

**T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**



**DERİN ÖĞRENME YÖNTEMLERİ KULLANARAK EKG
GÖRÜNTÜLERİNDEN COVID-19'UN TESPİT EDİLMESİ**

Nida AKKUZU

Yüksek Lisans Tezi

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

Kuramsal Temeller Bilim Dalı

HAZİRAN 2023

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

DERİN ÖĞRENME YÖNTEMLERİ KULLANARAK EKG GÖRÜNTÜLERİNDEN COVID-19'UN TESPİT EDİLMESİ

Tez Yazarı
Nida AKKUZU

Danışman
Prof. Dr. Mehmet KAYA

HAZİRAN 2023
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Başlığı:	Derin Öğrenme Yöntemleri Kullanarak EKG Görüntülerinden Covid-19'un Tespit Edilmesi
Yazarı:	Nida AKKUZU
İlk Teslim Tarihi:	15.05.2023
Savunma Tarihi:	15.06.2023

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Prof. Dr. Mehmet KAYA Fırat Üniversitesi, Mühendislik Fakültesi	<i>İmza</i> Onayladım
Başkan:	Doç. Dr. Muhammed YILDIRIM Malatya Turgut Özal Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Dr. Öğr. Üyesi Ertan BÜTÜN Fırat Üniversitesi, Mühendislik Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza

Prof. Dr. Burhan ERGEN
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Derin Öğrenme Yöntemleri Kullanarak EKG Görüntülerinden Covid-19’un Tespit Edilmesi” Başlıklı Yüksek Lisans Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

15.06.2023

Nida AKKUZU



ÖNSÖZ

Koronavirüs hastalığı Covid-19 hastalığı 2019 yılının sonlarına doğru Çin'in Wuhan şehrinde ortaya çıkmıştır. Milyonlarca kişinin etkilendiği ve milyonlarca kişinin daha enfeksiyon kapma riski altında olduğu küresel bir salgındır. Dünya genelinde pandemi haline gelen Covid-19 hastalığının yayılmasını önlemek amacıyla birçok önlem alınmıştır. Bu önlemlerin yanında enfekte olan kişilerin tespiti hastalığın yayılmasını önlemek ve virüsün vereceği zararları en aza indirmek çok önemlidir. Derin öğrenme yöntemleri kullanılarak EfficientNet-B0 modeli ile Covid-19 teşhisi ve diğer hastalıkların sınıflandırılması, hastalığın yayılmasını önlemek ve etkilediği kalp rahatsızlıklarını erken olarak öğrenebilmek amacıyla çalışma yürütülmüştür. Bu tez çalışması Covid-19 teşhisi alanında araştırma yapmak isteyenlere referans kaynağı olacaktır.

Akademik kariyerimin ilk basamağı olan yüksek lisans eğitimim ve tez yazım sürecinde hiçbir desteğini esirgemeyen, değerli bilgi ve mesleki deneyimlerini benimle paylaşan, iyi bir eğitim alabilmem için her konuda destek olan tez danışanım çok değerli hocam **Prof. Dr. Mehmet KAYA**'ya sonsuz teşekkürlerimi sunarım.

Hayatımın her anında yanımda olan ve bana güç veren başta annem ve babam olmak üzere tüm aileme ve arkadaşlarıma teşekkür ederim.

Bu tez çalışması, Fırat Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi (FÜBAP) tarafından **MF.22.37** numaralı proje ile desteklenmiştir.

Nida AKKUZU
ELAZIĞ, 2023

İÇİNDEKİLER

	Sayfa
ÖNSÖZ.....	iv
İÇİNDEKİLER.....	v
ÖZET	vi
ABSTRACT.....	vii
ŞEKİLLER LİSTESİ.....	viii
TABLolar LİSTESİ.....	x
SİMGELER VE KISALTMALAR.....	xi
1. GİRİŞ.....	1
1.1. Tezin Amacı.....	4
1.2. Tezin Yapısı.....	4
2. LİTERATÜRDEKİ ÇALIŞMALAR.....	5
3. MATERYAL VE METOT	10
3.1. Derin Öğrenme.....	10
3.2. Evrişimsel Sinir Ağları (CNN).....	12
3.2.1. Evrişim Katmanı (Convolution Layer)	12
3.2.2. Havuzlama Katmanı (Pooling Layer)	13
3.2.3. Tam Bağlı Katman (Fully-Connected Layer).....	14
3.3. Aktivasyon Fonksiyonları.....	14
3.3.1. Lineer Aktivasyon Fonksiyonu	15
3.3.2. İkili Adım İşlevi	15
3.3.3. Doğrusal Olmayan Aktivasyon Fonksiyonu	15
3.4. Transfer Öğrenme	17
3.5. EfficientNet	18
3.6. Sınıflandırma	21
3.7. Veri Seti.....	22
3.8. Önerilen Yöntem.....	24
4. UYGULAMA SONUÇLARI	29
5. SONUÇLAR.....	38
KAYNAKLAR	39
ÖZGEÇMİŞ	

ÖZET

Derin Öğrenme Yöntemleri Kullanarak EKG Görüntülerinden Covid-19'un Tespit Edilmesi

Nida AKKUZZU

Yüksek Lisans Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Haziran 2023, Sayfa: xi + 42

Tüm dünyayı etkisi altına alan ve 11 Mart 2020'de WHO tarafından küresel salgın olarak ilan edilen Covid-19 hastalığı başta akciğer ve kalp olmak üzere çoklu organ sistemlerini etkilemektedir. Hastalığın verdiği hasarlar ile ölümle sonuçlanabilen virüsün etkisini en aza indirmek için izolasyon ve tedavi sürecine erken başlanması çok önemlidir. Hastalığın teşhisinde kullanılmak üzere geliştirilen yöntemlerin yanlış sonuçlar beraberinde uzun teşhis süresinin olmasından dolayı yeni yöntemlerin geliştirilmesi gerekmektedir. Yeni yöntem olarak elektrokardiyogram (EKG) sinyal görüntüleri kullanılarak Covid-19 durumu, Anormal kalp atışı, Miyokard enfarktüsü, Miyokard Enfarktüsü Öyküsü ve Normal bulgular tespit edilebilmektedir. Alanında uzman doktorlar tarafından geleneksel yöntemlerle yapılan hastalık tespitleri, insan hatasından kaynaklı kötü muamelelere yol açabilmektedir. Bu tez çalışmasında EKG ile teşhis yapılması için derin öğrenme yöntemleri kullanılmıştır.

Bu çalışmanın amacı, EKG görüntüleri kullanılarak hastalıkların saptanmasında başarı oranı yüksek yeni bir yaklaşım önermek ve ayrıntılı test sonuçlarını analiz etmektir. Bu çalışmada 5 sınıf EKG görüntüleri içeren halka açık bir veri seti kullanılmıştır. EfficientNetB0 konvolüsyonel sinir ağı mimarisi kullanılarak eğitim ve test süreçleri gerçekleştirilmiştir. Daha sonra sonuçlar ayrıntılı olarak incelenmiş, grafikler çizilmiş ve sonuçlar literatürdeki diğer çalışmalarla karşılaştırılmıştır. Önerilen çok sınıflı sınıflandırma mimarisi, %99,13 doğruluk sunar. Elde ettiği başarı ile literatürdeki diğer çalışmalardan üstün olmuştur. Bu çalışma, EKG görüntülerinden tespit edilebilecek 5 farklı bulgunun hızlı ve güvenilir bir şekilde saptanmasına ve hastaların daha doğru tedavi edilmesine katkı sağlayacaktır.

Anahtar Kelimeler: Covid-19, Sınıflandırma, EfficientNet, Elektrokardiyogram, EKG, Derin Öğrenme, Evrişimsel Sinir Ağı

ABSTRACT

Detecting Covid-19 from ECG Images Using Deep Learning Methods

Nida AKKUZU

Master's Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

June 2023, Pages: xi + 42

The area to affect the whole world and declared as global sources by WHO on March 11, 2020, Covid-19 diseases mainly affect Multiple organ systems, mainly large and heart. Isolation and early initiation of treatment is essential to minimize exit damage and death during periods of time. Measurement methods to be used in instrument inspection should consist of new methods due to the long measurement end, along with incorrect results. Covid-19 status can be detected as Abnormal heartbeat, Myocardial infarction, History of Myocardial Infarction and Normal. Disease detections traditionally made by specialist doctors in the field can lead to ill-treatment caused by human error. In this thesis, deep learning methods were used to diagnose with ECG.

The aim of this study is to propose a new approach with high success rate for the detection of diseases using ECG images and to analyze detailed test results. A publicly available dataset containing 5-class ECG images was used in this study. Training and testing processes were carried out using the EfficientNetB0 convolutional neural network architecture. Afterwards, the results were analyzed in detail, graphs were drawn and the results were compared with other studies in the literature. The proposed multi-class classification architecture offers 99.13% accuracy. With the success achieved, it was superior to other studies in the literature. This study will contribute to the rapid and reliable detection of 5 different findings that can be detected from ECG images and to more accurate treatment of patients.

Keywords: Covid-19, Classification, EfficientNet, Electrocardiogram, ECG, Deep Learning, Convolutional Neural Network

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 1.1. (a) Bir koronavirüsün yapısı, (b) SARS-CoV-2'nin yapısı.....	2
Şekil 1.2. Toplam Vaka ve Ölüm Sayısı	2
Şekil 3.1. Derin öğrenme	10
Şekil 3.2. Hassas tıp araştırmalarında derin öğrenme modelinin uygulanması	11
Şekil 3.3. Evrişim katmanı.....	13
Şekil 3.4. Maksimum ve Ortalama Havuzlama.....	13
Şekil 3.5. Evrişimli sinir ağları temel katman sıralaması.....	14
Şekil 3.6. Transferin öğrenmeyi geliştirebileceği üç yol	18
Şekil 3.7. Model Ölçeklendirme örnekleri. (a) temel ağ, (b) genişlik ölçekli ağ, (c) derinlik ölçekli ağ ve (d) çözünürlük ölçekli ağ. (e) tüm genişliği, yüksekliği ve çözünürlüğü eşit şekilde ölçekleyen bileşik ölçeklendirme yöntemi.....	19
Şekil 3.8. EfficientNet-B0 model blok şeması	20
Şekil 3.9. Sinir Ağı.....	21
Şekil 3.10. Veri setinden hastalıklara ait örnek görüntüler	24
Şekil 3.11. Karışıklık Matrisi.....	26
Şekil 4.1. EfficientNet-B0 Epoch 5 (a) eğitim ve değerlendirme kaybı (b) eğitim ve değerlendirme doğruluğu grafikler	29
Şekil 4.2. EfficientNet-B0 Epoch 10 (a) eğitim ve değerlendirme kaybı (b) eğitim ve değerlendirme doğruluğu grafikleri	30
Şekil 4.3. EfficientNet-B0 Epoch 20 (a) eğitim ve değerlendirme kaybı (b) eğitim ve değerlendirme doğruluğu grafikleri	31
Şekil 4.4. EfficientNet-B0 Epoch 30 (a) eğitim ve değerlendirme kaybı (b) eğitim ve değerlendirme doğruluğu grafikleri	31
Şekil 4.5. EfficientNet-B0 Epoch 40 (a) eğitim ve değerlendirme kaybı (b) eğitim ve değerlendirme doğruluğu grafikleri	32
Şekil 4.6. 6 EfficientNet-B0 Epoch 50 (a) eğitim ve değerlendirme kaybı (b) eğitim ve değerlendirme doğruluğu grafikleri	33
Şekil 4.7. EfficientNet-B0 modeli a=5, b= 10, c= 20, d=30, e=40, f=50 epoch için çok sınıflı karışıklık matrisi	33-34
Şekil 4.8. 5 epoch için hatalı tahmin edilen hastalık sınıfları.....	35
Şekil 4.9. 10 epoch için hatalı tahmin edilen hastalık sınıfları.....	35
Şekil 4.10. 20 epoch için hatalı tahmin edilen hastalık sınıfları.....	35
Şekil 4.11. 30 epoch için hatalı tahmin edilen hastalık sınıfları.....	36
Şekil 4.12. 40 epoch için hatalı tahmin edilen hastalık sınıfları.....	36

Şekil 4.13.	50 epoch için hatalı tahmin edilen hastalık sınıfları.....	36
--------------------	--	----



TABLÖLAR LİSTESİ

	Sayfa
Tablo 3.1. Derin Öğrenme Kütüphaneleri	11
Tablo 3.2. Aktivasyon Fonksiyonları	16-17
Tablo 3.3. Sınıflandırılan hastalıklar	23
Tablo 3.4. Amaca yönelik kullanılan hiper parametreler	26
Tablo 4.1. EfficientNet-B0 kullanılarak elde edilen sınıf bazlı sınıflandırma sonuçları	29
Tablo 4.2. EKG veri seti üzerinde çalışmaların karşılaştırılması	37

SİMGELER VE KISALTMALAR

Kısaltmalar

AHB	: Anormal kalp atışı
AlphaCoV	: Alphacoronavirüs
BetaCoV	: Betacoronavirüs
BT	: Bilgisayarlı tomografi
CNN	: Evrişimli sinir ağı
Colab	: Colaboratory
CoV	: Koronavirüsler
Covid-19	: Koronavirüs hastalığı 2019
DeltaCoV	: Deltacoronavirüs
DL	: Derin öğrenme
DSÖ	: Koronavirüs hastalığı 2019
EKG	: Elektrokardiyogram
ELU	: Exponential Linear Unit
FC	: Tam bağlı katman
FN	: Yanlış negatif
FP	: Yanlış Pozitif
GammaCoV	: Gammacoronavirüs
GLCM	: Gri seviye eş oluşum matrisi
HD	: Kalp hastalığı
LSTM	: Uzun-Kısa süreli bellek
MI	: Miyokard Enfarktüsü
MLP	: Çok katmanlı algılayıcılar
MR	: Manyetik Rezonans
PCR	: Polimeraz Zincir Reaksiyonu
PMI	: Miyokard Enfarktüsü Öyküsü
ReLu	: Rectified Linear Unit
RNA	: Ribonükleik Asit
RNN	: Özyinelemeli sinir ağı
Sars-cov-2	: Koronavirüs hastalığı 2019
TN	: Gerçek negatif
TP	: Gerçek pozitif


1. GİRİŞ

Koronavirüsler (CoV'ler), zarf üzerinde sivri uçlu glikoproteinlerin varlığından dolayı elektron mikroskobu altında taç benzeri bir görünüme sahip olan tek sarmallı RNA virüsleridir. CoV'ler pleomorfiktir; uzunlukları 80 ila 160 nm arasındadır. Koronavirüsler; Alphacoronavirüs (alphaCoV), Betacoronavirüs (betaCoV), Gammacoronavirüs (gammaCoV) ve Deltacoronavirüs (deltaCoV) olmak üzere dört önemli cinse ayrılırlar. Bu, daha önce insanlarda gözlenmemiş benzersiz bir RNA virüs türüdür. Koronavirüsün yapısı Şekil 1.1 (a) 'da gösterildiği gibidir.


Koronavirüs hastalığı 2019 (Covid-19), 2019 yılının aralık ayında Çin'in Wuhan kentinde ortaya çıkmıştır ve dünya çapında hızla yayılıp çok sayıda ölüme sebep olmuştur. Virüsün resmi adı DSÖ tarafından SARS-CoV-2 (Şiddetli Akut Solunum Sendromu-Koronavirus-2) olarak belirlenmiştir. Dünya Sağlık Örgütü Virüsün neden olduğu hastalığı tanımlamak için Covid-19 terimini kullanmaktadır. Daha sonra 11 Mart 2020 tarihinde Dünya Sağlık Örgütü Tarafından Covid-19 bir pandemi olarak ilan edilmiştir. Bu daha önce insanlarda gözlemlenmemiş benzersiz bir RNA virüs türüdür. SARS-CoV-2'nin dış yapısının modeli Şekil 1.1 (b) 'de gösterilmiştir. En belirgin semptomları ateş, öksürük, yorgunluk, tat ve koku kaybı olarak söylenebilir. Ciddi semptomlar ise solunum güçlüğü, göğüs ağrısı, konuşma ya da hareket kaybı veya bilinç bulanıklığıdır. Ağır vakalarda zatürre, ağır solunum yetmezliği, böbrek yetmezliği ve ölüm gelişebilmektedir.

Şu anda, Covid-19 hastalığı için spesifik bir tedavi yoktur, sağlık çalışanları Covid-19 teşhisi konulmuş hastaların tedavisine yönelik klinik rehberlik mevcuttur. Araştırma sonuçlarına bakılarak yeni tedavi seçenekleri ortaya çıkmıştır ve sonuç alındıkça güncellenmektedir. Covid-19 virüs taşıyan bireylerin öksürmeleri ile ortama saçılan damlacıkların solunması ile bulaşır. Covid-19 küresel olarak Mart 2023 itibarıyla 6,5 milyondan fazla ölüm dahil 761 milyonu geçen vaka sayısı vardır. Ayrıca 1 Nisan 2023 tarihi itibarıyla toplam 13.321.840.096 doz aşı yapılmıştır. Toplam vaka ve ölüm sayısı grafiği [1] sayfasından alınmış olup Şekil 1.2' de gösterilmiştir. Grafik en son 29 Mart 2023 tarihinde güncellenmiştir.

Virüs çok yüksek bulaşıcılığa sahiptir ve bu durum göz önüne alındığında hastalığın yayılmasını kontrol edebilmek için hızlı sonuç beraberinde doğru bir teşhis yöntemi gerekmektedir. Kesin teşhis yöntemi olarak günümüzde PCR Testi (Polimeraz Zincir Reaksiyonu) kullanılmaktadır. PCR testleri yüksek doğruluk oranı nedeniyle altın standart olmasına rağmen, sonuçlardan önce uzun bekleme süreleri (en az 4 ila 6 saat), deneyimli personel ve lojistik olarak merkezi bir konum gerektirir. Kullanılan bir diğer yöntem radyolojik görüntüleme teknikleri olan MR ve BT'dir. Bu araçların doğruluğu ve duyarlılığı %95'in üzerindedir ve akciğer görüntüleri kullanılarak Covid-19 tespiti ile ilgili birçok çalışma yapılmıştır [2]–[5]. Bu yöntemlerin Covid-19 hastalığı teşhisi dışında birçok negatif yönü vardır. Bazı bölgelerde radyolojik görüntüleme



7-day rolling average. Limited testing and challenges in the attribution of cause of death means the cases and deaths counts may not be accurate.



CC BY

Şekil 1.2 Toplam Vaka ve Ölüm Sayısı

Covid-19 vücudumuzda solunumun sisteminin yanında farklı organları da etkilemektedir. Covid-19 hastalığından etkilenen organlarımızdan biride kardiyovasküler sistemdir [6], [7]. Bu sebeplerden dolayı elektrokardiyogram görüntülerinden Covid-19 hastalığının teşhisine hızlı ve güvenilir şekilde ulaşabilmek için araştırmalar yapılmıştır. Elektrokardiyogram (EKG) sinyali kalbin kasılması sırasında ortaya çıkan elektriksel aktivitenin kayıt edilmesini sağlayan cihazdır. Aktif olarak kullanılmaktadır. Literatürde EKG sinyali, kalp atış hızının ölçülmesi, kalp atışlarının ritminin incelenmesi, kalp anormalliklerinin teşhisi, duygu tanıma ve biyometrik tanımlama gibi çeşitli amaçlar için analiz edilmiş ve kullanılmıştır. Özellikle bilgilendiricidir ve birçoğu yüzüstü yatan ve birden fazla intravenöz damla uygulanan ve BT görüntüleme odalarına taşınması zor olan kritik hastalarda benzersiz bir şekilde uygulanabilir. Klinik ekokardiyografiden elde edilebilecek verilerle, ekokardiyografi tabanlı derin öğrenme platformlarının geliştirilmesi için geniş bir fırsat vardır. EKG analizi kalp hastalıklarının teşhisi dışında bulunabilir, maliyetsiz, taşınabilir olması ve gerçek zamanlı inceleme gibi katkılarına bakılırsa kullanımı oldukça yaygındır [8].

Yukarıdaki faydalardan yola çıkılarak akciğer grafisi ve PCR testleri dışında EKG sinyalleri kullanarak Covid-19 teşhisi büyük önem taşımaktadır.

Elektrokardiyogram (EKG) görüntülerinden otonom hastalık tespiti çalışmasının literatüre başlıca katkıları aşağıda sıralanmıştır:

- Elektrokardiyogram görüntülerinin derin öğrenme yöntemleriyle otonom analizi, literatürde yeterince çalışılmamış bir alandır. Literatürdeki çalışmaların sınıflandırma başarısı henüz yeterince yüksek değildir. Önerilen yöntem ile daha yüksek başarı elde edilmesi amaçlanmaktadır.

- Önerilen yöntemle çok sınıflı bir sınıflandırma yapılması amaçlanmaktadır. Derin öğrenme mimarisi toplam 5 derste eğitim verilecektir. Bu katkı sayesinde önerilen mimari, ilgili elektrokardiyogram görüntüsünün hangi hastalığa sahip olduğunu veya normal bir birey olduğunu tespit edebilecektir.

- Önerilen mimari alanda uzman olan hekimlerin tedaviye başlamadan önce karar vermelerine yardımcı olacaktır.

- Bu çalışma araştırmacılara derin öğrenme ve EfficientNet-B0 modeli konusunda yol gösterecek ve geliştirilebilecek farklı proje ve çalışmalara örnek teşkil edecektir.

Tez çalışmasında, 1114 tane Kardiyak ve Covid-19 hastalarının EKG görüntülerinin veri setini içeren ve beş farklı kategoriden oluşan halka açık bir veri setinin güncel hali kullanılmıştır[9]. Elde edilen veri seti ile derin öğrenme metotları kullanarak EfficientNet-B0 modeli ile sınıflandırma çalışmaları yapılmıştır

1.1. Tezin Amacı

Bu çalışmanın amacı, EKG görüntüleri kullanılarak hazırlanmış olan veri seti ile hızlı ve güvenilir bir şekilde Covid-19 semptomlarını, anormal kalp atışını, miyokard enfarktüsünü ve miyokard enfarktüsü öyküsünün teşhisini yapmaktır. Geleneksel hastalık tespit tekniklerine göre daha hızlı, insan hatasız bir alternatif olacak. Çalışmada derin öğrenme yöntemleri kullanarak EfficientNet-B0 modeli ile hastalığın teşhisi ve sınıflandırılması yapılmıştır. Derin öğrenme, teşhis sırasında klinisyen yorumunu derin öğrenme kullanılarak türetilen bilgilerle birleştirerek ekokardiyografinin doğruluğunu ve güvenilirliğini artırma potansiyeli sunar ve insan gözü tarafından algılanamayacak kadar ince olabilecek ek tahmine dayalı bilgiler sağlayabilir. Derin öğrenme böylece bu alanda potansiyel olarak önemli fayda sağlayabilir. Hızlı ve güvenilir teşhis pandemi sürecinde hastalığın yayılmasını önlemek ve hasta tedavi izlemine başlanması için çok önemlidir. Bu, yoğun acil servis odalarının yükünün hafifletilmesini sağlayacak ve sağlık hizmeti sağlayıcıları üzerindeki baskıyı azaltacaktır. Ayrıca Covid-19 hastalığının etkilediği kardiyovasküler sistemin de yaşanacak aksaklıkların gözden kaçmamasını sağlamaktır.

Bu tez çalışmasında gerçekleştirilen uygulamalar ile sınıflandırma için yüksek başarı oranları elde edilmiştir. Elde edilen yüksek başarı ile yapılan çalışmanın kullanılabilir bir seviyede olduğu anlaşılmıştır.

1.2. Tezin Yapısı

Bu tez çalışması beş bölümden meydana gelmektedir. Birinci bölümde tezin amacı ve tezin yapısı bulunmaktadır. İkinci bölümde, literatürdeki çalışmalar başlığı altında Covid-19 teşhisi için önerilen yöntem ve yapılan çalışmalara yer verilmiştir. Üçüncü bölümde, çalışmada kullanılan yazılım ve teknolojiler detaylı bir şekilde anlatılmıştır. Dördüncü bölümde, uygulama sonuçları başlığı altında yapılan sınıflandırma sonucunda elde edilen bulgulara yer verilmiştir. Beşinci bölümünde araştırma kapsamında elde edilen sonuçlar değerlendirilmiştir.

2. LİTERATÜRDEKİ ÇALIŞMALAR

Çok sayıda araştırmacı, Covid-19 hastalığını teşhis etmek için yeni sistemler geliştirmektedir. Geliştirilen sistemlerde yapay zekâ teknolojileri kullanılarak Covid-19 teşhisi için yeni otomatik sistemler oluşturmaktadırlar. Derin öğrenme yöntemlerini kullanarak tıptaki uygulamaların doğruluğu arttırılmaktadır. 2022'nin başında Covid-19 hastalığının teşhisi için otomatik derin öğrenme yaklaşımları oluşturmak üzere çeşitli incelemeler yapılmıştır [10], [11]. Son gelişmelerle birlikte derin öğrenme yöntemlerinin hastalıkların belirlenmesi, risk değerlendirmesi, etkili ilaç geliştirilmesi ve hastalara kişiselleştirilmiş sağlık hizmeti vermekte önemli bir etken olduğu belirlenmiştir. Ayrıca, sağlık kurumlarında artan iş yoğunluğu beraberinde tıp uzmanlarını etkileyen stres faktörlerini azaltmak için derin öğrenme yöntemleri kullanılabilir. Derin öğrenme yöntemleri, teşhis edilecek hastalığı otomatik olarak hızlı ve doğru teşhis edebilir ve böylece hastalara zamanında yardım sağlama potansiyeli çok yüksektir. Uzmanlık gerektirmeyen bu yöntemler sayesinde alanında uzman sağlık çalışanlarına yardımcı olabilir. Sınıflandırma, tespit ve yerelleştirme, segmentasyon, kavramsallaştırma, sıralı öğrenme, gömme gibi derin öğrenme teknikleriyle halledilebilecek önemli öğrenme görevleri vardır. Elektrokardiyogram (EKG) adı verilen bir tıbbi görüntüleme cihazı, kalp kasılırken meydana gelen elektriksel aktiviteyi izler. EKG sinyali, kalp atış hızı ölçümü, kalp atışı ritmi analizi, kalp anormalliği teşhisi, duygu tespiti ve biyometrik tanımlama dahil olmak üzere literatürde çeşitli nedenlerle incelenmekte ve kullanılmaktadır. EKG erişilebilir, uygun fiyatlı, taşınabilir ve gerçek zamanlı analiz gibi faydalı katkılar sağlıyor. Bu bağlamda, birçok bozukluğun tanımlanmasında sıklıkla kullanılmaktadır[12]. COVID-19'un erken vakalarında, virüs bulaşmış hastalarda miyokard Hasarı bulunmuştur [13]. En çok kullanılan klinik muayene yöntemlerinden biri olarak, COVID-19 ile ilgili EKG özelliklerinin anlaşılmasının yanı sıra elektrokardiyografik aktivitedeki değişikliklerin incelenmesi büyük önem taşımaktadır [14]. EKG görüntülerinden alınan sinyallerdeki değişiklikleri saptayarak Covid-19 ve diğer hastalıkları derin öğrenme yöntemleriyle saptamak mümkündür.

Strodthoff et al. [15] nolu çalışmada, derin öğrenme yöntemleri kullanarak farklı elektrokardiyogram verilerini analiz edip bu verileri sınıflandırmak için yöntem geliştirilmiştir. Farklı EKG bildirimi tahmin görevlerinden yaş ve cinsiyet tahminine kadar çeşitli görevleri kapsayan, yakın zamanda yayınlanan, ücretsiz olarak erişilebilen klinik 12 derivasyonlu EKG veri seti PTB-XL ve ICBEB2018 EKG veri seti olmak üzere iki farklı veri seti kullanılmıştır. Çalışmada derin sinir ağları, CNN ve RNN mimarileri tartışılmıştır. İncelenen makalede, derin öğrenme yöntemleri kullanılarak EKG verilerinin sınıflandırılması ve hastalık tespiti için derin öğrenme yöntemleri beraberinde birçok farklı modelin kullanılabileceğini göstermektedir.

Rath et al. [16] nolu çalışmada, MLP, LSTM ve Generative Adversarial Network gibi farklı derin öğrenme yöntemleri kullanılarak EKG sinyalinin HD tespiti yapılmıştır. Çalışmada uygun DL ve ML modelleri tanımlanmış ve gerekli sınıflandırma modelleri geliştirilip test edilmiştir. Kalp hastalıklarının daha iyi saptanması için GAN topluluk modeli önerilmiştir. Topluluk modelinin 0,994 doğruluk, 0,993 F1 skoru ve 0,995 AUC değeri ile en iyi performansı sağladığı görülmektedir. Yakın geçmişte, derin öğrenme tabanlı sınıflandırıcılar varyans hastalıklarının tespiti için önem kazanmıştır.

Sakr et al [17] nolu çalışmada, Covid-19 tespiti için EKG'ye dayalı yeni bir uçtan uca derin öğrenme modeli önermişlerdir. Çalışmada 1109 EKG görüntüsünde oluşan Covid-19 ve kalp hastalarından oluşan veri seti beraberinde birkaç derin CNN kullanılmıştır. Önerilen ikinci CNN modelinde, COVID-19 tespiti için ortalama %98,81 doğruluk, %98,8 Kesinlik, %98,8 Hassasiyet ve %98,81 F1 skoru elde etti. Önerilen yöntem, en kötü durum senaryolarında kullanılabilir (yani, yoğun bakım odalarının aşırı kalabalık olması ve hastanelerin maksimum kapasiteye ulaşması). Bu durumlarda, doktorlar kimin hayatta kalma şansı olup kimin olmadığına öncelik verebilir. Bu şekilde, kaynakların kullanımının dikkatli bir şekilde rasyonelleştirilmesi yoluyla daha fazla hayat kurtarılabilir.

Sobahi et al. [18] nolu çalışmada, 12 uçlu EKG sinyalleriyle Covid-19, normal ve anormal kalp atışı olan birey gruplarının on kat çapraz doğrulama kullanarak ikili ve çok sınıflı otomatik olarak sınıflandırmasını yapmışlardır. Halka açık bir veri seti ile tespit için RC ile dikkat tabanlı 3D CNN modeli kullanmışlardır. Önerilen modelin doğruluğu ikili sınıflandırmalar için %99,0 ve çok sınıflı sınıflandırmalar için %92,0 şeklinde bulunmuş olup EKG veri tabanı ile test edilmeye hazır haldedir.

Attallah [8]'de, Covid-19 teşhisi için ECG-BiCoNet adlı derin öğrenme tabanlı kendi geliştirdiği mimari önermektedir. ECG-BiCoNet ResNet-50, DenseNet-201, Inception-V3, Xception ve Inception-ResNet olmak üzere beş evrişimli sinir ağından oluşan halka açık bir veri setini kullanarak iki düzeyde derin özellik çıkarmaktadır. EKG-BiCoNet, ikili ve çoklu sınıflandırma gerçekleştirmiştir ve modelin doğruluğu sırasıyla %98,8 ve %91.73 olarak bulunmuştur. Bu sonuçlardan yola çıkarak EKG verilerinden Covid-19'u otomatik olarak tespit etmek için kullanılabileceği anlaşılmaktadır.

Shahin et al. [19] nolu çalışmada, derin öğrenme algoritmalarının, özellikle Konvolüsyonel Sinir Ağı (CNN) modellerinin entegrasyonu ile Elektrokardiyogram (EKG) verilerinin kullanılmasıyla COVID-19'u otomatik olarak teşhis etmek için yeni bir yaklaşım önerilmiştir. Çalışmada CNN'de önceden eğitilmiş ResNet50, DenseNet-201, VGG16, VGG19, Inceptionv3 ve Inceptionresnetv2 modelleri test edilmiştir. İstenmeyen bozulmaları ortadan kaldırmak için EKG ön işleme yapılmıştır. Ardından, CNN modellerine girmeden önce veri setini yapay olarak şişirmenin bir yolu olarak bir veri artırma tekniği uygulandı ve bu çalışmada test edilen tüm

modeller arasında VGG16 modeli, Normal EKG'ler içeren bir hedef için %81,39 ile Doğruluk açısından en iyi sonuca ulaşmıştır.

Ozdemir et al. [20] nolu çalışmada, EKG verilerini ilk kez derin öğrenme yöntemi ile kullanarak Covid-19 tespiti için altı eksenli öznetelik adı verilen yeni ve etkili bir yöntem önermiştir. Özellik çıkarımında GLCM matrisi uygulanmıştır. Halka açık kâğıt tabanlı EKG görüntü veri seti ile CNN mimarisini kullanarak tespit yapılmıştır. Önerilen modelin doğruluğu ilk olarak Covid-19 ve Bulgu Yok olarak belirlenen ikili sınıflandırmada %96,20 doğruluk ve %96,30 F1-Skoru bulunmuştur. Sonrasında Negatif (normal, anormal, miyokard enfarktüsü) ve Pozitif olarak belirlenen ikili sınıflandırmada ise %93,00 doğruluk ve %93,20 F1- Skoru ile yüksek bir performans sağlanmıştır.

Rahman et al. [21] nolu çalışmada, derin öğrenme yöntemlerini kullanarak Covid-19 ve diğer kardiovasküler hastalıkları tespit etmişlerdir. Çalışmada beş farklı kategoriden oluşan ve halka açık EKG görüntüleri veri seti kullanılmıştır. İki ve üç sınıflı sınıflandırma için Densenet201 CNN modeli ile yüksek başarı sağlanmıştır. Doğrulukları sırasıyla %99,1 ve %97,36 olarak belirlenmiştir.

Bassiouni et al. [6] nolu çalışmada, veri toplama, görüntüleri filtreleme ve büyütme, öznetelik çıkarma ve EKG görüntülerini sınıflandırma gibi bir dizi aşama gerçekleştirilmişlerdir. Çalışmada veriler halka açık iki EKG görüntü veri seti kullanılmış olup model olarak SVM'ye dayalı ECGConvNet kullanarak diğer derin öğrenme modellerine göre en yüksek doğruluğu elde etmişlerdir. Elde edilen doğruluklar ikili sınıf ve çok sınıflı tanı görevlerinde sırasıyla %99,8 ve %99,1 olarak bulunmuştur ve belirlenen yüksek başarı doğrultusunda EKG verileri ile derin öğrenmeye dayalı otomatik bir Covid-19 tespit sistemi geliştirmenin mümkün olacağını belirlemişlerdir.

Attallah [22] nolu çalışmada, çeşitli derin öğrenme modeli kullanarak Covid-19'u teşhis etme amacıyla yeni bir otomatik teşhis yöntemi geliştirmiştir. Çalışmada Covid-19'un EKG kayıtları için birincil ve tek halka açık veri seti kullanılmıştır. Çalışmada çeşitli mimarilerin 10 derin öğrenme modeli kullanılmıştır. İkili sınıflandırmayı gerçekleştirmek için birkaç makine öğrenimi sınıflandırıcısı kullanılmıştır. İki sınıflı ve çok sınıflı sınıflandırma seviyeleri için çalışmada sırasıyla %98,2 ve %91,6 doğruluk oranına ulaşılmıştır. Bu performans sonuçlarına bakılarak EKG'nin Covid-19 hastalığını tespit etmek için alternatif bir tanı yöntemi olarak kullanılabileceği gösterilmektedir.

Irmak [23] nolu çalışmada, sadece Covid-19 virüsünün kardiyovasküler sistemde neden olduğu anormallikleri incelemiştir. Veri setindeki EKG görüntüleri kullanılarak yeni bir derin Evrişimli Sinir Ağı modeli geliştirilmiştir. Çalışmada halka açık bir veri seti kullanılmıştır. Çalışmada Covid-19 ve Normal, Covid-19 ve Anormal Kalp Atışları, Covid-19 ve Miyokard Enfarktüsü olmak üzere üç farklı ikili sınıflandırma kullanılmıştır. Genel sınıflandırma doğrulukları

sırasıyla %98,57, %93,20. %96,74 olarak hesaplanmıştır. Ayrıca COVID-19 ile Anormal Kalp Atışı ve Miyokard Enfarktüsü ve Normal ile COVID-19 ile Anormal Kalp Atışı ve Miyokard Enfarktüsü çoklu sınıflandırma görevleri için %86,55 ve %83,05'lik bir genel sınıflandırma doğruluğu elde edilmiştir.

Gomes et al. [24] nolu çalışmada, elektrokardiyografi sinyallerini makine öğrenimi yaklaşımı kullanarak Covid-19'un kalp fonksiyonlarını nasıl etkilediği incelenmiştir. Çalışmada acil bakım bağlamından elde edilen halka açık bir veri tabanı kullanılmıştır. Çalışmada %94 doğruluk elde edilmiştir. Bu çalışmaya bakılarak Covid-19'un kalp fonksiyonu üzerindeki etkisinin çok fazla olduğu görülmektedir.

Anwar et al. [25] nolu çalışmada, derin öğrenme yöntemleri kullanılarak Covid-19 tespiti ve kalp hastalıklarının tespiti gerçekleştirilmiştir. Çalışmada hastalık tespiti için EKG görüntülerini arttırmanın etkileri incelenmiştir. Çalışmada halka açık veri seti kullanılmıştır. Çalışmada arttırma olmadan, çoklu büyütme teknikleri uygulanarak sırasıyla 0,764 ve 0,768'e düşen 0,818 ve 0,776 F1 puanını ve doğruluğu elde edilmiştir.

Nguyen et al. [26] Nolu çalışmada, derin öğrenme yöntemlerini kullanarak EKG kâğıt kayıtlarından EKG sinyallerini elde ettikten sonra tek boyutlu evrişimli sinir ağına (1D-CNN) girdi olarak girilip Covid-19 hastalığını doğru bir şekilde teşhis etmişlerdir. Çalışmada halka açık Covid-19 EKG görüntüleri veri kümesi kullanılmıştır. Çalışmada Covid-19, Normal ve diğer olmak üzere üç sınıf kullanılmıştır. Diğer adlı sınıf miyokard enfarktüsü, anormal kalp atışı ve miyokard enfarktüsü öyküsü olan hastaları içermektedir. Dijitalleştirilmiş EKG sinyalleri üzerinde eğitilen 1D-CNN modeli, Covid-19'u üç sınıf kullanarak sınıflandırmak için elde edilen doğruluk, F1 puanı, hassasiyet ve özgünlük değerleri sırasıyla %83,17, %85,38, %84,81 ve %86,28 olarak bulunmuştur.

Muscato et al. [27] nolu çalışmada, EKG'lerde Covid-19 hastalığının belirtilerinin tespiti için uçtan uca otomatik bir algoritma geliştirmişlerdir. Çalışmada Covid-19 ile Covid-19 hastalığına sahip olmayan olarak iki gruba ayrılmış veri setleri kullanılmıştır. Covid-91 grubu, ilk 2020 pandemik salgını sırasında İtalya'da bulunan bir hastanenin 19-96 yaş aralığındaki hastalarından alınan 12 derivasyonlu EKG kayıtlarını içermektedir. Covid olmayan (kontrol grubu) grubu ise farklı ülkelerde toplanan ve daha önce Physionet Challenge 2021' de kullanılan üç genel veri kümesinden sinüs ritmindeki EKG seçilerek oluşturulmuştur. Çalışmada Covid-19'a karşı kontrol grubunu sınıflandırmak için 4 katmanlı bir evrişimli sinir ağı kullanılmıştır. Genel olarak doğruluk $0,85 \pm 0,01$, ortak test setinde $0,89 \pm 0,01$ olarak bulunmuştur.

Bu çalışma kapsamında Kardiyak ve Covid-19 hastalarının EKG görüntülerini içeren veri seti kullanılmıştır. Çalışmada son yıllarda popüler olan birçok alanda başarılı sonuçlar elde edilen EfficientNet mimarisi kullanılmıştır [28]–[30] . Yapılan çalışmada EfficientNet mimarisi kullanılarak Kardiyak ve Covid-19 hastalarının EKG görüntülerinden beş sınıflı hastalık tespiti

yapılmaya çalışılmıştır. Çalışmada farklı epoch değerleri kullanılmıştır. Ayrıntılı olarak test sonuçları, doğrulama kaybı, eğitim kaybı, doğrulama başarıları ve eğitim başarıları gösterilmiştir. Ayrıca CNN mimarisi kullanılarak sonuçları elde edilen her epoch değeri için karışıklık matrisleri gösterilmiştir.

Literatürde Covid-19 hastalığını otomatik olarak teşhis etmek için çok sayıda yöntem önerilmiştir. Covid-19 hastalık tespitinin hızlı ve güvenilir bir şekilde elde edilmesi çok önemlidir. EKG kırsal alanlarda kullanım açısından taşınabilirliği ile daha ulaşılabilir. Ciğer görüntülerinden tespit edilmesi maliyetli ve uzundur. Bu nedenlerden dolayı alternatif yöntemlerin kullanılması gerekmektedir. EKG görüntüleri kullanılarak Covid-19 tespiti yapıldığı takdirde hastanelerdeki bazı ünitelerde oluşan sıkışıklık önlenmektedir.



3. MATERYAL VE METOT

Materyal ve metot bölümünde EKG görüntülerini kullanarak Covid-19'un sınıflandırılması için önerilen sistemin mimarisi ve kullanılan teknolojiler anlatılmıştır. Sistemde EfficientNet-B0 mimarisini kullanarak hastalık tespiti yapılmıştır. Veri seti Kaggle veri bilimi sitesinden alınmış olup aşağıda açıklanan işlemler esas alınarak eğitilip sonuca ulaşılmıştır.

3.1. Derin Öğrenme

Derin öğrenme, yapay sinir ağları algoritmalarını kullanarak çok katmanlı mimarilerde büyük miktarda karmaşık olan veriler ile çalışan bilgisayarların edindiği deneyimlerden ders çıkarmasını sağlayan ve Şekil 3.1'de verildiği gibi makine öğreniminin bir alt dalıdır. Veri işlemede ve karar vermede kullanmak için kalıplar oluşturmada insan beyninin çalışmalarını taklit eden bir yapay zekâ işlevidir. Derin öğrenme teknikleri ile sınıflandırma, algılama ve yerelleştirme, segmentasyon, kavramsallaştırma, sıralı öğrenme, gömme gibi ele alınabilecek önemli öğrenme görevleri vardır. Derin öğrenme denetimli, denetimsiz, yarı denetimli olarak ayrılabilirler.



Şekil 3.1. Derin öğrenme

Derin öğrenme çok katmanlı algılayıcı, radyal temelli ağ, tekrarlayan sinir ağları, üretken düşman ağları, evrişimli sinir ağları olmak üzere beş temel sinir ağına sahiptir. Sinir ağları, tek çıktı üretmek için fazla sayıda girdi alan yapay nöronlardan oluşan karmaşık yapılardır [31].


Derin öğrenmede, bir bilgisayar modeli sınıflandırma görevlerini doğrudan görüntülerden, metinden veya sestten yapmayı öğrenir. Derin öğrenme modelleri, bazen insan düzeyindeki performansı aşan son teknoloji doğruluk sağlayabilir. Derin öğrenme modelleri çok sayıda katman içeren çok sayıda etiketli veri ve sinir ağı mimarileri kullanılarak eğitilir [32]. Derin öğrenme yöntemleri, eğitim aşamasında mevcut örnek sayısı fazla olduğunda oldukça etkilidir. Derin öğrenme modelleri, aç gözlü, katmanlı, denetimsiz bir ön eğitim olarak da çalışabilir. Bu, bir

seferde her katmandan çıkarılan özelliklerden hiyerarşiyi öğrendiği anlamına gelir. Özellik öğrenme, her katmanı, önceki katmandan çıkarılan özellikleri alan ve sonraki katman için girdi olarak kullanan denetimsiz bir öğrenme algoritmasıyla eğitilerek elde edilir. Böylece, özellik öğrenme, her yeni katmanda daha önce öğrenilen özelliklerin dönüşümünü öğrenmeye çalışmaktadır. Derin öğrenme mimarisi son zamanlarda çok fazla gelişim göstermiştir bu gelişim beraberinde yapay zekaya önemli katkıları olmuştur. Son yıllarda hızla gelişen derin öğrenmenin birçok kütüphanesi vardır. Tablo 3.1’de derin öğrenmenin çeşitli alanlarda uygulanmasını ve geliştirilmesi için sık kullanılan derin öğrenme kütüphaneleri verilmiştir.

Tablo 3.1. Derin Öğrenme Kütüphaneleri

İSİM	ARAYÜZ	URL
Keras	Python	https://keras.io/
PyTorch	Python	https://pytorch.org/
TensorFlow	Python	https://www.tensorflow.org/?hl=tr
Caffe	C++/ Python/MATLAB	https://caffe.berkeleyvision.org/
MXNet	Python/R	https://mxnet.apache.org/versions/1.9.1/
Torch	LuaJIT/C	http://torch.ch/
Scikit - learn	Phyton	https://scikit-learn.org/stable/

Derin öğrenme modelleri, büyük ve karmaşık verileri önceden işlemek için az uğraş gerektirdiğinden hassas tıp araştırmalarında kullanılmaktadır ve geniş bir uygulama beklentisine sahiptir. En gelişmiş yapay zekâ yöntemi olan derin öğrenme yönteminin hassas tıp araştırmalarında ki şematik diyagramı Şekil 3.2’de gösterildiği gibidir. Ayrıca derin öğrenme yöntemleri kullanılarak Covid-19 teşhisi [33] makalesinde kanıtlanmıştır.



Şekil 3.2. Hassas tıp araştırmalarında derin öğrenme modelinin uygulanması

3.2. Evrişimsel Sinir Ağları (CNN)


Evrişimsel sinir ağı 1980'li yıllarda ortaya çıkmıştır ve [34] Evrişimsel sinir ağı türünün ilk mimarisidir. Çalışmada özellik çıkarımı, katmanları birleştirme ve bir sinir ağında evrişim katmanları tanıtılıp sınıflandırılma önerilmiştir. İlk eğitilmiş CNN modeli [35] çalışmasında oluşturulup geliştirilmiştir. El yazısı ve rakam tanıma görevi için geliştirilmiştir. Geliştirilen mimari LeNet mimarisidir. Bu mimaride konvolüsyon katmanları ve havuzlama katmanları art arda bulunmaktadır. Son olarak tam bağlantılı katmana bağlanmaktadır. Artık tıbbi uygulamalarda CNN ilk sıralarda yer almaktadır.

Derin öğrenmede Evrişimsel Sinir Ağı, canlıların doğal görsel algılama mekanizmasından ilham alan tanınmış bir derin öğrenme mimarisidir. Evrişimli sinir ağında görüntüden öğrenilen özellikler ötelemelidir ve deforme olmaz. Ayrıca evrişim katmanı ne kadar yüksekse, çıkarılan özellikler o kadar soyut ve karmaşıktır. Bir girdi katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanı içeren düğüm katmanlarından oluşmaktadır.

CNN mimarisinin evrişimli katman, havuzlama katmanı ve tamamen bağlı katman olmak üzere üç temel katman türü vardır. Evrişim katmanı, evrişim ağının ilk katmanıdır. Evrişim katmanları ek evrişimli katmanlar veya havuzlama katmanları takip edebilirken, tam bağlantılı katman son katmandır. CNN her katmanda görüntünün daha büyük bölümlerini tanımlar. Bu durum CNN'nin karmaşıklığını artırır. İlk katmanlar renk ve kenar gibi basit özelliklere odaklanır. Kullanılan verilerde amaçlanan durumu tanımlayana kadar CNN katmanları boyunca ilerlemeye devam eder ve nesnenin daha büyük şekillerini tanımaya başlar. CNN'de sonraki katmanlar önceki katmanların alıcı alanları içerisindeki pikselleri görebilir. Bu durum beraberinde CNN'nin yapısı hiyerarşik hale gelir [36].

3.2.1. Evrişim Katmanı (Convolution Layer)

Evrişim katmanı CNN'nin temel bloğu olarak kabul edilmektedir. Ana işlevi girdi görüntülerinden öznitelikleri çıkartmaktır. CNN'de, katmanların parametrelerinin ve kanalının bir dizi öğrenilebilir kanal veya nörondan oluştuğunu anlamak için çok önemlidir. Bu kanalların küçük bir alıcı alanı vardır. Evrişim katmanında belirli bir $M \times M$ boyutunda bir filtre arasında evrişimin matematiksel işlemi gerçekleştirilir. Filtreyi giriş görüntüsünün üzerinde kaydırarak, filtrenin boyutuna göre filtre ile giriş görüntüsünün parçaları arasında iç çarpım alınır. Uygulanan filtre sonucunda giriş görüntüsünden daha küçük bir çıktı matrisi elde edilir. Şekil 3.3'de evrişim katmanının matematiksel işlemi yer almaktadır. Çıktı görüntü hakkında köşeler, kenarlar, dokular, nesneler gibi farklı özellik haritasını vermektedir [37].




Şekil 3.3. Evrişim katmanı

3.2.2. Havuzlama Katmanı (Pooling Layer)

Havuzlama katmanında ana fikir olarak daha fazla katman için karmaşıklığı azaltmak adına aşağı örneklemedir [38]. Görüntü işleme alanında, çözünürlüğü düşürmeye benzer olarak kabul edilebilir. Havuzlama katmanı filtre sayısını etkilemez. Maksimum havuzlama ve ortalama havuzlama olmak üzere iki farklı havuzlama türü vardır. Maksimum havuzlama giriş boyunca hareket eden filtreyi çıkış dizisine göndermek için maksimum değeri seçmektedir. Bu yaklaşım ortalama havuzlamaya göre daha sık kullanılmaktadır. Ortalama havuzlama da giriş boyunca hareket eden filtreyi çıkış dizisine göndermek için uygulanan filtre içinde kalan değerlerin ortalama değerini hesaplayarak çıkışa göndermektedir [39]. Şekil 3.4’de maksimum ve ortalama havuzlamanın örneği yer almaktadır.

Havuzlama katmanında bilgilerden birçoğu kaybolmaktadır. Fakat karmaşıklığı azaltma, verimliliği arttırma ve aşırı uyum riskini sınırlama gibi önemli faydaları vardır.




Şekil 3.4. Maksimum ve Ortalama Havuzlama

3.2.3. Tam Bağlı Katman (Fully-Connected Layer)

Tam bağlı katman (FC), gizli katman olarak da bilinmektedir. Evrişimli sinir ağındaki son katmandır. Çalışma düzeni olarak yapay sinir ağı gibidir. Önceki katmanların çıktılarını alır, “düzleştirir” ve bir sonraki aşama için girdi olabilecek tek bir vektöre dönüştürür [40]. Tam bağlı katmandan gelen özellik vektörü, eğitimden sonra görüntüleri farklı kategoriler arasında sınıflandırmak için kullanılır. Bu katmandan gelen tüm girdiler, bir sonraki katmanın her aktivasyon birimine bağlanır. Şekil 3.5’de evrişimli sinir ağı temel katman sıralaması gösterilmiştir.

Evrişim ve havuzlama katmanları ReLu işlevlerini kullanma eğilimindeyken, tam bağlı katman genellikle girdileri uygun şekilde sınıflandırmak için softmax aktivasyon işlevinden yararlanarak 0’dan 1’e kadar bir olasılık üretir [41].



Şekil 3.5. Evrişimli sinir ağı temel katman sıralaması

3.3. Aktivasyon Fonksiyonları

Evrişim katmanları sonrasında aktivasyon fonksiyonları gelmektedir. Aktivasyon fonksiyonu, ağı verilerdeki karmaşık kalıpları öğrenmesine yardımcı olmak için yapay sinir ağına eklenen bir fonksiyondur. Bir aktivasyon işlevi, bir nöronun etkinleştirilip etkinleştirilmeyeceğini belirler. Bir önceki hücreden gelen çıkış sinyalini alır ve bir sonraki hücreye girdi olarak alınabilecek bir forma dönüştürür. Bu, nöronun ağı girişinin tahmin sürecinde alakalı olup olmadığını belirlemek için bazı basit matematiksel işlemleri kullanacağı anlamına gelmektedir [42]. Aktivasyon fonksiyonlarının kullanılmadığı ağlarda her nöron, ağırlıkları ve önyargıları kullanarak girdiler üzerinde yalnızca doğrusal bir dönüşüm gerçekleştirecektir. Doğrusal dönüşümler sinir ağını daha basit hale getirir de bu ağ daha az güçlü olacak ve karmaşık kalıpları verilerden öğrenemeyecektir. Aktivasyon fonksiyonları lineer aktivasyon fonksiyonu, ikili adım işlevi, doğrusal olmayan aktivasyon fonksiyonları olmak üzere 3 türe ayrılırlar.

3.3.1. Lineer Aktivasyon Fonksiyonu

Genellikle kimlik aktivasyon fonksiyonu olarak adlandırılan lineer aktivasyon fonksiyonu, girdiyle orantılıdır. Doğrusal aktivasyon fonksiyonunun aralığı $(-\infty$ ila $\infty)$ olacaktır. Yani fonksiyonların çıktısı herhangi bir aralık arasında sınırlandırılmayacaktır. Doğrusal aktivasyon işlevi, girdilerin ağırlıklı toplamını basitçe toplar ve sonucu döndürür. Sinir ağlarına beslenen olağan verilerin karmaşıklığına veya çeşitli parametrelerine yardımcı olmaz. Matematiksel olarak aşağıdaki şekilde ifade edilir.

$$F(x) = x \quad (3.1)$$

3.3.2. İkili Adım İşlevi

İkili adım işlevi, bir nöronun etkinleştirilip etkinleştirilmeyeceğine karar veren bir eşik değerine bağlıdır. Etkinleştirme işlevine beslenen girdi, belirli bir eşikle karşılaştırılır; girdi ondan büyükse, nöron etkinleştirilir, aksi takdirde devre dışı bırakılır, yani çıktısı bir sonraki gizli katmana aktarılmaz.

$$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases} \quad (3.2)$$

3.3.3. Doğrusal Olmayan Aktivasyon Fonksiyonu

Doğrusal olmayan aktivasyon fonksiyonları en çok kullanılan aktivasyon fonksiyonlarıdır. Modelin çeşitli verilerle genelleştirilmesini veya uyarlanması ve çıktılar arasında ayırım yapılmasını kolaylaştırır [43]. Bu aktivasyon fonksiyonları temel olarak aralıklarına ve eğrilerine göre bölünmüştür. Tablo 3.2’de doğrusal olmayan aktivasyon fonksiyonları denklem, aralık ve grafik halinde gösterilmiştir.

Sigmoid Fonksiyonu: En yaygın kullanılan doğrusal olmayan aktivasyon fonksiyonudur. 0 ile 1 arasındaki değerleri dönüştürür. Hesaplama açısından pahalıdır. Genellikle sigmoid yöntemi ikili sınıflandırma problemlerinde kullanılır.

Tanh Fonksiyonu: Sigmoid fonksiyonuna benzer. Tek farkı orijine göre simetrik olmasıdır yani sınıf merkezlidir. -1 ile 1 arasında değer üretir.




Softmax Fonksiyonu: Sigmoid fonksiyonunun geliştirilmiş halidir. 0 ile 1 aralığında değerler üretir. Çok sınıflı sınıflandırma problemlerinde kullanılır[44].




ReLU (Rectified Linear Unit) Fonksiyonu: ReLu, doğrultulmuş doğrusal birim anlamına gelir. Derin öğrenme alanında popüler doğrusal olmayan aktivasyon işlevidir. ReLu 0 ile ∞ aralında değerler üretir. ReLu işlevini kullanmanın diğer etkinleştirme işlevlerine göre en büyük avantajı, tüm nöronları aynı anda etkinleştirmemesidir. Bu, nöronların yalnızca doğrusal dönüşümün çıktısı 0'dan küçükse devre dışı bırakılacağı anlamına gelir.

ELU (Exponential Linear Unit) Fonksiyonu: Sinir ağları için bir aktivasyon işlevidir. Üstel Doğrusal Birim veya kısaca ELU, aynı zamanda, fonksiyonun negatif kısmının eğimini değiştiren bir ReLU çeşididir. ReLu'ların aksine ELU'lar ortalama birim aktivasyonlarını toplu normalleştirme gibi sifra yaklaşıtırmalarına, ancak daha düşük hesaplama karmaşıklığına sahip olmalarına izin veren negatif değerlere sahiptir[45]. Sıfıra doğru ortalama kaymalar, azaltılmış sapma kaydırma etkisi nedeniyle normal gradyanı birim doğal gradyana yaklaştırarak öğrenmeyi hızlandırır.

Swish Fonksiyonu: Google beyin ekibi tarafından geliştirilmiştir. Bu fonksiyon alttan sınırlı, üstten sınırsızdır yani X negatif sonsuza yaklaşırken Y sabit bir değere yaklaşır, ancak X sonsuza yaklaşırken Y sonsuza yaklaşır. Hesaplama açısından ReLU kadar verimlidir ve daha derin modellerde ReLU'dan daha iyi performans gösterir.

Tablo 3.2. Aktivasyon Fonksiyonları

Fonksiyon Adı	Denklem	Aralık	Grafik
Sigmoid Fonksiyonu	$f(x) = \frac{1}{1 + e^{-x}}$	(0,1)	
Tanh Fonsiyonu	$F(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	(-1, 1)	
Softmax Fonksiyonu	$Softmax(x_i) = \frac{\exp(x_i)}{\sum_j \exp(x_j)}$	(0,1)	

ReLu Fonksiyonu	$F(x) = \max(0, x)$	$(0, \infty)$	
Swish Fonksiyonu	$\sigma(x) = \frac{x}{1 + e^{-x}}$	$(-\infty, \infty)$	
ELU Fonksiyonu	$\begin{cases} x & \text{for } x \leq 0 \\ a(e^x - 1) & \text{for } x < 0 \end{cases}$	---	

3.4. Transfer Öğrenme


Transfer öğrenimi, bir veya daha fazla kaynak görevde öğrenilen bilgileri aktararak ve bunu ilgili bir hedef görevde öğrenmeyi geliştirmek için kullanarak geleneksel makine öğrenimini geliştirmeye çalışır. Yani daha önce öğrenilmiş olan ilgili bir görevden bilgi aktarım yolu ile yeni bir görevde öğrenmenin iyileştirilmesidir. İkinci bir görevi modellerken hızlı ilerleme veya iyileştirilmiş performans sağlayan bir optimizasyondur. İkinci görev birinci göreve benzer olduğunda veya ikinci görev için yeterli veri olmadığında faydalıdır. İlk görevden öğrenilen bilgileri başlangıç noktası olarak kullanıp ikinci görevde daha hızlı ve etkili öğrenir. İki model benzer görevleri yerine getirmek için geliştirilirse, aralarında genelleştirilmiş bilgi paylaşılabilir. Makine öğrenimi geliştirmeye yönelik bu yaklaşım, yeni modelleri eğitmek için gereken kaynakları ve etiketlenmiş veri miktarını azaltır.

Transfer öğrenimi kavramını uygulamak için önceden eğitilmiş modellerden yararlanılır. Önceden eğitilmiş modellere omurga denir. Önceden eğitilmiş modeller, çok büyük veri kümeleri üzerinde eğitilen, geliştirilen ve benzer türdeki sorunları çözmek için bu makine öğrenimi topluluğuna katkıda bulunmak isteyen diğer geliştiriciler tarafından kullanıma sunulan derin öğrenme modelleridir [46]. Bilgisayarla görme sorunları için ResNet, DenseNet, EfficientNet popüler olarak kullanılmaktadır. Önceden eğitilmiş bir model kullanmak genellikle modeli yeni bir görev üzerinde eğitme sürecini hızlandırır ve genel olarak daha doğru ve etkili bir modelle sonuçlanabilir.

Transfer öğrenimi genellikle şu durumlarda kullanılır[47]:

- Benzer görevleri tamamlamak için birden fazla makine öğrenimi modelini sıfırdan eğitmek sorunda kalmadan zamandan ve kaynaklardan tasarruf etmek.
- Görüntü sınıflandırma veya doğal dil işleme gibi yüksek miktarlarda kaynak gerektiren makine öğrenimi alanlarında verimlilik tasarrufu olarak.
- Önceden eğitilmiş modelleri kullanarak bir kuruluş tarafından tutulan etiketli eğitim verilerinin eksikliğini ortadan kaldırmak.

Transfer öğrenimini kullanırken aranacak üç olası fayda Şekil 3.6’da verilmiştir. İlk olarak daha yüksek başlangıç. Kaynak modeldeki ilk beceri (modeli iyileştirmeden önce), aksi takdirde olacağından daha yüksektir. İkinci olarak daha yüksek eğim Kaynak modelin eğitimi sırasında becerinin gelişme oranı, aksi takdirde olacağından daha yüksektir. Üçüncüsü ise daha yüksek asimptot Eğitilmiş modelin birleştirilmiş becerisi, aksi durumda olacağından daha iyidir şeklinde açıklanabilir.



Şekil 3.6. Transferin öğrenmeyi geliştirebileceği üç yol


3.5. EfficientNet

EfficientNet, evrişimli sinir ağı modelidir. Görüntü tanıma için en güncel teknolojidir. Model 2019 yılında Tan ve Le tarafından [48] geliştirilmiştir ve ImageNet popüler veri setlerinde yüksek başarı elde etmiştir. EfficientNet mimarisi, zamandan ve hesaplama gücünden tasarruf etmek için transfer öğrenmeyi kullanır. Sonuç olarak, rakip bilinen modellerden daha yüksek doğruluk değerleri sağlar. Bunun nedeni bileşik bir katsayı kullanarak derinlik, genişlik ve çözünürlükte akıllı bir ölçeklendirmenin kullanılmasıdır [49].

EfficientNet modelde derinlik, genişlik ve çözünürlüğün tüm boyutlarını eşit olarak ölçeklemektedir. Şekil 3.7’ de bileşik ölçeklendirme adı verilen ölçeklendirme yöntemi gösterilmiştir. Modelde derinlik ağı derinliğidir ve bir ağıdaki katman sayısına eşittir. Modelde

genişlik bir Konvolüsyonel katmanda bulunan kanal sayısıdır. Modelde çözünürlük ise CNN'ye gönderilen resim kalitesidir.


EfficientNet bileşik ölçekleme yaklaşımı kullanır bu yaklaşım ile verimliliği en üst düzeye çıkarmaktadır. EfficientNet-B0 modeli derin öğrenme algoritması olarak belirlenirken hesaplama maliyeti, erişilebilirlik, hız ve kullanılabilirlik parametreleri dikkate alınmıştır[50].



Şekil 3.7. Model Ölçeklendirme örnekleri. (a) temel ağ, (b) genişlik ölçekli ağ, (c) derinlik ölçekli ağ ve (d) çözünürlük ölçekli ağ. (e) tüm genişliği, yüksekliği ve çözünürlüğü eşit şekilde ölçekleyen bileşik ölçeklendirme yöntemi.

EfficientNet-B0 bu gruptaki en temel modeldir. EfficientNet-B0, 5,3 milyon parametre ve 0,39 milyar FLOPS'tan oluşur. Bu modelin ana yapı taşı, sıkma ve uyarma optimizasyonunun eklendiği MBConv'den oluşmaktadır. MBConv, MobileNet v2'de kullanılan ters çevrilmiş artık bloklara benzer. Bu bloklar evrişimli bloğun başlangıcı ve sonu arasında kısayol bağlantısı oluşturmaktadır. Ağın her özellik haritasının ağırlıklarını ayarlayabilmesi için parametreler her kanala eklenir. Girdi aktivasyon haritaları, özellik haritalarının derinliğini artırmaya yardımcı olmak için 1×1 boyutlu evrişimler kullanır ve bunu, derinlemesine gerçekleştirilen 3×3 evrişimler takip eder ve son olarak, çıkış özellik haritasının boyutunu azaltmak için noktasal evrişimler izler. Bu mimari, modelin boyutunu ve gerekli işlem sayısını azaltmaya yardımcı olur.

EfficientNet şu anda sınıflandırma için en performanslı evrişimli sinir ağıdır. Şekil 3.8 çalışmada hedeflenen sınıflandırmayı yapmak için kullanılan Covid-EfficientNet-B0 mimarisini göstermektedir. Önerilen EfficientNet modeli yüksek doğruluk sağlar ve son teknoloji modellerine göre parametreleri azaltarak modellerin verimliliğini de artırmaktadır.




Şekil 3.8. EfficientNet-B0 model blok şeması

3.6. Sınıflandırma

Görüntü sınıflandırma, dünyada her zaman sıcak bir araştırma yönü olmuştur ve derin öğrenmenin ortaya çıkışı bu alanın gelişimini desteklemiştir. Görüntü sınıflandırma, görüntülere sınıf atama işlemidir. Bu, farklı sınıflara ait görüntülerde benzer özellikler bularak ve bunları görüntüleri tanımlamak ve etiketlemek için kullanarak yapılır. Görüntü sınıflandırması yapay sinir ağları yardımıyla yapılır. Sinir ağları derin öğrenme algoritmalarıdır. Şekil 3.9 sinir ağını göstermektedir [51].

Genel olarak, görüntü sınıflandırması, özellikleri veya özellik öğrenme yöntemlerini manuel olarak çıkararak tüm görüntüyü tanımlar ve ardından nesne kategorisini tanımlamak için sınıflandırıcıyı kullanır. Bu nedenle, görüntünün özelliklerinin nasıl çıkarılacağı özellikle önemlidir.



Şekil 3.9. Sinir Ağı

Görüntü sınıflandırmanın ikili sınıflandırma, çok sınıflı sınıflandırma, çok etiketli sınıflandırma ve dengesiz sınıflandırma olmak üzere dört farklı türü vardır [52].

İkili sınıflandırma: İki sınıf etiketine sahip sınıflandırma görevlerini içerir. İkili sınıflandırma normal durum olan bir sınıfı ve anormal durum olan başka bir sınıf olmak üzere iki sınıf içerir. Normal durum sınıfına sınıf etiketi 0 atanır ve anormal duruma sahip sınıfa sınıf etiketi 1 atanır. Örnek olarak Covid-19 tespiti sırasında alınacak iki sonuç vardır. Hasta veya hasta değil.

Çok sınıflı sınıflandırma: İki'den fazla sınıf etiketi içeren sınıflandırma görevlerini ifade eder. İkili sınıflandırma gibi normal ve anormal şeklinde iki sonuç vermez. Bilinen bir dizi sınıf arasından birine ait olarak sınıflandırılabilir. Çok sınıflı sınıflandırma, her numunenin bir ve yalnızca bir etikete atandığı varsayımı yapar. Örnek olarak bir hasta hem Covid-19 hastalığına sahip olup aynı zamanda hastalığı olmayan kişiler grubunda yer alamaz. Çalışmada çok sınıflı sınıflandırma kullanılmıştır.

Aynı Anda Çok etiketli sınıflandırma: Çok etiketli sınıflandırma veya çok çıktılı sınıflandırma, her bir örneğe ait olmayan birden çok etiketin atanabileceği sınıflandırma problemidir. Çoklu etiket problemlerinde etiketlerin kaç tane sınıfa atanabileceği konusunda kısıtlama yoktur.

Dengesiz sınıflandırma: Her sınıftaki örnek sayısının eşit olmayan bir şekilde dağıldığı sınıflandırma görevlerini ifade etmektedir. Dengesiz sınıflandırma görevleri, eğitim veri kümesindeki örneklerin çoğunluğunun normal sınıfa ve az sayıda örneğin anormal sınıfa ait olduğu ikili sınıflandırma görevleridir.


3.7. Veri Seti

Veri kümesi, modeli eğitmek için kullanılan veri koleksiyonudur. Veri türlerini metin verileri, görüntü verileri, ses verileri, video verileri ve sayısal veriler olarak örneklendirilebilir. Doğru veri setini hazırlamak ve seçmek derin öğrenme modelinin eğitimindeki en önemli adımlardan biridir. Bir veri kümesinin modeli eğitmek ve modeli eğittikten sonra doğrulunu ölçmek olarak iki temel amacı vardır.

Önerilen çalışmada 1114 tane farklı EKG görüntü içeren halka açık bir görüntü veri seti kullanılmıştır. Veri seti 250 tane Covid-19, 250 tane normal, 239 tane miyokard enfarktüsü, 233 tane anormal kalp atışı, 172 tane miyokard enfarktüsü öyküsü olmak üzere beş sınıftan oluşmaktadır. Tablo 3.3'de sınıflandırılan hastalıkların tanımı ve sayısı verilmiştir. Şekil 3.10'da ise veri setinden rastgele seçilmiş görüntüler bulunmaktadır. [53] veri setinin orijinal halidir. Veri setinin birçok versiyonu vardır çalışmada en güncel 4. Versiyonu kullanılmıştır.

Tablo 3.3. Sınıflandırılan hastalıklar

KATEGORİ	AÇIKLAMA	FARKLI EKG GÖRÜNTÜLERİNİN SAYISI
Covid-19	Koronavirüs 2019'un sonlarına doğru çıktı ve tüm dünyaya yayıldı. Covid-19 virüsü bulaşmış bireyler solunum yolu hastalıkları yaşarlar. Özel veya özel tedavi olmadan iyileşebilirler. Covid-19 hastalığı olan bireylerin EKG görüntüleridir.	250
Normal	Gözlenebilir anormallikten yoksun olan bireylerdir. Bilinen hastalıkları olmayan hastaların EKG görüntüleridir.	250
Anormal kalp atışı	Kalp atışlarında anormallik olan, Covid-19 ve Miyokard enfarktüsü hastalığı atlatan ve solunum yolu hastalığı semptomları olan hastaların EKG görüntüleridir.	233
Miyokard enfarktüsü	Kalp krizinin tıbbi adıdır. Kalbin bir kısmına kan akışının azalması veya durması sonucunda kalpte hasar meydana getirir. En yaygın belirtileri göğüste basınç veya sıkışma, göğüste, sırtta, çenede ve vücudun diğer bölgelerinde birkaç dakikadan uzun süren veya kaybolup geri gelen ağrı nefes darlığıdır.	239
Miyokard enfarktüsü öyküsü	Yakın zamanda Miyokard enfarktüsünden iyileşen hastalardır.	172



Şekil 3.10. Veri setinden hastalıklara ait örnek görüntüler

3.8. Önerilen Yöntem

Çalışmada tasarlanan CNN modeli, modelin etkinlik düzeyini gözlemlemek için test verileri üzerinde eğitilmiş ve test edilmiştir. Yapılan çalışmanın eğitim, doğrulama ve test aşamaları Python programlama dili ve Google Research tarafından sunulan Colaboratory kullanılarak yapılmıştır. Google Colab, Jupyter Notebook'un bulutta barındırılan bir sürümüdür. Colab depolama, bellek, işlem kapasitesi, grafik işleme birimleri (GPU'lar) ve tensör işleme birimleri (TPU'lar) gibi bilgi işlem altyapısına ücretsiz erişim sağlar.

Veri setinde bulunan görüntüler rastgele %80 eğitim, %10 doğrulama ve %10 test olmak üzere 3 gruba ayrılmıştır. Eğitim veri seti veri kümesinin en önemli alt kümelerinden biridir ve modeli eğitmek için kullanılan verileri içerir. Doğrulama veri kümesi eğitim aşaması tamamlandıktan sonra modelin tüm parametrelerini değerlendirmek için kullanılır. Test veri kümesi ise eğitim sürecinin son aşamasında girilir ve bu alt kümedeki veriler model tarafından bilinmemektedir. Modelin doğruluğunu test etmek için kullanılmaktadır. Ayrıca modelin sınıflandırma sonrasında kullanılan yöntemlerin performans değerlendirmesinde karışıklık matrisi kullanılmıştır.

Hiper Parametreler

Hiper parametreler, değerleri öğrenme sürecini kontrol eden ve bir öğrenme algoritmasının öğrenmeye son verdiği model parametrelerinin değerlerini belirleyen parametrelerdir. Model eğitim sürecine başlamadan önce değerleri ayarlanan parametrelerdir. Hiper parametreler için belirtilen değerler, eğitim sürecindeki model öğrenme oranını ve diğer düzenlemeleri ve son model performansını etkileyebilir.

Optimize edici algoritmalar derin öğrenme modelinin performansını iyileştirmeye yardımcı olan optimizasyon yöntemidir. Bu optimizasyon algoritmaları veya optimize ediciler, derin öğrenme modelinin doğruluğunu ve hız eğitimini büyük ölçüde etkiler. Son yıllarda, bir modelin parametrelerini güncellemek için farklı optimizasyon algoritmaları önerilmiştir. 2015 yılında Kingma et al. [54] tarafından tanıtılan Adam bu algoritmalarından en yaygın kullanılanıdır. Adam (Uyarlanabilir Moment Tahmini), birinci ve ikinci dereceden momentumlarla çalışır. Hesaplamalı olarak pahalı olsa da yöntem çok hızlı ve hızla yakınsıyor. Kaybolan öğrenme oranını, yüksek varyansı düzeltir gibi avantajları bulunmaktadır.

Öğrenme hızı hiper parametresi, modelin öğrendiği hızı veya hızı kontrol eder. Spesifik olarak, modelin ağırlıklarının, örneğin her bir eğitim örneği grubunun sonunda olduğu gibi, her güncellenişlerinde güncellendiği paylaştırılmış hata miktarını kontrol eder.

Epoch sayısı, öğrenme algoritmasının tüm eğitim veri kümesi boyunca kaç kez çalışacağını tamamlayan bir hiper parametredir. Epoch bir döngüdeki tüm eğitim verileriyle makine öğrenimi modelini eğitmek için toplam yineleme sayısı olarak tanımlanır. Epoch 'ta tüm eğitim verileri tam olarak bir kez kullanılır. Ayrıca, başka bir deyişle Epoch, bir algoritmanın eğitim veri kümesi etrafında tamamladığı toplam geçiş sayısı olarak da anlaşılabilir. Bir ileri ve bir geri pas birlikte antrenmanda bir pas olarak sayılır. Epoch sayıları genellikle büyüktür. Hata yeterince en aza indirilene kadar çalışmasına izin verilir. Büyük miktarda kullanılabilir veri varsa, tüm veri kümelerini ortak gruplara veya yığınlara bölünebilir. Her dönem, dahili model parametrelerini güncellemek için kullanılan ağırlık güncelleme adımlarını içerir.


Batch size, sinir ağlarını eğitirken hata gradyanı tahmininin doğruluğunu kontrol eder. Değerinin hesaplama süresini etkilemediği öğrenme hızı hiper parametresinin aksine, batch size, eğitimin yürütme süresi ile bağlantılı olarak incelenmelidir. Batch size ile öğrenme sürecinin hızı ve kararlılığı arasında bir gerilim vardır. Batch size boyutunu arttırmak eğitim sürecini hızlandırmaktadır. Tablo 3.4'de amaca yönelik kullanılan hiper parametreler gösterilmiştir.

Tablo 3.4 Amaca yönelik kullanılan hiper parametreler

Hiper Parametreler	Değerler
Optimizer	Adam
Weight	ImageNet
Metrics	Accuracy
Epochs	50
Batch Size	20
Initial learning rate	0.001

Metrikler

Bir karışıklık matrisi, bir sınıflandırma algoritmasının performansını tanımlamak için kullanılan tablodur. Tablo Şekil 3.11’de gösterildiği gibidir. Hata matrisi olarak da bilinen karışıklık matrisi, bir sınıflandırma modelinin bir dizi test verisi üzerindeki performansını açıklayan bir matrisle gösterilir. Sınıf başına kaç tahminin doğru ve yanlış olduğunu gösterir. Model tarafından diğer sınıf olarak karıştırılan sınıfların anlaşılmasına yardımcı olur. Karışıklık matrisi, ikili sınıflandırmaya uygulanabileceği gibi çok sınıflı sınıflandırma problemlerine de uygulanabilir [55]. Bu metrikler sınıflandırma çalışmalarındaki sonuçları değerlendirirken yüksek performans gösterdikleri için yaygın olarak kullanılmaktadırlar. Bu nedenle, çalışmada yukarıda belirtilen performans ölçümleri kullanılmıştır.

**Şekil 3.11.** Karışıklık Matrisi

TP (Gerçek Pozitif):

Eğitilen modelde değerlendirme sonucunda pozitif olan hastalığın pozitif olarak tahmin edilmesidir. Yani hastalığa sahip olan hastaların sayısını temsil eder.

TN (Gerçek Negatif):

Eğitilen modelde değerlendirme sonucunda negatif olan hastalığın negatif olarak tahmin edilmesidir. Yani sağlıklı hastaların sayısını temsil eder.

FP (Yanlış Pozitif):

Eğitilen modelde değerlendirme sonucunda gerçekte negatif olan durumun pozitif olarak tahmin edilmesidir. Yani hastalığa sahip olarak sınıflandırılan ancak sağlıklı olan bireylerin sayısını temsil eder. FP Tip I hatası olarak bilinir.

FN (Yanlış Negatif):

Eğitilen modelde değerlendirme sonucunda gerçekte pozitif olan durumun negatif olarak tahmin edilmesidir. Sağlıklı olarak yanlış sınıflandırılan ancak hasta olan kişilerin sayısını temsil eder. FN Tip II hatası olarak bilinir.

Bir algoritmanın performans ölçütleri yukarıda belirtilen TP, TN, FP ve FN temelinde hesaplanan doğruluk, kesinlik, duyarlılık, özgüllük, hassasiyet ve F1- Skorudur.

Doğruluk (Accuracy)

Bir algoritmanın doğruluğu, doğru sınıflandırılan hastaların toplam hasta sayısına oranı olarak temsil edilmektedir.

$$\text{doğruluk} = \frac{(TP + TN)}{(TP + FP + FN + TN)}$$

Kesinlik (Precision)

Bir algoritmanın kesinliği, hastalığa sahip doğru bir şekilde sınıflandırılan hastaların, hastalığa sahip olduğu tahmin edilen toplam hastalara oranı olarak temsil edilir. Bu ölçümün hesaplamasına izin verdiği şey, pozitif tahminlerin gerçekte pozitif olma oranıdır.

$$\text{kesinlik} = \frac{TP}{(TP + FP)}$$

Hassasiyet (Recall)

Hatırlama veya duyarlılık olarak da bilinir. Doğru şekilde sınıflandırılan hasta olan kişilerin, hastalığa gerçekten sahip olan toplam hasta sayısına bölünmesiyle elde edilen orandır.

$$hassasiyet = \frac{TP}{(TP + FN)}$$

Özgüllük (Specificity)

Spesifiklik, toplam gerçek negatif örneklerden negatif değerlerin oranını verir. Başka bir deyişle, doğru olarak tanımlanan gerçek olumsuz vakaların oranıdır.

$$özgüllük = \frac{TN}{(TN + FP)}$$

F1-Skor

F 1 puanı, F puanı veya F ölçüsü, kesinlik ve duyarlılığın harmonik ortalamasıdır ve her iki faktöre de önem verir

$$F1 - Skoru = \frac{2 \times (Kesinlik \times Duyarlılık)}{(Kesinlik + Duyarlılık)}$$


4. UYGULAMA SONUÇLARI

Yapılan çalışmalar kapsamında EKG görüntülerinden alınan veriler ile Covid-19 ve diğer hastalıkların tespiti için derin öğrenme yöntemleri kullanılarak başarılı bir şekilde sınıflandırılabilen sonuçlara varılmıştır. Test süresince alınan doğruluk, keskinlik ve F1 skoru verileri ile hastalık tespiti beraberinde uygulanacak olan tedaviye karar verme aşamalarında alanında uzman doktorlara zaman tasarrufu ve hızlı doğru teşhis ile önemli bir katkı sağlayacağı anlaşılmıştır. Tablo 4.1’ de önerilen mimari eğitildiğinde 5 hastalık ile elde edilen değerler 50 epoch değeri için verilmiştir.

Tablo 4.1 EfficientNet-B0 kullanılarak elde edilen sınıf bazlı sınıflandırma sonuçları


	Precision	Recall	F1-score	Support
Covid-19	1.00	1.00	1.00	21
HB	1.00	0.97	0.98	31
MI	1.00	1.00	1.00	24
Normal	1.00	1.00	1.00	25
PMI	0.93	1.00	0.97	14

Bir model eğitildiğinde, veri kümesi eğitim ve doğrulama şeklinde alt kümelerine bölünmektedir. Epoch değeri arttıkça eğitim kaybı her epochta düşerken eğitimin başarısının arttığı görülmektedir.



Şekil 4.1 EfficientNet-B0 Epoch 5 (a) eğitim ve değerlendirme kaybı (b) eğitim ve değerlendirme doğruluğu grafikleri

Şekil 4.1 (a) da 5 epoch için eğitim ve doğrulama kaybı grafikleri verilmiştir. Ayrıca mavi yuvarlak nokta ile en iyi sonucun bulunduğu epoch etiketlenmiştir. Şekil 4.1'a da görüldüğü gibi epoch sayısı arttıkça eğitim ve doğrulama kaybı düzenli olarak azalmaktadır. Bu durum epoch sayısı arttıkça accuracy'nin (doğruluğun) arttığını göstermektedir. En iyi epoch Şekil 4.1 (b) de 5 nolu epoch olarak görülmektedir.




Şekil 4.2 EfficientNet-B0 Epoch 10 (a) eğitim ve değerlendirme kaybı (b) eğitim ve değerlendirme doğruluğu grafikleri

Şekil 4.2 (a) da epoch sayısı arttıkça eğitim ve doğrulama kaybı doğrusala yakın olarak azalmaktadır. Şekil 4.2 (b) de doğrulama doğruluğu (başarısı) 8 nolu epochta 6 nolu epoch a göre 0,02 oranında düşmüştür. En iyi epoch mavi yuvarlak ile 10 epoch olarak gösterilmiştir. Eğitim başarısı 0-3 epochlar arasında fazla değişim göstermemiştir. 3'den 4. epocha geçerken yaklaşık olarak 0,02'lik bir artış göstermiştir.



Şekil 4.3 EfficientNet-B0 Epoch 20 (a) eğitim ve değerlendirme kaybı (b) eğitim ve değerlendirme doğruluğu grafikleri

Şekil 4.3 (a) da epoch sayısı arttıkça eğitim ve doğrulama kaybının azaldığı gözlemlenmektedir. Şekil 4.3 (b) de test doğruluğu ve doğrulama doğruluğu sürekli değişkenlik göstermektedir. Şimdiye kadarki incelenen tüm grafiklerde en iyi epoch son epoch olarak etiketlenmişti fakat Şekil 4.3 (b)'de en iyi epoch mavi nokta ile gösterilmiş olup 2 epoch değerini göstermektedir. Bu durum ikinci epochdan sonra doğrulama doğruluğu değerinin artmadığını göstermektedir.




Şekil 4.4 EfficientNet-B0 Epoch 30 (a) eğitim ve değerlendirme kaybı (b) eğitim ve değerlendirme doğruluğu grafikleri

Şekil 4.4 (b)'de epoch 30'da doğrulama başarısı en iyi 13. epoch olarak mavi yuvarlak ile etiketlendiği görülmektedir. Bu durum doğrulama doğruluğunun 13. epochdan sonra artış göstermediği anlamına gelmektedir. Normalde beklenti her epochta geliştirilen derin öğrenme ağının daha çok öğrenmesi ve test başarısının ve doğrulama başarısının yükselmesidir. Fakat ağdaki eğitim ve öğrenme doygunluğa ulaştığında derin öğrenme ağının öğrenmesi yavaşlayabilir hatta sıfırlanabilir. Bu durumun ilk epochlar da ortaya çıkması derin öğrenme mimarisindeki rastgelelikten kaynaklanmaktadır.



Şekil 4.5 EfficientNet-B0 Epoch 40 (a) eğitim ve değerlendirme kaybı (b) eğitim ve değerlendirme doğruluğu grafikleri


Şekil 4.5'de EfficientNet-B0 mimarisinin 40 epoch eğitildiğinde eğitim ve doğrulama doğruluğu grafikleri gösterilmiştir. Şekil 4.5 (a)'da ki eğitim ve doğrulama kaybı grafiğinde en iyi epoch 39. Epoch olarak mavi yuvarlak ile etiketlenmiştir. Şekil 4.5 (b)'de doğrulama doğruluğu grafiğinde en iyi epoch 2. epoch olarak mavi yuvarlak ile etiketlenmiştir. Şekil 4.5 (a)'da doğrulama kaybı grafiği 20. epoch sonra doğrusala yakın olarak devam etmiştir. Şekil 4.5 (a)'da gösterilen eğitim başarısı grafiği 0'dan 50. epocha kadar salınım göstermektedir. Bu durum çizilmiş olan grafiğin Y ekseninin daha net olarak görülebilmesi için 0,99-1,00 skalasına ayarlanmış olmasından kaynaklanmaktadır.



Şekil 4.6 EfficientNet-B0 Epoch 50 (a) eğitim ve değerlendirme kaybı (b) eğitim ve değerlendirme doğruluğu grafikleri

Şekil 4.6 (a) da epoch sayısı arttıkça eğitim ve değerlendirme kaybı yaklaşık 15. epochdan sonra doğrusal olarak azalmaktadır. Şekil 4.6 (b) de en iyi epoch 28 olarak bulunmuştur ve 28. doğrulama doğruluğu değerinden sonra artış göstermemektedir. En yüksek başarıyı epoch 50 de elde edildiği anlaşılmaktadır.

Sınıflandırıcıların her sınıfta gösterdiği performansı belirlemek için karışıklık matrisi kullanılmıştır. Karışıklık matrisi tahmin edilen değerlerin gerçek değerlerle karşılaştırmak için kullanılmaktadır. Karışıklık matrisleri, sınıflandırıcının güçlü ve zayıf performans gösterdiği kısımları belirlemiştir. Mavi renkte gösterilen çapraz hücreler, sınıfların ne kadar doğrulukta sınıflandırıldığını belirtmektedir. Önerilen CNN mimarisinin karışıklık matrisleri Şekil 4.7’de gösterildiği gibidir.






Şekil 4.7 EfficientNet-B0 modeli a=5, b= 10, c= 20, d=30, e=40, f=50 epoch için çok sınıflı karışıklık matrisi

Şekil 4.7’de gösterilen karışıklık matrislerinden


5 epoch için; Şekil 4.7 (a)’da Covid-19 hastalarının tamamı doğru tahmin edilmiştir. Gerçekte anormal kalp atışına sahip olan 3 tane birey Covid-19 hastası olarak, 1 tane birey miyokard enfarktüsü hastası olarak toplam 4 birey yanlış tahmin edilmiştir. Gerçekte miyokard enfarktüsü hastası olan 2 birey Covid-19 hastası, 1 birey miyokard enfarktüsü öyküsü olan toplam 3 hasta yanlış tahmin edilmiştir. Gerçekte normal (sağlıklı) olan bireylerde 7 tane birey Covid-19 hastası, 2 tane birey miyokard enfarktüsü öyküsü olan 9 hasta yanlış olarak tahmin edilmiştir. Gerçekte miyokard enfarktüsü öyküsü olan hastalardan 3 birey Covid-19, 1 birey miyokard

enfarktüsü hastası olarak toplam 4 hasta yanlış tahmin edilmiştir. Şekil 4.8’de 5 epoch değerlerinde önerilen model için analiz edilen test seti grafiklerindeki hataları sınıfa göre göstermektedir.




Şekil 4.8 5 epoch için hatalı tahmin edilen hastalık sınıfları

10 epoch için; Şekil 4.7(b)’de Covid-19, miyokard enfarktüsü hastası ve miyokard enfarktüsü öyküsü olan hastaların tahminleri doğru yapılmıştır. Gerçekte anormal kalp atışı hastalığına sahip olan 3 tane birey miyokard enfarktüsü öyküsü hastası olarak yanlış tahmin edilmiştir. Gerçekte normal olan kişilerden 1 hasta miyokard enfarktüsü öyküsü hastası olarak yanlış tahmin edilmiştir. Şekil 4.9’da 10 epoch değerlerinde önerilen model için analiz edilen test seti grafiklerindeki hataları sınıfa göre göstermektedir.



Şekil 4.9 10 epoch için hatalı tahmin edilen hastalık sınıfları


20 epoch için; Şekil 4.7 (c)’de Modelin eğitimi sonrasında yapılan tahminlerde gerçekte anormal kalp atışı hastalığına sahip olan 1 tane birey miyokard enfarktüsü hastası olarak, 4 tane miyokard enfarktüsü öyküsü olan hasta olarak tahmin edilmiştir. Toplamda 5 tane anormal kalp atışı hastalığı yanlış tahmin edilmiştir. Şekil 4.10’da 20 epoch değerlerinde önerilen model için analiz edilen test seti grafiklerindeki hataları sınıfa göre göstermektedir.



Şekil 4.10 20 epoch için hatalı tahmin edilen hastalık sınıfları


30 epoch için; Şekil 4.7 (d)’de miyokard enfarktüsü hastası, normal ve miyokard enfarktüsü öyküsü olan hastaların tahminleri doğru yapılmıştır. Gerçekte Covid-19 hastası olan 2 birey normal birey olarak yanlış tahmin edilmiştir. Gerçekte anormal kalp atışına sahip olan 1 hasta miyokard

enfarktüsü hastası olarak yanlış tahmin edilmiştir. Şekil 4.11’de 30 epoch değerlerinde önerilen model için analiz edilen test seti grafiklerindeki hataları sınıfa göre göstermektedir.




Şekil 4.11 30 epoch için hatalı tahmin edilen hastalık sınıfları

40 epoch için; Şekil 4.7 (e)’de miyokard enfarktüsü hastası, normal ve miyokard enfarktüsü öyküsü olan hastaların tahminleri doğru yapılmıştır. Gerçekte Covid-19 hastası olan 2 birey normal birey olarak yanlış tahmin edilmiştir. Gerçekte anormal kalp atışına sahip olan 1 hasta miyokard enfarktüsü hastası olarak yanlış tahmin edilmiştir. Şekil 4.12’de 40 epoch değerlerinde önerilen model için analiz edilen test seti grafiklerindeki hataları sınıfa göre göstermektedir.



Şekil 4.12 40 epoch için hatalı tahmin edilen hastalık sınıfları

50 epoch için; Şekil 4.7 (f)’de Covid-19, miyokard enfarktüsü hastası, normal ve miyokard enfarktüsü öyküsü olan hastaların tahminleri doğru yapılmıştır. Gerçekte anormal kalp atışı hastalığına sahip olan 1 birey miyokard enfarktüsü öyküsüne sahip hasta olarak yanlış tahmin edilmiştir. Şekil 4.13’de 50 epoch değerlerinde önerilen model için analiz edilen test seti grafiklerindeki hataları sınıfa göre göstermektedir.



Şekil 4.13 50 epoch için hatalı tahmin edilen hastalık sınıfları

Çalışmada önerilen yöntem literatürdeki diğer çalışmalarla karşılaştırılarak da analiz edilmiş olup Tablo.4.2’de aynı veri setini kullanarak eğitilmiş çalışmalarla karşılaştırılmıştır.

Tablo 4.2. EKG veri seti üzerinde çalışmaların karşılaştırılması

Method	Accuracy
O. Attallah ve diğerleri [8]	0,917
M. A. Ozdemir ve diğerleri [20]	0,930
T. Rahman ve diğerleri [21]	0,973
Önerilen Yöntem	0,991

Önerilen modelin doğruluğu diğer çalışmalarla kıyaslandığı zaman daha yüksek doğruluk elde edildiği görülmektedir. EKG görüntüleri ile Covid-19 ve diğer sınıflandırılan hastalıkların tespitinin yapıp sınıflandırılabilceği ve gerçek hayatta insanlara katkı sağlayacağı sonucuna varılmıştır. Çalışmada test sürecinde elde edilen doğruluk, keskinlik ve F1 skor değerleri incelendiğinde alanında uzman doktorlara hız ve zaman açısından önemli derecede fayda sağlayacağı görülmüştür.

5. SONUÇLAR

Tıp alanında derin öğrenme yöntemleri ile hastalık tespiti ve öngörüsü çalışmaları artmaktadır. 2019 yılının sonlarına doğru ortaya çıkan oldukça bulaşıcı olan ve tüm dünyayı etkisi altına alan Covid-19 virüsü sonucunda 6,5 milyondan fazla insan öldü. Hastalığın yayılmasını önlemek ve hasta kişilere belirlenen uygun tedavi yöntemine başlanması amacıyla hastalığın erken teşhisi büyük önem taşımaktadır. Doğruluğu güvenilir olmayan ve uzun süren teşhis yöntemlerinin yanında güvenilir, hızlı, kullanışlı yeni teşhis yöntemlerinin araştırılıp çalışma yapılması gereklidir.

Bu tez, EKG görüntülerini kullanarak Covid-19, normal, anormal kalp atışı, miyokard enfarktüsü ve miyokard enfarktüsü öyküsü olmak üzere 5 sınıf bulgunun otomatik teşhisi için EfficientNet konvolüsyonel sinir ağı yöntemini önermektedir. Önerilen yöntem, EfficientNet-B0 mimarisi kullanılarak eğitilmiş ve test edilmiştir. Önerilen model çoklu sınıflandırma için %99.13 doğruluk sunmaktadır.

Sonuç olarak, çalışma kapsamında elde edilen sonuçlar EKG görüntülerinden otonom hastalık tespitinin derin öğrenme mimarileri kullanılarak başarılı bir şekilde gerçekleştirilebileceğini göstermektedir. İleride yapılacak çalışmalarda veri setine özel yeni derin öğrenme mimarileri geliştirilerek hastalık tespit başarısının daha da arttırılması planlanmaktadır.

Ayrıca tıbbi görsellerden cümle ve paragraf düzeyinde çıktılar üretilmesi henüz yeterince çalışılmamış yeni bir alandır. Gelecekteki çalışmalarda, EKG görüntüleri kullanılarak cümle ve paragraf düzeyinde tıbbi raporlar oluşturmak için doğal dil işleme tabanlı mimarilerin geliştirilmesi üzerinde çalışılması planlanmaktadır.

KAYNAKLAR

- [1] ["https://ourworldindata.org/covid-cases,"](https://ourworldindata.org/covid-cases) Apr. 01, 2023.
- [2] A. Haghanifar, M. M. Majdabadi, Y. Choi, S. Deivalakshmi, and S. Ko, "COVID-CXNet: Detecting COVID-19 in frontal chest X-ray images using deep learning," *Multimed Tools Appl*, vol. 81, no. 21, pp. 30615–30645, Sep. 2022, doi: 10.1007/s11042-022-12156-z.
- [3] E. Hussain, M. Hasan, M. A. Rahman, I. Lee, T. Tamanna, and M. Z. Parvez, "CoroDet: A deep learning based classification for COVID-19 detection using chest X-ray images," *Chaos Solitons Fractals*, vol. 142, Jan. 2021, doi: 10.1016/j.chaos.2020.110495.
- [4] E. Luz *et al.*, "Towards an effective and efficient deep learning model for COVID-19 patterns detection in X-ray images", doi: 10.1007/s42600-021-00151-6/Published.
- [5] P. R. A. S. Bassi and R. Attux, "A deep convolutional neural network for COVID-19 detection using chest X-rays", doi: 10.1007/s42600-021-00132-9/Published.
- [6] M. M. Bassiouni, I. Hegazy, N. Rizk, E. S. A. El-Dahshan, and A. M. Salem, "Automated Detection of COVID-19 Using Deep Learning Approaches with Paper-Based ECG Reports," *Circuits Syst Signal Process*, vol. 41, no. 10, pp. 5535–5577, Oct. 2022, doi: 10.1007/s00034-022-02035-1.
- [7] A. L. Caforio, "COVID-19: Cardiac manifestations in adults," 2023. [Online]. Available: www.uptodate.com
- [8] O. Attallah, "ECG-BiCoNet: An ECG-based pipeline for COVID-19 diagnosis using Bi-Layers of deep features integration," *Comput Biol Med*, vol. 142, Mar. 2022, doi: 10.1016/j.compbimed.2022.105210.
- [9] A. H. Khan, M. Hussain, and M. K. Malik, "Specifications Table," / *Data in Brief*, vol. 34, p. 106762, 2021, doi: 10.17632/gwbz3fsgp8.1.
- [10] P. Aggarwal, N. K. Mishra, B. Fatimah, P. Singh, A. Gupta, and S. D. Joshi, "COVID-19 image classification using deep learning: Advances, challenges and opportunities," *Computers in Biology and Medicine*, vol. 144, Elsevier Ltd, May 01, 2022. doi: 10.1016/j.compbimed.2022.105350.
- [11] H. Hassan *et al.*, "Supervised and weakly supervised deep learning models for COVID-19 CT diagnosis: A systematic review," *Computer Methods and Programs in Biomedicine*, vol. 218, Elsevier Ireland Ltd, May 01, 2022. doi: 10.1016/j.cmpb.2022.106731.
- [12] A. Haghanifar, M. M. Majdabadi, Y. Choi, S. Deivalakshmi, and S. Ko, "COVID-CXNet: Detecting COVID-19 in frontal chest X-ray images using deep learning," *Multimed Tools Appl*, vol. 81, no. 21, pp. 30615–30645, Sep. 2022, doi: 10.1007/s11042-022-12156-z.
- [13] L. Bergamaschi *et al.*, "The value of ECG changes in risk stratification of COVID-19 patients," *Annals of Noninvasive Electrocardiology*, vol. 26, no. 3, May 2021, doi: 10.1111/anec.12815.
- [14] Y. Wang *et al.*, "Electrocardiogram analysis of patients with different types of COVID-19," *Annals of Noninvasive Electrocardiology*, vol. 25, no. 6, Nov. 2020, doi: 10.1111/anec.12806.

- [15] N. Strodthoff, P. Wagner, T. Schaeffter, and W. Samek, "Deep Learning for ECG Analysis: Benchmarks and Insights from PTB-XL," *IEEE J Biomed Health Inform*, vol. 25, no. 5, pp. 1519–1528, May 2021, doi: 10.1109/JBHI.2020.3022989.
- [16] A. Rath, D. Mishra, G. Panda, and S. C. Satapathy, "Heart disease detection using deep learning methods from imbalanced ECG samples," *Biomed Signal Process Control*, vol. 68, Jul. 2021, doi: 10.1016/j.bspc.2021.102820.
- [17] A. S. Sakr, P. Pławiak, R. Tadeusiewicz, J. Pławiak, M. Sakr, and M. Hammad, "ECG-COVID: An end-to-end deep model based on electrocardiogram for COVID-19 detection," *Inf Sci (N Y)*, vol. 619, pp. 324–339, Jan. 2023, doi: 10.1016/j.ins.2022.11.069.
- [18] N. Sobahi, A. Sengur, R. S. Tan, and U. R. Acharya, "Attention-based 3D CNN with residual connections for efficient ECG-based COVID-19 detection," *Comput Biol Med*, vol. 143, Apr. 2022, doi: 10.1016/j.compbimed.2022.105335.
- [19] I. Shahin, A. B. Nassif, and M. B. Alsabek, "COVID-19 Electrocardiograms Classification using CNN Models," in *Proceedings - International Conference on Developments in eSystems Engineering, DeSE*, Institute of Electrical and Electronics Engineers Inc., 2021, pp. 448–452. doi: 10.1109/DESE54285.2021.9719358.
- [20] M. A. Ozdemir, G. D. Ozdemir, and O. Guren, "Classification of COVID-19 electrocardiograms by using hexaxial feature mapping and deep learning," *BMC Med Inform Decis Mak*, vol. 21, no. 1, Dec. 2021, doi: 10.1186/s12911-021-01521-x.
- [21] T. Rahman *et al.*, "COV-ECGNET: COVID-19 detection using ECG trace images with deep convolutional neural network," *Health Inf Sci Syst*, vol. 10, no. 1, Dec. 2022, doi: 10.1007/s13755-021-00169-1.
- [22] O. Attallah, "An Intelligent ECG-Based Tool for Diagnosing COVID-19 via Ensemble Deep Learning Techniques," *Biosensors (Basel)*, vol. 12, no. 5, May 2022, doi: 10.3390/bios12050299.
- [23] E. Irmak, "COVID-19 disease diagnosis from paper-based ECG trace image data using a novel convolutional neural network model," *Phys Eng Sci Med*, vol. 45, no. 1, pp. 167–179, Mar. 2022, doi: 10.1007/s13246-022-01102-w.
- [24] J. C. Gomes *et al.*, "Covid-19's innuence on cardiac function: a machine learning perspective on ECG analysis Covid-19's influence on cardiac function: a machine learning perspective on ECG analysis," 2022, doi: 10.21203/rs.3.rs-1490774/v1.
- [25] T. Anwar and S. Zakir, "Effect of Image Augmentation on ECG Image Classification using Deep Learning," in *2021 International Conference on Artificial Intelligence, ICAI 2021*, Institute of Electrical and Electronics Engineers Inc., Apr. 2021, pp. 182–186. doi: 10.1109/ICAI52203.2021.9445258.

- [26] T. Nguyen, H. H. Pham, K. H. Le, A. T. Nguyen, T. Thanh, and C. Do, "Detecting COVID-19 from digitized ECG printouts using 1D convolutional neural networks," *PLoS One*, vol. 17, no. 11 November, Nov. 2022, doi: 10.1371/journal.pone.0277081.
- [27] "Federico M. Muscato *et al.*," "A CNN for Covid Detection Using ECG signals," in *2022 Computing in Cardiology Conference (CinC)*, Computing in Cardiology, Nov. 2022. doi: 10.22489/cinc.2022.196.
- [28] M. M. A. Monshi, J. Poon, V. Chung, and F. M. Monshi, "CovidXrayNet: Optimizing data augmentation and CNN hyperparameters for improved COVID-19 detection from CXR," *Comput Biol Med*, vol. 133, Jun. 2021, doi: 10.1016/j.compbiomed.2021.104375.
- [29] Z. Müftüoğlu, M. A. Kızrak, and T. Yıldırım, "Differential Privacy Practice on Diagnosis of COVID-19 Radiology Imaging Using EfficientNet; Differential Privacy Practice on Diagnosis of COVID-19 Radiology Imaging Using EfficientNet," 2020. [Online]. Available: <https://orcid.org/0000-0001-9993-5583>
- [30] V. Nikolaou, S. Massaro, M. Fakhimi, L. Stergioulas, and W. Garn, "COVID-19 diagnosis from chest x-rays: developing a simple, fast, and accurate neural network," *Health Inf Sci Syst*, vol. 9, no. 1, Dec. 2021, doi: 10.1007/s13755-021-00166-4.
- [31] "<https://www.upgrad.com/blog/neural-network-architecture-components-algorithms/> ," Apr. 07, 2023.
- [32] "<https://www.mathworks.com/discovery/deep-learning.html> ," Apr. 07, 2023.
- [33] Z. A. A. Alyasseri *et al.*, "Review on COVID-19 diagnosis models based on machine learning and deep learning approaches," *Expert Syst*, vol. 39, no. 3, Mar. 2022, doi: 10.1111/exsy.12759.
- [34] K. Fukushima, "Biological Cybernetics Neocognitron: A Self-organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position," 1980.
- [35] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2323, 1998, doi: 10.1109/5.726791.
- [36] "<https://www.ibm.com/topics/convolutional-neural-networks> ," Oct. 04, 2023.
- [37] "<https://www.upgrad.com/blog/basic-cnn-architecture/#:~:text=other%20advanced%20tasks,-.What%20is%20the%20architecture%20of%20CNN%3F,the%20main%20responsibility%20for%20computation> ," Apr. 10, 2023.
- [38] "<https://www.simplilearn.com/tutorials/deep-learning-tutorial/convolutional-neural-network> ," Apr. 12, 2023.
- [39] "<https://www.ibm.com/topics/convolutional-neural-networks> ," Apr. 12, 2023.
- [40] "<https://sarathpanat.medium.com/all-about-convolutional-neural-network-cnn-6ccce6738958> ," Apr. 15, 2023.
- [41] "<https://www.ibm.com/topics/convolutional-neural-networks> ," Apr. 15, 2023.

- [42] ["https://www.kdnuggets.com/2022/06/activation-functions-work-deep-learning.html#:~:text=The%20activation%20function%20compares%20the,Binary%20Step%20Function%20%E2%80%94%20Graph"](https://www.kdnuggets.com/2022/06/activation-functions-work-deep-learning.html#:~:text=The%20activation%20function%20compares%20the,Binary%20Step%20Function%20%E2%80%94%20Graph), May 12, 2023.
- [43] ["https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6"](https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6), May 12, 2023.
- [44] ["https://www.analyticsvidhya.com/blog/2020/01/fundamentals-deep-learning-activation-functions-when-to-use-them/"](https://www.analyticsvidhya.com/blog/2020/01/fundamentals-deep-learning-activation-functions-when-to-use-them/), May 12, 2023.
- [45] ["https://paperswithcode.com/method/elu#:~:text=The%20Exponential%20Linear%20Unit%20\(ELU\)%20is%20an%20activation%20function%20for,but%20with%20lower%20computational%20complexity"](https://paperswithcode.com/method/elu#:~:text=The%20Exponential%20Linear%20Unit%20(ELU)%20is%20an%20activation%20function%20for,but%20with%20lower%20computational%20complexity), May 13, 2023.
- [46] ["https://www.geeksforgeeks.org/multiclass-image-classification-using-transfer-learning/"](https://www.geeksforgeeks.org/multiclass-image-classification-using-transfer-learning/), May 13, 2023.
- [47] ["https://www.seldon.io/transfer-learning"](https://www.seldon.io/transfer-learning), May 13, 2023.
- [48] M. Tan and Q. V Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks."
- [49] G. Marques, D. Agarwal, and I. de la Torre Díez, "Automated medical diagnosis of COVID-19 through EfficientNet convolutional neural network," *Applied Soft Computing Journal*, vol. 96, Nov. 2020, doi: 10.1016/j.asoc.2020.106691.
- [50] A. Altan and S. Karasu, "Recognition of COVID-19 disease from X-ray images by hybrid model consisting of 2D curvelet transform, chaotic salp swarm algorithm and deep learning technique," *Chaos Solitons Fractals*, vol. 140, Nov. 2020, doi: 10.1016/j.chaos.2020.110071.
- [51] ["https://www.simplilearn.com/tutorials/deep-learning-tutorial/guide-to-building-powerful-keras-image-classification-models#what_is_image_classification"](https://www.simplilearn.com/tutorials/deep-learning-tutorial/guide-to-building-powerful-keras-image-classification-models#what_is_image_classification), May 14, 2023.
- [52] ["https://machinelearningmastery.com/types-of-classification-in-machine-learning/"](https://machinelearningmastery.com/types-of-classification-in-machine-learning/), May 14, 2023.
- [53] A. H. Khan, M. Hussain, and M. K. Malik, "ECG Images dataset of Cardiac and COVID-19 Patients," *Data Brief*, vol. 34, Feb. 2021, doi: 10.1016/j.dib.2021.106762.
- [54] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," Dec. 2014, [Online]. Available: <http://arxiv.org/abs/1412.6980>
- [55] A. Kulkarni, F. A. Batareseh, and D. Chong, "Chapter 5: Foundations of Data Imbalance and Solutions for a Data Democracy."

ÖZGEÇMİŞ

Nida AKKUZU

[Redacted]	
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	
[Redacted]	[Redacted]
[Redacted]	[Redacted]
[Redacted]	[Redacted]