ICT4SD), 21-33.

- Pang, B. and Lee, L. (2008). Opinion mining and sentiment analysis. *Foundations and Trends in Information Retrieval*, 2(1–2), 1-135.
- Parker, J., Wei, Y., Yates, A., Frieder, O., and Goharian, N. (2013). *A framework for detecting public health trends with Twitter*. IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining, 556-563.
- Pershad, Y., Hangge, P. T., Albadawi, H., and Oklu, R. (2018). Social medicine: Twitter in healthcare. *Journal of Clinical Medicine*, 7(6), 121.
- Pierri, F., Tocchetti, A., Corti, L., Di Giovanni, M., Pavanetto, S., Brambilla, M., and Ceri, S. (2021). VaccinItaly: monitoring Italian conversations around vaccines on Twitter and Facebook. *arXiv preprint arXiv:2101.03757*.
- Poddar, S., Mondal, M., Misra, J., Ganguly, N., and Ghosh, S. (2022). *Winds of change: Impact of COVID-19 on vaccine-related opinions of Twitter users*. International AAAI Conference on Web and Social Media, 16, 782-793.
- Polignano, M., Basile, P., De Gemmis, M., Semeraro, G., and Basile, V. (2019). *AlBERTo: Italian BERT language understanding model for NLP challenging tasks based on tweets*. CEUR Workshop Proceedings, 2481, 1-6.
- Qazi, U., Imran, M., and Ofli, F. (2020). GeoCoV19: a dataset of hundreds of millions of multilingual COVID-19 tweets with location information. *SIGSPATIAL Special*, 12(1), 6-15.
- Qorib, M., Oladunni, T., Denis, M., Ososanya, E., and Cota, P. (2023). COVID-19 vaccine hesitancy: Text mining, sentiment analysis and machine learning on COVID-19 vaccination Twitter dataset. *Expert Systems with Applications*, 212, 118715.
- Rabarison, K. M., Croston, M. A., Englar, N. K., Bish, C. L., Flynn, S. M., and Johnson, C. C. (2017). Measuring audience engagement for public health Twitter chats: insights from #LiveFitNOLA. *JMIR Public Health and Surveillance*, 3(2), e7181.
- Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., and Yang, G. Z. (2017). Deep learning for health informatics. *IEEE Journal of Biomedical and Health Informatics*, 21(1), 4-21.
- Ritter, A., Clark, S., and Etzioni, O. (2011). *Named entity recognition in tweets: An experimental study*. Conference on Empirical Methods in Natural language processing, 1524-1534.
- Ritonga, M., Ihsan, M. A. A., Anjar, A., and Rambe, F. H. (2021). *Sentiment analysis of COVID-19 vaccine in Indonesia using Naïve Bayes algorithm*. IOP Conference Series: Materials Science and Engineering, 1088(1), 012045.
- Saleh, S. N., McDonald, S. A., Basit, M. A., Kumar, S., Arasaratnam, R. J., Perl, T. M., Lehmann, C. U. & Medford, R. J. (2021). Public perception of COVID-19 vaccines through analysis of Twitter content and users. *medRxiv*, 2021-04.

- Santillana, M., Nguyen, A. T., Dredze, M., Paul, M. J., Nsoesie, E. O., and Brownstein, J. S. (2015). Combining search, social media, and traditional data sources to improve influenza surveillance. *PLoS Computational Biology*, 11(10), e1004513.
- Sarker, A., Belousov, M., Friedrichs, J., Hakala, K., Kiritchenko, S., Mehryary, F., Han, S., Tran, T., Rios, A., Kavuluru, R., de Bruijn, B., Ginter, F., Mahata, D., Mohammad, S. M., Nenadic, G., Gonzalez-Hernandez, G. (2018). Data and systems for medication-related text classification and concept normalization from Twitter: insights from the Social Media Mining for Health (SMM4H)-2017 shared task. *Journal of the American Medical Informatics Association*, 25(10), 1274-1283.
- Sarker, A., Ginn, R., Nikfarjam, A., O'Connor, K., Smith, K., Jayaraman, S., Upadhaya, T., Gonzalez, G. (2015). Utilizing social media data for pharmacovigilance: A review. *Journal of Biomedical Informatics*, 54, 202-212.
- Sattar, N. S. and Arifuzzaman, S. (2021). COVID-19 vaccination awareness and aftermath: public sentiment analysis on Twitter data and vaccinated population prediction in the USA. *Applied Sciences*, 11(13), 6128.
- Sauvayre, R., Vernier, J., and Chauvière, C. (2022). An analysis of French-language tweets about COVID-19 vaccines: Supervised learning approach. *JMIR Medical Informatics*, 10(5), e37831.
- Saxena, A., Khanna, A., and Gupta, D. (2020). Emotion recognition and detection methods: A comprehensive survey. *Journal of Artificial Intelligence and Systems*, 2(1), 53-79.
- Scannell, D., Desens, L., Guadagno, M., Tra, Y., Acker, E., Sheridan, K., Rosner, M., Mathieu, J., Fulk, M. (2021). COVID-19 vaccine discourse on Twitter: A content analysis of persuasion techniques, sentiment and mis/disinformation. *Journal of Health Communication*, 26(7), 443-459.
- Seltzer, E. K., Horst-Martz, E., Lu, M., and Merchant, R. M. (2017). Public sentiment and discourse about Zika virus on Instagram. *Public Health*, 150, 170-175.
- Shamrat, F. M. J. M., Chakraborty, S., Imran, M. M., Muna, J. N., Billah, M. M., Das, P., and Rahman, O. M. (2021). Sentiment analysis on Twitter tweets about COVID-19 vaccines using NLP and supervised KNN classification algorithm. *Indonesian Journal of Electrical Engineering and Computer Science*, 23(1), 463-470.
- Shim, J. G., Ryu, K. H., Lee, S. H., Cho, E. A., Lee, Y. J., and Ahn, J. H. (2021). Text mining approaches to analyze public sentiment changes regarding COVID-19 vaccines on social media in Korea. *International Journal of Environmental Research and Public Health*, 18(12), 6549.
- Singh, C., Imam, T., Wibowo, S., and Grandhi, S. (2022). A deep learning approach for sentiment analysis of COVID-19 reviews. *Applied Sciences*, 12(8), 3709.
- Stella, M., Vitevitch, M. S., and Botta, F. (2021). Cognitive networks identify the content of English and Italian popular posts about COVID-19 vaccines: Anticipation, logistics, conspiracy and loss of trust. *arXiv preprint arXiv:2103.15909*.

- Stoové, M. A. and Pedrana, A. E. (2014). Making the most of a brave new world: Opportunities and considerations for using Twitter as a public health monitoring tool. *Preventive Medicine*, 63, 109-111.
- Sundheim, B. M. (1995). *Overview of results of the MUC-6 evaluation*. Message Understanding Conference (MUC-6), Columbia, Maryland.
- Sv, P., Tandon, J. and Hinduja, H. (2021). Indian citizen's perspective about side effects of COVID-19 vaccine—A machine learning study. *Diabetes & Metabolic Syndrome: Clinical Research & Reviews*, 15(4), 102172.
- Sv, P., Ittamalla, R., and Deepak, G. (2021). Analyzing the attitude of Indian citizens towards COVID-19 vaccine—A text analytics study. *Diabetes & Metabolic Syndrome: Clinical Research & Reviews*, 15(2), 595-599.
- Thiébaud, R. and Thiessard, F. (2018). Artificial intelligence in public health and epidemiology. *Yearbook of Medical Informatics*, 27(01), 207-210.
- Unger, J. B., Urman, R., Cruz, T. B., Majmundar, A., Barrington-Trimis, J., Pentz, M. A., and McConnell, R. (2018). Talking about tobacco on Twitter is associated with tobacco product use. *Preventive Medicine*, 114, 54-56.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., and Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30.
- Velardi, P., Stilo, G., Tozzi, A. E., and Gesualdo, F. (2014). Twitter mining for fine-grained syndromic surveillance. *Artificial Intelligence in Medicine*, 61(3), 153-163.
- Villavicencio, C., Macrohon, J. J., Inbaraj, X. A., Jeng, J. H., and Hsieh, J. G. (2021). Twitter sentiment analysis towards COVID-19 vaccines in the Philippines using naïve Bayes. *Information*, 12(5), 204.
- Wakamiya, S., Kawai, Y., and Aramaki, E. (2018). Twitter-based influenza detection after flu peak via tweets with indirect information: Text mining study. *JMIR Public Health and Surveillance*, 4(3), e8627.
- Wakamiya, S., Morita, M., Kano, Y., Ohkuma, T., and Aramaki, E. (2019). Tweet classification toward Twitter-based disease surveillance: new data, methods, and evaluations. *Journal of Medical Internet Research*, 21(2), e12783.
- Wang, G. and Kwok, S. W. H. (2021). *Using k-means clustering method with Doc2Vec to understand the Twitter users' opinions on COVID-19 vaccination*. IEEE EMBS International Conference on Biomedical and Health Informatics (BHI), 1-4.
- Wei, J. and Zou, K. (2019). EDA: Easy data augmentation techniques for boosting performance on text classification tasks. *arXiv preprint arXiv:1901.11196*.

- Wiemken, T. L., Furmanek, S. P., Mattingly, W. A., Wright, M. O., Persaud, A. K., Guinn, B. E., Carrico, R. M., Arnold, F. W., Ramirez, J. A. (2018). Methods for computational disease surveillance in infection prevention and control: Statistical process control versus Twitter's anomaly and breakout detection algorithms. *American Journal of Infection Control*, 46(2), 124-132.
- Winslow, C. E. (1920). The untilled fields of public health. *Science*, 51(1306), 23-33.
- Xia, L., Wang, G. A., and Fan, W. (2017). *A deep learning based named entity recognition approach for adverse drug events identification and extraction in health social media*. Smart Health: International Conference (ICSH), Hong Kong, China, 237-248.
- Xiang, R., Chersoni, E., Lu, Q., Huang, C. R., Li, W., and Long, Y. (2021). Lexical data augmentation for sentiment analysis. *Journal of the Association for Information Science and Technology*, 72(11), 1432-1447.
- Xu, H., Liu, R., Luo, Z., Xu, M., and Wang, B. (2021). *COVID-19 vaccine sensing: Sentiment analysis from Twitter data*. IEEE International Conference on Systems, Man, and Cybernetics (SMC), 3200-3205.
- Xue, J., Chen, J., Hu, R., Chen, C., Zheng, C., Su, Y., and Zhu, T. (2020). Twitter discussions and emotions about the COVID-19 pandemic: Machine learning approach. *Journal of Medical Internet Research*, 22(11), e20550.
- Yan, C., Law, M., Nguyen, S., Cheung, J., and Kong, J. (2021). Comparing public sentiment toward COVID-19 vaccines across Canadian cities: analysis of comments on Reddit. *Journal of Medical Internet Research*, 23(9), e32685.
- Yao, Z. J., Bi, J., and Chen, Y. X. (2018). Applying deep learning to individual and community health monitoring data: A survey. *International Journal of Automation and Computing*, 15, 643-655.
- Ye, J., Hai, J., Wang, Z., Wei, C., and Song, A. J. (2022). Leveraging natural language processing and geospatial time series model to analyze COVID-19 vaccination sentiment dynamics from Tweets. *medRxiv*, 2022-08.
- Yin, H., Song, X., Yang, S., and Li, J. (2022). Sentiment analysis and topic modeling for COVID-19 vaccine discussions. *World Wide Web*, 25(3), 1067-1083.
- Yousefinaghani, S., Dara, R., Mubareka, S., Papadopoulos, A., and Sharif, S. (2021). An analysis of COVID-19 vaccine sentiments and opinions on Twitter. *International Journal of Infectious Diseases*, 108, 256-262.
- Zhang, B., Ding, D., and Jing, L. (2022). How would stance detection techniques evolve after the launch of ChatGPT?. arXiv preprint arXiv:2212.14548.
- Zhang, Y., Lyu, H., Liu, Y., Zhang, X., Wang, Y., and Luo, J. (2021). Monitoring depression trends on Twitter during the COVID-19 pandemic: Observational study. *JMIR Infodemiology*, 1(1), e26769.

- Zhang, S., Qiu, L., Chen, F., Zhang, W., Yu, Y., and Elhadad, N. (2017). *We make choices we think are going to save us: Debate and stance identification for online breast cancer CAM discussions*. International Conference on World Wide Web Companion, 1073-1081.
- Zhang, L., Wang, S., and Liu, B. (2018). Deep learning for sentiment analysis: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(4), e1253.
- Zhao, L., Chen, J., Chen, F., Wang, W., Lu, C. T., and Ramakrishnan, N. (2015). *Simnest: Social media nested epidemic simulation via online semi-supervised deep learning*. IEEE International Conference on Data Mining, 639-648.
- Zhou, L., Zhang, D., Yang, C. C., and Wang, Y. (2018). Harnessing social media for health information management. *Electronic Commerce Research and Applications*, 27, 139-151.
- Zhu, L., Fang, Z., Pergola, G., Procter, R., and He, Y. (2022). Disentangled learning of stance and aspect topics for vaccine attitude detection in social media. *arXiv preprint arXiv:2205.03296*.
- Zulfiker, M. S., Kabir, N., Biswas, A. A., Zulfiker, S., and Uddin, M. S. (2022). Analyzing the public sentiment on COVID-19 vaccination in social media: Bangladesh context. *Array*, 15, 100204.



Gazili olmak ayrıcalıktır