

T.C.

ALTINBAŞ ÜNİVERSİTESİ

Lisansüstü Eğitim Enstitüsü

Elektrik ve Bilgisayar Mühendisliği

COVİD-19 SÜRECİNDE KULLANILAN YAPAY ZEKA TEKNİKLERİ

Mustafa ÖNAL

Yüksek Lisans Tezi

Danışman

Dr. Öğr. Üyesi Oğuz KARAN

İstanbul, 2022

COVİD-19 SÜRECİNDE KULLANILAN YAPAY ZEKA TEKNİKLERİ

Mustafa ÖNAL

Elektrik ve Bilgisayar Mühendisliği

Yüksek Lisans Tezi

ALTINBAŞ ÜNİVERSİTESİ

2022

Mustafa ÖNAL tarafından hazırlanmış ve 27.02.2022 tarihinde sunulmuş COVİD-19 SÜRECİNDE KULLANILAN YAPAY ZEKA TEKNİKLERİ başlıklı tez Elektrik ve Bilgisayar Mühendisliği Anabilim Dalında Yüksek Lisans Tezi olarak **oy birliği** ile kabul edilmiştir.

_____

Dr. Öğr. Üyesi Oğuz KARAN

Danışman

Tez Savunma Sınavı Jüri Üyeleri:

Dr. Öğr. Üyesi Oğuz KARAN	Mühendislik ve Mimarlık Fakültesi Altınbaş Üniversitesi	_____
Dr. Öğr. Üyesi Sefer KURNAZ	Mühendislik ve Mimarlık Fakültesi, Altınbaş Üniversitesi	_____
Dr. Öğr. Üyesi Serdar KARGIN	Mühendislik ve Mimarlık Fakültesi, Beykent Üniversitesi	_____

Bu tezin Yüksek Lisans tezi olarak bütün şartları sağladığını beyan ederim.

Tezin Lisansüstü Eğitim Enstitüsüne teslim tarihi: ____/____/____

Bu tezdeki tüm bilgilerin akademik kurallara ve etik davranışlara uygun olarak edinildiğini ve sunulduğunu beyan ederim. Ayrıca, bu kuralların ve davranışların gerektirdiği şekilde, bu çalışmada, orijinal olmayan tüm materyalleri ve sonuçları tamamen alıntı yaptığımı ve referans gösterdiğimi de beyan ederim.

Mustafa ÖNAL

İmzası

İTHAF

Bu tez çalışmamı desteklerinden dolayı Dr. Öğr. Üyesi Oğuz KARAN ithaf ediyorum.

ÖNSÖZ

Bu tez çalışmamda desteklerinden dolayı Dr. Öğr. Üyesi Oğuz KARAN hocama teşekkürlerimi sunarım.

ÖZET

COVİD-19 SÜRECİNDE KULLANILAN YAPAY ZEKA TEKNİKLERİ

ÖNAL, Mustafa

Yüksek Lisans Projesi, Elektrik ve Bilgisayar Mühendisliği, Altınbaş Üniversitesi

Danışman: Dr. Öğr. Üyesi Oğuz KARAN

Tarih: Mart/2022

Sayfa: 75

Günümüzde sağlık hizmeti sunumu, yeni hastalıklarla mücadele etmek için Yapay Zeka (AI), Nesnelerin İnterneti (IoT), Büyük Veri ve Makine Öğrenimi gibi yeni teknolojiler kullanılmaktadır. Yapay zekanın, COVID-19 (Koronavirüs) ve diğer pandemileri analiz etmek, önlemeye ve bunlarla mücadeleye hazırlamak için belirleyici bir teknoloji olarak rolünü gözlemlemek bu çalışmanın amacıdır.

Sağlık kuruluşları, bu virüsün üstesinden gelmek ve yayılmasını önlemek için gerçek zamanlı olarak uygun önerileri almalarına yardımcı olmak için karar verme teknolojilerine acil ihtiyaç duymaktadır. Yapay zeka, insan zekasını taklit etmek için yetkin bir şekilde çalışır. Ayrıca COVID-19 için bir aşının geliştirilmesini anlamada ve önermede hayati bir rol oynayabilir. Bu sonuç odaklı teknoloji, mevcut hastaların ve muhtemel gelecekteki hastaların uygun şekilde taranması, analiz edilmesi, öngörülmesi ve izlenmesi için kullanılır. Önemli uygulamalar, teyit edilmiş, kurtarılmış ve ölüm vakalarının takip verilerine uygulanır. Yapay zeka sayesinde tüm dünyadaki doktorlar, sağlık personeli, bilim adamları, araştırma laboratuvarları gibidir.

Anahtar Kelimeler: Yapay Zeka, Covid 19, Nesnelerin İnterneti, Büyük Veri.

ABSTRACT

ARTIFICIAL INTELLIGENCE (AI) APPLICATIONS USED IN THE COVID-19 PROCESS

ÖNAL, Mustafa

Master Thesis, Electrical and Computer Engineering, Altınbaş University,

Supervisor: Ass. Prof. Dr. Oğuz KARAN

Date: March/2022

Pages: 75

Today, healthcare is leveraging new technologies like Artificial Intelligence (AI), Internet of Things (IoT), Big Data, and machine learning to fight new diseases. The aim of this study is to observe the role of Artificial Intelligence as a crucial technology for the analysis, prevention and control of COVID-19 (Coronavirus) and other pandemics.

Health organizations urgently need decision technology that will help them receive appropriate recommendations in real time on how to fight this virus and prevent it from spreading. Artificial intelligence works competently to mimic human intelligence. It can also play an important role in understanding and recommending developing a vaccine for COVID-19. This results-oriented technology is used to adequately screen, analyze, predict, and monitor current patients and potential future patients. Critical uses apply to follow-up dates from confirmed, recovered, and deaths. Thanks to artificial intelligence, it is like doctors, health workers, scientists, research laboratories all over the world.

Keywords: Artificial Intelligence, Covid 19, Internet of Things, Big Data.

İÇİNDEKİLER

Sayfa

ÖZET ..... **vii**
ABSTRACT ..... **viii**
İÇİNDEKİLER ..... **ix**
ŞEKİL LİSTESİ ..... **xii**
1. GİRİŞ **1**
1.1. ÇALIŞMANIN AMACI 2
1.2. ÇALIŞMANIN ÖNEMİ 3
2. YAPAY ZEKA **7**
2.1. YAPAY ZEKANIN TANIMI VE ÖNEMİ 7
2.2. YAPAY ZEKANIN TARİHSEL GELİŞİMİ 8
2.3. YAPAY ZEKA TEKNOLOJİLERİ VE UYGULAMALARI 11
2.3.1. Makine Öğrenmesi 12
2.3.2. Yapay Sinir Ağları 14
2.3.3. Derin Öğrenme 16
2.3.4. Uzman Sistemler 17
2.3.5. Genetik Algoritmalar 19
2.3.6. Bulanık Mantık 22
3. COVİD-19 PANDEMİSİNDE KULLANILAN YAPAY ZEKA TEKNOLOJİLERİNİN MİMARİSİ **24**
3.1. YOLO VE MASK-RCNN 24
3.1.1. İşlemci 25
3.1.2. Gpu 25
3.1.3. Google Colaboratory 25
3.2. NESNE ALGILAMA 26
3.3. KONVOLÜSYONEL SİNİR AĞLARI (CNN) 27
3.3.1. Evrişim Katmanı 27
3.3.2. Havuz Katmanı 28
3.3.3. Çıktı Katmanı 29
3.4. NESNE ALGILAMA TÜRLERİ 30
3.4.1. İki Aşamalı Dedektörler 30

3.4.1.1. Rcnn dedektörü (bölgesel tabanlı) 30
3.4.1.2. Hızlı r-cnnn 31
3.4.1.3. Daha hızlı r-cnn 32
3.4.1.4. Maske rcnn (bölgesel konvolüsyonel sinir ağı) 33
3.4.2. Tek Kademeli Dedektör 34
3.5. YOLO VE MASKE RCNN UYGULAMASI 36
3.5.1. Yolo ve Mask Rcnn Uygulamasında Kullanılan Kütüphaneler 36
3.5.1.1. Opencvname 36
3.5.1.2. Argparse (komut satırı seçenekleri, bağımsız değişkenler ve alt komut için ayrıştırıcı) 37
3.5.1.3. Numpy (sayısal python) 37
3.5.1.4. İşletim sistemi (çeşitli işletim sistemi arayüzleri) 37
3.5.2. Maske-RCNN Uygulama Adımları 37
3.5.3. Yolo Uygulama Adımları 38
3.6. YOLO'NUN SOSYAL MESAFE DEDEKTÖRÜNE UYGULANMASI 38
3.6.1. Proje yapısı 38
3.6.2. Video Akışında Nesne Algılama 39
3.6.3. Yolo Modelini Yükleme 39
3.6.3.1. Video akışını başlatma 39
3.6.3.2. Giriş çerçevelerini ön işleme alma 39
3.6.3.3. Maksimum olmayan bastırma uygulama 40
3.6.4. Filtrasyon 41
3.6.5. Çift Mesafeyi Hesapla 41
3.6.6. Sonuçların Görselleştirilmesi 41
4. COVİD-19 SÜRECİNDE KULLANILAN YAPAY ZEKA TEKNOLOJİLERİNİN ETKİLERİ 43
4.1. GENEL UYGULAMALAR 43
4.2. SAĞLIK UYGULAMALARI 46
4.2.1. Ses Verileri 47
4.2.2. Diğer Ses Verileri 48
4.2.3. Video 48
4.2.4. Resim 49

4.2.5. Metinsel Veriler 49
4.3. CHATBOTLAR 50
4.4. SENSÖRLER 51
4.5. AI UYGULAMA GELİŞTİRİCİLERİ 51
4.6. KULLANILAN YAPAY ZEKA TEKNİKLERİNİN ANALİZİ 53
4.6.1. Arama Stratejisi 53
4.6.2. Çalışma Seçimi (Dahil Etme ve Hariç Tutma Kriterleri) 53
4.6.3. Çalışma Uygunluğu ve Kalite Değerlendirmesi 54
SONUÇ **61**
REFERANSLAR **63**

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1: Makine Öğrenmesinin Genel Süreci 12

Şekil 2.2: Organik Sinir Ağı ve Yapay Sinir Ağı 15

Şekil 2.3: Uzman Sistemlerin Genel İşleyiş Yapısı 18

Şekil 2.4: Genetik Algoritmaların Genel Süreci 21

Şekil 2.5: Bulanık Mantık Sisteminin Genel Yapısı 22

Şekil 3.1: CPU Bileşenleri 25

Şekil 3.2: Nesne Algılama Görüntüsü 26

Şekil 3.3: CNN Mimarisi 27

Şekil 3.4: Görüntü Matrisine (3X3) Filtre Uygulanması 28

Şekil 3.5: Convolved Özelliğinin Üretilmesinin İlk Bölümü 28

Şekil 3.6: Maksimum Havuzlama 29

Şekil 3.7: R-CNN Mimarisi 31

Şekil 3.8: Hızlı R-CNN Mimarisi 31

Şekil 3.9: Daha Hızlı R-Cnn Modeli 33

Şekil 3.10: Maske RCNN Yapısı 34

Şekil 3.11: Yolo Mimarisi 35

Şekil 3.12: Sınırlayıcı Kutu Tanımlayıcıları 35

1. GİRİŞ

Dünya, Çin'in Wuhan kentinde yeni 2019 Koronavirüsünün (COVID-19) ortaya çıkmasından bu yana değişti, küresel olarak yayıldıkça dünya çapında 180 ülkeye ulaştı [1]. Bu virüsle başa çıkmak için, güçlü bir teknoloji sektörü, büyük ölçüde yapay zeka, veri bilimi ve pveemiyi izlemek ve mücadele etmek için diğer teknolojiler gerekmiştir. Buna göre, teknoloji girişimlerinin tümü, dünyadaki klinisyenler, akademisyenler ve devlet kurumları ile ilgili sağlık sistemlerinin ayrılmaz bir parçası haline geliyor ve daha birçok ülkede yayılma arttıkça teknolojileri harekete geçiriyor.

Ciddi hastalık olasılığı kişiden kişiye değişmekle birlikte, COVID-19 herkesi enfekte edebilir. Herkesin enfeksiyonun yayılmasını sınırlamak ve kendilerini, ailelerini ve toplumunu korumak için oynayacağı bir rol vardır. COVID-19'un yayılmasını engellemeye yönelik düzenli önlemleri takip etmenin yanı sıra, virüse maruz kalmayı önlemek ve toplumlarda patlak vermesini geciktirmek için en güçlü stratejilerden biri, insanlar arasında sosyal uzaklık olarak bilinen yeterli alan yaratmaktır.

Sosyal veya fiziksel mesafeyi korumak için hem iç hem de dış mekanlarda aynı haneden olmayan diğer insanlardan yaklaşık 2 kol uzunluğu bırakmak, bir yüz maskesi takmak, yüze dokunmaktan kaçınmak ve en az 20 saniye boyunca su ve sabunla sık sık el yıkamak gibi virüsün yayılma risklerini azaltmak için günlük önleyici tedbirlerle el ele gelir. COVID-19 esas olarak enfekte bireylerle uzun süreler boyunca yakın temas halinde olan bireyler arasında yayılmaktadır. Soğuk algınlığı, hapşırma veya görüşmeler ve damlacıklar ağız ya da burun hava ve düşmek yakındaki o ağız veya burun üzerine çıktığında genellikle, İletim oluşur. Ayrıca damlacıklar akciğerlere solunabilir.

Son araştırmalar, enfeksiyondan sonra asemptomatik olan kişilerin COVID-19'un yayılmasında rol oynama ihtimalinin daha yüksek olduğunu göstermektedir. Bireylerin virüs bulaştığını fark etmeden önce virüsü bulaşma olasılığı yüksek olduğundan, belirtileriniz olmasa bile sizden ve diğerlerinden en az 6 metre uzakta kalmak önemlidir. Güneş ışığı, nem ve yüzey tipi gibi faktörlere bağlı olarak, COVID-19 bir yüzeyde saatlerce veya günlerce yaşayacaktır. Virüsün üzerinde bulunduğu bir yüzeye veya nesneye dokunarak ve sonra ağzınıza, burnunuza veya gözlerinize dokunarak, bir kişinin COVID-19 alması mümkün olabilmektedir. Sosyal mesafe, ev dışında kirli yüzeyler ve bulaşıcı bireylerle temas etme şansını azaltma eğilimindedir.

1.1. ÇALIŞMANIN AMACI

Virüsten bireysel olarak korunma yollarının yanında toplu yaşamın içerisinde korunmanın zorluğu yapay zeka uygulamalarını da gündeme getirmiştir. Örneğin Türkiye'de de oluşturulan yapay zeka yazılımları ile kameralar artık iş yerindeki çalışanlarla okul öğrencileri arasındaki sosyal mesafeyi takip edebilmekte, yakın temas halinde olanları tanımakta ve bildirim gönderebilmektedir [2].

Kalabalık yerlerde belli bir mesafeyi korumayan kişiler bilgisayar görüşü kullanılarak tespit edilebilir. İhlal Edenlere karşı harekete geçmek için kullanılabilecek bir video kaydı sistem tarafından korunur. İki veya daha fazla kişi yakın temas halindeyse, kamerayla yakalanırsa, bölgedeki insanları uyaran bir alarm ve insanlardan mesafelerini korumalarını isteyebilecek ilgili yetkililere veya gardiyanlara AI uyarıları gönderilir. Canlı Sayım Entegrasyon Eklentileri; alışveriş merkezleri ve süpermarketler gibi kalabalık alanların, bireylerin sosyal mesafeyi takip edebilmeleri için web sitelerinde veya uygulamalarında bireylerin canlı sayısını göstermek için bir eklenti içermesi gerekir. Mağaza web sitesinde kalabalık tahmini analizlerini görecek ve müşterilerin ücretsiz alma yuvasını ayırmalarına yardımcı olacaktır. Ayrıca, metro istasyonları, bireyleri ve ilgili yetkilileri uyararak, sosyal uzaklaşma AI uygulamasının COVID-19 riskini en aza indirmeye yardımcı olacağı en kalabalık alanlar olarak kabul edilir. Metro istasyonlarında inşa edilen kameralar, AI'nın insanların hareketlerini izleme ve kimsenin sosyal mesafelerini koruyup korumadığını bulma yeteneğini kullanacaklardır [3].

Yapay zeka, bölgelerdeki salgınları tanımlamayı, görüntüleme yoluyla virüsün teşhisine yardımcı olmayı ve sağlık taleplerini işleyerek hastalar ve sağlık personeli arasındaki yüz yüze teması en aza indirmeyi öğrenebilir.

Bu çalışmanın amacı, makine öğrenimini ve COVID-19 salgınına karşı mücadelede yapay zekanın rolünü analiz ederek, bu uygulamalardan bazılarını ve bunların gerçek hayattaki etkinliğini tartışmaktadır. Ayrıca, makine öğreniminin ve bilgisayar temelli çerçevenin bir açıklamasını ve uygulanmasını sağlayarak COVID-19 yayılımının azaltılmasını desteklemeye çalışmaktır.

Çalışma iki aşamada odaklanmaktadır. Daha hızlı modeli belirlemek için iki nesne algılama modeli arasındaki karşılaştırma. Karşılaştırma sonucuna göre insan algılama modülü ve sosyal mesafe dedektörü modülünün oluşturulması.

1.2. ÇALIŞMANIN ÖNEMİ

Gerçekle başa çıkmak için, bilgisayarlı programlanmış bir sistem önemlidir, böylece halkın bir pveeminin ortasında günlük operasyonlara devam etmesine izin verilir. Sosyal mesafe, halk sağlığına uyum için çok önemli bir önlemdir ve insan kalabalığı makul bir mesafe olmadan hareket etmektedir.

Tanıma ve tanımlama için, sosyal mesafeyi insanlar takip ederse, kameraların sosyal mesafeyi kontrol etmelerini sağlar. İşyerlerinde eğitimden üretime, ulaşımdan turizme kadar her alvea sadece işyeri sosyal mesafesinin korunması değil, sosyal mesafe düzenlemeleri de büyük önem taşımaktadır. Yazılım şirketleri artık insanların mesafesini ve yoğunluğunu ölçmek için yapay zeka teknolojilerini kullanıyor. Dünya Sağlık Örgütü'ne (WHO) göre en az, insanlar arasındaki 1 metrelik mesafe korunmalı ve bu mesafeyi takip etmek için teknolojiyi kullanmak mümkün [4].

Üç boyutlu kameralar ve ışın sensörleri kullanılarak Sensormatic'in kurduğu "Yoğunluk Ölçüm Çözümü" kapsamında yoğunluk artarsa alanlardaki yoğunluk oranı kolayca hesaplanır ve girdiler sınırlveırılır. Çözüm ayrıca, giriş noktalarına yerleştirilen ekranlar aracılığıyla, bir alanın içinde kaç kişinin bulunduğu, kaç kişinin gireceği ve en uygun yoğunluğa ulaşıldığında yeniden giriş için beklenecek süre hakkında görsel ve işitsel bilgiler sunar.

Ürün İnceleme Öğrenme ve Optimizasyon Aracı, imalat sektöründe yapay zeka tabanlı görüntü işleme ile kalite yönetim yaklaşımı olarak süreci hızlveırmaktadır. Başka bir deyişle, tekerleklerin çıkışta çalışmasını sağlarken maliyeti düşürür. Proses üretim şirketlerinin yapay zekaya dayalı görüntü işleme sistemleri geliştirmelerini sağlayan Hizmet Olarak Yazılım (SaaS) için bir üretim ve kalite yönetimi çözümüdür. Şirketler, üretim maliyetlerini en aza indirmek için herhangi bir yazılım veya kodlama bilgisine sahip olmadan üretim süreçlerini ProcessEye Studio ile optimize edebilir, kalite yönetim süreçlerini geliştirebilir ve sistemlerine dahil edebilirler.

Bilgisayar Görüşü ile birlikte, Sosyal Uzaklık Uyarı Sistemi, insanların belirli bir mesafede olup olmadıklarını ve sosyal mesafeye bağlı olup olmadıklarını belirlemek için mevcut İnternet Protokolü (IP) kameraları ve Kapalı Devre Televizyon (CCTV) kameraları kullanır. Sosyal mesafe uyarı sistemi platformu, bireylerin sosyal mesafeye uyup uymadığını test etmek için mevcut ıp kameraları kullanır. Sosyal mesafenin bilgisayarla görme yöntemi,

kameranın algıladığı iki kişi arasındaki mesafeyi bulur. Platform uyarılar üretir ve herhangi birinin düzenlemeleri ihlal ettiği tespit edilirse uyarmak için harici bir alarm (hoparlör aracılığıyla) çağrılır.

Mask-RCNN, Faster-RCNN dedektörünün bir sonraki sürümüdür. Özellik eşlemelerini giriş görüntüsünden çıkarmak için RESNET101 mimarisini kullanır. Sosyal uzaklık modülü bu adımları uygulanır: video akışı tespit insanlar, filtre sınıfı bireysel algılamaları, her iki ağırlık merkezi sınırlayıcı kutuları bu mesafe eşik aykırı olan, set mesafe eşik, kontrol arasındaki öklid uzaklığı hesaplamak tespit için bir merkez ve bir sınırlayıcı kutu almak. Kalabalık yerlerde belli bir mesafeyi korumayan kişiler bilgisayar görüşü kullanılarak tespit edilecektir. İhlal Edenlere karşı harekete geçmek için kullanılabilecek bir video kaydı, gösterge tablosunda sistem tarafından tutulur [5].

Bildirimler ve alarmlar Kamerada iki veya daha fazla kişi birbiriyle yakın temas halinde olduğunda, o bölgedeki bireyler uyarılır ve AI bildirimleri, bireylerden mesafelerini korumalarını isteyebilecek konumda olan ilgili yetkililere veya gardiyanlara gönderilir.

COVID-19 pveemisi insanları çeşitli şekillerde etkilemekte ve küresel çapta yayılmaya devam etmektedir. Aşı geliştirme çalışmaları devam etmekte olup, teşhis ve tedavide Tıp ve Biyolojinin geleneksel yöntemleri uygulanmaktadır. 10 Kasım 2020 itibariyle iyileşen vakaların başarı öyküleri olsa da, COVID-19 için onaylanmış tedaviler ve aşılar yoktur. Pveemi yayılmaya devam ederken, mevcut önlemler önleme, gözetim ve sınırlamaya dayanmaktadır. Bunun ışığında, COVID-19 ile mücadele için ortaya çıkan teknolojiler kaçınılmaz hale geliyor. Jeo-uzamsal teknoloji, yapay zeka (AI), büyük veri, teletıp, blok zinciri, 5G teknolojisi, akıllı uygulamalar, Tıbbi Nesnelerin İnterneti (IoMT), robotik ve eklemeli üretim gibi gelişen teknolojiler, COVID-19'un tespiti, izlenmesi ve teşhisi için büyük önem taşımaktadır. , tarama, gözetleme, haritalama, izleme ve farkındalık yaratmadır [6].

Bu nedenle, bu çalışma, özelliklere, zorluklara ve ikamet edilen ülkeye vurgu yaparak COVID-19 ile mücadele için bu teknolojilerin kapsamlı bir incelemesini sağlamayı amaçladı. Sonuçlarımız, yeterli COVID-19 veri kümesinin bulunmaması, mevcut veri kümelerinin bazılarındaki tutarsızlık, zıt veri biçimi, eksik veriler ve gürültü nedeniyle veri kümesinin toplanmaması nedeniyle ortaya çıkan teknolojilerin performansının henüz istikrarlı olmadığını göstermektedir. Ayrıca, kişilerin sağlık bilgilerinin güvenliği ve

mahremiyeti tam olarak garanti edilmez. Bu nedenle, mevcut teknolojileri güçlendirmek için daha fazla araştırmaya ihtiyaç vardır ve COVID-19'un erken ayırıcı tanısı için sağlam, hesaplamalı olarak akıllı bir modelin ortaya çıkmasına güçlü bir ihtiyaç vardır. ve farkındalık yaratmak. Bu nedenle, bu çalışma, özelliklere, zorluklara ve ikamet edilen ülkeye vurgu yaparak COVID-19 ile mücadele için bu teknolojilerin kapsamlı bir incelemesini sağlamayı amaçladı. Sonuçlarımız, yeterli COVID-19 veri kümesinin bulunmaması, mevcut veri kümelerinin bazılarındaki tutarsızlık, zıt veri biçimi, eksik veriler ve gürültü nedeniyle veri kümesinin toplanmaması nedeniyle ortaya çıkan teknolojilerin performansının henüz istikrarlı olmadığını göstermektedir [7].

Ayrıca, kişilerin sağlık bilgilerinin güvenliği ve mahremiyeti tam olarak garanti edilmez. Bu nedenle, mevcut teknolojileri güçlendirmek için daha fazla araştırmaya ihtiyaç vardır ve COVID-19'un erken ayırıcı tanısı için sağlam, hesaplamalı olarak akıllı bir modelin ortaya çıkmasına güçlü bir ihtiyaç vardır. ve farkındalık yaratmak. Bu nedenle, bu çalışma, özelliklere, zorluklara ve ikamet edilen ülkeye vurgu yaparak COVID-19 ile mücadele için bu teknolojilerin kapsamlı bir incelemesini sağlamayı amaçladı. Sonuçlarımız, yeterli COVID-19 veri kümesinin bulunmaması, mevcut veri kümelerinin bazılarındaki tutarsızlık, zıt veri biçimi, eksik veriler ve gürültü nedeniyle veri kümesinin toplanmaması nedeniyle ortaya çıkan teknolojilerin performansının henüz istikrarlı olmadığını göstermektedir. Ayrıca, kişilerin sağlık bilgilerinin güvenliği ve mahremiyeti tam olarak garanti edilmez. Bu nedenle, mevcut teknolojileri güçlendirmek için daha fazla araştırmaya ihtiyaç vardır ve COVID-19'un erken ayırıcı tanısı için sağlam, hesaplamalı olarak akıllı bir modelin ortaya çıkmasına güçlü bir ihtiyaç vardır. Bu çalışma, özelliklere, zorluklara ve ikamet edilen ülkeye vurgu yaparak COVID-19 ile mücadele için bu teknolojilerin kapsamlı bir incelemesini sağlamayı amaçlamıştır. Sonuçlarımız, yeterli COVID-19 veri kümesinin bulunmaması, mevcut veri kümelerinin bazılarındaki tutarsızlık, zıt veri biçimi, eksik veriler ve gürültü nedeniyle veri kümesinin toplanmaması nedeniyle ortaya çıkan teknolojilerin performansının henüz istikrarlı olmadığını göstermektedir. Ayrıca, kişilerin sağlık bilgilerinin güvenliği ve mahremiyeti tam olarak garanti edilmez [8].

Bu nedenle, mevcut teknolojileri güçlendirmek için daha fazla araştırmaya ihtiyaç vardır ve COVID-19'un erken ayırıcı tanısı için sağlam, hesaplamalı olarak akıllı bir modelin ortaya çıkmasına güçlü bir ihtiyaç vardır. Bu çalışma, özelliklere, zorluklara ve ikamet edilen ülkeye vurgu yaparak COVID-19 ile mücadele için bu teknolojilerin kapsamlı bir

incelemesini sağlamayı amaçlamıştır. Sonuçlarımız, yeterli COVID-19 veri setinin bulunmaması, mevcut veri setlerinin bazılarındaki tutarsızlık, zıt veri formatı, eksik veriler ve gürültü nedeniyle veri setinin toplanmaması nedeniyle ortaya çıkan teknolojilerin performansının henüz istikrarlı olmadığını göstermektedir. Ayrıca, kişilerin sağlık bilgilerinin güvenliği ve mahremiyeti tam olarak garanti edilmez. Bu nedenle, mevcut teknolojileri güçlendirmek için daha fazla araştırmaya ihtiyaç vardır ve COVID-19'un erken ayırıcı tanısı için sağlam, hesaplamalı olarak akıllı bir modelin ortaya çıkmasına güçlü bir ihtiyaç vardır. Sonuçlarımız, yeterli COVID-19 veri setinin bulunmaması, mevcut veri setlerinin bazılarındaki tutarsızlık, zıt veri formatı, eksik veriler ve gürültü nedeniyle veri setinin toplanmaması nedeniyle ortaya çıkan teknolojilerin performansının henüz istikrarlı olmadığını göstermektedir. Ayrıca, kişilerin sağlık bilgilerinin güvenliği ve mahremiyeti tam olarak garanti edilmez. Bu nedenle, mevcut teknolojileri güçlendirmek için daha fazla araştırmaya ihtiyaç vardır ve COVID-19'un erken ayırıcı tanısı için sağlam, hesaplamalı olarak akıllı bir modelin ortaya çıkmasına güçlü bir ihtiyaç vardır. Sonuçlarımız, yeterli COVID-19 veri kümesinin bulunmaması, mevcut veri kümelerinin bazılarındaki tutarsızlık, zıt veri biçimi, eksik veriler ve gürültü nedeniyle veri kümesinin toplanmaması nedeniyle ortaya çıkan teknolojilerin performansının henüz istikrarlı olmadığını göstermektedir [9].

Ayrıca, kişilerin sağlık bilgilerinin güvenliği ve mahremiyeti tam olarak garanti edilmez. Bu nedenle, mevcut teknolojileri güçlendirmek için daha fazla araştırmaya ihtiyaç vardır ve COVID-19'un erken ayırıcı tanısı için sağlam, hesaplamalı olarak akıllı bir modelin ortaya çıkmasına güçlü bir ihtiyaç vardır. İnsanların sağlık bilgilerinin güvenliği ve gizliliği tamamen garanti edilmez. Bu nedenle, mevcut teknolojileri güçlendirmek için daha fazla araştırmaya ihtiyaç vardır ve COVID-19'un erken ayırıcı tanısı için sağlam, hesaplamalı olarak akıllı bir modelin ortaya çıkmasına güçlü bir ihtiyaç vardır.

2. YAPAY ZEKA

2.1. YAPAY ZEKANIN TANIMI VE ÖNEMİ

Yapay zekanın, herkesin hemfikir olduğu bir tanımı bulunmamaktadır. Bu yüzden yapay zekâ çok boyutlu kabul edilmeli, bileşenlerin entegrasyonu ve sinerjisi dikkate alınmalıdır [10]. Teoride ve pratikte verimli olması, herhangi bir hedefe yönelik olması gibi faktörler yapay zekâ için genel bir tanıma tabi tutulmasından çok daha önemlidir [11]. Alan Mathison Turing'in "Computing Machinery ve Intelligence" yani "Bilgi işlem makineleri ve Zekâ" makalesindeki makinelerin düşünebilmesi ihtimaline yönelik soru ile gündeme gelen yapay zekâ kavramı, 1956 yılında Dartmouth çalıştayında John McCarthy tarafından ilk kez terim olarak kullanılmıştır. 1950'lere dayanan yapay zekâ kavramı, makine öğrenimiyle bilgisayarın gerçek dünya ile etkileşimlerini sürekli analiz etme yeteneğine dayanmaktadır [11].

Sürekli güncellenen yapay zekâ, çevresinden etkilenerek ve kendi başına öğrenme ile ortamdaki değişiklikleri algılayarak adapte olabilen sistemlerdir. Makinelerin mevcut girdi verilerini kullanarak çıkarımlar yapması, kendi tecrübelerinden öğrenmesi ve elde ettiği çıktılarla karar verme yetisine sahip olması yapay zekâ olarak adlveırılmaktadır. Makinelerin etkin öğrenimi sadece topladığı verilerle çıkarımlar yapabilmesine değil, dolaylı öğrenme yeteneği ile kendi başına öğrenmesiyle mümkündür. Bu sayede insan gibi hareket etmesi söz konusu olabilmektedir [12].

Yapay zeka, görsel algılama, konuşma tanıma, dil tanıma, karar verme gibi insan zekası gerektiren işlevleri yerine getirebilen bilgisayar sistemlerinin gelişmiş halidir. Rasyonel bir etmen olan, algıladığı ortama etki eden yapay zekâ sistemleri "tahmin, karar ve eylem" döngüsü içinde hareket etmektedir. Teknolojinin itici gücü olarak kabul edilen yapay zekâ, insansı tepkiler verebilen akıllı programlama sistemleri olarak da tanımlanabilmektedir. Yapay zeka, bilgisayar veya bilgisayar destekli bir makineye programlama ile derinleştirilmiş bilgiyle, akıl yürütmeye, problem çözmeye, öğrenme ve planlama yani insana özgü davranış özelliklerini somutlaştırılmasına denilmektedir. Lakin yapay zeka insan beyninin tüm işlevlerini yerine getirememekte, kendini anlama, özdenetim, öz bilinç gibi beyin işlevleriyle iş birliği yapamamaktadır [13].

Girdi verilerini kullanarak çıkarım yapabilen algoritmalar oluşturularak, bilinmeyene dair tahminlerde bulunulmasına olanak tanıyan paradigmalara makine öğrenmesi denilmektedir.

Sahip olunan veriler arasında ilişki kurulmasıyla gerçekleşebilen makine öğrenmesinde, insan beyninden alınan ilham ile ortaya konan yapay sinir ağları sayesinde büyük veriler ilişkilendirilebilmekte ve çeşitli katmanlara sahip derin öğrenme gerçekleştirilebilmektedir. Derin öğrenme algoritmaları, yüksek miktardaki veri kaynaklarına veri tabanlarından veri madenciliği ile ulaşmaktadır [14]. İlk zamanlarda geniş bağlamın farkında olmayan yalnızca yaptığına odaklanan yapay zekâ sistemlerinin, geniş bağlamda farkındalığa sahip, adaptasyon sağlayabilen sistemler haline gelmesi uzun ve kapsamlı bir süreç dâhilinde gerçekleşmiştir.

Tutarlı davranış gösteren yapay zekâ teknolojileri, insanlar gibi değişkenlik göstermemekte ve süreç içerisinde topladığı bilgiler ışığında analiz yaptıktan sonra davranışı gerçekleştirerek kullanıcılar için oldukça önemli hale gelmiştir. Tarım alanından, hukuk, müzik, bankacılık, sağlık gibi birçok farklı alvea yapay zekâ teknolojileri ve uygulamaları yaygın olarak kullanılır hale gelmiştir. Kişilerin hayatındaki karmaşık problemleri sembolik, matematiksel, algoritmik bir dizi işlevle kısa sürede çözüme kavuşturabilen yapay zekâ; insan beyninin işlevlerini, insana kıyasla çok daha az maliyet ile yerine getirebilen sistemlerdir. Büyük verileri işleyerek elde ettiği bilgileri insan zekasının yansıması olarak işleyen yapay zeka, işletmeler için yeni bir üretim faktörüdür. Karlılığı ve verimliliği arttırmakta, rekabet etmede şirkete etkinlik sağlayarak çeşitli stratejilerde kullanılması önemli hale gelmiştir [15].

2.2. YAPAY ZEKANIN TARİHSEL GELİŞİMİ

Başlangıcı felsefe, kurgu ve hayal gücüne kadar uzanmakta olan yapay zeka

18. Yüzyılda insan zekasının makinelere uyarlanması fikri ve birçok farklı disiplinlerdeki icatlar ile gelişme göstermiştir. 1950 yılında Mind dergisindeki çığır açan “Computing Machinery ve Intelligence” makalesi ile Alan Turing, makale içeriğinde yer verdiği taklit oyunu ile Turing Testini literatüre geçirmiş ve makinelerin düşünebilme ihtimalini gündeme getirerek yapay zeka tarihinde önemli bir yapıtaşı olmuştur (Buchanan, 2006). İlk sinir ağlarına dayalı çalışma prensibiyle “SNARC” 1951 yılında geliştirilmesine rağmen yapay nöron modelinin oluşturulması 1940lı yıllara dayanmaktadır. 1957 yılında Rosenblatt tarafından geliştirilen yapay sinir ağı olan “Perception” ile bu alveaki çalışmalar hızla artmıştır [15].

1956 yılında Dartmouth Çalıştayı ile yapay zeka, John McCarthy tarafından ilk kez kavramsallaştırılmıştır. Yine aynı yıl ilk yapay zeka programı olan Logic Theorist; Newell, Simon ve Shaw tarafından geliştirilmiştir [15]. 1957 yılında Newell ve Simon tarafından tasarlanan bilgi işlemenin gelişmiş hali olan programlama dili LISP, John McCarthy tarafından geliştirilmiştir. 1959'da dama kuralları ve stratejisini başarılı bir şekilde öğrenmek için kural tabanlı sistemleri kullanan algoritmalar ile makine öğrenimi, Arthur Samuel tarafından geliştirilmiş ve "machine learning" yani "makine öğrenimi" terimi IBM Journal 'da yayınlanan sonuçlarda ortaya atılmıştır. Yine aynı yıl gerçek dünya problemlerine uygulanan ilk sinir ağı olan "MADALINE" geliştirilmiştir [16].

1964 yılında Danny Bobrow tarafından geliştirilen "STUDENT" adlı bilgisayar programı ile doğal dil işlemenin temelleri atılmıştır. 1965 yılında geliştirilen ELIZA, doğal dil işleme programlarının en önemlilerinden biridir. Aynı dönemde Lotfi Zadeh "Fuzzy Logic" yani "Bulanık Mantık" fikrini bulmuştur. 1962'de ilk endüstriyel robot şirketi "Unimation" kurulmuştur [16]. 1969 yılına gelindiğinde Papert ve Minsky tartışmaları ve tekabülünde 1971 yılında DARPA'nın finanse ettiği konuşma tanıma sistemi, yapay zeka araştırmacılarının beklentileri karşılamamasından ve vaat edilen sonuçlara ulaşamamasından dolayı yapılan yatırımlar hezeyanla sonuçlanmıştır. Hızla gelişim gösteren ve gittikçe beklentileri arttıran yapay zeka, tüm bunların neticesinde ilk kışını yaşamıştır. 1975 yılında Michigan Üniversitesi profesörü Hollve, 1960'ların ortasında tasarladığı doğal genetik ve doğal seçilim mekaniğine dayanan bilgisayarlı arama ve optimizasyon algoritması "Genetic Algorithms" yani "Genetik Algoritmaları" ufuk açıcı bir çalışma yayınlayarak ortaya koymuştur [16].

1980'de Amerikan Yapay Zeka Derneği (AAAI)'nin, ilk ulusal konferansı Stanford Üniversitesinde yapılarak yapay zeka araştırmaları yeniden gündem olmuştur [17]. 1986 yılında yapay sinir ağlarına Hinton, Rumelhart ve Williams tarafından getirilen yeni yaklaşım ile çok katmanlı yapay sinir ağları "Backpropagation" algoritması (geri yayılım algoritması) ile hata fonksiyonu en aza indirgenmiş ve öğrenme problemine çözüm getirilerek "Deep Learning" yani "Derin Öğrenme" fikrinin temeli atılmıştır [18]. 1980'li yıllarda; 1970'lerde Feigenbaum ve arkadaşları tarafından geliştirilen ilk büyük boyuttaki uzman sistem MYCIN gibi uzman sistemler ticari olarak kullanılmaya başlanmıştır. 1980'den 1987'ye kadar, şirketler tarafından benimsenen uzman sistemler; 1987'de yapay zeka bilgisayar donanımı pazarının çökmesi ve yüksek bakım maliyetleri, güncellemelerinin

zorluğunda etkilenmiş, ikinci yapay zeka kışına girilmesine neden olmuştur. İkinci yapay zeka kışı 1993 yılına kadar sürmüştür [18].

1993 sonrasında ortaya atılan "Intelligent agent" (akıllı ajanlar) kavramı ile uzman sistemlerin başardıklarının ötesinde, insanların kolektif çalışmalarını taklit etmeyi amaçlayan bulanık mantık gibi çeşitli perspektiflerle öğrenerek kararların belirsizliği ile başa çıkabilen yapay zeka teknolojisi gündeme gelmiştir. Makine öğreniminin getirdiği daha yeni ve kapsamlı kaynak ihtiyacını destekleyen "Big Data"nın doğuşu ile görüntü tanıma, konuşma tanıma, doğal dil işleme gibi sistemler birleştirilerek geliştirilmiştir [19]. 1997'de dünya satranç şampiyonu Gary Kasparov'u yenen Deep Blue ile yeniden yükselen yapay zeka, problemlerin boyutlarının artmasına rağmen tatmin edici çözümler sunmaya başlamıştır. 2000 yılında, Breazeal tarafından duyguları tanıyıp, taklit edebilen "Kısmet" adlı robot geliştirilmiştir [20].

2001 yılında yapay zeka; mantık, çıkarım, eylem tekniklerinin bir arada kullanıldığı World Wide Web'de uluslararası bilimsel, kültürel birçok verinin alışverişini gerçekleştirebilecek olan Semantic Web üzerine çalışmalara başlanmıştır. Yeni nesil bir World Wide Web olan Semantic Web minimum çaba ile verilere ulaşımı sağlamaktadır. 2006'da "Derin Öğrenme" derin sinir ağlarıyla modellenerek günümüzdeki haline en yakın hale gelmiştir (Doğan ve Türkoğlu, 2019). 2010 yılında bağımsız bir uygulama olarak piyasaya sürülen, konuşarak etkileşim kurmayı sağlayan sesli asistan "Siri", 2011 yılında iOS'a eklenmiştir [8].

2011'de Jeopardy adlı yarışmada en iyi iki yarışmacıyla rekabet eden "Watson" adlı bilgisayar sistemi galip gelmiştir. 2012 yılında Krizhevsky, Sutskever ve Hinton "Large Scale Visiual Recognition Challenge" (LSVRC) yarışmasının 2010 yılındaki yüksek çözünürlüklü görüntüleri sınıflveırmak için derin sinir ağlarını GPU (grafik işlemci) ile eğitmişlerdir. Bu sayede "Supervised Learning" yani denetimli makine öğrenmesi ile derin öğrenme gerçekleştirilmiştir [12]. 2013'te Microsoft sesli asistan olan Cortana'yı geliştirdi. 2014 yılında da Amazon, Echo bağlantılı ev hoparlörü ile sesli asistan Alexa'yı kullanıma sundu. 2016 da Google kendi asistanını geliştirmiş ve Android tabanlı akıllı telefonlar için uygulamasına yerleştirmiştir [20]. Yine aynı yıl DeepMind'ın Go oyunu için geliştirdiği bilgisayar programı AlphaGo, dünyanın en iyi Go oyuncularından biri olan Lee Sedol'e karşı galibiyet elde etmiştir. 2017'de "Transformer Networks" yani dönüştürücü ağlar adında yeni bir sinir ağı ortaya konmaktayken, 2018'de "BERT" adlı Transformer network tabanlı doğal

dil işleme modeli geliştirilmiştir. 2017 yılının sonlarına gelindiğinde Deep Mind, AlphaZero'nun satranç, Go ve shagi oyunlarında herhangi bir insvean daha iyi oynamayı kendi kendine oynayarak öğrendiğini bildirmiştir [20]. Mantıksal ve matematiksel kodlama işlemleri yapan algoritmalardan verilerden öğrenen makine öğrenmesine, yapay sinir ağlarının kullanıldığı derin öğrenmeden tahmin ve karar işlemlerinin gerçekleşmesini sağlayan teknolojilere kadar her biri bir öncekinden farklı ve gelişmiş olan bu yapay zeka uygulaması ve teknolojileri, günümüzde de gelişmeye ve farklılaşmaya devam etmektedir.

2.3. YAPAY ZEKA TEKNOLOJİLERİ VE UYGULAMALARI

Her geçen gün artan bilgi miktarı, işletmeleri iş ortamında tutunabilmeleri için büyük verileri analiz etmeye yöneltmektedir. Ekonomi ve iş dünyasında yeni yaşam tarzı getiren ve sosyolojik etkiler yaratan yapay zeka teknolojileri ve uygulamaları, iş süreçlerini optimize ederek yeniden yapılveırılmalarını sağlamaktadır [16]. Mevcut bilginin belirli bir karmaşık karaktere sahip olduğu durumlarda hedeflere ulaşma yöntemleriyle ilgilenen yapay zeka, farklı teorik temellere dayanabilmesi ve farklı problemlere uygulanabilmesi için makine öğrenimi, derin öğrenme, uzman sistemler gibi çeşitli alanlardan oluşmaktadır [12].

Yapay zeka teknolojileri, pazarı sürekli değiştirmekte; şirketler için yapay zeka teknolojilerini elde edip kullanmak elzem haline gelmektedir. Fırsatları hızla algılayabilme ve bunlara yanıt verebilmede çevik olan kuruluşlar, uygulanabilirliği sağladıklarında yapay zeka destekli ortamda avantaj elde etmektedir. Maliyetleri azaltma, karlılığı arttırma ve riskleri daha etkin bir şekilde yöneterek minimalize etmeyi sağlayan yapay zeka uygulamaları, işletmelerin hem kendi içlerinde hem rakipleriyle hem de müşterileriyle ilişkilerini düzenlemesinde oldukça önem arz etmektedir [8]. İşletmelerin karar sürecinde belirsiz birçok değişkenle karşılaşması ve zamanın kısıtlı kaynak olması sebebiyle tahminlerde bulunurken yapay zeka uygulamalarından faydalanmaları iş dünyasında doğru kararlar alma konusunda işletmelere oldukça yardımcı olmaktadır. Birçok alvea kullanılan yapay zeka teknolojileri ve uygulamaları sayesinde, makineler sadece topladığı verilerden yeni çıkarımlar yapmakla kalmayıp, öğrenme yeteneğine sahip olarak kendi başına öğrenmeyi gerçekleştirebilmekte ve bilgi tabanı, programcının sağladıklarıyla sınırlı kalmayarak insan gibi düşünüp hareket edebilmektedir [21].

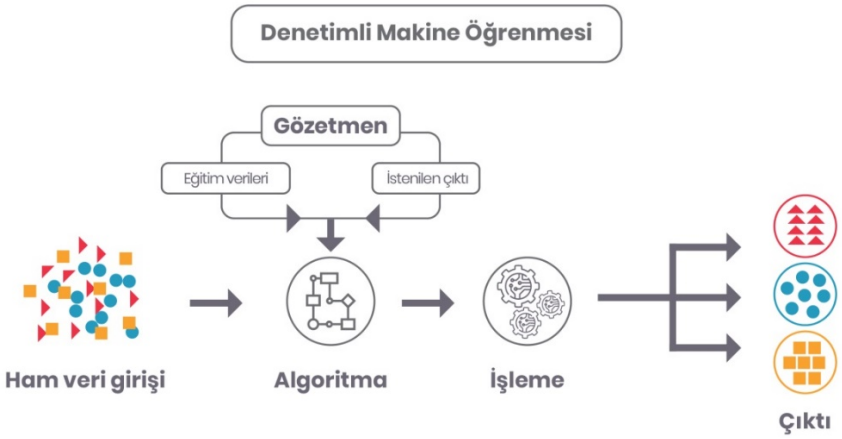
Finans sektöründen, pazarlama sektörüne; ulaşımdan üretime insanın olduğu her alvea yer alan yapay zeka teknolojileri ve uygulamaları, karar verme aşamasında da yer almaktadır.

İnsan zekasını taklit eden uzman sistem, yapay sinir ağları, bulanık mantık ve genetik algoritma gibi uygulamaların birlikte kullanılmasına yumuşak programlama denilmekte [21] ve tek tek değil de bir arada kullanılarak birbirlerinin eksik kaldıkları noktaları tamamlayabilmektedirler.

2.3.1. Makine Öğrenmesi

Karşılaşılan her problemde çözüm için gerekli olan adımları bilgisayarlara önceden vermek yerine, algoritmalar aracılığıyla ne yapacaklarını öğrenmelerini sağlama yöntemine makine öğrenmesi denilmektedir. Makine öğrenme algoritmaları, fazla sayıda içerik kullanarak model oluşturan ve daha sonra karşılaşılabilecek sorunları ön görerek çözüm bulabilen, dinamik yapılardır. Bu algoritmalar, büyük veri giriş ve çıkış setlerini kullanarak kalıpları tanımakta ve karar alma üzerine eğitmektedir. Algoritmaların yeteri kadar tekrarı ve modifikasyonu ile alınan girdilerin sonuçları ve tahminleri karşılaştırılıp, daha sonraki sonuçların tahminlerinde mükemmele yakınlık sağlanmıştır. Metin dosyaları, tablolar, veri tabanları gibi girdilerin seçilen algoritma aracılığıyla yapısal formatta gösterilmesi ve genelleme ile makine öğrenmesi gerçekleşmektedir. Algoritmanın kalitesini tanımlamak için doğruluk, kesinlik gibi çeşitli önlemler geliştirilmekte ve güven aralıkları, stveart sapma gibi istatiksel yöntemler ile doğru bilgi sağlanmaktadır [12].

Şekil 2.1'de görüleceği üzere, eğitim kümesinde yer alan veriler tanımlanan algoritma aracılığıyla eğitilerek modellenmektedir. Daha sonra bu model üzerinden makine öğrenmesi algoritması geliştirilmekte ve giriş kümesindeki veriler bu algoritma ile işlenerek, model tahmini yapılabilmektedir.



Şekil 2.1: Makine Öğrenmesinin Genel Süreci [12].

Makine öğrenimi kısaca, hesaplama yöntemleri ile girilen verilerden bilgi çıktıları elde etme sürecidir. Makine öğrenmesi; karmaşık kalıpları, veriler hakkında tahminlerde bulunulmasını sağlayan modelleme ile öğrenmesinin yanı sıra öğrenilenleri yorumlama yeteneğine de sahiptir. Girdi verilerini, çıktılarıyla ilişkilendirerek algılayabilmesi ve tecrübelere dayanarak düşünce sistemini değiştirebilmesi makine öğrenmesinin öne çıkan özelliklerindendir. Bilgisayar sistemlerinin bir görevde insanın gösterebileceği performansı göstermesi; görev alanlarından bağımsız analiz yapabilmesi, bilişsel süreci simüle edebilmesi ve deneyimlerden öğrenebilmesi makine öğrenimi ile mümkündür [21].

Öğrenme paradigmalarının gelişmesiyle zaman içinde davranışların iyileştirilmesi olarak tanımlanmakta olan makine öğrenmesi, Supervised Learning (Denetimli öğrenme) ve Unsupervised Learning (Denetimsiz öğrenme) olarak iki farklı paradigma üzerine kuruludur. Denetimli öğrenmede, aracı eğitim verileri olan girdi çıktıları etiketlenmekte ve makine bu etiketlerle öğrenmektedir. Denetlenen algoritmalar, eğitim sırasındaki tahminlerin doğruluğunu geri bildirimlerle sağlamaktadır [13].

Önceden tanımlanmış girdiler ve bilinen çıktılar etiketlenerek eğitilmekte, girdi ve çıktı parametreleri arasındaki öğrenilen ilişkiyi temsil etmek için model kullanılmaktadır. Denetimli öğrenme algoritmalarına; K-Nearest Neighbour (K-En yakın komşu), Decision Tree (Karar ağaçları), Bayesian Statistics (Bayes istatistikleri), Support Vector Machines (Destek vektör makineleri) ve Neural Networks (Sinir ağları) örnek verilebilmektedir. K-en yakın komşu yöntemi; yakın veri örneklerinin etiketlerine dayalı olarak veri örneğini sınıflveırmasıdır. Karar ağacı; girilen verileri yineleyerek veri etiketlerini tahmin etmeye yönelik bir sınıflveırma yöntemidir. Sinir ağları; doğrusal olmayan ve karmaşık fonksiyonları tanımak için kullanılan algoritmalardır. Destek vektör makineleri; etiketli eğitim örneklerini kullanarak veri noktalarını sınıflveırmayı öğrenen bir makine öğrenme algoritmasıdır. Bayes istatistikleri; çoğu makine öğrenme algoritmasının aksine nispeten az sayıda eğitim örneği ile çalışan algoritmalardır [21]. Denetimli öğrenmede; çoğunlukla ne öğrenilmesi ve nasıl öğrenilmesi gerektiğine dair talimatlar en baştan net bir şekilde verilmektedir.

Denetimsiz öğrenmede ise aracı açık bir geri bildirim olmadan girdilerden yaptığı çıkarımlarla öğrenmektedir. Çıktı vektörü yoktur ve girdilere etiketler verilmemektedir. Örnek setlerinin arasındaki benzerlik araştırılarak farklı gruplar halinde sınıflveırmak

amaçlanmaktadır. K-Means Clustering (K-ortalama kümeleme) ve Principal Component Analysis (Temel bileşen analizi) denetimsiz öğrenme algoritmalarına örnektir. K-ortalama kümeleme; verilere farklı kümeler tanımlamak için kullanılır. Temel bileşen analizi; veriden önemli bilgileri çıkarmayı amaçlayan ve bir dizi yeni değişken sunarak veri sıkıştırma ve boyutsallığı azaltmak için kullanılan çok değişkenli yöntemdir. Denetimsiz öğrenmede; parametrelere ait girdiler kendi içlerinde değerlendirilmekte ve hedef belirtilmemektedir [22].

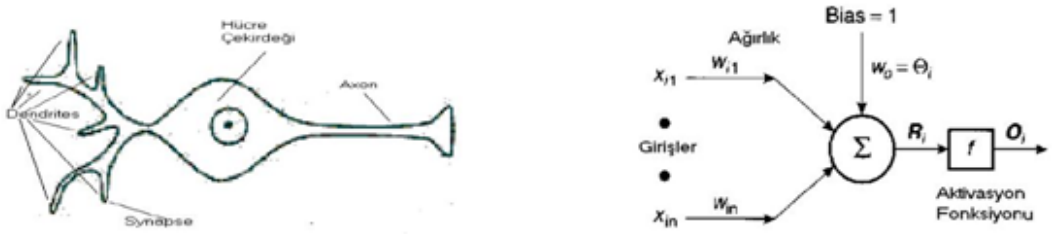
1950'lerin sonunda yapay zeka için bir teknik olarak tanıtılan makine öğrenimi, son zamanlarda konuşma tanıma, bilgisayarla görme gibi uygulamaları sınıflveırma, regresyon ve yoğunluk tahmini dahil çok çeşitli görevler için kullanılmaktadır. Aynı zamvea makine öğrenmesi yöntemleri, değişen girdilere esnek bir şekilde uygulanabilmekte ve iş süreçlerinin esnekliğini attırılabilmekte, performansı sürekli iyileştirmektedir [22]. Makine öğrenmesinde, modellerin şeffaf olmasının ve sık kontrol edilmelerinin gerekliliği dezavantajları olarak görülebilmektedir.

2.3.2. Yapay Sinir Ağları

İnsan beynindeki öğrenmeyi sağlayan sinir hücrelerinden esinlenilerek matematiksel olarak modellenen ve bilgisayar sisteminin benzer bir yaklaşımla makine öğrenimini gerçekleştirmesini sağlayan Artificial Neural Networks (ANN) yani yapay sinir ağlarıdır. Sınıflveırılmış bilgileri sinir algılayıcılarını kullanarak öğrenen, yeni bilgiler üreterek karar verebilen bilgisayar programlarıdır. Yapay sinir ağları (YSA), veriler arasındaki ilişkiyi ortaya çıkarabilme yeteneğiyle öğrenme ve hafızaya alma işlevlerine sahiptir. Örnekler yardımıyla öğrenen yapay sinir ağlarında her bir sinirde bir ağırlık değeri bulunmakta ve sahip oluğu bilgi ağa yayılmaktadır [22].

Beynin sinirsel yapısına dayalı bu elektronik modellerin amacı insan beyninin bir kopyasını oluşturmak değil, insana özgü çözüm üretebilme ve çıkarım yapabilmek için hesaplamalar yapabilme özelliklerini taşıyabilmektir. Yapay sinir ağları, deneyimlerinden öğrenerek, öğrendiği bilgileri genele indirgeyebilir ve yeni sonuçlar çıkarabilmektedir. Hatta yeni edindiği bilginin gereksiz gördüğü kısımlarını çıkararak önemli olan özü yakalayabilmektedir [23].

Şekil 2.2'de yapay sinir ağlarının esinlenmiş olduğu sinir ağlarıyla görsel karşılaştırılmaları sunularak benzerlikleri gösterilmek istenmiştir.



Şekil 2.2: Organik Sinir Ağı ve Yapay Sinir Ağı [23].

Yapay sinir ağlarında; insan beynindeki nöronlar birim olarak adlveırılmaktadır. Çok sayıda birimlerden oluşan bu ağlarda her birim başka birimlere bağlı ve bu bağlantı ile sinyal alışverişi gerçekleşmektedir. Birbirlerine belli ağırlıklarla bağlı olan birimler, dışarıdan gelen bilgileri toplama fonksiyonu ile elde edip, aktivasyon fonksiyonu aracılığıyla çıktıyı üretmekte ve bağlantılar ile diğer birimlere iletmektedir. Birbirlerine paralel olan katmanlarda; girdi katmanından giren bilgi, ara katmvea işlenerek çıktı katmanına ulaşmaktadır. Doğru çıktıya ulaşmak için girdilere doğru ağırlık değeri verilmesi gerekmektedir. Ağa gösterilen her örnek ile pekişen öğrenme kuralları, ağın eğitilmesini sağlamaktadır. Tüm ağa ağırlıklarla dağıtılmış olan, daha sonra ne anlama geldiğine dair açıklamaya gerek duyulan bilgilerin birleştirilmesinde zorluk yaşanması yapay sinir ağlarının bir dezavantajı olarak görülmekte ve kara kutu olarak adlveırılmasına neden olmaktadır [21].

1943'de McCulloch ve Pitts'in elektrik devreleriyle oluşturdukları basit sinir ağı modeliyle çalışan nöronlar üzerine yazdıkları makale ile başlayan yapay sinir ağları serüveni, en eski sinir ağı olan Perceptron'un ortaya çıkışı ile yükselişe geçmiştir. Biyolojik sinir ağlarından esinlenen yapay sinir ağları, çok sayıdaki ara bağlantıya sahip basit işlemcilerden meydana gelen büyük ölçüdeki paralel bilgi işlem sistemleridir. Problem veya süreç hakkında detaylı bilgiye gerek duymadan gürültülü veri setlerinden etkilenmeyerek, doğrusal olmayan çok değişkenli problemleri çözebilen yapay sinir ağları, paralel yapıda olmaları ve donanımlardaki kolay kullanımlarıyla farklı niteliklerdeki problemlerde bile aynı modelleme ile çözüm sağlayabilmektedirler [23].

Yapay sinir ağları, diğer tahmin modellerine kıyasla daha doğru tahminler yapması açısından karar verme ve tahmin etme aracı olarak işletme yönetimlerince kullanılmaktadır. Tahmin, sınıflveırma, veriyi ilişkilendirip yorumlamaya veya filtreleme de kullanılan yapay sinir

ağları; eksik verilerle çalışabilecek şekilde esnek ve hata toleransına sahiptir. Çözümü zor olan birçok problemde kullanılan yapay sinir ağlarının her birinin farklı çözüm sunması, kullanılması gereken problemin çözümünde büyük önem taşımaktadır. Backpropagation network (Geri yayılım ağı), Multi layer perceptron (Çok katmanlı algılayıcı) ve Radial basis function (Radyal bazlı fonksiyon) bazı yapay sinir ağı çeşitlerindendir [11], [24].

Gerçek hayat problemlerinin çözümünde aşırı uzun eğitim ve öğrenme zamanına ihtiyaç duyması, öğrenme aşamasında özelliklerinin sürekli değişmesi, uzun süren tekrarlardan öğrenebiliyor olmaları, hangi yapının hangi problem için kullanılması gerektiğine dair bir bilginin yetersiz olması gerçeği yansıtması konusunda yapay sinir ağlarının zayıf kalmasına neden olmaktadır.

2.3.3. Derin Öğrenme

Makine öğrenmesinin bir parçası olan Deep Learning yani derin öğrenme, derin sinir ağlarıyla bağlantılı veri temsillerinden oluşmaktadır. Farklı katmanlar aracılığıyla bilgiyi düşük seviyeli parametrelerden yüksek seviyeli parametrelere taşımaktadır. Bu farklı seviyeler, öğrenmeye yol açan farklı veri soyutlama seviyelerine karşılık gelmektedir. Derin öğrenme, bir makinenin her katmveaki temsili, önceki katmveaki temsilden hesaplamaktadır. Bu hesaplama için kullanılan parametreleri nasıl değiştirmesi gerektiğini belirlemek için geri yayılım algoritmasını kullanmakta ve büyük veri kümelerindeki karmaşık yapıyı keşfetmektedir [24].

Yapay sinir ağlarının daha fazla birim ve katman ile çalışan versiyonu olan derin öğrenme, birden fazla işlem katmanı bulunan hesaplama modellerini kapsamaktadır. Üst üste bulunan farklı katmanlar ile veriyi temsil etmekte, ham verilerden öğrenerek büyük veri kümelerini entegre ederek, öznitelik kümelerine ulaşmaktadır. Temsil öğrenimi, bir makinenin ham verilerle beslenerek algılamasına veya sınıflveırma için gereken temsilleri otomatik olarak keşfetmesine imkan tanıyan yöntemler dizisidir. Derin öğrenme, her bir temsili ham girdiden başlayarak daha yüksek ve daha soyut bir düzeyde temsile dönüştüren, basit ve doğrusal olmayan modüller oluşturarak elde edilen, birden çok temsil düzeyine sahip temsil-öğrenme yöntemlerine denilmektedir [24].

Birçok işlemi bir arada yürütebilen derin öğrenme, ön işlemi ve katmanlar arasındaki hiyerarşik yapıyla ağ içinde istenen yapıya ait özelliklerin belirlendiği özellik çıkarımını otomatik olarak gerçekleştirmektedir. Hopfield ve Rumelhart tarafından popülerlik

kazveırılan derin öğrenme, daha evvel saklanan ya da kullanılmış olan bilgilerin yeni deneyimlerde kullanılmasını sağlamaktadır. Derin öğrenme modelleri doğrudan verilerden öğrendiğinden eğitmek için çok sayıda veriye ihtiyaç duyulmamaktadır. Yüksek boyutlu verilerdeki karmaşık yapıları keşfetmede çok iyi olan, sinir ağları aracılığıyla konuşma ve görme fonksiyonları içeren lakin bunlarla sınırlı kalmayan derin öğrenme, Natural Language Process yani doğal dil işleme, Speech yani konuşma, Vision yani bilgisayarlı görü, bilgi erişimi, çoklu öğrenme gibi çeşitli uygulama alanları içinde farklı amaçlar için kullanılmaktadır [7], [13], [24].

2.3.4. Uzman Sistemler

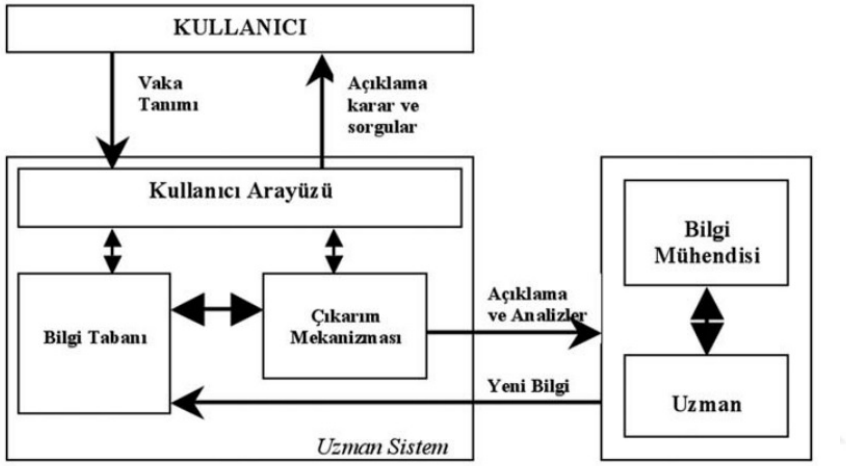
Sınırlı problem karşısında ilgili alveaki uzman kişi gibi davranarak, kapsamlı bilgiye sahip olma ve görevleri gerçekleştirebilme özelliklerini yapay zeka algoritmaları aracılığıyla çözüm üretebilme amacıyla bilgisayar programlarına entegre edebilen sistemlere Expert Systems, yani uzman sistemler denilmektedir. İnsan muhakemesine yakın sonuçlar sunan uzman sistemler, birer karar elemanı olarak kullanılabildikleri gibi karmaşık problemlerde karar destek elemanı olarak da kullanılabilmekte ve öneri sunabilmektedirler [25].

Edward Feigenbaum tarafından geliştirilen program, karar mekanizmalarına benzer bir süreci taklit etmesiyle ilk uzman sistem olarak nitelendirilmektedir. Yazılım algoritmasına gömülü olan uzman kabiliyetleri, yeni yargılar ve tavsiyeler oluşturmak için uzman sistemler tarafından kullanılmaktadır. Uzman sistemler, bilgi tabanına daha evvelden aktarılıp, saklanan uzman bilgi ve tecrübelerini kullanarak insan karar verme sürecine benzer bir şekilde problemlere çözüm getirmektedirler. Uzman olmayan kişilerce kullanılan uzman sistemler; destekleyici nitelik taşırken, uzmanlar tarafından kullanıldığında kararları pekiştirici nitelik taşımaktadır [25].

İnsanın karar verme yeteneğine benzemeye çalışarak karmaşık problemleri bilgi tabanından yararlanarak çözen uzman sistemler, bir çeşit muhakeme sistemleridir. Problem çözümünde hiyerarşik bir yaklaşım izleyen uzman sistemler, farklı noktalardan gelen düşük seviyeli bilgileri birleştirerek mevcut uzmanlık bilgisini çoğaltmaktadır. Veri tabanı ve kurallardan oluşan bilgi tabanı, gerçekleşen duruma ait bilgilerin alındığı haberleşme aracı olan kullanıcı ara birimi ve bilginin işlendiği çıkarım mekanizması uzman sistemlerin temel bileşenlerini meydana getirmektedir. Bilgi tabanında saklı olan bütün uzmanlık alanı bilgileri çıkarım

mekanizması ile filtrelenerek, yorumlanmakta ve sonuç elde edilmektedir. Sonuç kullanıcı ara birimi vasıtasıyla kullanıcıya ulaştırılmaktadır [21].

Şekil 2.3'de uzman sistemlerin çalışma prensibi görselleştirilerek; bir uzman veya bilgi mühendisinden alınan yeni bilginin uzman sistem aracılığıyla bilgi tabanına aktarılması burada kullanıcıdan gelen vaka tanımına uygun çıkarımlar yaparak açıklama ve analizlerle bunları teyit ederek kullanıcı arayüzü ile kullanıcıya kararı açıklaması gösterilmektedir. Genel işleyişi özetleyen bu görsel ile uzman sistemlerin çalışma sistemi daha net anlaşılabilmektedir.



Şekil 2.3: Uzman Sistemlerin Genel İşleyiş Yapısı [25].

Gerekli bilgiyi biriktirmeye çalışması ile kapsamını sınırlveıran uzman sistemler, akıllı karar verme programları olarak birçok alvea kullanılmaktadır. Uzman sistemler iyi geliştirildiklerinde, konusunda uzman olan kişilerin işlevlerini yerine getirerek; planlama ve tasarım yaparak yorumlayabilir, özetleyerek genelleme yapabilir ve kontrol ederek tavsiyelerde bulunabilir hale gelmektedit. Sistem karmaşıklığı arttıkça talep edilen bilgi işlem kaynağı artmakta ve bu da sistemi yavaşlatmaktadır [25]. Bunun önüne geçebilmek adına geliştirilmesi ve sürdürülmesi gereken uzman sistemlerin maliyeti yüksektir. Uzman sistemlerin; girdi verileri ile kuralları tam olarak eşleştirme zorunluluğu, muhakeme durumunu hassas hale getirmektedir. Uzman kişilerin yerine geçen bu sistem, problemlerin doğru ve hızlı bir şekilde çözülmesini amaçlayarak çalışma verimliliğini ve alınan kararların kalitesini arttırmaktadır [26].

Uzman sistemlerin; mantıksal neden-sonuç ilişkisine dayanması, güvenilir bilgi ve öneri sunması, belirsiz veri ve kurallarla çalışabilmesi güçlü yönlerini ifade ederken, bilgi edinmenin zorluğu, öğrenerek kendilerini yenileyemiyor olmaları ve geliştirmenin maliyetinin yüksek olması zayıf yönleri olarak sayılabilmektedir.

2.3.5. Genetik Algoritmalar

Doğal evrimsel süreçten esinlenerek, karmaşık çok boyutlu arama uzayında seçim ve çaprazlama yöntemleriyle çalışan Genetic Algorithms, yani genetik algoritma, arama uzayında yeni noktalar yaratan ana kütle tabanlı sezgisel optimizasyon yöntemi olup, en iyinin hayatta kalmasına dayanarak en iyi çözümü arama yöntemidir [26].

Bir problemin olabilecek farklı çözümlerinden en iyi sonucu verenin bulunmasına optimizasyon denilmektedir. Geleneksel optimizasyon yöntemlerinden farklı olan genetik algoritmalar, değişkenlerin kodlanmasıyla çalışmakta ve aynı vea birkaç tasarımı, rastgele operatörlerle arama alanına uygulayabilecek şekilde iyileştirerek işleyebilmektedir. Çözüm için tek bir yapı yerine birçok yapıdan meydana gelen kümeler oluşturmakta ve bu olası pek çok çözümü temsil eden kümeler nüfus yani popülasyon olarak nitelendirilmektedir [27].

1970'li yıllarda ortaya çıkan genetik algoritmalar, doğal evrim prensibini yani daha uyumlu canlıların ve onların genlerinin hayatta kalmasını simüle ederek, Darwin'in evrim teorisini bilgisayar ortamına aktaran bir arama ve optimizasyon tekniği olup rastgele hipotezler, çaprazlama, mutasyon işlemleriyle en başarılı hipotezlerin seçilip, veriyi en iyi açıklayan kuralları bulmayı sağlamaktadır [27].

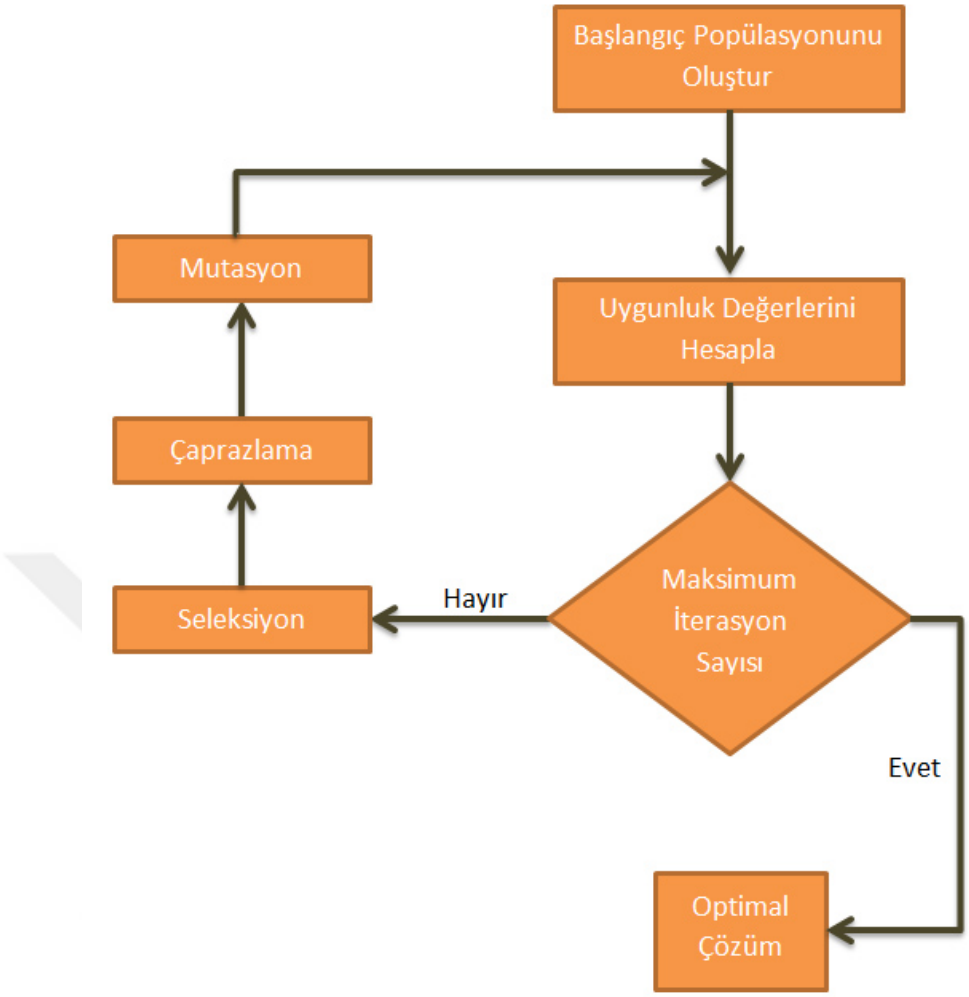
Yapay zeka tabanlı arama yöntemi olan genetik algoritmalar, ilk kez John Hollve tarafından geliştirilmiştir. Olasılıksal karakterlere ve çoklu mümkün çözümlerini araştırabiliyor olması genetik algoritmaların en önemli iki özelliğidir. Çözüm uzayının tamamını değil de belirli bir kısmını tarayarak etkin arama yapan genetik algoritmalar, kısa sürede çözüme ulaşıp çözümlerden oluşan popülasyonu aynı vea inceleyerek yerel en iyi çözümlere takılmadan globale ulaşabilmektedir [28].

Genetik algoritmalarda, her çözüm bir kromozoma karşılık gelirken her parametre bir geni temsil etmektedir. Problemi sonuca ulaştırmak için doğal seçim fonksiyonu olan çaprazlama ve mutasyon kullanan genetik algoritmalar, her çözümün uygunluğu için seçtiği uygunluk fonksiyonlarını değerlendirerek seçim yapmaktadır. Bu seçim; 0-1 aralığında oluşturulan başlangıç popülasyonu rastgele tüm çözümlerin alt kümesinden oluşmakta ve rastgele

oluşturulan, her biri bir kromozoma eş kodlanan bireyler, 0 ya da 1'e yuvarlanarak uygunluk fonksiyonuna göre değerlendirilmekte ve bu değerlendirme sonrasında amaç fonksiyonundan geçirilerek iyi olup olmadıkları tespit edilmektedir. Belirlenen çözümlerin uygunluğu, uygunluk fonksiyonunda ölçülerek, her problem için ayrı uygunluk fonksiyonları belirlenmektedir [13], [28].

Her nesilde en iyi çözümlerin korunup, bir sonraki nesle aktarılmasıyla tüm popülasyonu nesilden nesile daha iyi hale getiren seçim yöntemiyle genetik algoritmalar güvenilir hale gelmektedir. Eşleşme sürecinde çaprazlanarak yapılan gen takası sırasında mutasyon yöntemi ile kromozomun bir elemanı değiştirilerek aramanın yönü değiştirilmekte ve arama kolaylaştırılmaktadır. Mutasyon işleminde popülasyondaki bireylerin çeşitliliği korunmakta ve kromozomlardaki genler rastgele değiştirilerek global optimuma doğru ilerlenmektedir. Seçim fonksiyondan sonra çaprazlama fonksiyonuyla daha önce hiç denenmemiş iki yeni çözüm üretildikten sonra mutasyon fonksiyonu ile son bulan bu süreç yeni bir popülasyona kadar sürekli tekrarlanmaktadır. Seçim fonksiyonunda; en iyi çözüme yaşama şansı tanıyan ekilmiş seçim, elde edilen çözümlerden rastgele seçim yapan rastgele seçim ve sürekli en iyi çözümü kuşaktan kuşağa aktaran seçkin seçim olmak üzere üç fonksiyon bulunmaktadır [29].

Şekil 2.4'de genetik algoritmaların işleyiş süreci gösterilmektedir. İlk popülasyonun oluşturulması ile başlayan süreç, uyum değerinin hesaplanmasıyla devam etmektedir. Eğer oluşturulan popülasyon, uyum değerine bakılarak uygunluk fonksiyonunu sağlıyorsa süreç sonlanmaktadır. Sağlamıyorsa sırasıyla çoğalma işlemi, çaprazlama işlemi ve mutasyon işlemi uygulanarak yeni bir nesil oluşturulmaktadır. Bu yeni nesil, yeni popülasyonu oluşturmakta ve süreç bu sefer yeni popülasyon için işlemektedir.



Şekil 2.4: Genetik Algoritmaların Genel Süreci [29].

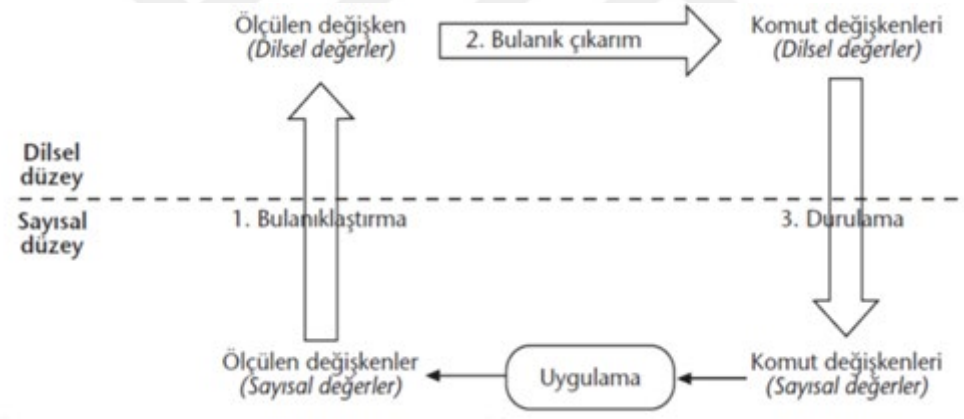
Genetik algoritmalar rastgele başlangıç çözümlerinin birbirleriyle eşleştirilmesiyle karmaşık optimizasyon problemlerinde yüksek performanslı çözümler üretilebilmektedir. Uygulveıkları problemlerde çözümü istenen parametreler yerine onları temsilen kullanılan kodlar ile problemlerin çözümü kolaylaştırılmıştır. Probleme özgü parametrelerin seçiminde kullanılan genetik algoritmalar yerel optimuma karşı dirençli olup öznel karar vermeyi sağlayan güçlü bir yöntemdir [29].

Yapılveırmanın basit olmaması, probleme ilişkin bilgilerin yönetilmesinin zorluğu ve ne zaman durulacağının tam olarak bilinememesi genetik algoritmaların bazı dezavantajlarıdır (Özçalıcı ve Ayrıçay, 2016). Genetik algoritmalar, finans, üretim, pazarlama gibi alanlarda çizelgeleme, tesis yerleşim, montaj hattı dengeleme, atama, taşıma, sistem güvenirliği, araç rotalama gibi problemlerin çözümünde kullanılmaktadır [29].

2.3.6. Bulanık Mantık

Bulanık mantık, günlük hayatta kullanılan her zaman net olmayan, belirsizlik içeren ifadelerin yani bulanık terimlerin, bilgisayar ortamına aktarılarak insan ve makineyi birbirine daha çok yakınlaştırmıştır. İlk kez 1965'lerin ortalarında Berkeley üniversitesi profesörlerinden Lotfi A. Zadeh tarafından ortaya konulan bulanık mantık, belirsiz veya kısmı belirsiz kavramlarıyla başa çıkabilmek adına geliştirilmiş, Aristoteles'in iki değerli mantık önermesine karşılık ortaya konan çok değerli mantık çalışmalarıdır [30].

Gerçek dünya varyasyonlarını hesaba katan bulanık mantık, öğrenilmiş modellerin yorumlana bilirliğini arttırmak adına yapısal unsurlarla sınırlı kalmayarak belirsizlik sayılan verilerle gözlem yöntemiyle çalışabilecek bir çerçeve ortaya koymaktadır. Şekil 2.5. ile sözcüksel ifadelerin bulanık çıkarımla birer değişken olarak kabul edilmesi ve sayısal değerlerin uygulanmasıyla bulanıklaştırılmasını yani bulanık mantık sisteminin genel yapısını görselleştirmektedir.



Şekil 2.5: Bulanık Mantık Sisteminin Genel Yapısı [30].

Bulanık mantık nitelendirmelerin kesin olmadan hükümler olarak kural tabanında kullanılmasına olanak tanımaktadır. İnsana ait olan sözel verilerin 0 ve 1 gibi, doğru ve yanlış, siyah ve beyaz gibi mutlak değerleri olmayıp, net sınırları yoktur. Karmaşık durumlarda yetersiz bilginin kişilerin değer ve görüşleri ile kullanılması; kavrayış, muhakeme ve karar aşamalarında bulanık mantık ile mümkündür. Bu önermelerin varlığını kabul edip, bunları bulanık küme teorisine dayveırarak kullanıcıların bulanık bilgiyi (çok doğru, az çok doğru, gri vb.) ifade etmelerini sağlayan bulanık mantık, kendi başına öğrenme yeteneği sağlayamamaktadır [30].

Bir olayın oluşunun kesinliğini belirleyen, olma olasılığındaki belirsizliğin sayısal ölçüsü rasgelelik iken, olayın ne derece olduğunu ölçen ve sözel olan belirsizliklere bulanıklık denilmektedir. Doğrusal olmayan denetimle insan düşünce ve karar mekanizmasına benzer şekilde bulanık ortamda önerme ve kural yürütme işlemlerinin yapılmasına olanak tanıyan bulanık mantık, makinelerin insan gibi karar vermesini sağlamaktadır [31].

3. COVİD-19 PANDEMİSİNDE KULLANILAN YAPAY ZEKA TEKNOLOJİLERİNİN MİMARİSİ

Bu çalışma, nesneleri tespit etmede daha hızlı modülün kim olduğunu belirlemek için Gerçek Zamanlı Nesne Algılama (YOLO) ve Maske Bölgesel tabanlı konvolüsyonel sinir ağı (Mask-RCNN) nesne dedektörlerini uygular. YOLO, farklı nesne türlerini tek bir çerçevede diğer algılama sistemlerine göre daha güvenilir bir şekilde ayırt edebilen, hızlı işleyen bir nesne algılama sistemidir [32].

Kayıtlara göre, 9000 sınıfa kadar tahmin edilebilir. YOLO, CNN'den (konvolüsyonel sinir ağı) tek bir mimariye dayanmaktadır. CNN bir görüntüyü bölgelere ayırır ve her bölge için sınırlayıcı kutusunu ve olasılıklarını belirler. Yolov4'te, EfficientDet (YOLOV3 CNN geliştirme), Retinanet'ten çok daha hızlı olan Cspdarknet53'ü (öğrenme kapasitesini artırmak için CNN geliştirme) kullanır. YOLO, geleneksel bir grafik işlem birimi (GPU) ile kullanılabildiğinden, geniş kullanım, Saniyede daha hızlı Kare (FPS) ve daha fazla hassasiyet sağlar. Mask-RCNN nesne algılama ve görüntü segmentasyon modelidir ve örnekleri iki aşamada algılar. Birinci aşama bölgesel teklifleri oluşturur, ikinci aşama ise sınırlayıcı kutuları kullanarak girdi görüntüsündeki her teklifteki sınıfları algılar ve sınıflveırır ve aynı vea her nesne için bir segmentasyon maskesi oluşturur. Yani, sadece nesne algılama için kullanılan ama aynı zamvea bölümleme nesne değildir.

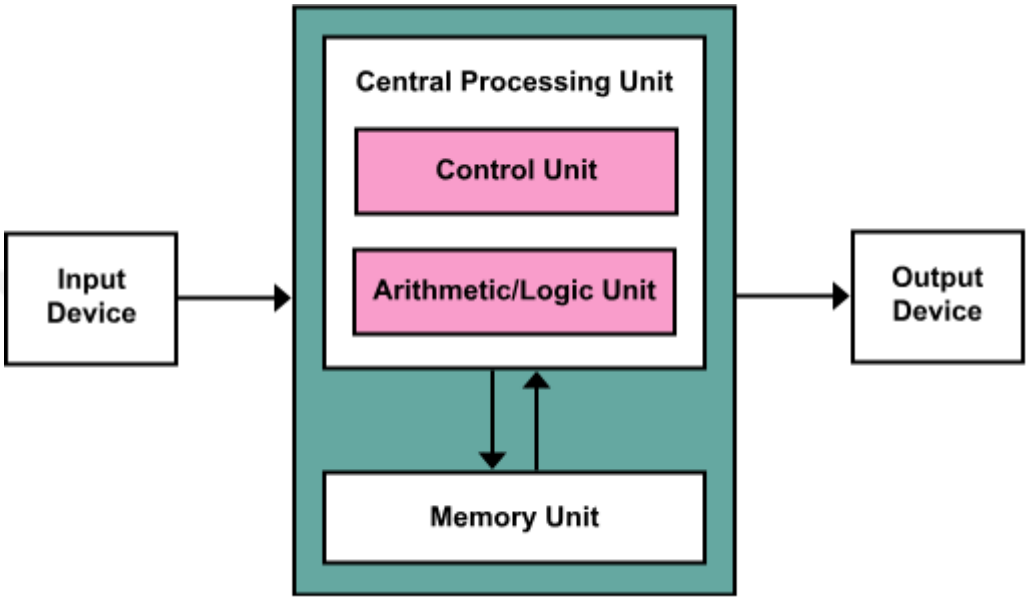
3.1.YOLO VE MASK-RCNN

COCO veri kümesi üzerinde önceden eğitilmiş olan YOLO ve Mask-RCNN dedektörleri, nesne tespitinin hızlanma yüzdesini göstermek için hem CPU hem de GPU üzerinde karşılaştırılacaktır. Daha sonra bir sonraki aşamada, sosyal mesafe dedektörünün yapımında en iyi model kullanılacaktır [32].

Bilgisayarla görme ve görüntü işleme uygulamalarının ortaya çıkmasıyla birlikte, daha doğru ve daha hızlı nesne algılama tekniklerine duyulan ihtiyaç önemli ölçüde artmıştır. Çünkü bu teknikler sadece nesneleri algılayıp sınıflveırmakla kalmaz, aynı zamvea görüntüde yerelleştirerek görevi daha karmaşık hale getirir. Ve bu zorlu görevi başarmak için, grafik işlem biriminin paralel işlem yeteneğinin avantajı, merkezi olanın yanında alınmalıdır.

3.1.1. İşlemci

CPU, merkezi işlem birimini ifade eder. Bilgisayarın kalbidir ve bilgisayarın yazılım ve donanımından alınan tüm talimatları (kontrol, aritmetik / mantıksal, giriş / çıkış (G / Ç) işlemleri) işler ve birçok farklı hesaplama türünü seri olarak işler. Bu nedenle genel hesaplamalarda kullanılmaktadır.



Şekil 3.1: CPU Bileşenleri [32].

3.1.2. Gpu

GPU, grafik işlem birimini ifade eder. Oyun, bilgisayar, içerik oluşturma ve makine öğrenimi dünyasına yeni fırsatlar sunan özel bir donanımdır. GPU, karmaşık hesaplamaları aynı vea yürütülebilen daha küçük bağımsız hesaplamalara bölerek modelleri hızlveırmak ve bunları paralel işlemlere dönüştürmek için kullanılır. Büyük miktarda hesaplama yeteneğine sahiptir, bu nedenle GPU'nun son derece paralel özelliğinden yararlanan iş yüklerinde yüksek hızlanma sağlayabilir.

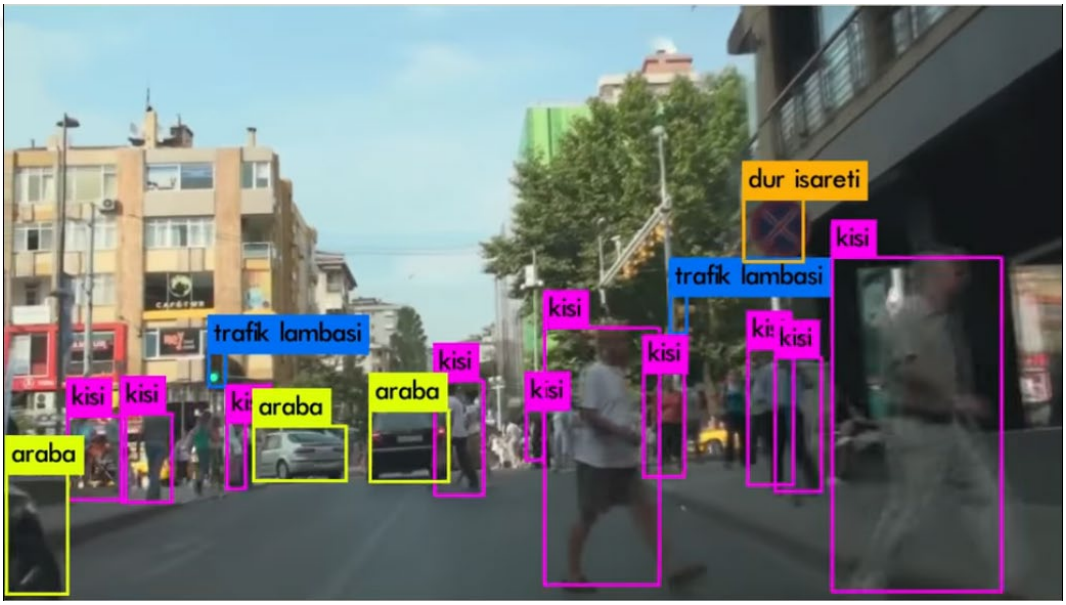
3.1.3. Google Colaboratory

Günümüzde makine öğrenimi uygulamaları, büyük veri kümelerini kullanan karmaşık hesaplamalara dayanmaktadır. Google Colaboratory, GPU'ları ve diğer bilgi işlem kaynaklarını özgürce destekleyen bir bulut hizmetidir, bu nedenle bu hizmetten yararlanarak kullanıcı Python kodlama becerilerini geliştirebilir ve derin öğrenme uygulamalarını kolayca

geliştirebilir. Ayrıca, makine öğrenimi ve veri analizi eğitimi ve araştırmasını da teşvik eder [33].

3.2.NESNE ALGILAMA

Nesne algılama, anlamsal görüntü / çerçeve anlayışı elde etmek için kullanılan bilgisayar görme tekniklerinden biridir. Bilgisayarların bir görüntü veya video akışındaki örnekleri algılama, sınıflveırma ve bulma yeteneğini ifade eder. Nesne sınıflarını (bisiklet, köpek, kamyon vb.) tanımlar ve Şekil 3.2'de gösterildiği gibi (sınırlayıcı kutular) olarak nesnelerin etrafına dikdörtgenler çizerek onları bulur [33].



Şekil 3.2: Nesne Algılama Görüntüsü [33].

Nesne algılama genellikle birçok alt görevden oluşur, örneğin:

i. Yüz algılama
ii. Yaya algılama
iii. İskelet tespiti

Nesne algılama, kendi kendini süren araçlarda, gözetleme, görüntü, poz tahmini, yüz tanıma ve daha pek çok alvea kullanılır [33].

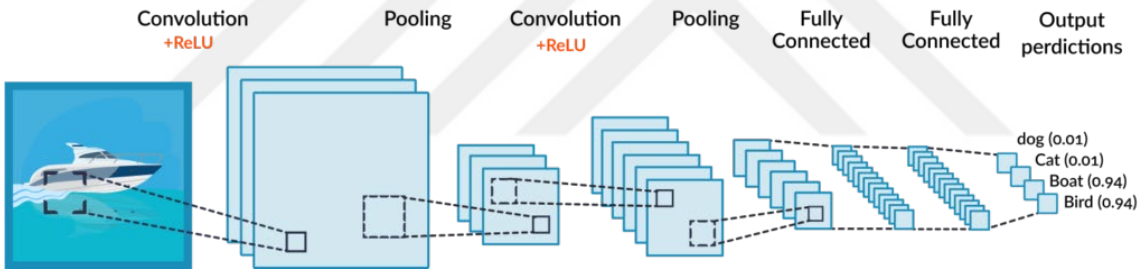
Geleneksel nesne algılama modelleri boru hattı öncelikle bu aşamalara ayrılabilir:

i. Bilgilendirici bölgesel seçim.
ii. Özellik çıkarma.
iii. Sınıflveırma.

3.3. KONVOLÜSYONEL SİNİR AĞLARI (CNN)

CNN, hem görüntüleri hem de videoları işleyen Sinir Ağı gibi derin bir öğrenme ağıdır. Sınıflveırma ve nesne tespitinde ana rolü oynar. Birden çok katmvean oluşur Sınıflveırma işlemi, girdi görüntüsü konvolüsyonel ağa iletildiğinde başlar ve daha sonra nihai çıktıyı sınıf biçiminde elde etmek için birçok konvolüsyonel ve havuzlama katmanından gönderilir.

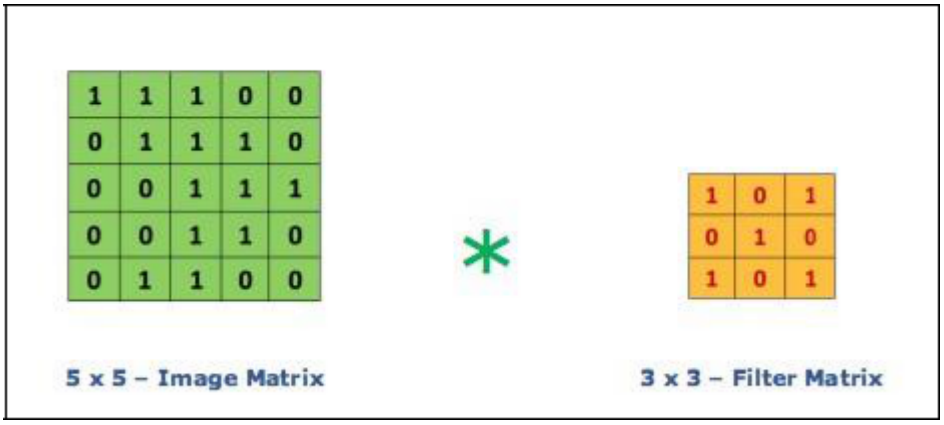
İlk başta, CNN giriş görüntüsünü / çerçevesini alır ve ağırlık matrisini tanımlar. Daha sonra giriş görüntüsü toplanacak ve mekansal düzenlemesini herhangi bir kayıp olmadan tutmayı göz önünde bulundurarak özellikler ondan çıkarılacaktır.



Şekil 3.3: CNN Mimarisi [34].

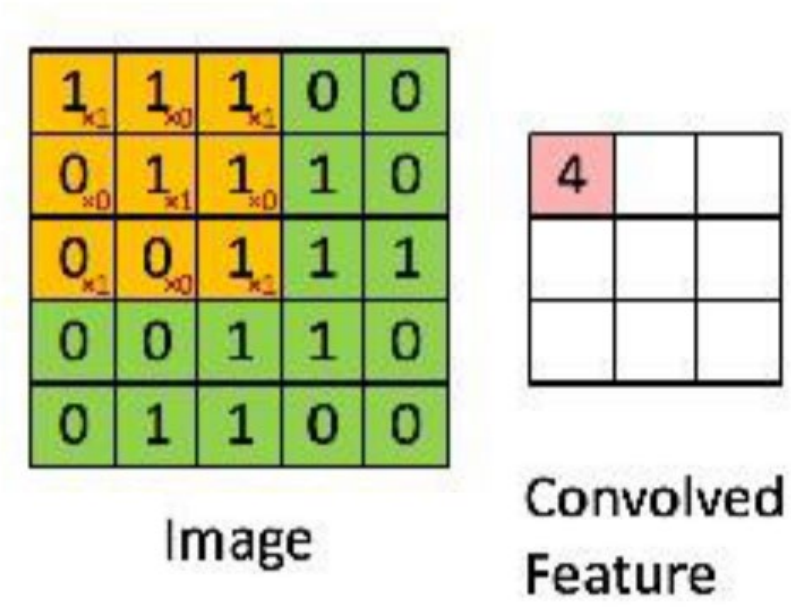
3.3.1. Evrişim Katmanı

Bu katmvea, giriş görüntüsünden (köşegen / yatay kenarlar) olduğu gibi özellikleri ve belirli bilgileri çıkarmak için bir filtre olarak bir ağırlık matrisi kullanılır. Bu filtre, her pikselin en az bir kez kaplanması ve sonuç olarak konvolved bir çıktı vermesi için giriş görüntüsünün üzerinde çalışacaktır. Örneğin bir (5X5) giriş görüntüsü ve aşağıdaki Şekil 3.4'da gösterildiği gibi (3X3)'ün bir filtresi (Çekirdeği):



Şekil 3.4: Görüntü Matrisine (3X3) Filtre Uygulanması [35].

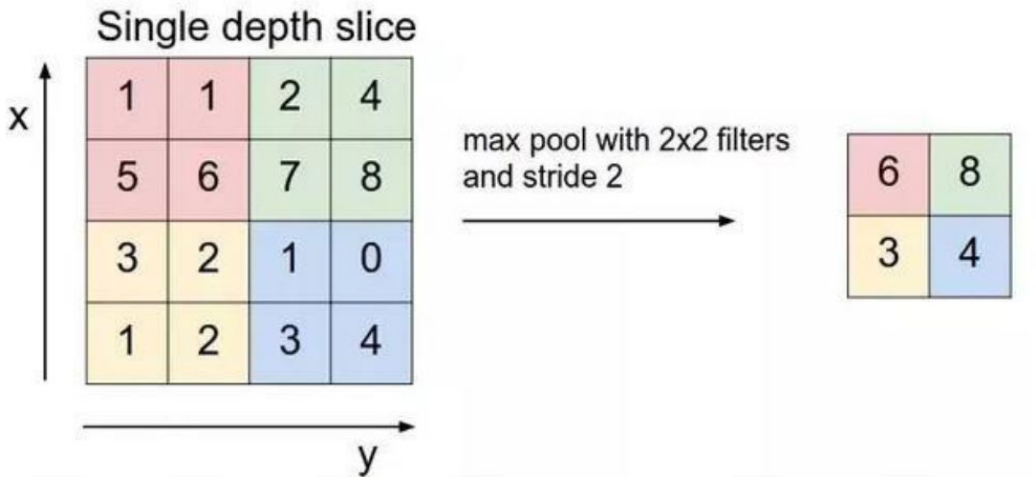
Bundan sonra, giriş görüntüsünün (5X5) evrişimi, çıktı olarak "Özellik haritası" olarak adlveırılan (3X3) çekirdek ile çarpılır. (3X3) filtresi, Şekil 3.5'de gösterildiği gibi vurgulanan kısımdan başlayarak giriş görüntüsüne uygulanacaktır.:



Şekil 3.5: Convolved Özelliğinin Üretilmesinin İlk Bölümü. [35].

3.3.2. Havuz Katmanı

Bu katman, giriş görüntüsünün uzamsal boyutunu azaltmak için kullanılır, böylece parametre sayısını ve ağ hesaplamalarını da azaltır. Maksimum havuzlama, Şekil 3.6'da adım 2 ile gösterildiği gibi en popüler kullanılan havuzlama katmanı şeklidir ve havuzlamanın boyutu da 2'dir. Max havuzu, birleştirilmiş çıktımızın tüm derinlik boyutlarında kullanılır.



Şekil 3.6: Maksimum Havuzlama [35].

3.3.3. Çıktı Katmanı

Çıktı katmanı, ilk önce önceki katmanlardan gelen girdiyi düzleştiren ve daha sonra ağda gerektiği gibi aynı sayıda sınıfa sahip bir çıktı üretmek için ona tamamen bağlı katmanlar uygulanacak olan tamamen bağlı bir katmandır.

Çıktı katmanı ayrıca tahmin hatasını hesaplayan bir kayıp fonksiyonuna sahiptir. İleri geçişi tamamladıktan sonra, önyargıları ve ağırlıkları değiştirmek için hata geri yayılımı uygulanacaktır.

Tüm CNN ağı, her giriş görüntüsünü işlemek ve bir sınıf biçiminde bir çıktı almak için aşağıdaki adımları uygular:

i. Giriş görüntüsü birçok bölgeye bölünecektir.
ii. Her bölge bağımsız bir imaj olarak değerlendirilecektir.
iii. Tüm görüntüler (bölgeler) cnn'ye aktarılacak ve bu da onları birçok sınıfa ayıracaktır.
iv. Her bölge kendi sınıfına bölünecek; algılanan tüm nesneleri içeren bir görüntü elde etmek için birleştirileceklerdir.

Bu yaklaşımla ilgili sorun, aynı nesnenin gerçek hayatta olduğu gibi farklı şekillere sahip olabilmesidir. Ek olarak, görüntülerdeki nesneler farklı konumlara ve birçok en boy oranına sahip olabilir. Örneğin, nesne görüntü alanının çoğunu kaplayabilirken, görüntünün yalnızca küçük bir alanını kaplayabilir. Bu nedenle, hesaplamalar çok karmaşık olacak ve bu sorunu çözmek için yeni bir yaklaşım - Bölgesel temelli CNN kullanılacaktır [35].

3.4. NESNE ALGILAMA TÜRLERİ

Nesne algılama çerçeveleri iki türe ayrılır:

3.4.1. İki Aşamalı Dedektörler

İki aşamalı dedektörler, geleneksel nesne algılama boru hattını takip eder. Nesne algılama ile iki aşamada ilgilenir. Birinci aşama bölgesel teklifleri oluşturur, ikinci aşama ise her teklifteki sınıfları tespit eder ve sınıflveırır. İki aşamalı dedektörler arasında R-CNN, Hızlı R-CNN, Daha Hızlı R-CNN ve Maske R-CNN bulunur.

3.4.1.1. Rcnn dedektörü (bölgesel tabanlı)

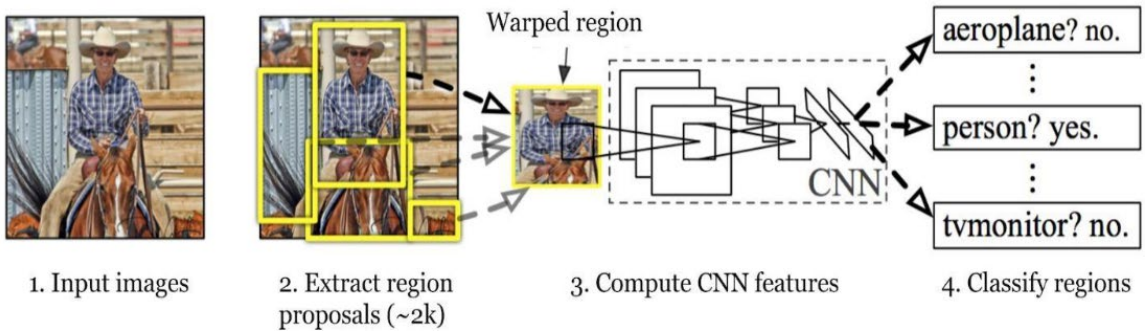
R-cnn'nin temel amacı, bir görüntü elde etmek ve her bir sınırlayıcı kutunun bir nesneye ve bir sınıfa, örneğin kişiye, dizüstü bilgisayara ve topa sahip olduğu çıktı olarak önerilen sınırlayıcı kutu grubuyla yeniden oluşturmaktır.

RCNN, giriş görüntüsünden 2000 bölge önerilerini ayıklayan seçici bir arama mekanizması kullanarak sınırlayıcı kutuları ayıklar. Aşağıdaki adımlar seçici arama algoritmasını göstermektedir [36]:

i. Alt segment ve çoklu aday bölgeler oluşturma
ii. Karşılaştırılabilir bölgeleri yinelemeli olarak daha büyük bölgelere entegre etmek için açgözlü bir algoritma kullanmak.
iii. Bölgeleri kullanarak nihai bölge önerisinin oluşturulması.
iv. RCNN tarafından nesne algılama şu adımlarla gerçekleştirilir:
v. Giriş görüntüsü alma

İlgi Alanlarını (YG) çıkarmak için seçici arama gibi çeşitli teklif yöntemlerini kullanarak. Her yatırım getirisi, görüntüde öngörülen bir nesneyi temsil eden bir kutudur. Senaryoya göre, 2000 ROI'ye sahip olmak mümkündür.

i. Her yatırım getirisi yeniden şekillendirilir ve daha sonra konvolüsyonel ağa geçirilir.
ii. CNN, her YG'den özellikler çıkaracak ve daha sonra Destek Vektör Makinesi (SVM) sınıflveırıcısı tarafından çeşitli sınıflar için bölünecektir.
iii. Sınırlayıcı kutu regresyonu ile tespit edilen her bölge için sınırlayıcı kutuları tahmin etme



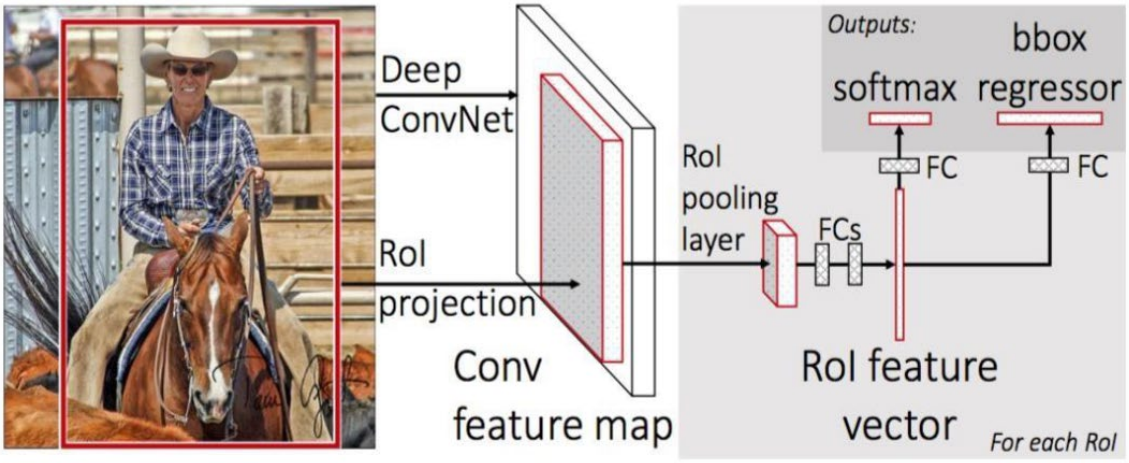
Şekil 3.7: R-CNN Mimarisi [36].

RCNN problemi, cnn'yi eğitmek ve her görüntü sınıflveırma işleminde yaklaşık 2000 Bölge önerisini sınıflveırmak nedeniyle yavaş ve hesaplama açısından pahalı olmasıdır, ayrıca bir düzeltme algoritmasına dayanan R-CNN "seçilen arama" Bu işlem aşamasında öğrenme yoktur. Bu sorunları gidermek için Fast R-CNN adlı yeni bir nesne dedektörü geliştirilmiştir.

3.4.1.2. Hızlı r-cnnn

R-Cnn'de her görüntü konvolüsyon sinir ağını 2000 kez çalıştırıyordu, bu sorunu çözmek için bu dedektör geliştirildi, buna Hızlı R-CNN deniyor. Çünkü öyle, eğitmek ve test etmek hızlı [36].

Ağı yalnızca bir kez çalıştırır ve bu nedenle önceki modelden daha hızlıdır. Şekil 3.8'de Hızlı R-CNN mimarisini göstermektedir.



Şekil 3.8: Hızlı R-CNN Mimarisi [36].

Hızlı R-CNN algılama aşağıdaki adımları izleyerek yapılır:

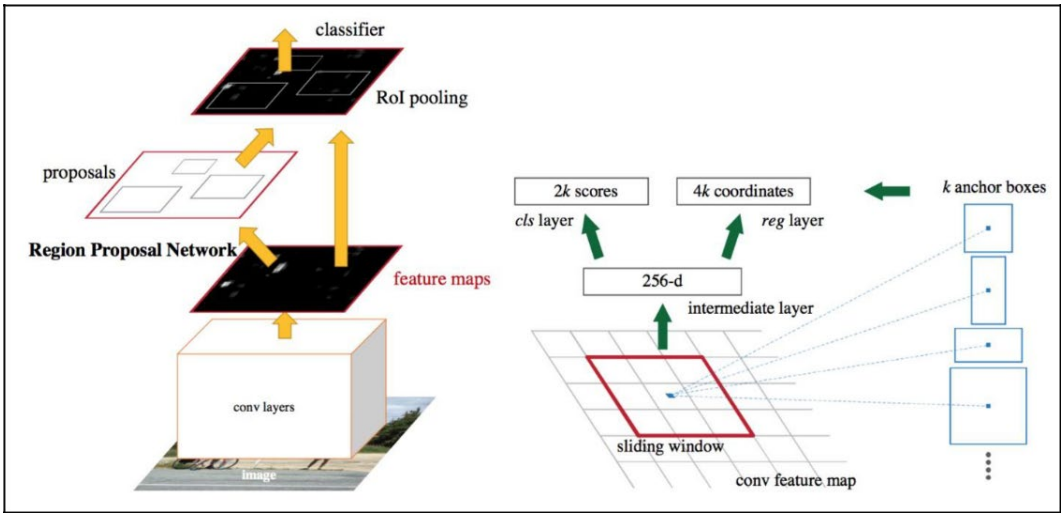
i. Giriş görüntüsü alma.
ii. Görüntüyü, görüntü özelliği eşlemelerini geri veren Kıvrımlı ağa geçirme. Çıkarılan tüm bölge tekliflerini, üzerinde yatırım getirisi havuzu adı verilen yeni bir yöntem uygulayarak aynı boyutta yeniden şekillendirmek.
iii. Yeniden boyutlveırılan RIO'ları, önerilen nesneleri sınıflveırmak ve çevrelerindeki BB'yi (Sınırlayıcı Kutuları) döndürmek için SoftMax regresyonuna ek olarak doğrusal regresyon katmanlarını kullanacak tam bağlı bir katmana geçirmek.

Her ne kadar Hızlı RCNN, rcnn'ye kıyasla nesne tespitinde büyük bir gelişme sağlamış olsa da, bölge önerilerini tespit etmede seçici bir arama yaklaşımı kullanması nedeniyle hala birçok kısıtlamaya sahiptir, bu da zaman alıcı ve yavaş olmasını sağlar.

3.4.1.3. Daha hızlı r-cnn

Daha hızlı RCNN, hızlı rcnn'nin bir sonraki sürümüdür, Hızlı R-CNN ise bölge önerileri oluşturmak amacıyla Seçici Arama'yı kullanırken, Daha Hızlı R-CNN Bölge Önerisi Ağı'nı (RPN) kullanır. RPN Çalışma mekanizması, özellik haritalarını alarak ve daha sonra önerilen her nesne için iğrenme puanı olarak çıktı ile olası mevcut nesneleri önererek başlar. Hızlı RCNN nesne algılamada şu adımları izlemektedir [36]:

Görüntüyü, görüntü özelliği eşlemelerini geri veren Kıvrımlı ağa geçirme. Özellik haritalarına RPN uygulamak, özellik haritalarının üzerinde slayt penceresi yöntemini kullanır, her pencereden farklı boyut ve şekillerde K bağlantı kutuları oluşturulur. Burada bağlantı kutuları, veri kümesindeki nesnelerin boyutuna uyacak şekilde seçilen belirli bir boyuta ve önceden tanımlanmış yükseklik ve ağırlıklara sahip bir sınır kutuları grubudur. Bu nedenle, RPN nedeniyle öngörülen nesne ve aşağılanma puanı önerilecektir. YG havuzu katmanı uygulayarak önerilen nesneyi aynı boyuta getirmek. Önerileri, öngörülen nesneleri sınıflveıracak ve sınırlayıcı kutularını çıkaracak tam bağlı katmana iletmek.



Şekil 3.9: Daha Hızlı R-Cnn Modeli [36].

Daha hızlı RCNN önceki dedektörler gibi, hepsi nesneleri tanımlamak ve tespit etmek için bölgelere bağlıdır, ağ giriş görüntüsünü tam tek bir resim olarak ele almaz, ancak bölgelere böler ve bunlara sırayla odaklanır.

3.4.1.4. Maske rcnn (bölgesel konvolüsyonel sinir ağı)

Mask RCNN, Daha Hızlı RCNN dedektörünün bir sonraki sürümüdür, mask RCNN çerçevesi, iki ana eklemeyle Daha Hızlı RCNN çerçevesinin üzerine inşa edilmiştir: ROI Havuzu yerine ROI hizalama modülünü (daha doğru) kullanma.

İlgi bölgesi (RIO) algin modülünün dışına fazladan bir departman yerleştirmek.

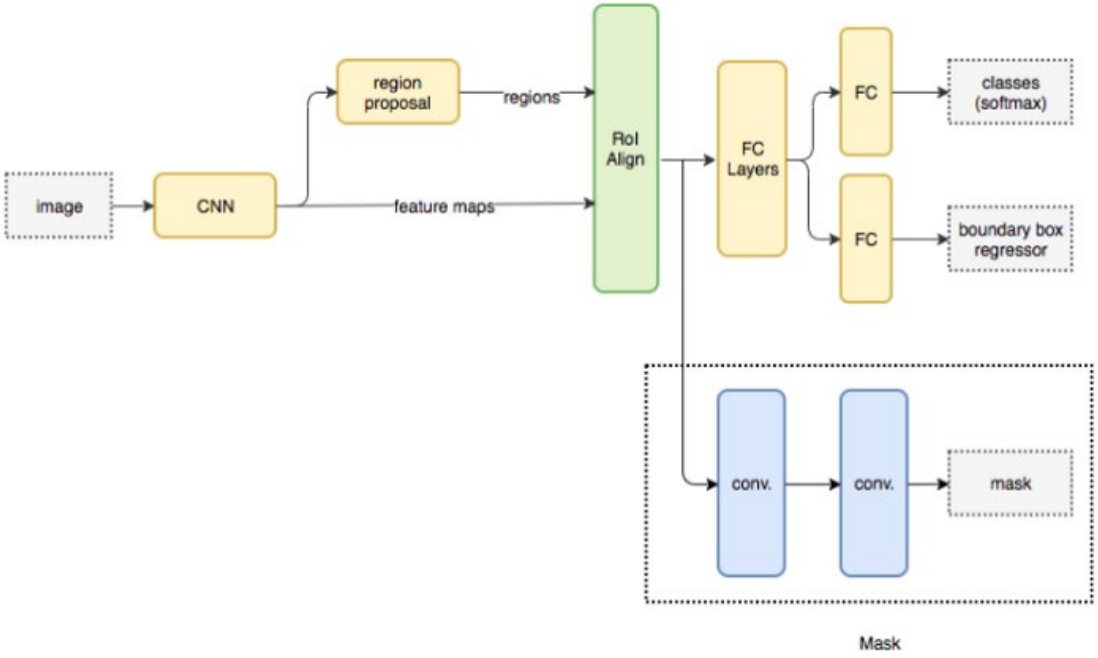
Mask RCNN, sınırlayıcı kutuları kullanarak giriş görüntüsündeki örnekleri algılar ve aynı vea her nesne için bir segmentasyon maskesi oluşturur. Bu nedenle, yalnızca nesne algılamada değil, aynı zamvea nesne segmentasyonunda da kullanılır.

RCNN mekanizmasını aşağıdaki gibi maskelenebilir:

i. Özellik eşlemelerini giriş görüntüsünden çıkarmak için RESNET101 mimarisini kullanır.
ii. Çıkarılan özellik haritaları bir sonraki katmana aktarılacaktır.
iii. Çıkarılan özellik haritalarına RPN uygulanacak ve bölgenin bir nesnesi olup olmadığını tahmin edecektir. Yalnızca nesneleri içereceği tahmin edilen bölge dikkate alınacaktır. ROI hizalamasını uygulayarak bölgeleri aynı boyuta ve şekle dönüştürmek ve sonuç olarak RIO elde etmek.

Roı'ler, nesne sınıfı tahmini, sınırlayıcı kutu tahminleri için paralel olarak üç dala ayrılır ve bunlar (isteğe bağlı olarak) tahmin edilen her nesne üzerinde piksel düzeyinde maske oluşturmaktadır.

RCNN Maske yapısı Şekil 3.10'da gösterilmiştir.



Şekil 3.10: Maske RCNN Yapısı [37].

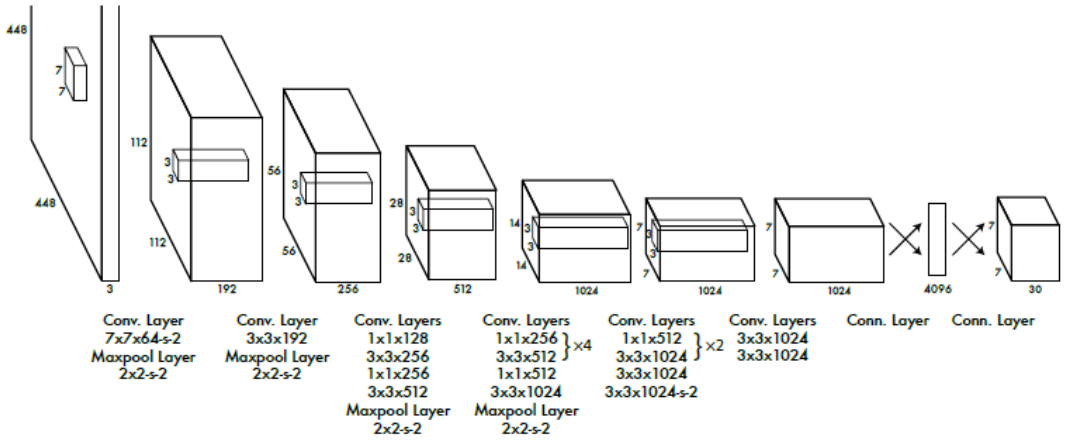
3.4.2. Tek Kademeli Dedektör

Tek aşamalı dedektör: tek aşamalı dedektör modelleri, herhangi bir ara görev olmaksızın doğrudan bir sınıflveırma veya regresyon problemi olarak nesne algılama ile ilgilenir, bu da daha hızlı ve daha basit bir mimari anlamına gelir [37].

En yaygın tek aşamalı dedektörler YOLO ve SSD'dir.

YOLO, diğer geleneksel dedektörlerden farklı bir yaklaşım kullanan son teknoloji ürünü bir nesne algılama algoritmasıdır. Gerilemeye dayanır. Bu modelin en belirgin özelliği hızdır, saniyede 45 kare işler (Sharma, 2018).

Şekil 3.11 YOLO mimarisini göstermektedir.



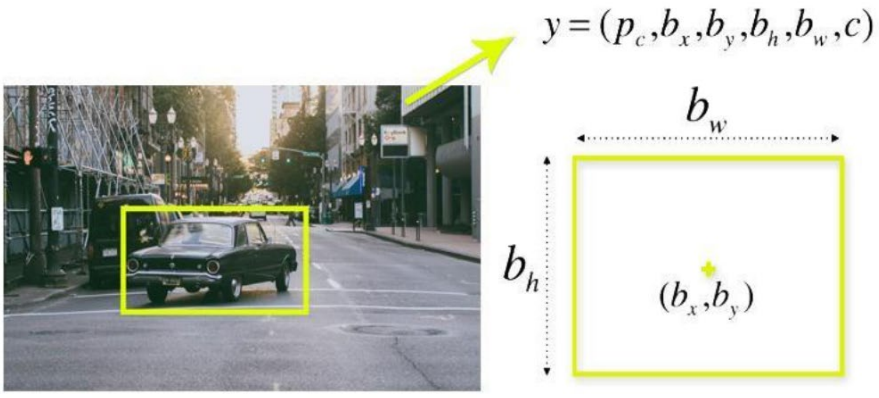
Şekil 3.11: Yolo Mimarisi [37].

Sınırlayıcı kutu koordinatlarına ek olarak olası nesnelerin sınıflarını tahmin etmek için tek seferde tüm görüntüye tek bir sinir ağı uygular.

Her Sınırlayıcı Kutunun, Şekil 3.12'de gösterildiği gibi tespit edilmesi için aşağıdaki tanımlayıcılara ihtiyacı vardır:

i. Sınırlayıcı kutu centroid. (bx, by) kılavuz hücre sınırlarına göre.
ii. Öngörülen giriş görüntüsüne göre genişlik (bw). 3. Tahmin edilen giriş görüntüsüne göre yükseklik (bh).
iii. C, Sınıf olasılıklarını (araba, kişi, kedi vb.) Temsil eder.

Sınırlayıcı kutu bir nesne içeriyorsa (güven puanı) Hücrede nesne yoksa, Pc'nin sıfır olma olasılığını temsil eder. Aksi takdirde, yer gerçeği ile öngörülen kutular arasındaki Birlik (IOU) Üzerindeki Kesişme Noktası olacaktır [37].



Şekil 3.12: Sınırlayıcı Kutu Tanımlayıcıları [37].

YOLO, büyücüyü (S × S) ızgaraya böler ve ızgaranın her hücresi için B sınırlayıcı kutuları, güven ve C'yi tahmin eder. Bu nedenle, tahmin S × S × (B 5 + C) tensörü olarak olacaktır. YOLO, nesne algılama işleminde şu adımları takip ediyor [38]:

i. Giriş görüntüsünü alır ve (SXS) ızgarasına böler.
ii. Nesnenin merkez birimi kılavuz birimindeyse, bu kılavuz birimi bu nesne sınıfını tahmin etmekten sorumlu olacaktır.
iii. Her ızgara hücresi, k-means kümelemesini kullanarak sınırlayıcı kutu tanımlayıcılarını tahmin edecektir.
iv. Özellikleri ondan çıkarmak için giriş görüntüsünü ağa geçirir.

Her ızgara görüntüsünde yerelleştirme ve sınıflveırma uygulanacak ve ardından YOLO olası nesne sınıflarını ve bunların sınırlayıcı kutu koordinatlarını önerecektir. Bu hücrelerin ve sınırlayıcı kutuların çoğu, içindeki nesnelerden boştur. Bu nedenle, pc değerinin, içinde herhangi bir nesne bulunması muhtemel olmayan kutuları, maksimum olmayan bastırma adı verilen bir işlemde kaldıracağı tahmin edilmiştir.

CUDA teknolojisi ve C dili, yolo'yu hızlı hale getiren ve yolo'nun gerçek zamanlı tahmin modelleri için çok gerekli olan GPU'ya uygulanmasına izin veren Darknet'in yazılmasında kullanıldı.

3.5. YOLO VE MASKE RCNN UYGULAMASI

Bu çalışmanın ilk bölümünde, aynı veri kümesi (MS COCO) veri kümesi üzerinde önceden eğitilmiş olan YOLO ve MASK RCNN önce cpu'da sonra gpu'da karşılaştırılacaktır. Modelin GPU üzerinde uygulanması, opencv'nin derin sinir ağı modülü (DNN) ve etkinleştirilmiş NİVİDİA / CUDA GPU kullanılarak google Collab hizmetinde yapılır.

3.5.1. Yolo ve Mask Rcnn Uygulamasında Kullanılan Kütüphaneler

Başlıca kullanılan kütüphaneler şunlardır [38]:

3.5.1.1. Opencvname

Bu uygulamalar için ortak bir altyapı sağlamak ve başta ticari olmak üzere birçok üretim alanında makine algısı kullanımını hızlveırmak amacıyla makine öğrenimi ve bilgisayarla görme uygulamalarında kullanılan açık kaynaklı bir kütüphanedir. İnsan eylemlerini sınıflveırmak, nesne algılama ve sınıflveırma, yüz tanıma, nesne izleme vb. İçin kullanılan

2500'den fazla optimize edilmiş algoritma (klasik ve son teknoloji makine öğrenimi ve bilgisayar görüşü) içerir.

OpenCV, Java, MATLAB, Python ve C ++ arayüzleri gibi birçok arayüze ek olarak tam özellikli bir CUDA arayüzü geliştirdi ve Mac OS, Android, Linux ve Windows'u destekliyor.

3.5.1.2. Argparse (komut satırı seçenekleri, bağımsız değişkenler ve alt komut için ayrıştırıcı)

Programa çalışma zamanında ek bilgi sağlayan kullanıcı dostu bir komut satırı yazma işlemini kolaylaştırır, böylece kodun kendisini değiştirmeden girişleri değiştirmek kolay olabilir [38].

3.5.1.3. Numpy (sayısal python)

Genellikle dizileri ve matrisleri, Fourier dönüşümünü ve lineer cebiri işlemek için kullanılan açık kaynaklı, kullanımı kolay, performanslı ve birlikte çalışabilir bir Python kütüphanesidir.

3.5.1.4. İşletim sistemi (çeşitli işletim sistemi arayüzleri)

Kullanıcıların işletim sistemi işlevselliğini taşınabilir bir şekilde kullanmalarını sağlayan bir modüldür, örneğin yolları manipüle etmek, bir dosyayı okumak / yazmak, geçici dosyalar oluşturmak için kullanılır [38].

Birincisi "yaya" video akışı, diğeri "sokak gürültüsü" video akışı olmak üzere iki farklı video akışı, her ikisi de karşılaştırılan modellerin uygulanmasının değerlendirilmesinde kullanılmıştır. Aşağıdaki adımları izleyerek modelleri uygulama:

3.5.2. Maske-Rcnn Uygulama Adımları

İşletim sistemi kitaplığı işlevini kullanarak dataset (MS COCO) sınıf etiketlerini yükleme.

Yapı Maskesi-OS kitaplığı işlevlerini kullanarak RCNN ağırlığı ve yapılveırma yolu. Önceden eğitilmiş modeli (mask_rcnn_ınceptıon_v2_coco) sabit masadan DNNs modülü işlevini (cv2.dnn.readNetFromTensorflow). OpenCV işlevini kullanarak video akışını başlatma (cv2.VideoCapture) ve video işaretçisini başlatır. OpenCV işlevini kullanarak giriş video karelerinin ön işleme alınması (cv2.dnn.blobfromgörüntüler)

Ve sonra çıktıyı mask-RCNN ağına iletin, sonuç iki değişken içerir [39]:

i. Her karede öngörülen nesnenin sınırlayıcı kutusunun koordinatları. (kutucuk)

ii. Her karede öngörülen her nesne için piksel bazında segmentasyon (MASK).
iii. Sonucu post-processing ve zayıf tahmin nesnelerini (varsayılvean daha az güvene sahip) hariç tutarak filtreleyerek.
iv. Tahmin edilen nesnelerin sonuçlarını (MASK, sınırlayıcı kutular ve güven) görselleştirme.

Mask-RCNN, Opencv'nin etkin NVIDIA GPU'ya sahip DNN modülü tarafından Google-Colab hizmetini kullanarak gpu'da da uygulanmaktadır.

3.5.3. Yolo Uygulama Adımları

Dataset (MS COCO) sınıf etiketleri yükleniyor. İşletim sistemi işlevini kullanma

Önceden eğitilmiş modelin yüklenmesi (YOLO. v3) DNNs modül işlevlerini kullanarak sabit masadan video akışını ve video işaretçisini başlatma. Giriş video karelerini cnn'ye aktarmadan önce ön işleme alın. Ağ sonucunun işlenmesinden ve zayıf tahminlerin filtrelenmesinden ve maksimum bastırma uygulanmasından sonra tahmin edilen nesnelerin sonuçlarını (sınırlayıcı kutular ve güven) görselleştirin. YOLO, Opencv'nin etkin NVIDIA GPU'ya sahip DNN modülü tarafından Google-Colab hizmetini kullanarak gpu'da da uygulanmaktadır [39].

Aşağıdaki şekiller, YOLO modelinin birinci ve ikinci videolara uygulanmasının ekran görüntülerini göstermektedir YOLO V3 modelini ve Mask-RCNN modelini hem CPU hem de gpu'da nesne algılama hızı açısından test ettikten sonra, sonuçlar YOLO V3'ün MASK rcnn'den önemli ölçüde daha hızlı olduğunu gösterdi. YOLO V3 ilk videoda MASK RCNN'den % 401'in üzerinde, ikinci videoda (CPU hızında)% 353'ün üzerinde daha hızlıydı. Bu nedenle, YOLO nesne algılama modeli, sosyal mesafe dedektörünü oluşturmak için kullanılır.

3.6. YOLO'NUN SOSYAL MESAFE DEDEKTÖRÜNE UYGULANMASI

Bu çalışmanın ikinci bölümü, YOLO nesne algılama modelini kullanarak sosyal mesafe dedektörünü uygulamak için OpenCV, bilgisayar vizyonu ve derin öğrenmeyi kullanacaktır.

3.6.1. Proje yapısı

Oluşturmaya başlamak için, bir video akışındaki nesne algılama uygulanacak, ardından yalnızca bireyleri algılamak için filtrelenecektir. Tanımlanan tüm bireyler arasındaki iki

mesafeyi hesaplayın. İki kişinin güvenli mesafeden daha az olup olmadığını kontrol edin. Open CV sosyal mesafe dedektörünün uygulanması piksel mesafelerine dayanacaktır.

3.6.2. Video Akışında Nesne Algılama

Daha önce de belirtildiği gibi, video karelerindeki her nesneyi algılamak için video akışlarında opencv'li YOLO modeli uygulanacaktır. Nesne algılama aşağıdaki adımlarda uygulanmıştır:

3.6.3. Yolo Modelini Yükleme

YOLO modeli, Darknet ekibi tarafından COCO veri kümesi üzerinde önceden eğitildi. Bu çalışma, bu önceden eğitilmiş modelden yararlanır ve derin öğrenmenin özel araçlarını ve kütüphanelerini kullanır. Birçok amaç için DNN modülü işlevleri de dahil olmak üzere opencv'nin bazı işlevlerini kullanır. Örneğin, Yolo modelinin ağını bellekten (hard desk) OPENCV'ye yüklemek için readNetFromDarknet işlevi kullanıldı [39].

3.6.3.1. Video akışını başlatma

OpenCV ve DNN modül fonksiyonlarını kullanarak video akışı ile ilgilenmek [40]:

i. Video yazıcısı başlatılıyor.
ii. Çerçeve boyutları başlatılıyor.
iii. Giriş videosuna bir işaretçi açma.
iv. Giriş video akışının karelerini okuma.
v. Bu karelerin sayısını sayıyorum.
vi. İşlem süresi tahmini.

3.6.3.2. Giriş çerçevelerini ön işleme alma

Daha iyi tahminlere sahip olmak için, yolo'nun kıvrımlı ağına aktarılmadan önce video karelerinde bazı ön işlemler uygulanır. DNN modülü işlevi blobFromImages video karelerini (görüntü serileri) girdi olarak alır ve çıktı olarak onlardan bir blob yapar, ardından sınıflveırmayı uygulamak için CNN'ye iletir.

Bir blob, aynı şekilde hazırlanmış ve önceden işlenmiş, aynı zamvea benzer uzamsal boyutlara ve derinliğe sahip bir görüntü veya görüntü grubudur. Bu işlev girişi alır ve isteğe bağlı işlemler uygulveıktan sonra dört boyutlu bir blob oluşturur, örneğin görüntüyü yeniden

boyutlveırın, kırpın, mavi ve kırmızı kanalları değiştirin, ortalama değerleri çıkarın ve bir Ölçek faktörü ile ölçeklendirilmektedir [40].

Ortalama değer, görüntünün RGB biçiminde olduğunu varsayar, ancak OpenCV bununla başa çıkmak için BGR biçiminde olduğunu varsayar, mavi ve kırmızı kanallar bu aşamada değiştirildi. Blob, Yolo'nun cnn'inden geçecek. Sonuç olarak, CNN zayıf öngörüleri (varsayılvean daha düşük güvene sahip) filtreleyecek ve kutuları sınırlayarak her karedeki nesneleri algılayacaktır. YOLO, her sınırlayıcı kutuyu temsil etmek için dört koordinat döndürür [41]:

(centroid x, centroid y, genişlik ve yükseklik).

Her bb'nin sol üst köşesi, bu matematiksel işlemler uygulanarak kutu koordinatlarından sürülecektir:

Sol üst x = int (centroid x - (genişlik / 2))

Sol üst y = int (centroid y - (yükseklik / 2))

Sonunda, kutu koordinatlarının, güven puanının ve algılanan nesne sınıfının her biri, her karede nesne algılaması için çıktı olacaktır.

3.6.3.3. Maksimum olmayan bastırma uygulama

Opencv'de maksimum olmayan bastırma yerleşiktir. Gereksiz ve çakışan sınırlayıcı kutuları filtrelemek ve opencv'nin DNN işlevini kullanarak öngörülen nesneyi temsil ederken yerelleştirme doğruluğunu artırmak için yalnızca en yüksek güven puanına sahip en iyi sınırlayıcı kutuyu çıkarmak için uygulanan bir işlem sonrası yöntemdir. Maksimum olmayan bastırma eşiği ve bu çalışmaya duyulan güven varsayılan değerlere ayarlanmıştır. NMS sonucunun en az bir algılama sağladığını varsayarsak, bunların üzerinde döngü yapın, sınırlayıcı kutu koordinatlarını ayıklanmalı ve aşağıdakilerden oluşan sonuç listesi güncellenmelidir [41].

i. Her algılama Sınırlayıcı Kutu koordinatları.
ii. Her Sınırlayıcı Kutunun sentroidi.
iii. Her video karesindeki nesneleri tespit ettikten sonra, kişileri filtrelemek bir sonraki adım olacaktır:

3.6.4. Filtrasyon

YOLO modeli tarafından çeşitli nesne türleri algılanabilir Bu nedenle dedektör, yalnızca "kişi" sınıfını göz önünde bulundurarak her karedeki algılanan tüm sınıfları filtreleyecek ve diğer sınıfları hariç tutacaktır. Çalışmada, insanların filtreleme sonucunun çıktısı (1) bireyin (kişi) tahmin olasılığından, (2) algılama sınırlayıcı kutu koordinatlarından ve (3) nesnenin sentroidinden oluşacaktır.

3.6.5. Çift Mesafeyi Hesapla

DSÖ rehberliğini takip eden ve diğer insanlardan güvenli bir mesafeyi koruyan bu günlerde, Hastalık Kontrol ve Önleme Merkezlerinin (CDC) diğer insanlardan yaklaşık 1,5 metre uzakta kalması tavsiyesi olarak, toplumdaki COVID-19 yayılımını sınırlamak için gerekli hale geliyor.

Bu çalışma, aşağıdaki adımları uygulayarak sosyal mesafeyi izlemeye çalışmaktadır [41]:

i. Her karedeki sınıftan (kişi) nesneleri belirler.
ii. Video karelerindeki her örnek çifti arasındaki çift yönlü mesafeyi hesaplar. Aralarında güvenli bir mesafe olup olmadığını kontrol eder. (en az 1,5 metre)
iii. Piksel ölçümleri, feet cinsinden güvenli mesafeden 50 piksele yaklaşan piksel ölçümüne dönüştürmek için kullanılmıştır.

Her karede, tespit edilen tek tek centroidler çıkarılır ve tüm centroidler arasındaki Öklid mesafesi hesaplanır, daha sonra iki kişinin çok yakın olup olmadığını ve izin verilen mesafeyi (50 piksel eşiğinden az) ihlal edip etmediğini kontrol eder, böylece ihlal listesine eklenir ve kırmızı kutulara açıklama eklenir.

Halk sağlığı uzmanları tarafından belirlenen sosyal mesafe kurallarını ihlal eden kişilerin listesi olan ihlaller kümesidir.

3.6.6. Sonuçların Görselleştirilmesi

Son adım, sonuçları görselleştirmek ve çerçeveye sınırlayıcı kutuları temsil eden dikdörtgenler, nesne merkezlerini temsil eden daireler ve her karedeki ihlallerin sayısını göstermek için metinle açıklama şöyledir [42]:

i. Centroidlerin koordinatlarını çıkarın.
ii. Video karesindeki her centroid arasındaki Öklid mesafesini hesaplayın.

iii. Mesafe eşiğini ayarlayın (bu çalışmada 50 piksel)

iv. Eşikten daha az Öklid mesafesi olup olmadığını kontrol edin ve eğer öyleyse, sosyal mesafe ihlali listesini güncelleyin ve sınırlayıcı kutuları kırmızıya boyayın. Değilse, herhangi bir ihlal yoktur, sınırlayıcı kutuları yeşil renkte yapın.

Hem bireyin sınırlayıcı kutusunu hem de centroid nesnesini çizin, her biri renk eşgüdümlüdür, bu nedenle hangi kişilerin çok yakın olduğunu gösterecektir. Sosyal mesafe ihlallerinin toplam sayısı (ihlal kümesinin uzunluğu) hakkında bilgi görüntüler. Bu çalışma, Opencv'nin DNN modülünü Google-Colab kullanarak NVIDIA desteğiyle kullanarak çerçeve işleme hızını artırmak için NVIDIA CUDA özellikli GPU'yu kullanmıştır [42].

4. COVİD-19 SÜRECİNDE KULLANILAN YAPAY ZEKA TEKNOLOJİLERİNİN ETKİLERİ

4.1. GENEL UYGULAMALAR

As Ulusal Sağlık Enstitüsü tarafından bildirilen Temmuz 2019 yılında bir atölyede birkaç diğer kurumları ile ortaklaşa "Makine Zekası (MI), biyomedikal keşif, klinik araştırma, tıbbi teşhis/cihazlar ve hassas tıpta hızla önemli bir yaklaşım haline geliyor. Bu tür araçlar, araştırmacılar, doktorlar ve hastalar için daha bilinçli kararlar vermelerine ve daha iyi sonuçlar elde etmelerine olanak tanıyarak yeni olasılıkları ortaya çıkarabilir. Sağlık hizmetleri ortamlarında uygulveığında, bu yaklaşımlar sağlık araştırmaları ve bakım ekosisteminin verimliliğini ve etkililiğini artırma ve nihayetinde hasta bakımının kalitesini artırma potansiyeline sahiptir." [43].

Koronavirüsün (COVID-19) yayılmasından kaynaklanan pveeminin gelişmesiyle birlikte, tıbbi sağlayıcılar, kurumlar ve ticari geliştiricilerin tümü, bu mevcut krizin tehdidiyle yüzleşmek için makine öğrenimini uygulayıp uygulamamayı ve nasıl uygulayacaklarını düşünmektedirler [44].

Bazıları makine öğrenimine dayanan yapay zeka, pveemideki ilk savunma hatlarına dahil ediliyor. Önde gelen epidemiyologlar, ancak virüsün yayılmasını öngörmede başarılı olabileceğimiz konusunda ısrar ediyor ve bu krizle mücadele için adımlar atıyorsak:

1) kimin hastalığa sahip olduğunu bilirsek; 2) kimin alması muhtemel olduğunu güvenilir bir şekilde tahmin etmek için verileri inceleyin; 3) ve kısa ve uzun vadede kaynak ve tedarik zincirini bilgilendirmek için mevcut verileri kullanın. Hastanelerdeki triyajdan, sıcaklıkları kontrol etmek için yüzleri taramaya veya bireysel verileri kullanarak yayılmayı takip etmeye kadar çeşitli kuruluşlar, çeşitli karmaşıklık veya karmaşıklık düzeylerine sahip makine öğrenimi tabanlı algoritmalar kullanıyor [44].

Genel olarak, etkili yapay zeka, insanların yapabileceklerini daha hızlı ve daha tutarlı bir şekilde çoğaltabilir (CCTV kameralarına bakın, yüzleri tespit edin, CT taramalarını okuyun ve radyologların başka şekilde bulabilecekleri pnömoni 'bulgularını' belirleyin) veya bu sistemler insanların yaptığı şeyleri yapabilir. yapamaz (umut verici ilaç adaylarını belirlemek için binlerce kimyasal bileşiği hızla taramak gibi). Hastalık yayıldıkça, dünyanın dört bir yanındaki tıp araştırmacılarının mevcut verileri anlamlveırmak için acele ettiğini ve

başkaları için faydalı olması için bir zaman diliminde güvenilir analizi tamamlamaya çalışma ihtiyacıyla karşı karşıya kaldıklarını görüyoruz. Yakın tarihli bir makalede, Yapay Zeka Göğüs BT'sinde COVID-19'u Toplumdan Edinilmiş Pnömoniden Ayırıyor, Bir grup Çinli doktor, göğüs BT'lerini kullanarak COVID-19'un otomatik ve doğru tespitini sağlayabilecek bir model denemek için orada salgının ilk aylarındaki verileri aldı. Çalışmadaki amaçları, yalnızca bu düzenli göğüs taramalarını kullanarak COVID-19'u tespit etmek ve performansını değerlendirmek için tam otomatik bir çerçeve geliştirmekti. Çalışmaları, derin öğrenme modelinin COVID-19'u doğru bir şekilde tespit edebileceği ve onu diğer akciğer hastalıklarından ayırt edebileceği sonucuna vardı. Diğerleri gelmiş geri iten bu AI sistemi öğrenme COVID-19 veri konulara uygun bitmişti endişesiyle ancak, bu iddialara karşı hala etkileyici bir ustalık verilen hız ve durum ve büyük olasılıkla daha ölçülen dereceye kadar yararlı bir araç olmasına rağmen kullanılmaktadır [45].

Carnegie Mellon'dan araştırmacılar, bir enfeksiyonu tespit etmek için kullanıcının sesini analiz edecek bir uygulama olan COVID Voice Detector'ın erken bir sürümünü düşündüler . Araya girmesinden bu yana, önerilen bu uygulama, teşhisin ele alındığı "kullanıma hazır" yöntemlerin çeşitliliğini göstermiştir. Uygulama bir puan atarCOVID-19 teşhisi konanların sesleriyle benzerliklere dayalı olarak her bir ses örneğine. Uygulanırsa, uygulama hem sağlıklı hem de enfekte bireylerden ses örnekleri yoluyla eğitim verileri toplayarak kitle kaynak kullanımına bağlı olacaktır. İnsan kulağının duyabileceğinin ötesindeki sesi analiz ederek, sağlık camiasının semptomlar ve umarız COVID-19 virüsünün başlangıcı hakkında bilgi edinmesini sağlayacak vokal biyobelirteçleri belirleyecektir. Uygulama, sesi COVID-19 semptomlarıyla analiz etmek ve ilişkilendirmek için Yapay Zeka kullanarak çalışır. Ardından, erken semptomları açıklayan ve evde yalnızca bir akıllı telefon kullanarak izlemenin yollarını açıklayan bir uyarı tetiklenir [46].

Makine öğrenimi ayrıca ilaç geliştirme sürecini hızlveırmaya yardımcı olabilir, mevcut antivirallerin fayda sağlayabileceği konusunda fikir verebilir, enfeksiyon oranlarını tahmin edebilir ve hastaların daha hızlı taranmasına yardımcı olabilir. Kanadalı start up BlueDot, COVID-19'un ortaya çıkışını ilk olarak, küresel sağlık raporlarını ve haber kaynaklarını izleyen bir ML doğal dil işleme programı kullanarak Wuhan'daki pnömoni vakalarındaki artışa atıfta bulunarak tanımlamıştır.

Bu yeni ve hızlveırılmış uygulamaların çoğu, veri kümesi listelerinden ortaya çıkan derlemeler ve koronavirüse uygulanan makine öğrenimi vakalarını kullanması nedeniyle mümkündür. Bu veri kümelerinin ve analizlerin dikkate alınması, verilerin entegrasyonunun yetkin bir şekilde yapılabilmesi için (gerçek sorunları çözmek için tasarlanmış doğru soruları sormak) biyologlar, kimyagerler ve diğer uygun uzmanlar gibi bilim adamlarının inceleme ve katılımının dahil edilmesinin önemine işaret eder. Ve ayrıca sonuçların pveemik konuşmalar etrafında yayılan yanlış bilgilere katkıda bulunmamasını sağlamak [46].

Etik etkileri de çoktur. Bu acil durum, yapay zeka sistemlerine karşı yaygın olarak karşılaşılan zorlukların gerçek yaşam örneklerini yaratıyor. AI, koronavirüs savaşında ölüm kalım kararları vermeye yardımcı olmalı mı? Çinli araştırmacılar, doktorlara Kovid-19 hastalarını öncelik sırasına koymada yardımcı olabilecek bir yapay zeka aracı geliştirdiklerini söylüyorlar. Karşılaştırılabilir hayatta kalma oranlarını tahmin etmek için kan örneklerini analiz eder. Ancak bu, hayatta kalma/tedavi edilebilirliğin triyaj önceliklendirmesinde belirleyici bir faktör olması gerekip gerekmediğine dair karmaşık soruları gündeme getiriyor. Aynı şekilde, hastanın yaşı, doktorun sezgisi veya bu tür birkaç faktörü birleştiren ve ağırlıklveıran bir formülün nasıl tasarlanacağı ile ilgili sorularda. Son belirleyici olarak kullanılmasa bile AI'nın bunun adımlarında yardımcı olması mümkündür - yani, hangi belirteçlerin (örneğin kvea) hayatta kalma oranları veya durumun ciddiyeti ile en çok ilişkili olduğunu hızlı bir şekilde belirlemeye yardımcı olabilir [47].

Yapay zekanın bireysel düzeyde sorumlu bir şekilde tıbbi yardım sağlayıp sağlayamayacağını düşünürken benzer etik ve pratik düşünceler ortaya çıkıyor. İnsanlar bir dijital asistana sorarsa veya bir sağlayıcı, sigortacı veya başka bir platformdan bir sohbet robotuna çevrimiçi giderse ne olur?

Hastaneler, halk sağlığı kurumları ve ticari sağlık şirketleri, hastaları COVID-19 belirtileri açısından taramak için çevrimiçi semptom kontrolörleri gibi kendilerini taramalarına izin verebilecek erişilebilir yollar arıyor. Asıl soru, bu yapay zeka tabanlı erişim noktalarının hem sağlıklı insanların acil servislere girmesini engelleyip hem de bakıma ihtiyacı olanları koruyup koruyamayacağıdır. Aşırı dışlayıcı olmamak veya zararlı yanlış bilgilerin yayılmasına izin vermemekle birlikte hastalara faydalı bakım sağlamak için önemli bir risk/fayda analizi var mı? Amazon, Alexa'nın artık kullanıcılara yardımcı olabileceğini duyurduSeyahat geçmişi, semptomlar ve COVID-19'a olası maruz kalma ile ilgili bir dizi

soru sorarak virüse bulaşıp bulaşmadıklarını belirlemede. Alexa ayrıca Hastalık Kontrol Merkezi (CDC) tavsiyelerine dayalı olarak kullanıcılara tavsiyeler sunar. Diğer özellikler arasında, insanların ellerini ne kadar süreyle yıkamaları gerektiğine yardımcı olmak için 20 saniyelik bir şarkı söylemek yer alıyor [47].

Tıpta AI/ML'nin ortaya çıkışı, aynı zamvea, tıbbi AI/ML tabanlı ürünlerin tıbbi cihazlar veya hizmetler olarak gözden geçirilmesi gerektiği ve AI/ML tabanlı yazılımların pazarlamaya izin vermek için hangi kanıtların gerekli olması gerektiği gibi düzenleyici zorluklar yaratır. tıbbi cihaz (SaMD). ABD Gıda ve İlaç Dairesi yakın zamvea bu sorunlardan bazılarını ele almak için bir tartışma makalesi önerdi ve bir Nature.com makalesi, değerlendirmenin tek tek ML tabanlı ürünler yerine tüm sistemleri değerlendirmeye odaklanması gerektiğini savunarak yanıt vermiştir [48].

Son olarak, AR (artırılmış gerçeklik) ve VR (sanal gerçeklik) teknolojisi, COVID-19 hastalarına hizmet vermeyi ve başkalarını eğitmeyi amaçlayan diğer AI tabanlı sistemlerdir. Bir örnek, USA Today'in "Flatten the Curve: A Week in Social Mesafe" AR uygulamasıdır. Uygulama, cihazın kamerasına erişir ve bir AR şehrini boş bir yüzeye yerleştirir. Kullanıcı, bir şehirde hareket eden durumları ele alır ve etkili sosyal mesafeyi nasıl en üst düzeye çıkaracağını öğrenmek için iki seçenek arasından seçim yapmalıdır [49].

Diğer AR/VR platformları, COVID-19 hastalarının grup terapisine katılmasını sağlar. XR Health kısa süre önce, COVID-19 pozitif hastaları ve tıp uzmanlarını sanal olarak bir araya getiren bir VR telesağlık destek grubu duyurdu. XR Health'in arkasındaki ekip, VR deneyiminin , etkileşimin terapötik faydalarını artırmak ve hastaları kişisel deneyimlerini ve duygularını paylaşmaya teşvik etmek için geleneksel telekonferansı iyileştireceğini umuyor.

4.2. SAĞLIK UYGULAMALARI

Doktorlardan radyoloji teknisyenlerine kadar sağlık pratisyenleri, COVID-19 pveemisinin getirdiği yüksek stres, kaynak kısıtlı, çevre altında çalışmanın pratik zorluklarıyla boğuşuyor. Uygulayıcılar ve ilgili politikacılar tarafından yapılan çağrılar, bu çalışanların kendilerini korumalarına yardımcı olmak için hem düşük teknolojili çözümlere (ör. yüz maskeleri), geleneksel teknolojilere (ör. ventilatörler) hem de yüksek teknoloji araçlarına (ör., AI destekli hızlı triyaj) duyulan ihtiyaca odaklanıyor. ve hastalarına hizmet eder. Özellikle yapay zeka kullananlar olmak üzere, mevcut bir dizi yüksek teknolojili araç,

halihazırda uygulayıcıların kullanımına sunulan araçların bir parçasıdır. Bu AI araçlarından bazıları nelerdir? Ve onlara hangi yapay zeka biçimleri güç veriyor?

Sağlık pratisyenlerinin kullanımına sunulan, bazıları pveemi öncesinde dağıtılmış, ancak şimdi COVID-19 veri kullanımına dayalı yeni yeteneklere sahip olarak tanımlanan bazı uygulama ve araçları aşağıda gözden geçirilmektedir.

4.2.1. Ses Verileri

İster COVID-19 hastalığından şüphelenilen hastalar için isterse sıradan klinik ziyaretleri için olsun, doktorlar tarafından klinik notları kaydetmek ve otomatik olarak tamamlamak için kullanılan "AI destekli bir sesli asistveır". Suki, yapay zeka ve makine öğrenimi, özellikle de sistemin "doktorun muayenehanesinin bağlamını anlamasını ve doktorun tercihlerini öğrenmesini" sağlayan doğal dil işleme ile destekleniyor. Suki niyeti belirler ve benzer terimler arasından doğru seçim yapar". Çünkü Suki verileriKlinik etkileşimlerden ve sağlık kayıtlarından elde edilen son derece hassastır, veriler "modern şifreler ve maksimum güç kriptografisi ile şifrelenmiş geçiş halinde ve hareketsiz durumda" olarak tanımlanmaktadır. Anormallikleri veya şüpheli yazılım davranışlarını tespit etmek, ihlallere karşı koruma sağlamak için gerçek zamanlı analiz yapılır". Web sitelerinde bulunan bilgilere dayanarak, Suki "şu vea tüm Acil Bakım, Hastaneler, Yoğun Bakım, açılır ve triyaj klinikleri ve locum doktor atamaları için ücretsizdir"[50].

Black tarafından üretilen iPhone'lar için bir ürün Saykara, hekim sesle başka bir biçimidir geçenlerde COVID-19 özel kullanımlar ve kullanılabilirlik artar edilmiş görevlisi etkin olduğunu. Bazıları tarafından "Doktorlar için Alexa" olarak tanımlanan, Bu sesli metin uygulaması, tıbbi kayıtların gerçek zamanlı olarak güncellenmesi sürecini otomatik hale getirir ve çoklu grafik sistemleriyle (örneğin, EPIC) arayüz oluşturur. Bu "ortam" sistemi, "dinler, hastalarla yapılan konuşmaları yorumlar, böylece bir odaya girebilir, hastayı tedavi edebilir ve tablolama yapılabilir". COVID-19 pveemisi bağlamında Kara, yakın zamvea, uzaktan hasta karşılaşmalarının (örn. Teletıp karşılaşmaları sırasında çizelgelerin iyileştirilmesi, yeni ve normal tıp için mevcut sağlık verilerinin kalitesini ve ayrıntı düzeyini iyileştirebilir. Kara, şirketle iletişime geçerek sınırlı ücretsiz kullanım için de kullanılabilir [50].

Elektronik sağlık kayıtları devi EPIC, özellikle COVID-19 hastalarının izlenmesine izin veren yeni bilgilere sahip benzer bir ses özellikli sanal asistana sahiptir. EPIC, semptom

uygulamaları oluşturmakve EHR verilerini AI ve diğer veri odaklı COVID-19 yanıtlarını iyileştirmeye çalışan belirli bir kuruluş grubuyla paylaşmakiçin uygulama geliştiricileriyle özellikle ortaklık kurmuştur [50].

4.2.2. Diğer Ses Verileri

EKO,"AI ile çalışan bir stetoskop"tur. Eko'nun kardiyak ürünleri, kalpteki kan akışının ürettiği normal ve anormal sesleri ayırt etmek için derin sinir ağlarını kullanır. Benzer şekilde, etiketli ekokardiyogram (EKG, diğer adıyla EKG) verilerinin kapsamlı veri tabanları üzerine kurulan sinir ağları, anormal kalp ritimlerini tespit eder. Aksi takdirde geleneksel bir stetoskop aracı, teletıp fonksiyonlarını kullanan hastalarda kardiyopulmoner fonksiyonun etkin bir şekilde izlenmesini sağlamak için kalp ve akciğer seslerini almak ve analiz etmek için öğrenme sistemlerine yerleştirilmiştir. Ön saflarda, Eko, doğrudan hastaları tedavi eden uygulayıcılara, kalbin ve/veya akciğerlerin "kablosuz oskültasyonuna" izin veren bir ürün paketi sunan bir üründür. Bu, önemli miktarda koruyucu ekipman giyen pratisyenlerin hastalarını uzaktan dinlemelerini sağlar [51].

Ses verileri tabanlı AI araçları Bina Ayrıca gibi başlatılması, getiriyor Cure için Öksürük, onların öksürük sesleri dayalı acı COVID-19 hastalığın bireylerin olasılığını skoru araçları geliştiriyorlar. Benzer bir araç Coughvid tarafından geliştirilmektedir. Eğer geliştirilirse, böyle bir araç, uygulayıcıların semptom olarak öksürük ile başvuran hastaların daha doğru triyajına girmesine yardımcı olabilir [51].

4.2.3. Video

Termal taramalı yüz kameralarının kullanımının video verilerinin kullanımı olarak sayılıp sayılmadığı tartışılabilir. Care.ai yüz tanıma (ve duygu ve niyet tespiti) gibi "sağlık için özerk izleme sensörlerinin" kullanım bilgisayarla görme araçları, paketi hastaların durumu, uygulayıcı-hasta etkileşimi, davranışlarını izlemekten platform "her zaman" bir desteklemek ve Mevzuata uygunluk ve idari veri kayıtları oluşturma ile ilgili olaylar. Bu sensör araçları paketi artık "ateş, terleme ve renk bozulmasını aramak" için termal tarama özelliğinden yararlanıyor. Bununla birlikte, termal görüntülemeyi yorumlamak için kullanılan belirli AI araçları ve bunun Care.ai araç takımının normal bir parçası olan sinir ağı tarafından yönlendirilen verilere nasıl entegre olduğu veya olmadığı açık değildir [52].

4.2.4. Resim

AI'nın COVID-19 teşhisine yönelik gücüne ilişkin ilk tartışma, Çin'deki radyolojik verileri analiz ederken AI'nın güçlü kullanımlarından lezyonları tanımlamak veya görüntü yorumlama süresini hızlveırmak için röntgen, Bilgisayarlı Tomografi (CT), Manyetik Rezonans Görüntüleme (MRI) ve Pozitron Emisyon Teknolojisi (PET) taramalarını analiz etmek için derin öğrenme teknikleri kullanıldı. Görüntü tanıma için evrişimli sinir ağları gibi sinir ağı teknikleri geliştirmeye yönelik benzer çabaların İngilizce dilindeki raporları, Radyoloji gibi mekanlarda artan bir sıklıkla görülmektedir [52].

Zatürre olduğundan şüphelenilen hastalar için göğüs röntgeni gibi tanısal görüntülemenin yorumlanmasında hız ve doğruluğu artırmak için derin öğrenmenin geliştirilmesi, behold.ai gibi şirketler tarafından sağlanan yeniliklerle hızlanıyor. Behold.ai, göğüs röntgeni üzerine bindirme için endişe duyulan alanları tanımlayan ısı haritaları oluşturmak için "kırmızı nokta" algoritmasını geliştirmek için derin öğrenmeyi kullvei. Behold.ai, "30.000'den fazla CXR üzerinde eğitilmiş ve sertifikalı radyologlardan ayrıntılı açıklamalar içeren kırmızı nokta algoritmasının", görüntülere dayalı olarak yorumlamayı, kavramayı ve eylemi katalize ettiğini öne sürüyor [52].

BioMind Bir ben, zaten beyinde lezyon sınıflveırması için derin öğrenmeyi kullanarak olarak tanımlanan, görüntü segmentasyon, görüntülerin yeniden ve görüntülerin yorumlanması dayalı önerilerin otomatik raporlama gerçekleştirmek için sinir ağı modelleri kullanır.

4.2.5. Metinsel Veriler

Görüntüler için derin öğrenme, görüntüleme temelinde tanıyı almaya yardımcı olurken, laboratuvar testleri COVID-19 tanılamanın önemli bir bileşeni olmaya devam ediyor. Surgisphere tarafından açıklveığı gibi, QuartzClinic sağlık veri analizi platformunun geliştiricisi, "koronavirüs enfeksiyonu olması muhtemel hastaları belirlemek için üç yaygın laboratuvar testini" kullanan bir "makine öğrenimi modeli" kullanan bir "karar destek aracı" geliştirdi. Bu araç, COVID-19 hastalarının örneklem büyüklüğünü artırmak için sağlık sistemleri arasında artan miktarda veri paylaşımı işbirliğinden yararlanır [52].

JVİON, "Eigen Sphere motoru" veya "milyonlarca hastanın on binlerce Eigen'e karşı haritalveığı n-boyutlu bir alan ile tahmin edilen, bireysel hastanın bilinen risklere yakınlığını modelleme konsepti üzerine inşa edilmiş bir klinik yapay zeka platformudur. Küreler. Her

bir Eigen Sphere, klinik ve/veya davranışsal olarak benzerlikler gösteren hastalardan oluşur". JVion COVID Topluluk güvenlik açığı Haritası"Risk altındaki popülasyonların belirlenmesi" için topluluk düzeyinde bir görünüm oluşturmak için kimliği gizlenmiş hasta kayıtları, nüfus sayımı bilgileri, nüfus istatistikleri ve sosyoekonomik veriler (örneğin istihdama erişim) dahil olmak üzere birden çok veri biçimini kullanır. Nöral ağları kullanan veya bireysel hastaların tanı ve tedavisi için oluşturulmuş diğer AI araçlarının aksine, JVion'un araç takımı, diğer tahmine dayalı modellemenin arka planına dahil edilen matematiksel modellemeye dayalı hasta ve topluluk risklerini azaltmak için oluşturulmuştur [53].

Esri, HERE, Garmin ve USGS gibi birden fazla kaynaktan gelen CBS verilerinin ve ilçe düzeyindeki verilerin kullanımına dayanan benzer haritalama teknolojisi, Definitive Healthcare, mevcut lisanslı ve personelli hastane yataklarının sayısını belirlemek için bir haritalama aracı oluşturdu. Bu sağlık hizmeti veri analizi şirketi, AI araçlarını kullanma sözü vermez, ancak AI kullanımlarına ilişkin açık iddialarda bulunan başkaları tarafından halihazırda kullanılan birçok veri kaynağını içerir. Qventus, mevcut hastane altyapı kapasitesini izlemek için benzer yatak kapasitesi haritalama kaynakları sağlar. Qventus ayrıca COVID-19 planlamasına yardımcı olmak için bir analiz panosu sunmaktadır [53].

4.3. CHATBOTLAR

Microsoft Azure, yeni CDC COVID-19 sohbet robotu Clara'nın bel kemiğidir. CDC, Microsoft'un sağlık hizmeti bot hizmetinin özelleştirilebilirliğini kullanarak, bireylerin COVID-19'un teşhisi veya tedavisi için ek sağlık hizmetleri arayışıyla ilgili kararlar alırken kullanmaları için bu yaygın olarak bulunan sohbet botunu oluşturdu. Gibi diğer sağlık sistemleri, Providence, bireylerin sağlayıcılarına bağlamak için, gerekirse, kendi risklerini anlamak ve sohbet botlara oluşturmak için Microsoftun araçlarını kullanıyor. Azure ya powered by İster diğer platformlar , COVID-19 chatbots kalitesi olan düzensiz olduğu bildirildi muhtemelen verilerin hızlı temposu, onları eğitmek için kullanılan akışları tarafından geliştirilen bir diğer konuşma motoru tabanlı uygulama, Curai , yardım hastaları anlamak ve semptomlarını açıklamak ve doktorlar hastaları anlamak için metin verileri kullanır. NLP, derin öğrenme ve bilgi tabanı araçlarını kullanan Curai araçları, hastaların ve pratisyenlerin hem teletıp hem de doğrudan iletişim ortamlarında etkileşime girmesine yardımcı olur [54].

4.4. SENSÖRLER

Hong Kong'daki COVID-19 izleme konusundaki erken tartışmalardan bilinen Biofourmis, evde karantina altındaki hastaları izlemeye yardımcı olmak için Biovitals Sentinel platformunu ve Everion biyosensörünü yeniden kullveı. "Optik, sıcaklık, elektrodermal, ivmeölçer ve barometre dahil" bu sensör takımı, Biovitals Sentinel pano platformunun ana bileşenlerini oluşturur.

Ouraring, sağlık çalışanlarının biyometrik verilerinin takibi için sınırlı bir çalışmada kullanılan bir biyosensördür. Devam eden çalışmada, Ouraring kullanıcıları, biyometrik verilerin "gelecekteki COVID-19 vakalarında başlangıç, ilerleme ve iyileşmeyi öngörebilecek kalıpları belirlemeye" yardımcı olup olmayacağını belirlemek için semptom anketlerine yanıt veriyor [42].

Scripps Research, sağlık çalışanlarının izlenmesi için özel olarak tasarlanmasa da, kalp atış hızı gibi sağlık verilerini izleyen birçok giyilebilir cihazdan herhangi birinin COVID-19 enfeksiyonlarını tahmin etmek veya izlemek için kullanılıp kullanılamayacağını belirlemek için araştırmalar yürütüyor.

4.5. AI UYGULAMA GELİŞTİRİCİLERİ

COVID-19 pveemisi sırasında sağlık pratisyenlerinin ihtiyaçlarına cevap vermek, inkar edilemez bir şekilde tüm toplumun çabasıdır. Yapay zeka alanında çalışan kişiler, sağlık uzmanlarına yardımcı olmak için ne yapabilir? Üretim topluluğu gibi başkaları hangi yapay zeka araçlarını şu vea sağlık çalışanlarına yardımcı olmak için kullanabilir?

Politika uzmanlarından, hatta çağrılarına yanıt Beyaz Saray, veri bilimcilerin, makine uzmanlar öğrenme ve yapay zeka uzmanları, ilaç geliştirme, tanı uygulamaları, iletişim izleme, bilgi üretimi ve izleme rehberlik için derived yeni bakış açısı bir topluluk olarak toplanıyor ve daha fazla. COVID-19 pveemisi ayrıca AI girişimlerini hasta ve uygulayıcı ihtiyaçlarını karşılamak için ürünler geliştirmeye yönlendiriyor. Kaggle yarışmalarına ve ilaç keşif yarışmaları gibi diğer yarışmalara katılmak, epidemiyologlar, doktorlar ve diğer ilgili alan uzmanlarıyla çalışmak, pveeminin keskin ucunda olanlara yardım etmenin en açık yoludur [54].

Ancak, AI/ML uzmanlarının şu vea optimal ortaklık fırsatlarını beklerken yapabileceği daha "sıradan" şeyler var. Kısaca bunlar şunlardır [55]:

i. Verilerin ADİLliğini iyileştirin
ii. Uygulamaları kontrol edin
iii. Mevcut sistemlerin modellerini doğrulama
iv. Önerilere olan güveni artırın

AI/ML ve diğer veri uzmanları, inşa edilen herhangi bir sistemin kalitesinin veri kalitesine bağlı olduğunu iyi bilirler. Genel olarak verilerin nispeten sınırlı olduğu ve CDC Collection, veri gölü, WHO'nun araştırma veritabanı, CORD-19, Go.Data, SAS gibi yalnızca birkaç güvenilir havuzun bulunduğu COVID -19 bağlamında GitHub deposu veya İşlevsel Genomik Platformu , sistemleri oluşturmak için malzeme bulmak ciddi bir zorluk olabilir. Sentetik veriler bu alan için faydalı olabilirken, verileri iyileştirmeye yönelik daha fazla temel çaba tekrar ziyaret edilmelidir. Ulusal Akademiler gibi veri uzmanlarının ve diğerlerinin 2018 ve 2019'da tekrar tekrar belirttiği gibi, kaliteli, birlikte çalışabilir, ADİL ve etik olarak yeniden kullanılabilir verilerin eksikliği, yapay zeka sistemlerinin sağlık alanındaki performansını engelliyor. COVID ilgili veri setleri bağlı meta kalitesini artırma böyle en olarak kuruluşlar için bir görevdir. Bu özel girişimlerle arayüz oluşturmak yardımcı olmanın bir yoludur, ancak genel olarak, faydası henüz bilinmeyen veri kaynaklarının adaletini geliştirmek de veri uzmanlarının yardımcı olabileceği işaret eder [56].

COVID-19 müdahalesi ve hazırlıklı olmak için başvurular oluşturma telaşı, güzel olabilecek ancak nihayetinde kullanışlı olmayan ürünlerin sayısını artırabilir. Bazı performans sorunları, geliştiricilerin uygulamalarını başlatmak için günlük kod denetimi görevlerinin üzerinden atlamaya çalışması nedeniyle olabilir. Bu performans sorunlarını tespit etmek, hem sistemlere güç sağlamak için kullanılan kodun açık olmasını hem de programları bulmak ve hatalarını gidermek için insan ve makine kodu analiz araçlarının açık kullanımını gerektirecektir. İçin ilgi yardımına özellikle merak olan AI ürünlerin bir kısmının yardımcı yukarıda tarif değerlendirilmesi, bu ürünler için kodu (PubMed üzerinden örneğin,) (örneğin GitHub) ya da destek AI/ML araştırma için belirgin işaretçiler edilmiştir [56].

Model doğrulama, herhangi bir öğrenme sisteminin performans takibi için devam eden bir görevdir. Herhangi bir modeli doğrulamak zordur, ancak değişen kalitede, değişen sayıda ilgili parametre ve değişen performans beklentilerinde düşük miktarda veri (eğitim veya test) içeren modelleri doğrulamak zorlu bir iştir. Bir modelin çıktısının son kullanıcılar için kullanışlılığını doğrulamak da bir diğer önemli doğrulama görevidir [56].

Dünyanın dört bir yanında bireyler ve gruplar, eyleme geçirilebilir öneriler için boğuşuyor. AI/ML uzmanlarının araştırmacıların hipotezlerine olan güvenlerini artırmalarına yardımcı olmasının bir yolu, araştırma geliştirme için literatür incelemeleri oluşturmak için NLP'yi kullanmak için Kaggle yarışmalarına katılmaktır. Ön saflardaki uygulayıcılar için kaynakların geliştirilmesine özel olarak, bir uygulayıcının bir öğrenme sistemi tarafından üretilen tavsiyeye sahip olması gereken güven derecesi, tavsiyelerin olumlu sonuçlara yol açtığı bir ortamda kullanım yoluyla ortaya çıkar. Ancak, bir öneri bildirimine ne kadar geniş bir güven aralığı eklenmesi gerektiğini anlamak için belirli bir uygulamanın başarı oranını toplamak, devam eden bir zorluktur.

4.6. KULLANILAN YAPAY ZEKA TEKNİKLERİNİN ANALİZİ

Çeşitli elektronik veri tabanlarında ortaya çıkan teknolojilerin tespit edilmesi, izlenmesi, teşhis edilmesi, taranması, gözetimi, haritalanması, izlenmesi ve önlenmesi için farkındalık yaratılması için çeşitli elektronik veritabanlarında literatür taramasına rehberlik etmek için Kitchenham'daki (2004) yönergeleri izleyerek sistematik literatür taraması (SLR) uygulanmaktadır. COVID-19 ile araştırılan elektronik veri tabanları Google Scholar, Scopus, Science Direct, PubMed, Institute of Electrical ve Electronics Engineers (IEEE) Xplore Digital Library, Association for Computing Machinery (ACM) Digital Library, Wiley Library ve Springer Link'tir. Bu derlemede izlenen adımlar, Kitchenham (2004) tarafından belirtilen prosedürler tarafından yönlendirilmiştir.) yani; araştırma stratejisi, çalışma seçimi (dahil etme/hariç tutma kriterleri), çalışma uygunluğu ve kalite değerlendirmesi [57].

4.6.1. Arama stratejisi

COVID-19 salgınının başlangıcından itibaren daha önce yayınlanmış çalışmalar şu arama dizisine göre arveı: Dijital Teknoloji "COVID-19" Ebola "HIV AIDS" Hastalık Tüberküloz Sıtma Müdahale İzleme "Sosyal Mesafe" "Teşhis Tedavi Önleme ve "Yapay zeka" Artırılmış Gerçeklik" "5G Hücresel teknoloji" "makine öğrenimi" "Tıbbi Nesnelerin İnterneti" [57].

4.6.2. Çalışma Seçimi (Dahil Etme ve Hariç Tutma Kriterleri)

COVID-19 salgınının başlangıcından itibaren İngilizce yazılmış hakemli makaleleri seçtik. Bu makaleler ayrıca başlık ve özete göre taranmıştır. Fikir yazılarını, hakemli olmayan

makaleleri, eksik makaleleri ve İngilizce çevirisi olmayan diğer dillerdeki çalışmaları hariç tutulmuştur.

4.6.3. Çalışma Uygunluğu ve Kalite Değerlendirmesi

Tüm makaleler, uygunluk ve kalite değerlendirmesi için tüm yazarlar tarafından iki kez tarvei. Makaleler başlıkları ve özetleri incelendi. Tüm kopyalar elendi. Gelişmekte olan teknolojiler hakkında ve COVID-19 ile ilgili bilgilerin yer aldığı tüm makalelerin dahil edilmesini sağlamak için, alınan her makale için ek çalışmalar için atıf zinciri gerçekleştirdik. Makalelerin kalite değerlendirmesinin doğruluk ve güvenilirlik derecesi Cohen Kappa istatistiği kullanılarak ölçülmüştür [57].

2020'de yayınlanan elektronik veri tabanlarından 51 makaleyi dahil ettik. Gelişmekte olan teknolojilerin aşağıdaki önemli uygulamalarını, bunların COVID-19 salgınıyla mücadeledeki rollerini ve ilgili zorluklarını Tablo 1'de gösterildiği gibi belirledik. Gelişmekte olan her teknoloji için faaliyetleri ve rolleri, tartışma bölümünün altındaki alt bölümlerde ayrıca analiz edildi. Çalışma, COVID-19 ile mücadeleyle ilgili aşağıdaki gelişmekte olan teknolojileri belirledi: AI; Sosyal medya platformları; IoMT; Sanal Gerçeklik/Artırılmış Gerçeklik; blok zinciri; Katmanlı üretim; 5G Hücresel teknoloji ve Akıllı Uygulamalar; Coğrafi Bilgi Sistemleri; Büyük veri; Otonom Robotlar [58].

Yapay Zeka algoritmaları, COVID-19 hastalarının hızlı tespiti, sınıflveırılması, tanımlanması, taranması ve miktar tayininde muazzam bir rol oynamaktadır. Bu yapay zeka algoritmaları, veri kümelerindeki anlayışlı kalıpları keşfetmek için makine öğrenimi, derin öğrenme ve bilgisayar vizyonunda kullanılmıştır. [57], veri eksikliği nedeniyle yapay zeka teknolojilerinin sınırlı kullanımları olduğunu belirtti. Ayrıca AI'nın Avrupa, Güney ve Kuzey Amerika ve Afrika gibi etkilenen kıtalarda COVID-19 vakalarının izlenmesi ve tahmin edilmesi konusunda tam olarak araştırılmadığını belirtti. Bu, AI modellerini eğitmek için çok miktarda geçmiş verinin olmamasına bağlanabilir, bu da gürültülü verilere ve sosyal medya verilerine dayanan AI tahmin modellerinin geliştirilmesiyle sonuçlanmaktadır. Bu, farklı veri formatları, veri stveardizasyonu ve birlikte çalışabilirlik eksikliği ve genellikle yanlış ve güvenilmez olan eksik değerler nedeniyle tahmin modelinin performansını ve doğruluğunu ciddi şekilde etkiler [58].

Mevcut literatür, Çin'in COVID-19 salgınıyla mücadelede AI teknolojilerinin uygulanmasında lider grup olduğunu gösteriyor. Amerika Birleşik Devletleri (ABD), Güney

Afrika, Brezilya ve Hindistan gibi ülkeler 5,595,835'lik yüksek COVID-19 vakaları kaydetmiştir; 589,886; 3,343,925; 17 Ağustos 2020 itibariyle sırasıyla 2.701.604; COVID-19 ile mücadelede yapay zeka tekniklerini tam ve başarılı bir şekilde uygulamamıştır [59]. Yüksek enfeksiyon oranına sahip bu ülkeler, yeni COVID-19 vakalarını tespit etmek, teşhis etmek, tanımlamak ve tahmin etmek için AI'yı kullanabilir. Çoğu ülke COVID-19'u, tamamlanması 2 güne kadar süren transkriptaz-polimeraz zincir reaksiyonu (RT–PCR) testi kullanarak teşhis ediyor ve şu vea RT–PCR test kitleri sıkıntısı vardır. Sağlık sistemleri, RT-PCR test kitlerine yönelik artan talep nedeniyle bunalmış durumda ve bu da bazı ülkelerin etkilenen nüfusu test etmek yerine yalnızca temaslı takibine odaklanmasına neden oldu. Bu nedenle, göğüs bilgisayarlı tomografi (BT) görüntülerini kullanarak COVID-19'un erken tespiti ve teşhisi için AI modellerine ihtiyaç vardır ve radyologların zamanını kurtarabilir. Örneğin, göğüs BT görüntülerini kullanarak COVID-19'u teşhis etmek için bir COVID-Net derin öğrenme modeli (%98,9 doğrulukla) geliştirdi. Ayrıca AI modelleri, COVID-19 aşı geliştirme ve ilaç keşfi geliştirmek için kullanılabilir. Örneğin, Flinders Üniversitesi'nin trilyonlarca sentetik bileşik üreten ve aşı adjuvanı olarak en iyi deneme adaylarını belirleyen Ligvelar için Arama Algoritması (SAM) adlı AI tabanlı programı uyguladığını ve böylece COVID-19 aşı geliştirme sürecini azalttığını belirtiyor. Bu, sağlık politika yapıcılarına, sağlık uzmanlarına, kaynakları yüksek riskli bölgelere etkin bir şekilde tahsis etme ve araştırmayı kolaylaştırma konusunda fayda sağlayabilir. Yapay zeka teknolojilerinin COVID-19'un yükünü makul bir şekilde azalttığı şüphesizdir; ancak bu teknolojiler aşağıdaki gibi zorluklarla karşı karşıyadır [60]: (1) AI modellerini eğitmek ve test etmek için büyük bir COVID-19 veri kümesine sınırlı erişim; (2) Yapay zeka modellerinin güvenilirliği ve doğruluğu, yapılveırılmamış, gürültülü ve aykırı COVID-19 verilerinin mevcudiyeti ile de tehdit altındadır; (3) Asemptomatik COVID-19 şüpheli bireyleri tespit edememek [60].

COVID-19 ile mücadelede AI modellerinin uygulanmasında önemli ilerleme var. Aşağıdaki etkinlikleri gerçekleştirmek için AI kavramlarının, özellikle derin öğrenme modelleri ve makine öğrenimi modellerinin uygulveığını göstermektedir [61]:

i. Göğüs BT görüntülerini kullanarak COVID-19'un tanımlanması
ii. Göğüs BT görüntülerinden COVID-19 tespiti
iii. COVID-19 kantitatif göğüs BT değerlendirmesi
iv. BT görüntü analizi kullanılarak COVID-19'un sınıflveırılması
v. COVID-19 hastalarının hızlı teşhisi

vi. COVID-19 vakalarını tahmin etme
vii. COVID-19 ölüm oranını tahmin etme
viii. COVID-19 hastalarının ve temas kurulacak kişilerin takibi

Ancak bu modeller, kullanılan COVID-19 veri setine ve uygulanan farklı algoritmalara göre farklı performans gösterdi. Örneğin, bu değerler %90'ın üzerinde doğrulukla daha iyi performans göstermiştir. Bu çalışmaların kendi sınırlamaları vardır. Yukarıda belirtilen sınırlamalara rağmen, AI modelleri COVID-19 pveemisine önemli ölçüde katkıda bulunur. Tablo 2Çin'in COVID-19'u tespit etme, izleme, teşhis etme, tarama, gözetleme, haritalama ve izleme için AI modellerini uygulayan lider ülke olduğunu gösteriyor. Bu, COVID-19 veri kümelerinin kullanılabilirliği ile ilişkilendirilebilir.

IOMT, birbirine bağlı tıbbi ekipman, akıllı sağlık uygulamaları ve akıllı sensörler aracılığıyla sağlık ve tıp alanlarında Nesnelerin İnterneti (IOT) kavramlarının, araçlarının ve ilkelerinin uygulanmasını içerir. Ayrıca, özellikle sağlık hizmeti sunumunu iyileştirmek için akıllı uygulamalar ve akıllı giyilebilir cihazlar geliştirmekten oluşur. COVID-19 salgını sırasında, IoMT sağlık hizmetlerinin sunulma şeklini değiştirerek, kısıtlı hareketlilik nedeniyle fiziksel teması uzaktan sağlık hizmeti sunumuna kaydırıyor. Bu, sağlık sistemleri üzerindeki yükü azaltmak için sağlık sistemlerine entegre edilen çeşitli IoMT uygulamalarıyla açıkça görülmektedir. ABD, Çin, Hindistan, İsrail, Polonya, Hırvatistan, Kanada, Bahreyn, Singapur, Avustralya, Kolombiya, Gana ve Avusturya dahil olmak üzere birçok ülke, canlı web seminerleri, uzaktan danışma ve video konferans gibi teletıp stratejilerini uyguladı; COVID-19 salgınıyla mücadele için telesağlık ve akıllı termometreler. Bu ülkeler, gerçek zamanlı COVID-19 veri erişimini iyileştirmek için IoMT uygulamalarını hayata geçirdi. IoMT uygulamaları şunlar için kullanılır [62]:

i. Çevrimiçi bir COVID-19 gerçek zamanlı güncelleme veritabanı oluşturun
ii. COVID-19 tanı modellerinin gerçek zamanlı güncellenmesi
iii. Sağlık uzmanlarına COVID-19 tedavisini yönetmeleri için rehberlik edin
iv. Ön saflardaki sağlık profesyonelleri aracılığıyla danışmanlık hizmetleri sağlayın
v. Tanı konan COVID-19 hastalarının takibi
vi. COVID-19 etkin noktalarının haritalanması
vii. Temaslı kişiler, işaretler, semptomlar ve konum hakkında sık sık bildirim göndererek COVID-19 farkındalığı yaratın

Karantina tesisinden çıkmasına izin verilip verilmediğini belirlemek için kişinin kimliğini blok zinciri kayıtları ile ilişkilendiren ve dolayısıyla riski en aza indiren blok zinciri güvenlik sistemi blokzincir tabanlı ve IoMT kavramlarını kullanarak elektronik tıbbi kayıtların güvenliğini sağlamaktadır [62].

Blockchain, işlemlerin gerçekleşip gerçekleşmediğini doğrulayarak veri güvenliğini artırmak için iki taraf arasında kayıtların güvenliğini sağlamada sağlık sistemleri ve biyomedikal dahil olmak üzere çeşitli alanlarda sürekli olarak tanınmaktadır. COVID-19 salgınıyla savaşmak için Blockchain'in uygulanmasına dair sınırlı kanıt var. Bununla birlikte, blok zinciri teknolojisi Kanada'da Civitans adlı bir uygulamada uygulanmıştır. IBM ayrıca, bulut platformlarında sağlık verilerini ve konumunu paylaşırken ve aktarırken güvenliği sağlamak için MiPasa adlı bir blok zinciri uygulaması geliştirdi.. COVID-19 ile mücadelede sağlık uzmanları ve bireyler, sağlık verilerinin güvenliğini ve gizliliğini sağlamak için bu blok zinciri uygulamalarını kullanabilir [62].

Sağlık sistemlerinde blok zincir teknolojisini uygulamanın zorlukları aşağıdakilere atfedilir [63]:

i. Mevcut blok zinciri Uygulama programlama arayüzünü (API) sağlık bilgi sistemleriyle entegre etmek için teknik beceri eksikliği
ii. Sağlık sistemlerinde blok zincirinin potansiyeli hakkında farkındalık eksikliği
iii. API'ler üçüncü bir tarafça sağlveığından ölçeklenebilirlik sorunları

Blockchain'i sağlık sistemlerine entegre etmek, bazı etik sorunlar ve teknolojinin nispeten yeni ve olgunlaşmamış olması nedeniyle hala bir zorluktur.

Blockchain teknolojisinin sağlık sistemlerine entegrasyonuna ilişkin net olmayan WHO düzenlemeleri ve standartları API ve bulut tabanlı platformlar aracılığıyla veri sızıntısı, sağlık sistemlerinde benimsenmesini tehdit etmektedir.

5G teknolojisi, gerçek zamanlı iletişim için çok önemli olan en hızlı internet hızını ve yüksek bant genişliğini sağlar. COVID-19 sırasında bu teknoloji, sağlıkla ilgili akıllı uygulamaları, büyük veri hizmetlerini ve Tıbbi Nesnelerin İnternetini benimseyen halk sağlığı yönetiminde hayati bir rol oynamaktadır. 5G komplo teorisinin yanı sıra, 5G teknolojisinin düşük gecikme, yüksek hızlı iletim ve COVID-19 sağlık verilerinin ve güvenilirliğinin paylaşılması gibi faydalarının daha iyi anlaşılması ve daha geniş anlaşılması vardır. Örneğin, Çin'de 5G teknolojisinin kurulumu, birçok hastanede uzaktan danışma, 5G teknolojisine bağlı akıllı

kameralar, akıllı termometreler (temassız alın kızılötesi dijital termometre), akıllı dezenfeksiyon insansız araçları, akıllı swab alan tıbbi robot ve yüksek hızlı canlı yayın 5G teknolojisi Çin ve ABD'de yavaş yavaş kullanıma sunuluyor ancak aynı zamvea aşağıdaki gibi zorluklarla da karşı karşıyadır [63]:

i. 5G teknolojisi, büyük sermaye enjeksiyonları gerektirir ve mevcut ağ teknolojisine özgü bant genişliği, gecikme ve esneklik sorunlarının üstesinden gelir.
ii. Akıllı uygulamaların sağlık sistemlerine entegrasyonu, sağlık gizliliğinin ihlaline neden olabilir
iii. 5G henüz gelişme aşamasındadır ve mevcut ağ altyapısı ile desteklenmeyebilir
iv. 5G teknolojisi aracılığıyla paylaşılan ve iletilen sağlık verileriyle ilgili WHO yönergesi yok

Bazı ülkelerde, komplo teorisi ve yanlış anlaşılmasından sonra 5G teknolojisinin benimsenmesi hala tartışmalıdır. Sanal gerçeklik teknolojisi 1990'ların sonlarından beri var olmuştur, ancak halkın beklentileri ile teknolojik sınırlamalar arasında büyüyen bir boşluk nedeniyle ilgi yavaş yavaş kaybolana kadar tam olarak keşfedilmemiştir. 1990'ların sonlarında boyut, Bulantı, baş dönmesi, geçici olarak görme bozukluğu ve varlık hissi eksikliği gibi sanal gerçeklik teknolojik sınırlamaları olumsuz etkiler olarak bildirilmiştir. Hareket algılama, etkileşimli görüntüleme sistemleri ve kinestetik iletişim gibi dijital dönüşümdeki son atılım, tıp eğitiminde önemli kilometre taşlarına ulaşan sanal gerçeklik teknolojisinde bir evrim getirdi. Sanal gerçeklik uygulamaları bilişsel ve psikolojik engellerin, bozuklukların üstesinden gelir ve COVID-19 tıp eğitim ve öğretiminde benzeri görülmemiş fırsatlar sunar [64]. Sanal gerçeklik teknolojisi, sanal bir ortamda fiziksel gerçekliği simüle eden etkileşimli, yapay üç boyutlu bilgisayar tarafından oluşturulmuş bir dünya sağlamaktadır. Bu, fiziksel olmayan teması ve sosyal mesafeyi desteklediği için sağlık çalışanlarının eğitim ve öğretiminde kullanılabilir. Sanal gerçeklik teknolojisinin kullanıcıları, gerçek dünyaya benzer duyusal bilgileri algılayan VR'nin giriş ve çıkış cihazlarının arayüzü aracılığıyla kendilerini sistemle ilişkilendirir. Sanal gerçeklik teknolojisi, sanal bir ortamda duyguları göstermek üzere programlanmış giriş sensörleriyle entegre edilmiş başlıklardan oluşur. Sürükleyici VR sistemi, güvenli bir sanal ortamda içsel deneyim sağlamak için Başa Monte Ekran (HMD) veya Başa Bağlı Ekran (HCD) üzerine sabitlenmiş birçok görsel, işitsel ve dokunsal duyusal yön sağlamaktadır [65].

HCD ve HMD cihazları, taşınabilirlik ve minyatürleştirme gibi içsel özellikleri nedeniyle piyasada daha baskındır. Bu özellikler, sağlık çalışanlarının ve topluluk katılımının COVID-19 önleme, farkındalık, eğitim ve öğretim sırasında bilgi, beceri, hareketlilik ve bakım kalitesini iyileştirmek için bilişsel yeteneklerini geliştirmelerine yardımcı olur. Sürükleyici sanal gerçeklik ve e-öğrenme platformlarının entegrasyonu, öğrenim kurumlarındaki öğrencilerin sanal 3 boyutlu COVID-19 virüsünü, anatomik konumlarını keşfetmelerine ve fiziksel gerçeklikte imkansız ve zor bir şekilde nasıl bulaştığını görselleştirmelerine olanak tanır. Bu aynı zamvea okullarda, kolejlerde ve üniversitelerde farkındalık yaratılmasına da yardımcı olabilir. Ayrıca sanal gerçeklik, COVID-19'dan etkilenen ve travma, anksiyete gibi zihinsel sağlık sorunları yaşayan kişilere danışmanlık yapmak için kullanılabilir [65].

Ancak, eğitim ve öğretimde sanal gerçekliğin benimsenmesi, muazzam fırsat ve faydalarına rağmen bazı sınırlamalar ve engellerle karşılaşmaktadır. Gerçekçi sanal ortamı simüle etmek için yüksek maliyet ve bilgi işlem gücü, özellikle düşük gelirli ülkelerde tıp eğitiminde sanal gerçekliğin kullanılmasının başlıca sınırlamalarından bazılarıdır. Google Cardboard uygun fiyatlı sanal gerçeklik cihazları üretse de, ancak yetersiz destek altyapısı ve yavaş internet hızı nedeniyle sanal gerçeklik teknolojisinin tam olarak hayata geçirilmesini tehdit ediyor, dolayısıyla internet hızını artırmak için 5G teknolojisine ihtiyaç duyuluyor. Bu, tıp eğitiminde VR'yi benimsemenin başka bir dezavantajıdır. Diğer bir sınırlama, sanal gerçeklik uygulamaları ve sınıf düzenine en uygun sanal dünyalar oluşturmak için teknik sanal gerçeklik uzmanlarının bulunmamasıdır [65]. Ayrıca sağlık uzmanlarına, hastalara ve COVID-19 görev ekibine VR cihazlarının nasıl kullanılacağı konusunda eğitim vermek de zaman alıyor. Örneğin, başa takılan sanal gerçeklik cihazları yanlış ayarlanmışsa görüntüler ve metinler bulanık olabilir ve sanal dünyada nasıl gezinileceğini öğrenmenin ek bilişsel yükü, sağlık eğitimcilerinin derslerini planlamak için daha fazla zaman ve öğrencilere nasıl kullanacaklarını öğretmek için daha fazla zaman gerektirir. VR cihazları ve uygulamaları [66].

Coğrafi bilgi sistemleri (CBS) ve küresel konumlveırma sistemi (GPS) uygulamaları, gerçek zamanlı haritalama, izleme ve COVID-19 salgınıyla mücadele sağlayabilir. Bu ortaya çıkan teknolojiler, belirli bir süre boyunca gelişen iletişim araçları olarak hareket eder ve afet yönetimini modellemek, Sıtma, Ebola, Kolera ve sarıhumma gibi bulaşıcı hastalıkları anlamak ve izlemek için başvurdular [52].

Örneğin, hanelerin koordinatlarını ve insanların çevre ile nasıl etkileşime girdiğine dair içgörüler sağlayarak kolera önleyici tedbirleri anlamak için uydu tabanlı kayıt sistemlerini kullanarak kolera vakalarını haritalamak için GPS uygulanmıştır. GIS araçları, sıcak noktaları haritalamak için konum koordinatları ile COVID-19 pveemi vakaları arasındaki ilişkiyi haritalayabilir ve görselleştirebilir. COVID-19 pveemisinin ortasında, COVİD-19'un yayılmasını analiz etmek ve görselleştirmek için CBS araçları çok önemlidir. Örneğin, Johns Hopkins Üniversitesi Sistem Bilimi ve Mühendisliği Merkezi, COVID-19'un yayılmasını izlemek için ArcGIS Online'ı kullanmaktadır. DSÖ ayrıca salgın kaynağını haritalamak için ArcGIS Operations Dashboard'u uygular, ABD, COVID-19 verilerini derlemek ve COVID-19 onaylı vakaların çevresinde veya yakınında yaşayan insanları uyarmak için HealthMap'i kullanır. Çin'deki "yakın temas dedektörü" uygulaması gibi CBS araçları, insanların göç modellerini analiz eden ve bilinçli kararlar veren büyük veri ve IoT veri işleme araçlarını destekler. CBS ve GPS uygulamaları ayrıca aşağıdakiler için çok yararlı olabilir [66]:

i. Gerçek zamanlı COVID-19 coğrafi konum güncellemeleri sağlamak
ii. Sosyal mesafeyi ve kısıtlı insan sayısını ihlal eden halka açık etkinliklerin haritalanması
iii. COVID-19 KKD'lerinin ve ilaçlarının etkin bir şekilde tahsis edilmesini sağlamak için kaynakların dijital tedarik zinciri haritaları aracılığıyla dağıtılması
iv. COVID-19 için mekansal segmentasyon ve dinamik haritalama
v. Sosyo-ekonomik ve çevresel değişkenler gibi COVID-19 bulaşma risk faktörlerini belirlemek

Bununla birlikte, COVID-19 ile mücadele için CBS uygulamalarının uygulanması aşağıdaki zorluklardan etkilenmektedir: (1) mekansal haritalama ve görselleştirme için mekansal COVID-19 verilerine sınırlı erişim, (2) irtibat kişilerini izlemek için düzenlemelerin değiştirilmesini gerektirir.

SONUÇ

COVID-19, küresel olarak neredeyse tüm ülkeleri etkilemiş ve pandeminin sağlık sistemlerinde neden olduğu çeşitli sorunların üstesinden gelmek için çeşitli gelişmiş ve gelişmekte olan teknolojiler gerekmektedir. COVID-19, hastalığı yayma şansını artıran ters transkripsiyon-polimeraz zincir reaksiyonu (RT-PCR) COVID-19 test kiti, saptama, tarama ve izleme araçları konusunda muazzam bir eksiklik yaşayan ülkelerde şiddetlidir. 10 Kasım 2020 itibariyle, COVID-19 için onaylanmış bir tedavi mevcut değildir. Bu nedenle mevcut önlemler, gözetim ve sınırlamaya dayanmaktadır.

Sokağa çıkma kısıtlamaları, seyahat kısıtlamaları ve COVID-19 vakalarının sürekli artmasıyla karşı karşıya kalan insanlar, enfekte ülkelerin sağlık sistemlerini bunaltan COVID-19'un küresel acil durumuna yanıt vermede gelişmekte olan teknolojilerin rolünü göz önünde bulundurmalıdır. Jeo-uzamsal teknoloji, yapay zeka, büyük veri, bulut bilişim, teletıp, blok zinciri, 5G teknolojisi, akıllı uygulamalar, IoMT, robotik ve katmanlı üretim gibi gelişen teknolojiler, epidemiyolojik modelleme, akıllı yaşam takibi ve afet yönetiminde açıkça görüldüğü gibi büyük ölçüde önemlidir. Örneğin, küresel konumlandırma teknolojileri, yardım ve rehabilitasyon amaçları için kesin afet konumları sağlamaktadır. Aynı ideoloji, COVID-19 salgınıyla mücadeleye dahil edilebilmektedir. Örneğin, gelişen teknolojiler, etkili COVID-19 tespiti, izleme, teşhis, tarama, gözetim, izleme ve farkındalık sağlamak için sağlık hizmeti sunumunu destekleyebilir. Bu tür teknolojiler, COVID-19 virüsünün yayılmasını, temas takibini, yüksek riskli hastaların belirlenmesi, COVID-19 etkin noktalarının haritalanması, gerçek zamanlı vaka gözetimi, tarama, sağlık profesyonelleriyle gerçek zamanlı iletişim COVID-19 için yenilikçi uygulamalardandır. Ayrıca, gelişmekte olan teknolojiler, planlamayı, raporlama sürecini, tedaviyi, temaslı izlemeyi, kaynakların önceliklendirilmesini ve tahsisini, vaka bazlı sürveyans sistemini, ilaç ve aşıların geliştirilmesini nihai olarak iyileştiren COVID-19 kılavuzları, yanıtları ve politikaları geliştirmede muazzam bir rol oynayabilmekte ve farkındalık yaratmaktadırlar.

Gelişmiş ve gelişmekte olan ülkelerde salgın izleme, virüs izleme, kontrol, tedavi, kaynak tahsisi, aşı geliştirme, salgınları tahmin etme ve güvenlik açıklarındaki küresel çabaların etkinliğini etkin bir şekilde geliştirmek için teknolojilere acilen ihtiyaç duyulmaktadır. Enfekte olmuş ülkeler temaslı izlemeye, vakaların ve temaslıların karantinaya alınmasına, aktif vaka bulma ve test etmeye güven artmaktadır. Bununla birlikte, Ebola salgını ile ilgili

önceki deneyimlerden temaslı izleme sürecinin zorlukları bilinmektedir. Bu zorluklar, ilgili kişinin kimliğinin belirlenmesi, ilgili kişilerin güvenliğinin ve mahremiyetinin ihlali, ilgili kişilerin kaydedilmesi, ilgili kişilerin bulunması, temaslı izleme personelinin izlenmesi, temaslı izleme personelinin damgalanmaya yol açan COVID-19'a maruz kalmasının artması ve temaslı izlemeyi içermektedir. Örneğin, bazı temaslı kişilerin fiziksel adresleri yoktur. Bazıları sokak adlarının ve kimlik kartlarının olmadığı kırsal alanlarda yaşamakta, bazı kişiler takma ad kullanmakta, bu nedenle temas izleme personeli yalnızca irtibat kişilerinin fiziksel tanımlarına güvenmek zorunda kalacaktır. Bu zorlukları hafifletmek için ortaya çıkan teknolojiler, COVID-19 ile mücadele için sağlık hizmeti sunumunu destekleyebilmektedir.

COVID-19 ile mücadelede ortaya çıkan teknolojilerin uygulanmasındaki tüm önemli ilerlemeye rağmen, tespit, izleme, teşhis, tarama, gözetim, haritalama, izleme için bu teknolojilerin daha fazla uygulanmasına hala ihtiyaç vardır ve bu durum farkındalık yaratmaktadır. COVID-19 verilerinin boyutu, kullanılabilirliği ve erişilebilirliği, AI modellerinin, GIS konseptlerinin ve IoMT uygulamalarının performansını iyileştirmektedir. Gelecekteki çalışmalar mevcut teknolojileri güçlendirmeye odaklanmalıdır ve COVID-19'un erken ayırıcı tanısı için sağlam, hesaplamalı olarak akıllı bir modelin ortaya çıkmasına güçlü bir ihtiyaç vardır. Ayrıca, gelecekteki çalışmalar, insanların verilerinin güvenliğini ve gizliliğini gözlemlerken COVID-19 salgınıyla mücadele ederken ortaya çıkan teknolojilerin etik çerçevesine ve kabul edilebilir kullanımına odaklanmalıdır.

REFERANSLAR

[1] Maged, N. K., & Estella, M. G. (2020). Geographical tracking and mapping of coronavirus disease COVID-19/severe acute respiratory syndrome coronavirus 2 (SARS-CoV-2) epidemic and associated events around the world: How 21st century GIS technologies are supporting the global fight against outbr. International Journal of Health Geographics, 19(8), 1–15.

[2] Şeyhanlıoğlu, H., Kurçer, T. U., & Serdar, M. (2021). 21. Yüzyıl Dünya Düzeni'nin Araçları: Kovıd-19 Ve Yapay Zekâ. *Assam Uluslararası Hakemli Dergi*, *8*(19), 147-163.

[3] Cohen, J. (1968). Weighted kappa: Nominal scale agreement provision for scaled disagreement or partial credit. Psychological Bulletin, 70(4), 213–220.

[4] WHO. https://www.who.int/ (15.12.2021).

[5] Kitchenham, B. (2004). Procedures for performing systematic reviews. Avail-able from http://www.inf.ufsc.br/ aldo.vw/kitchenham.pdf.

[6] Pirim, A. G. H. (2006). Yapay zeka. *Journal of Yaşar University*, *1*(1), 81-93.

[7] Uğur, A., & Kınacı, A. C. (2006). Yapay zeka teknikleri ve yapay sinir ağları kullanılarak web sayfalarının sınıflandırılması. *XI. Türkiye'de İnternet Konferansı (inet-tr'06), Ankara*, *1*(4).

[8] Demirhan, A., Kılıç, Y. A., & İnan, G. (2010). Tıpta yapay zeka uygulamaları.

[9] Atalay, M., & Çelik, E. (2017). Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamalari-artificial intelligence and machine learning applications in big data analysis. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, *9*(22), 155-172.

[10] Zhang, H. (2017). Head-mounted display-based intuitive virtual reality training system for the mining industry. International Journal of Mining Science and Technology, 27(4), 717–722.

[11] Elliot, M., Fanwell, V., & Kinsley, K. (2018). A tool to predict the possibility of social unrest using sentiments analysis-case of Zimbabwe politics 2017-2018. International Journal of Science and Research, 6(10), 1541–1545.

[12] Aydogan, M., & Sener, A. (2020). An Artificial Intelligence Application in Health Developed on Covid-19 Documents. *Journal of Health, Medicine and Nursing*, *75*, 58-66.

[13] Karanfiloğlu, M., & Nurat, K. A. R. A. (2020). İletişimin Dijitalleşmesi: Pandemi (Covıd-19) Ve Enformasyon Teknolojileri. *Ajıt-E: Bilişim Teknolojileri Online Dergisi*, *11*(42), 87-99.

[14] Oran, İ. B. (2020). Türkiye'de Yapay Zeka Ve Robotik Teknolojileri Sektörünün Gelişimi & Covid-19 Etkisi. *Turan-Sam*, *12*(48), 516-523.

[15] Abdelhafid, Z., Fouzi, H., Abdelkader, D., & Ying, S. (2020). Deep learning methods for forecasting COVID-19 time-Series data: A Comparative study. Chaos, Solitons & Fractals, 140, 1–13.

[16] Abolfazl, M., Behzad, V., & Kiara, M. (2020). GIS-based spatial modeling of COVID-19 incidence rate in the continental United States. Science of the Total Environment, 728(1), 67–75.

[17] Aishwarya, K., Puneet, K., & Ankita, S. (2020). A review of modern technol-ogies for tackling COVID-19 pandemic. Diabetes & Metabolic Syn-drome: Clinical Research & Reviews, 14(4), 569–573.

[18] Benny, P. & Eyal, R. (2020). A proposal for a privacy-preserving bluetooth based contact tracing scheme for hamagen. Available from https:// www.cs.technion.ac.il/ biham/Workshops/Cyberday/2020/Slides/ benny-pinkas.slides.pdf.

[19] Boulos, M. K., & Estella, M. G. (2020). Geographical tracking and mapping of coronavirus disease COVID-19/severe acute respiratory syndrome coronavirus 2 (SARS-CoV-2) epidemic and associated events around the world: how 21st century GIS technologies are supporting the global fight against outbr. International Journal of Health Geographics, 19(8), 1–12.

[20] Javaid, M., & Abid, H. (2020). Virtual reality applications toward medical field. Clinical Epidemiology and Global Health, 8(2), 600–605.

[21] Kwabena, A., & Shankar, K. (2020). Application of geospatial technologies in the COVID-19 fight of Ghana. Transactions of the Indian National Academy of Engineering, 5, 193–204.

[22] Mehtar, S., Wolfgang, P., Ndèye, A. L., & Abdoulaye, B. (2020). Limiting the spread of COVID-19 in Africa: one size mitigation strategies do not fit all countries. The Lancet Global Health, 8(7), E881–E883.

[23] Nataliya, S., & Nadezhda, B. (2020). How soviet legacies shape Russia's response to the pandemic: Ethical consequences of a culture of non-disclosure. KIE Journal, 12(3), 22–32.

[24] Raju, V., Mohd, J., HaleemKhan, I., & Abid, H. (2020). Artificial Intelligence (AI) applications for COVID-19 pandemic. Diabetes & Metabolic Syn-drome: Clinical Research & Reviews, 14(4), 337–339.

[25] Sera, W., Mamas, A. M., Eric, T., & Harriette, G. C. V. S. (2020). Applica-tions of digital technology in COVID-19 pandemic planning and response. The Lancet, 2(8), 435–440.

[26] Swati, S., & Chandana, M. (2020). Application of cognitive Internet of Medical Things for COVID-19 pandemic. Diabetes & Metabolic Syn-drome: Clinical Research & Reviews, 14(5), 911–915.

[27] Thiele, C. (2020). Stop Corona–Theses and antitheses on the use of tracking apps in the corona crisis. Journal of Information Law, 7(2), 152–158.

[28] Tivani, P. M.-T., & Ellen, D. C. (2020). Blockchain and artificial intelligence technology for novel coronavirus disease 2019 self-testing. Diagnos-tics, 10(4), 198–209.

[29] Vinay, C., Vikas, H., Vatsal, G., & Mohsen, G. (2020). A comprehensive review of the COVID-19 pandemic and the role of IoT, Drones, AI, Blockchain, and 5G in Managing its. IEEE Access, 8, 1–41.

[30] Wang, L., Alexander, W. & Zhong, Q.L. (2020). COVID-Net: A tailored deep convolutional neural network design for detection of COVID-19 cases from chest X-ray images. Arvix, pp. 1–14.

[31] Wu, D., Tiantian, W., Qun, L., & Zhicong, Y. (2020). The SARS-CoV-2 out-break: What we know. International Journal of Infectious Diseases, 94 (8), 44–48.

[32] Zixin, H., Ge, Q., Jin, L. & Xiong, M. (2020). Artificial intelligence forecast-ing of Covid-19 in China. Arxiv, 34(15), 1–20.

[33] Elliot, M. (2020). Integrating emerging technologies into COVID-19 con-tact tracing: Opportunities, challenges and pitfalls. Diabetes & Meta-bolic Syndrome: Clinical Research & Reviews, 14(6), 1631–1636.

[34] Zheng, J. (2020). SARS-CoV-2: An emerging coronavirus that causes a global threat. International Journal of Biological Sciences, 16(10), 1678–1685.

[35] Muz, F. N. Ö., Kılınç, A., & Önsüz, M. F. (2020). Covıd-19 Pandemisinde Yapay Zekanın Kullanımı. *Estüdam Halk Sağlığı Dergisi*, *5*, 178-183.

[36] Arslan, İ., & Karagül, S. (2020). Küresel bir tehdit (COVID-19 salgını) ve değişime yolculuk. *Üsküdar Üniversitesi Sosyal Bilimler Dergisi*, (10), 1-36.

[37] Şahin, M. (2020). Corona Virüsün (Covid-19) Dünya Düzenine Etkileri. *Takvim-i Vekayi*, *8*(1), 72-79.

[38] Mbunge, E. (2020). Effects of COVID-19 in South African health system and society: An explanatory study. Diabetes & Metabolic Syndrome: Clinical Research & Reviews, 14(6), 1809–1814.

[39] Vinay, K.R. & Lei, Z. (2020). Time series forecasting of COVID-19 transmis-sion in Canada using LSTM networks. Chaos, Solitons & Fractals, 135.

[40] Wasim, A., Josep, V.-A., Joseph, D., & López, S. (2020). COVID-19 and the 5G conspiracy theory: Social network analysis of Twitter data. Journal of Medical Internet Research, 22(5), e19458.

[41] Whitworth, J. (2020). COVID-19: a fast evolving pandemic. Transactions of the Royal Society of Tropical Medicine and Hygiene, 114(4), 241–248.

[42] Wim, N. (2020). Artificial intelligence vs COVID-19: limitations, constraints and pitfalls. Springer Nature, 23(10), 1–5.

[43] Ertoy, U., & Akçay, M. (2021). Covid-19 Virüsü Salgını İle Mücadelede Büyük Veri Çalışmaları: Çin Örneği. *Journal Of Scientific, Technology And Engineering Research*, *2*(2), 4-14.

[44] Canbay, Y., İsmetoğlu, A., & Canbay, P. (2021). Covid-19 Hastalığının Teşhisinde Derin Öğrenme Ve Veri Mahremiyeti. *Mühendislik Bilimleri Ve Tasarım Dergisi*, *9*(2), 701-715.

[45] Agbehadji, I. E., Bankole, O. A., Alfred, B., & Richard, C. M. (2020). Review of big data analytics, artificial intelligence and nature-inspired comput-ing models towards

accurate detection of COVID-19 pandemic cases and contact tracing. International Journal of Environmental Research and Public Health, 17(15), 1–16.

[46] Antonio, C., Ruggeri, A., Fazio, M., Galletta, A., Villari, M., & Romano, A. (2020). Blockchain-based healthcare workflow for tele-medical laboratory in federated hospital IoT clouds. Sensors, 20(9), 2590–2600.

[47] Arni, S. R. S. R., & Jose, A. V. (2020). Identification of COVID-19 can be quicker through artificial intelligence framework using a mobile phone–based survey when cities and towns are under quarantine. Infection Control & Hospital Epidemiology, 41(7), 826–830.

[48] Chuansheng, Z., Xianbo, D., Qing, F., Qiang, Z., Jiapei, F., Hui, M., … Xinggang, W. (2020). Deep learning-based detection for COVID-19 from chest CT using weak label. Medrxiv, pp.1–13.

[49] Ensheng, D., Hongru, D., & Lauren, G. (2020). An interactive web-based dashboard to track COVID-19 in real time. The Lancet, 20(5), 533–534.

[50] Fatima, M. S., Abu-Naser, S. S., Alajrami, E., Abu-Nasser, B. S., & Alashqar, B. A. (2020). COVID-19 Detection using Artificial Intelli-gence. International Journal of Academic Engineering Research, 4(3), 18–25.

[51] Hu, Z., Song, C., Xu, C., Jin, G., Chen, Y., Xu, X., … Shen, H. (2020). Clinical characteristics of 24 asymptomatic infections with COVID-19 screened among close contacts in Nanjing, China. Science China Life Sciences, 63(5), 706–711.

[52] Javaid, M., Haleem, A., Vaishya, R., Bahl, S., Suman, R., & Vaish, A. (2020). Industry 4.0 technologies and their applications in fighting COVID-19 pandemic. Diabetes & Metabolic Syndrome: Clinical Research & Reviews, 14(4), 419–422.

[53] Kleinermann, F., De Troyer, O., Mansouri, H., Romero, R., Pellens, B. & Bille, W. (2017). Designing semantic virtual reality applications. Citeseerx.

[54] Li, B., Yang, D., Wang, X., Tong, L., Zhu, X., Zhong, N., … Song, Y. (2020a). Chinese experts' consensus on the internet of things-aided diagnosis and treatment of coronavirus disease 2019 (COVID-19). Clinical eHealth, 3, 7–15.

[55] Matheus, H. D. M., Ramon, G. S., Viviana, C., & Leandro, D. S. (2020). Short-term forecasting COVID-19 cumulative confirmed cases: Per-spectives for Brazil. Chaos, Solitons & Fractals, 135(34), 1–10.

[56] Mohammad, N., Pouriyeh, S., Parizi, R. M., Dorodchi, M., Valero, M., & Arabnia, H. R. (2020). Internet of Things for Current COVID-19 and Future Pandemics: an Exploratory Study. Journal of Healthcare Infor-matics Research, 4(4), 325–364. http://dx.doi.org/10.1007/s41666-020-00080-6.

[57] Nasajpour, M., Pouriyeh, S., Parizi, R. M., Dorodchi, M., Valero, M., & Arabnia, H. R (2020). Internet of Things for Current COVID-19 and Future Pandemics: an Exploratory Study. Journal of Healthcare Infor-matics Research, 4(4), 325–364. http://dx.doi.org/10.1007/s41666-020-00080-6.

[58] Panteleimon, P., Chorti, A., Papagiouvanni, I., Paparoidamis, G., Drosos, C., Panagiotakopoulos, T., … Sideris, M. (2017). Virtual and augmented reality in medical education. intechopen, pp. 78–96.

[59] Sarbjit, S., Parmar, K. S., Makkhan, S. J. S., Kaur, J., Peshoria, S., & Kumar, J. (2020). Study of ARIMA and least square support vector machine (LS-SVM) models for the prediction of SARS-CoV-2 confirmed cases in the most affected countries. Chaos, Solitons & Fractals, 139, 110086. http://dx.doi.org/10.1016/j.chaos.2020.110086.

[60] Xueyan, M., Lee, H. C., Diao, K.Y., Huang, M., Lin, B., Liu, C., … Bernheim, A. (2020). Artificial intelligence–enabled rapid diagnosis of patients with COVID-19. Nature Medicine, 26(10), 1–19.

[61] Zhao, X.-Y., Xu, X. X., Yin, H. S., Hu, Q. M., Xiong, T., Tang, Y. Y., … Huang, Z. P. (2020). Clinical characteristics of patients with 2019 coro-navirus disease in a non-Wuhan area of Hubei Province, China: A ret-rospective study. BMC Infectious Diseases, 20(311), 311.

[62] Zohair, M., Atlam, E.-S., Hassanien, A. E., Dagnew, G., Elhosseini, M. A., & Gad, I. (2020). Association between weather data and COVID-19 pan-demic predicting mortality rate: Machine learning approaches. Chaos, Solitons & Fractals, 138, 110137.

[63] Hussein, M. & Nätterdal, C.. (2015). The benefits of virtual reality in education-A comparision study. Semantic Scholar.

[64] Abhimanyu, S., Vineet, P., & Oge, M. (2020). Artificial intelligence and COVID-19: A multidisciplinary approach. Integrative Medicine Research, 9(3), 111–125.

[65] Ayyıldız, V. A. (2021). Covıd-19'da Kardiyotorasik Radyolojik Görüntüleme Ve Yapay Zekanın Rolü. *Medical Journal Of Suleyman Demirel University*, *28*.

[66] Karthikeyan, I., Gaurav, K., Raju, V., & Vijay, J. (2020). COVID-19 and appli-cations of smartphone technology in the current pandemic. Diabetes & Metabolic Syndrome: Clinical Research & Reviews, 14(5), 733–737.