



T. C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS PROGRAMI

**DERİN ÖĞRENME İLE RADYOLOJİK GÖRÜNTÜLER
ÜZERİNDEN COVID-19 TESPİTİ**

YÜKSEK LİSANS TEZİ

Tanju CEYLAN

Danışman: Doç. Dr. Özkan İNİK

TOKAT - 2024

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Doç. Dr. Özkan İNİK danışmanlığında hazırlamış olduğum “Derin Öğrenme İle Radyolojik Görüntüler Üzerinden Covid-19 Tespiti” adlı Yüksek Lisans tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

05/06/2024

Tanju CEYLAN

ÖNSÖZ

Tez konusunun belirlenmesinden çalışmanın tamamlanmasına kadar yürütülen bütün süreçte bana yol gösteren ve hiçbir yardımı esirgemeyen tez danışmanım Doç. Dr. Özkan İNİK hocama;

Destegini her zaman yanımda hissettiğim sevgili eşime, motivasyon kaynağım olan çocuklarım Hatice Miray ve Mehmet Han'a;

Teşekkürlerimi sunarım.

Tanju CEYLAN
TOKAT 2024

ÖZET

DERİN ÖĞRENME İLE RADYOLOJİK GÖRÜNTÜLER ÜZERİNDEN COVID-19 TESPİTİ

Ceylan, Tanju

Yüksek Lisans, Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Özkan İNİK

05.06.2024, XV + 71 Sayfa

Yeni Koronavirüs Hastalığı (COVID-19)dünya genelinde yayılım gösteren RNA tipi bir virüstür. İlk kez 2019 yılı Aralık ayında Çin'in Vuhan kentinde görülen COVID-19 hızlı bir şekilde yayılarak kısa sürede tüm dünya ülkelerinde görülmeye başlandı. Birçok ülke bu durumdan sağlık, ekonomik, sosyolojik ve psikolojik olarak olumsuz etkilenmiştir. Hastalığın teşhis konulmasında solunum yolu enfeksiyonları, ateş, öksürme, nefes darlığı gibi belirtiler önem arz etmektedir. 2019 yılından beri yaşanan olumsuzlukları en aza indirmek için birçok yöntem üzerinde çalışılmıştır. Hastalığın insanlarda bıraktığı hasarı en aza indirmek için yapılacak en önemli işlem bir an önce, semptom taşıyanlara teşhis koyabilmektir. Belirtilen şüphelerle hastaneye başvuran hastalarda teşhis konulması için genellikle ilk uygulanan işlem, PCR'dır. Laboratuvar testlerinin, Röntgen ve Bilgisayarlı Tomografi görüntülerinin uzun zaman dilimlerinde sonuçlanması araştırmacıları başka teşhis yöntemlerine yönlendirmiştir. Bu tez çalışmasında hekimlere, Bilgisayarlı Tomografi (BT) görüntüleri üzerinden hastalığın tespiti için yardımcı olabilecek bir model tasarlanmıştır. Derin öğrenme temeline dayanan bu model COVID-19 pozitif (enfekte olmuş), COVID-19 negatif (sağlıklı) göğüs BT görüntüleri üzerinden sınıflandırma metoduyla hastalığı tespit etmeyi amaçlamaktadır. BT görüntülerinde oluşan buzlu cam diye tabir edilen pnömoni görülmesi teşhis işlemini hızlandırmaktadır.

Tez çalışmasında kullanılan veri seti Tokat Gaziosmanpaşa Üniversitesi 23-KAEK-033 proje numaralı ve 83116987-092 sayılı etik kurul kararına göre alınan izinler neticesinde deneysel çalışmalar gerçekleştirilmiştir. Veri seti Tokat Gaziosmanpaşa Üniversitesi Araştırma ve Uygulama Hastanesi'nde muayene olan kişilerin BT görüntülerinden oluşmaktadır. Veri seti, ilgili poliklinik tarafından COVID-19 pozitif teşhisi girilmiş hastaların ve sağlıklı kişilerin BT görüntüleri üzerinden oluşturulmuştur.

Elde edilen Bt görüntülerinden oluşturulan veri setinde ilk olarak dcm formatındaki görüntüler çalışma için daha uygun olan jpg formatına dönüştürüldü. Uzantıları düzenlenen görseller ile COVID-19 pozitif, COVID-19 negatif şeklinde iki klasör halinde sınıflar oluşturuldu. İsimleri karmaşık ve anlamsız yapılar olan görsellerde yeniden isimlendirme yapıldı. Veri işleme için hazır hale getirilen veri setinde AlexNet, Densenet201, GoogleNet, ResNet-50, Vgg16, EfficientNet gibi derin öğrenme modelleri ve önerilen model üzerinde eğitimler gerçekleştirilerek elde edilen başarı oranları üzerinde karşılaştırmalar yapılmıştır.

Test verisi üzerinde Alexnet modeli ile % 88,81, DenseNet201 modeli ile % 86,16, EfficientNet modeli ile % 98,31, GoogleNet modeli ile % 95,52, Resnet-50 modeli ile % 94,02, VGG-16 modeli ile % 92,53 başarı oranı elde edilmiştir. Önerilen ESA modeline ait karışıklık matrisi incelendiğinde 375 COVID-19 pozitif hastasının 372'si doğru sınıflandırılmış 3'ü ise hatalı sınıflandırılmıştır. 375 sağlıklı örneğin 372'si doğru sınıflandırılmış 3'ü COVID-19 pozitif olarak hatalı sınıflandırılmıştır. Önerilen ESA modeli ile % 99,20 başarı oranı elde edilmiştir ve COVID-19 tespiti için etkili ve başarılı bir model önerilmiştir.

Anahtar Kelimeler: Derin Öğrenme, Yapay Zeka, Evrimsel Sinir Ağları (ESA), Görüntü Sınıflandırma, COVID-19, Bilgisayarlı Tomografi

ABSTRACT

COVID-19 DETECTION IN RADIOLOGICAL IMAGES WITH DEEP LEARNING

Ceylan, Tanju

Master's Thesis, Department Of Mechatronic Engineering

Advisor: Assoc. Prof. Dr. Özkan İNİK

05.06.2024, XV + 71 pages

New Coronavirus Disease (COVID-19) is an RNA type virus that is spreading worldwide. COVID-19, which was first seen in Wuhan, China, in December 2019, spread rapidly and soon began to be seen in all countries of the world. Many countries were negatively affected by this situation in terms of health, economy, sociology and psychology. Symptoms such as respiratory tract infections, fever, cough, and shortness of breath are important in diagnosing the disease. Many methods have been worked on to minimize the negativities experienced since 2019. The most important precaution to be taken to minimize the damage caused by the disease to people is to diagnose those who show symptoms as soon as possible. PCR is usually the first procedure performed to diagnose patients who apply to the hospital with the mentioned suspicions. Laboratory examinations, X-ray and Computed Tomography images take a long time, which has led researchers to other diagnostic methods. In this thesis study, a model that can help physicians detect the disease through Computed Tomography (CT) images has been designed. This model, based on deep learning, aims to detect the disease by classifying COVID-19 positive (infected) and COVID-19 negative (healthy) chest CT images. Seeing ground glass pneumonia on CT images speeds up the diagnosis process.

The data set used in the thesis study was carried out as a result of the permissions obtained according to the ethics committee decision of Tokat Gaziosmanpaşa University project number 23-KAEK-033 and number 83116987-092. The data set consists of CT images of people examined at Tokat Gaziosmanpaşa University Research and Application Hospital. The data set was created from CT images of patients and healthy people diagnosed as COVID-19 positive by the relevant polyclinic.

In the data set created from the obtained BT images, the images in dcm format were first converted to jpg format, which is more suitable for the study. With the images whose extensions were edited, classes were created in two folders: Covid-19 positive and Covid-19 negative. Images with complex and meaningless names have been renamed. In the dataset prepared for data processing, comparisons were made on deep learning models such as AlexNet, Densenet201, GoogleNet, ResNet-50, Vgg16, EfficientNet and the success rates obtained by training on the proposed model.

The result in the test data; This rate was 88.81 percent with the Alexnet model, 86.16 percent with the DenseNet201 model, 98.31 percent with the EfficientNet model, 95.52 percent with the GoogleNet model, 94.02 percent with the Resnet-50 model and 94.02 percent with the Resnet-50 model. A success rate of 92.53% was achieved with the VGG-16 model. When the confusion matrix of the proposed ESA model was examined, it was seen that 372 of 375 COVID-19 positive patients were classified correctly and 3 were classified incorrectly. Of the 375 healthy samples, 372 were correctly classified and 3 were incorrectly classified as COVID-19 positive. A 99.20% success rate was achieved with the proposed ESA model, and an effective and successful model was proposed for COVID-19 detection.

Keywords: Deep Learning, Artificial Intelligence, Convolutional Neural Networks (ESA), Image Classification, COVID-19, Computed Tomography

İÇİNDEKİLER

ETİK SÖZLEŞME	II
JÜRİ KABUL VE ONAY	Hata! Yer işareti tanımlanmamış.
ÖNSÖZ	IV
ÖZET	V
ABSTRACT	VII
İÇİNDEKİLER	IX
SİMGELER VE KISALTMALAR	XI
ŞEKİL LİSTESİ	XII
TABLO LİSTESİ	XV
1. GİRİŞ	1
1.1. Tezin Amacı ve Derin Öğrenme Yöntemlerinin Çalışmaya Katkıları	5
1.2. Tezin Organizasyonu	6
2. KAYNAK ARAŞTIRMASI	7
3. MATERYAL VE METOTLAR	12
3.1. Yapay Zeka	12
3.2. Makine Öğrenmesi	13
3.2.1. Yapay sinir ağları	15
3.3. Derin Öğrenme	17
3.4. Evrişimsel Sinir Ağları (ESA)	19
3.4.1. Giriş katmanı (Input layer):	19
3.4.2. Konvolüsyon katmanı (Convolution layer):	20
3.4.3. Havuzlama katmanı (Pooling layer):	23
3.4.4. Tam bağlantılı katman (Fully connected layer):	24
3.4.5. Seyreltme katmanı (Dropout):	24

3.4.6.	Sınıflandırma katmanı (Classification layer):	25
3.5.	Derin Öğrenme Ağ Modelleri	25
3.5.1.	LeNet.....	25
3.5.2.	AlexNet	26
3.5.3.	ZFNet	26
3.5.4.	VGGNet	27
3.5.5.	GoogLeNet.....	28
3.5.6.	Microsoft ResNet	29
3.6.	Bilgisayarlı Tomografi (BT)	30
3.7.	Veri Seti	31
4.	ÖNERİLEN YÖNTEM	35
5.	DENEYSEL ÇALIŞMALAR.....	38
5.1.	Performans Ölçütleri	38
5.2.	Derin Öğrenme Modellerinin Performansı	40
5.2.1.	AlexNet modelinin performans değerlendirmesi	40
5.2.2.	DenseNet201 modelinin performans değerlendirmesi	43
5.2.3.	EfficientNet modelinin performans değerlendirmesi	46
5.2.4.	GoogLeNet modelinin performans değerlendirmesi	49
5.2.5.	Resnet-50 modelinin performans değerlendirmesi.....	52
5.2.6.	VGG-16 modelinin performans değerlendirmesi.....	55
5.2.7.	Önerilen ağ modelinin performans değerlendirmesi	58
6.	SONUÇ VE ÖNERİLER.....	61
7.	ETİK KURUL KARARI.....	66
8.	KAYNAKLAR	67

SİMGELER VE KISALTMALAR

Simgeler	Açıklama
X_n	: Girdi Verisi
W_n	: Ağırlık
Σ	: Toplama Fonksiyonu
y	: Çıktı
$g(x)$	: Aktivasyon Fonksiyonu

Kısaltmalar	Açıklama
BT	: Bilgisayarlı Tomografi
CNN	: Convolutional Neural Network
CPU	: Central Processing Unit
D-ESA	: Dalgacık ESA
DSA	: Derin Sinir Ağları
DSÖ	: Dünya Sağlık Örgütü
DVM	: Destek Vektör Makineleri
ESA	: Evrişimsel Sinir Ağları
FN	: False Negative
FP	: False Positive
GPU	: Graphic Processing Unit
ILSVRC	: ImageNet. Large-Scale Visual Recognition Challenge
KNN	: K-Nearest Neighbors
MERS-CoVS	: Middle East Respiratory Syndrome-coronavirus
MÖ	: Makine Öğrenmesi
PCR	: Polymerase Chain Reaction
RGB	: Red (kırmızı), Green (yeşil) ve Blue (mavi)
RNN	: Recurrent Neural Network
ROC	: Receiver Operating Characteristic
SARS-CoV	: Severe Acute Respiratory Syndrome
TN	: True Negative
TP	: True Positive
X-Ray	: Röntgen
YSA	: Yapay Sinir Ağları
YSH	: Yapay Sinir Hücresi

ŞEKİL LİSTESİ

Şekil No	Sayfa
Şekil 1.1. Covid-19 toplam vaka sayısının bölgelere göre renk haritası (covid19.who, 2023).....	3
Şekil 1.2. Deneysel çalışma yapılan derin öğrenme modellerinin başarı oranları	5
Şekil 3.1. Yapay zekanın tarihsel gelişimi	13
Şekil 3.2. Makine öğrenmesi eğitim stratejileri	14
Şekil 3.3. İnsan sinir hücrelerinin bağlantı yapısı (Doğan, 2020)	15
Şekil 3.4. Yapay sinir hücresi (Nasip ve Zengin, 2018)	16
Şekil 3.5. Basit yapay sinir ağı modeli.....	17
Şekil 3.6. Çok katmanlı yapay sinir ağı modeli	17
Şekil 3.7. Dünya üzerindeki toplam veri sayısının yıllara göre artış hızı ve sonraki yılların tahmini boyutları (.....	18
Şekil 3.8. Klasik ESA mimarisi (Medium, 2023)	19
Şekil 3.9. Evrişim katmanında filtre işlemi uygulaması sonucu oluşan görüntü	20
Şekil 3.10. Konvolüsyon işlemi 1. adım	21
Şekil 3.11. Konvolüsyon işlemi 2. adım	21
Şekil 3.12. Konvolüsyon işlemi 3. Adım	22
Şekil 3.13. Konvolüsyon işlemi (4. Adımdan 9.adıma kadar olan işlemler)	22
Şekil 3.14. Maksimum havuzlama işlemi	23
Şekil 3.15. Ortalama havuzlama işlemi.....	23
Şekil 3.16. Tam bağlantılı katman	24
Şekil 3.17. Seyreltme işlemi (kırmızı çarpı atılan nöronlar ağdan çıkartılmıştır)	25
Şekil 3.18. LeNet Mimarisi (Lecun ve ark., 1998).	25
Şekil 3.19. AlexNet Mimarisi (Krizhevsky ve ark., 2012).	26
Şekil 3.20. ZFNet Mimarisi (Zeiler ve Fergus, 2013).....	26
Şekil 3.21. VGGNet ağ mimarisi (Rosebrock, 2023)	27
Şekil 3.22. VGG 16 katman parametre bilgileri (Simonyan ve Zisserman, 2014)	28
Şekil 3.23. GoogLeNet Mimarisi (Szegedy ve ark., 2015)	28
Şekil 3.24. Microsoft ResNet Mimarisi (He ve ark., 2016)	29
Şekil 3.25. Yıllara göre ImageNet sınıflandırma hata oranları	29
Şekil 3.26. Bilgisayarlı tomografi (BT) cihazı	30
Şekil 3.27. Bilgisayarlı tomografi (BT)çekilmiş organ görüntüleri. (Hekimoğlu_Görüntüleme, 2023), (Gümüş ve ark., 2012), (Erdoğan, 2023), (Koylan, 2023), (Anonim, 2023).....	31

Şekil 3.28. BT kesitlerinin .dcm formatından .Jpg formatına dönüştürülmesi (Converter, 2023)	32
Şekil 3.29. COVID-19 pozitif ve COVID-19 negatif kişilere ait BT görüntüleri	33
Şekil 3.30. BT görüntülerinin yeniden isimlendirilmesi (Renamer, 2023)	33
Şekil 4.1. Tez kapsamında önerilen yöntemin metodolojisi	35
Şekil 4.2. Önerilen modele ait ağ tasarımı	36
Şekil 5.1. AlexNet modeline ait eğitim aşamasındaki yakınsama grafiği	40
Şekil 5.2. AlexNet modelinin test verisi üzerinde elde ettiği karışıklık matrisi	41
Şekil 5.3. AlexNet modeline ait Roc Eğrisi	41
Şekil 5.4. AlexNet modeline ait AUC Şeması	42
Şekil 5.5. DenseNet201 modeline ait eğitim aşamasındaki yakınsama grafiği	43
Şekil 5.6. DenseNet201 modelinin test verisi üzerinde elde ettiği karışıklık matrisi	44
Şekil 5.7. DenseNet201 modeline ait Roc Eğrisi	44
Şekil 5.8. DenseNet201 modeline ait AUC Şeması	45
Şekil 5.9. EfficientNet modeline ait eğitim aşamasındaki yakınsama grafiği	46
Şekil 5.10. EfficientNet modelinin test verisi üzerinde elde ettiği karışıklık matrisi	47
Şekil 5.11. EfficientNet modeline ait Roc Eğrisi	47
Şekil 5.12. EfficientNet modeline ait AUC Şeması	48
Şekil 5.13. GoogleNet modeline ait eğitim aşamasındaki yakınsama grafiği	49
Şekil 5.14. GoogleNet modelinin test verisi üzerinde elde ettiği karışıklık matrisi	50
Şekil 5.15. GoogleNet modeline ait Roc Eğrisi	50
Şekil 5.16. GoogleNet modeline ait AUC Şeması	51
Şekil 5.17. Resnet-50 modeline ait eğitim aşamasındaki yakınsama grafiği	52
Şekil 5.18. Resnet-50 modelinin test verisi üzerinde elde ettiği karışıklık matrisi	53
Şekil 5.19. Resnet-50 modeline ait Roc Eğrisi	53
Şekil 5.20. Resnet-50 modeline ait AUC Şeması	54
Şekil 5.21. VGG-16 modeline ait eğitim aşamasındaki yakınsama grafiği	55
Şekil 5.22. VGG-16 modelinin test verisi üzerinde elde ettiği karışıklık matrisi	56
Şekil 5.23. VGG-16 modeline ait Roc Eğrisi	56
Şekil 5.24. VGG-16 modeline ait AUC Şeması	57
Şekil 5.25. Önerilen modele ait eğitim aşamasındaki yakınsama grafiği	58
Şekil 5.26. Önerilen modelinin test verisi üzerinde elde ettiği karışıklık matrisi	59
Şekil 5.27. Önerilen modele ait Roc Eğrisi	59
Şekil 5.28. Önerilen modele ait AUC Şeması	60
Şekil 6.1. Modellere ait deneysel sonuçların karşılaştırılması	61

Şekil 6.2. Modellere ait eğitim test süreleri ve devir sayılarının karşılaştırılması	62
Şekil 6.3. Sınıflandırma seviyelerine göre oluşan grafikler (mathworks.com, 2023).....	63
Şekil 6.4. Deneysel çalışma yapılan modellere ait roc eğrileri	65
Şekil 6.5. Modellere ait AUC şemalarının grafiksel gösterimi	65



TABLO LİSTESİ

Tablo No	Sayfa
Tablo 1.1. Covid-19 verilerinin bölgelere göre ayrıntılı istatistikleri (20 Eylül 2023)	3
Tablo 3.1. Deneysel çalışmalarda kullanılan veri setine ait görüntü sayıları	34
Tablo 4.1. Önerilen modele ait katmanların parametre değerleri	37
Tablo 5.1. Kullanılan donanım ve yazılımlara ait bilgiler	38
Tablo 5.2. Karışıklık matrisi	39
Tablo 5.3. AlexNet modeli ile yapılan deneysel çalışmalar sonrası elde edilen performans metrikleri	42
Tablo 5.4. Alexnet modeline ait hiperparametre değerleri.....	42
Tablo 5.5 . DenseNet201 modeli ile yapılan deneysel çalışmalar sonrası elde edilen performans metrikleri	45
Tablo 5.6. DenseNet201 modeline ait hiperparametre değerleri.....	45
Tablo 5.7. EfficientNet modeli ile yapılan deneysel çalışmalar sonrası elde edilen performans metrikleri	48
Tablo 5.8. EfficientNet modeline ait hiperparametre değerleri.....	48
Tablo 5.9. GoogleNet modeli ile yapılan deneysel çalışmalar sonrası elde edilen performans metrikleri	51
Tablo 5.10. GoogleNet modeline ait hiperparametre değerleri.....	51
Tablo 5.11. Resnet-50 modeli ile yapılan deneysel çalışmalar sonrası elde edilen performans metrikleri	54
Tablo 5.12. Resnet-50 modeline ait hiperparametre değerleri	54
Tablo 5.13. VGG-16 modeli ile yapılan deneysel çalışmalar sonrası elde edilen performans metriklerinin sonuçları	57
Tablo 5.14. VGG-16 modeline ait hiperparametre değerleri	57
Tablo 5.15. Önerilen model ile yapılan deneysel çalışmalar sonrası elde edilen performans metrikleri	60
Tablo 5.16. Önerilen modele ait hiperparametre değerleri	60

1. GİRİŞ

Pandemilerin geçmişteki etkileri ve türleri incelendiğinde kara veba, ispanyol gribi, kolera gibi birçok pandemi dönemi yaşandığı görülmektedir. Dünya’da görülen koronavirüs grubu hastalıklar ilk olarak 1960 yılında tanımlanmıştır (Selçuk, 2020). Son 25 yılda ise öldürücü etkisi yüksek olan virüs salgınları yaşanmıştır. Dilimize “Şiddetli Ani Solunumsal Sendrom” ya da “Ağır Akut Solunum Yetersizliği Sendromu” olarak çevrilen Severe Acute Respiratory Syndrome (SARS-CoV) solunum yolu hastalığı 2003 yılında Asya, Avrupa ve Kuzey Amerika kıtalarında görülmüştür (Durmaz Akyol, 2005). Ciddi solunum yetmezliği sorunları ile ortaya çıkan Middle East Respiratory Syndrome-Coronavirus (MERS-CoVS) virüsü 2012 yılında Arap Yarımadası’nda insanlığı etkisi altına almıştır (Nemli ve Demirel, 2016). Son olarak 2019 Aralık ayında Çin’in Hubei Eyaleti, Wuhan kentinde yüksek ateş, öksürük, halsizlik, nefes darlığı gibi belirtilerle beraber zatürre vakaları görülmeye başlandı. Belirtiler ilk olarak hayvan pazarı bulunan ve deniz ürünleri satılan bölgelerde görülmüştür.

Dünya Sağlık Örgütü (DSÖ), ortaya çıkan bu yeni virüsü “COVID-19” olarak tanımlamıştır. Bu isim "co" corona, "vi" virüs ve "d" ingilizce "dease" kelimelerinin baş harflerinden oluşmaktadır. DSÖ, COVID-19 hastalığına sebep olan bu virüsü ise Şiddetli Akut Solunum Sendromu-Koronavirus-2 (SARS-COV-2) olarak isimlendirmiştir. Pandemiler daha önceden de olduğu gibi son dönemde de dünya ülkeleri üzerinde sağlık, ekonomik ve sosyolojik yönden olumsuz etkiler bırakmış, dolayısıyla insan hayatının kalitesini ciddi şekilde düşürmüştür.

DSÖ, COVID-19’u 11 Mart 2020 tarihinde küresel salgın yani pandemi olarak duyurmuştur. Ülkemizde de ilk vaka 11 Mart 2020 tarihinde resmi olarak kayıtlara geçmiştir. COVID-19’un en çok görülen klinik belirtileri öksürük, halsizlik, yüksek ateş, göğüs bölgesinde ağrı, kas ağrıları, yorgunluk, nefes darlığı olarak gözlemlenmiştir (Singhal, 2020). Damlacık yoluyla bulaşan bu hastalığın seyri küçük çocuklarda ve bağışıklık sistemi güçlü bireylerde hafif seyretmiştir. Kronik rahatsızlığı olanlar, tütün ürünleri tüketenler, bağışıklığı zayıf olanlar ve yaşlılarda ise ağır semptomlar gözlemlenmiş olup, ölüm oranlarının bu grupta daha yüksek olduğu görülmüştür. COVID-19 pandemisinin etkisini en aza indirmek için bilim insanları, hekimler, bilişim


uzmanları ve sorumluluk üstlenen birçok meslek grubundan insan çaba göstermektedir. Bu doğrultuda 60'ı aşkın ülkede aşı için çalışmalar yapılmıştır. 500'e yakın aşı çalışması yapılmaktadır. Acil kullanım onayı verilen 21 aşı bulunmaktadır (Dayan, 2021). DSÖ tarafından acil kullanım izni verilen aşılarda bulunmasına rağmen, ülkelerin gelişmişlik seviyeleri, depolama şartları, ekonomi düzeyleri farklı olduğu için aşılama işlemleri her bölgede aynı düzeyde yapılamamıştır ve neticesinde hastalık birçok mutasyona da uğramıştır.

Alfa, Beta, Gamma, Delta, Delta Plus, Omicron varyantları kısa sürede görülen varyantlardır. Son olarak 2023 yılında EG.5 yani Eris varyantı ilk olarak Çin, Japonya ve Güney Kore'de gözlemlenirken şimdilerde ise Kuzey Amerika ve Avrupa'da sayısının arttığı görülmektedir (Euronews, 2023b). 2023 Eylül itibarıyla DSÖ tarafından doğrulanmış COVID-19 vaka sayısı 770 milyar kişi civarındadır. 7 milyona yakın kişi COVID-19 sebebiyle hayatını kaybetmiştir (covid19.who, 2023). Ülkemiz Sağlık Bakanlığı tarafından yapılan açıklamalar doğrultusunda Eylül 2023 tarihi itibarıyla Türkiye'de görülen Eris varyantı COVID-19 hastası olan kişi sayısı 9 olarak açıklanmıştır (Euronews, 2023a).

Tablo 1.1'de bölgelere göre COVID-19 hastalarının toplam sayısı, ölüm sayısı, ölüm oranı, aşılama oranı gibi istatistiksel bilgiler gösterilmiştir. Şekil 1.1'de bölgelerin toplam vaka sayısına göre renk haritası görülmektedir. Bölgelere göre toplam vaka ve ölüm sayıları göz önünde bulundurulduğunda en yüksek ölüm oranının Afrika olduğu görülmektedir. Ortalama yaş seviyeleri, ekonomik durum, Polymerase Chain Reaction (PCR) test sayısının yetersizliği, personel sayısının azlığı, tıbbi yetersizlikler ve aşılama sayısının azlığı gibi etkenler ölüm oranının yüksek olmasının sebepleri arasında sayılabilir.

Tablo 1.1. Covid-19 verilerinin bölgelere göre ayrıntılı istatistikleri (20 Eylül 2023)

Bölge	Toplam Vaka sayısı	Toplam Ölüm sayısı	Vaka/ Ölüm oranı	Ortalama 100 kişiye yapılan aşı doz sayısı
Avrupa	276.043.682	2.248.086	0,81	185
Batı Pasifik	207.125.459	416.157	0,20	242
Amerika	193.252.203	2.959.349	1,53	208
Güneydoğu Asya	61.203.510	806.772	1,32	166
Doğu Akdeniz	23.390.446	351.413	1,50	123
Afrika	9.548.167	175.439	1,84	57
TOPLAM	770.563.467	6.957.216	0,90	163,5 (Bölge ortalaması)



Şekil 1.1. Covid-19 toplam vaka sayısının bölgelere göre renk haritası (covid19.who, 2023)

Bu yüzden ki COVID-19’la mücadelede ilk yapılması gereken şey hızlı tanı ve tedavi sürecidir. COVID-19’un tespitinde en çok kullanılan yöntem PCR yöntemidir. PCR test sonuçlarının ortalama 6 saatte sonuçlandığı bilinmektedir (Ökçün ve ark., 2020). Yapılan bu testlerin neticelenmesi hem zaman almaktadır hem de vakalarda yalancı negatiflik durumu gözlemlenebilmektedir. Tanı ve tedaviyi geciktirici bir diğer husus da kırsal kesimde bulunan insanların PCR kitlerine ulaşmakta yaşadığı zorluktur. Hastalıkta mücadelede temel amaç zamanı en etkili biçimde kullanmakken kitlerle işlem yapılması

bazen hem sonucu geciktirmekte hem de ekonomik olarak fazla maliyet çıkarabilmektedir. Ülkelerin bu teste ulaşmaları ekonomik düzeyleri ile paralellik göstermektedir. PCR için kullanılan kitlerin üreticilerinin farklı olması, kitler ile numune toplanma yöntemleri, numune alım ortamındaki sıcaklık seviyesi, numune saklama koşulları gibi parametrelerde testlerin doğruluk seviyesini etkilemektedir. Bu etkenler göz önünde bulundurulduğunda T.C Sağlık Bakanlığı'nın da "COVID-19 Erişkin Tedavi Algoritması" incelendiğinde gerekli tetkiklerin istemiyle beraber hastalardan akciğer Bilgisayarlı Tomografi (BT) veya göğüs röntgeni (X-Ray) istenmesi önerilmektedir (S. B. C.-B. Platformu, 2023).


Hastalığın ilk aşamalarında PCR test sonucu negatif çıkmış olsa bile Röntgen veya BT gibi radyoloji görüntüleme yöntemlerinin avantajı hastalığın her aşamasında görüntülerden tespit edilebilmesidir. Hastalığın ilerleyen aşamaları için de hastanın durumu hakkında bu görüntüleme teknikleri sayesinde yorumlar yapılabilir ve gerekli tedbirler alınabilir. BT görüntüleri organların durumu, lezyonlar, gelişen pnömoniler, yumuşak dokular, damarların durumu gibi hayati önem taşıyan birçok yapı hakkında ayrıntılı bilgi alma imkânı sunmaktadır. BT görüntüleme yönteminin bu denli avantajları olmasının yanında hastanın durumunun bir hekim tarafından yorumlanarak rapor edilmesi gerekmektedir. Raporlama sonrasında hastaya uygun tedavinin en hızlı şekilde uygulanması gerekmektedir. Raporlama süreci ne kadar erken biterse hastanın izolasyonu, tedaviye başlanması bulaş riskini azaltacağından hayati önem taşımaktadır. Bu da hekimlerin iş yükünü bir hayli artırmaktadır. Pandemi sürecinde hasta sayılarının katlanarak artması, hekimler üzerinde ki bu yükü azaltmak için bilim dünyasını çeşitli çözümler aramaya yöneltmiştir.

Pandeminin ilk gününden itibaren yapılan çalışmalar toplumsal zararları mümkün olduğunca en aza indirmeyi hedeflemektedir. X-Ray görüntüleme ve BT görüntüleri üzerinden hastalıklar ile ilgili kısımların işaretlenmesi ve oluşturulan verilerin işlenmesi için çeşitli derin öğrenme modelleri kullanılmaktadır. Kalp hastalıkları, beyin tümörü, meme kanseri, deri hastalıkları gibi hastalıkların tespitinde hekimlere yardımcı olmayı amaçlayan literatürde birçok çalışma mevcuttur.

Bu tez çalışmasında veri seti olarak Tokat Gaziosmanpaşa Üniversitesi Araştırma ve Uygulama Hastanesi'nde muayene olmuş kişilere ait BT görüntüleri kullanılmıştır. Veri seti, 250 COVID-19 pozitif hastasına ait 2.500 görüntü ve 250 sağlıklı kişiye ait 2.500 akciğer BT'sinden oluşmaktadır. Toplam 5.000 adet görüntünün 3.500 adeti eğitim, 750 adeti doğrulama, 750 adeti test için kullanılmıştır.

1.1. Tezin Amacı ve Derin Öğrenme Yöntemlerinin Çalışmaya Katkıları

Derin öğrenme yöntemleri insan hayatında savunma sanayi, zirai faaliyetler, otomotiv sektörü gibi birçok alanda kullanılmakla beraber sağlık alanında da sorunlara çözüm üretmek ve insan hayatını kolaylaştırmak için aktif olarak kullanılmaktadır. Sağlık alanında derin öğrenme ile beyin tümörü, meme kanseri, cildiye vakaları ve COVID-19 gibi konularda bilimsel çalışmalar mevcuttur. Çalışmada AlexNet, Densenet201, GoogleNet, ResNet-50, EfficientNet, Vgg16 gibi önceden eğitilmiş derin öğrenme modelleri ve önerilen model üzerinde deneysel çalışmalar yapılmıştır. Elde edilen başarı değerleri üzerinde karşılaştırmalar yapılmış ve en yüksek doğruluk oranına % 99,20 ile önerilen modelin sahip olduğu gözlemlenmiştir.



Şekil 1.2. Deneysel çalışma yapılan derin öğrenme modellerinin başarı oranları

Bu tez çalışmasının amacı insan akciğerlerine ait bilgisayarlı tomografi görüntüleri kullanılarak, öznel bir Evrişimsel Sinir Ağları (ESA) modeli geliştirip görüntü tanıma ve işleme tekniklerini kullanarak COVID-19 tespiti ve tahmini yapmayı sağlamaktır. Çalışmanın ilkeleri test maliyetlerini azaltmak, teşhis süreçlerinin hızlandırılması ile zamandan tasarruf ve yayılımın artmasını engelleme, otomatik sınıflandırma işlemi, geliştirilmeye açık ağ tasarımları ve yüksek doğruluk elde etmektir. Çalışmamızın hedeflediğimiz ilkeler doğrultusunda hekimlere yardımcı olacağı düşünülmektedir.

1.2. Tezin Organizasyonu

Tez çalışması altı bölümden oluşmaktadır. Birinci bölüm olan giriş bölümünde COVID-19 hakkında genel bilgiler verilmiştir, ikinci bölümde ise COVID-19 teşhis amacıyla yapılan görüntü sınıflandırma çalışmalarından bahsedilmiştir. Üçüncü bölüm olan materyal ve metotlar bölümünde kullanılan veri seti, yapay zekada kullanılan mimariler, modeller ve katmanlar hakkında bilgiler verilmiştir. Tezin dördüncü bölümünde önerilen yöntemin şematik gösterimi, önerilen ESA modelinin tasarımı ve katmanlara ait parametrelerden bahsedilmiştir. Beşinci bölümde deneysel çalışma yapılan ESA modelleri ile elde edilen sonuçlara dair yakınsama grafikleri, AUC değerleri, ROC eğrileri, karışıklık matrisleri ve performans metrikleri gösterilmiştir. Son bölüm olan sonuç ve öneriler bölümünde tez hakkında genel bir değerlendirme yapılmıştır. Veri seti eğitimi yapılan ESA modellerinin doğruluk, kesinlik, duyarlılık, F1- skor değerleri karşılaştırılmıştır.

2. KAYNAK ARAŞTIRMASI

Literatürde yapay zeka ve makine öğrenmesi teknikleri kullanılarak COVID-19 hastalığının tespitini yapmayı amaçlayan birçok deneysel çalışma bulunmaktadır. Yapılan çalışmaların birçoğu hastalık tespiti için yapılmış olsa da tedavi süreç izlenimi, temas takibi, vaka ve ölüm oranı takibi gibi önemli durumlar için de yapılmış birçok çalışma da bulunmaktadır. Yapılan çalışmaların çoğunda açık erişimli veri setleri kullanıldığı görülmektedir. Önerilen yöntemlerden birçoğunun ESA tabanlı çalışmalar olduğu ve başarı oranlarının sahip olunan veri setine, ağ tasarım modeline ve eğitim değerlerine göre değiştiği gözlemlenmiştir. Bu tez çalışmasının kaynak araştırması bölümünde, derin öğrenme teknikleri kullanarak COVID-19 tespiti yapmayı amaçlayan bilimsel çalışmalar üzerinde durulacaktır.

Hemdan ve ark. COVIDX-Net isminde bir ESA modeli tasarlamışlardır. Bu tasarım ile COVID-19 hastalığına erken tanı koyabilmeyi amaçlayarak çalışmalarını yürütmüşlerdir. COVIDX-Net ile beraber VGG19, GoogleNet gibi sıklıkla kullanılan 7 farklı ESA mimarisini de kullanmışlardır. Veri setini % 80 eğitim verisi, % 20 test verisi olarak kullanmışlardır. Veri seti olarak 25'i doğrulanmış COVID-19 vakası ve 50 adet göğüs X-ışını görüntüsü kullanmışlardır. VGG-19 modeli ile % 89, DenseNet modeli ile % 91 başarı oranına erişmişlerdir (Hemdan ve ark., 2020). Bütüner ve Calp ESA, Derin Sinir Ağları (DSA) ve Makine öğrenmesi (MÖ) algoritmaları kullanarak COVID-19'un tespit edilmesi üzerine bir çalışma yapmışlardır. Veri seti olarak toplam 14.446 adet görüntü kullanmışlardır ve sınıf olarak bakteriyel zatürre, viral zatürre, COVID-19 ve normal olmak üzere dört sınıf üzerinde çalışmışlardır. Yapılan çalışmada kategoriler arası sınıflandırma işlemi deneysel olarak gerçekleştirilmiş ve 20 tekrar gerçekleştirilmiştir. Elde edilen sonuçların ortalaması alınarak ESA modelinde % 98,4, DSA modelinde % 90,37 ve MÖ modelinde % 91,72 başarı oranı yakalanmıştır (Bütüner ve Calp, 2020). Aydoğan ve Şener tıbbi dokümanlar üzerinde yaptıkları çalışmaları ile sağlık çalışanlarının yükünü azaltmayı ve geliştirdikleri yapay zeka modeli ile COVID-19 tahmini yapmayı amaçlamışlardır. Veri seti olarak sağlık alanında yapılmış akademik çalışmaları derlemişlerdir. Derlenen bu akademik çalışmaları işlenebilir hale getirmişler ve etiketleme süreci sonrası veri seti olarak kullanılabilir hale getirmişlerdir. Metot olarak

doğal dil işleme, varlık ismi tanıma ve kelime vektörlerini kullanmışlardır. Elde edilen veri setinin % 80'lik kısmını eğitim, % 20'lik kısmını ise test verisi olarak kullanmışlardır. Deneysel çalışmalar neticesinde geliştirdikleri modelde % 91'lik oranda doğruluk başarıları elde etmişlerdir (Aydoğan ve Şener, 2020). Bozkurt yapmış olduğu çalışmada COVID-19 hastalığının yayılımını engellemek ve hızlı teşhis koymak için derin öğrenme teknikleri kullanarak bir çalışma gerçekleştirmiştir. COVID-19 ve zatürre hastalıkları radyolojik X-Ray görüntülerinde oldukça benzerlik göstermektedir. Uygulanan yöntemler ile akciğer X-Ray görüntülerini COVID-19, normal ve zatürre hastaları olarak 3 sınıfta incelemişlerdir. 11 farklı yöntem ile gerçekleştirdiği çalışmada en yüksek başarı oranını % 97,17 ile DenseNet121 metodunu kullanarak elde etmiştir (Bozkurt, 2021). JavadiMoghaddam ve Gholamalinejad çalışmalarında BT görüntüleri üzerinden yapay zeka yardımı ile COVID-19 tespiti yapmayı amaçlamışlar ve bu çalışma için 2 ayrı kamu hastanesinden alınan verileri kullanmışlardır. Çalışmada kullanılan veri seti normal, COVID-19 ve pnömani olmak üzere 3 sınıftan oluşmaktadır. Sınıflarda kullanılan görüntü adetleri 5.705 pnömoni vakası, 4.001 COVID-19 hastası ve 9.979 normal kişiden oluşmaktadır. Yapılan çalışmada farklı ESA modellerini karşılaştırmışlardır. En iyi sonuca önerilen model olan Dalgacık CNN-4 adındaki model ile ulaşmışlardır. Başarı oranı olarak % 99,03 başarı oranı elde etmişlerdir (JavadiMoghaddam ve Gholamalinejad, 2021). Kaya ve Önal çalışmalarında BT görüntüleri üzerinden göğüs bölgesinde segmentasyon işlemi yapmışlar ve sınıflandırma metodu ile COVID-19 tespitinde hekimlere yardımcı olmayı amaçlamışlardır. Veri seri olarak erişime açık kaynaklardan elde edilen 3.520 kesitten faydalanmışlardır. Veri setindeki görsellerin % 80'ini eğitim, % 20'sini test için kullanmışlardır. Çalışmada COVID-19 ve normal olarak iki sınıf üzerinde çalışmışlardır. Kullanılan veri setine ait görsellerin standart oluşturmaması ve kategorize edilmemiş olmasından kaynaklı başarısının etkilendiğini belirtmişlerdir. Görsellerdeki gürültüler, gri seviyede tanımsız dokuların olması etkenlerini ortadan kaldırılarak görsellerin daha çalışılabilir olacağı sonucuna ulaşmışlardır (Kaya ve Önal, 2021). Oğuz yaptığı tez çalışmasında radyoloji uzmanlarına destek amaçlı bir COVID-19 tanı modeli üzerinde çalışmıştır. Siirt Eğitim ve Araştırma Hastanesi'nden alınan 1.345 adet BT görüntüsünü veri seti olarak kullanmıştır. Verilerin % 80'ini eğitim için, % 20'sini test için kullanmıştır. ResNet-50, ResNet-101, AlexNet, Vgg-16, Vgg-19, GoogLeNet, SqueezeNet, Xception ağ

modellerini kullanarak özellik çıkarma işlemi gerçekleştirmiştir. En başarılı sonuçlara ResNet-50 modeli aracılığıyla % 96,29 başarı oranı ile ulaşmıştır (Oğuz, 2021). Panahi ve ark. yaptıkları çalışmada COVID-19 hastalığının tespitinde PCR test kitlerinin ve BT yöntemlerinin hekimler tarafından yorumlanmasının süreci geciktirdiğini savunmuşlardır. Yapay zeka yöntemlerini kullanarak daha hızlı tanı koymayı amaçlamışlardır. Bu amaç doğrultusunda yaptıkları çalışma için veri seti olarak 940 kişiye ait X-Ray görüntüsü kullanmışlardır. Hızlı COVID-19 detektörü (FCOD) olarak adlandırdıkları bir sınıflandırma metodu geliştirmişler ve geliştirilen metot ile % 96 doğruluk oranı elde etmişlerdir (Panahi ve ark., 2021). Özbay ve Altunbey Özbay yaptıkları makale çalışmasında göğüs BT görüntüleri üzerinden sınıflandırma yaparak COVID-19 hastalık tahmini yapabilen bir model üzerinde çalışmışlardır. Veri seti olarak 2.482 göğüs BT görüntüsü kullanmışlardır. Görüntüler Python Open CV yazılımı ile tekrardan boyutlandırmışlar sonrasında renk uzayı dönüşümü ile gri renge dönüştürülmüşlerdir. Çalışmada, geliştirdikleri ESA modeli ile literatürde sıklıkla kullanılan sınıflandırma modellerini karşılaştırmışlardır. Yapılan bu çalışmada önerilen ESA modeli ile en yüksek başarı oranına ulaşmışlar ve % 98,1 başarı oranı elde etmişlerdir (Özbay ve Altunbey Özbay, 2021).

Ceylan ve İnik COVID-19 tespiti yapmayı amaçlayan özgün bir derin öğrenme modeli geliştirmişlerdir. Çalışmada kullanılan veri setini açık erişimli kaggle platformundan elde etmişlerdir. Toplam 6.000 adet görüntüden oluşturdukları veri setinde 3.600 görsel eğitim için 1.800 görsel test için, 600 görseli ise doğrulama için kullanmışlardır. Yapılan deneysel çalışmalar sırasında en yüksek % 99,7 başarı oranına ulaşmışlardır. Çalışma yapılan görsellerin netliği, boyutu, çalışmada kullanılan parametreler gibi etmenlerin başarı yüzdesini etkilediği sonucuna varmışlardır (Ceylan ve İnik, 2022). Gopatoti ve Vijayalakshmi yaptıkları çalışmada sınıflandırma temelli CXGNet modelini geliştirmişlerdir. 4 sınıflı (Covid-19, Normal, Pneumonia Bacterial, Pneumonia Viral), 3 sınıflı (Normal, Covid-19, Pneumonia), 2 sınıflı (Normal, Covid-19) olarak deneysel çalışmalar gerçekleştirmişlerdir. 4 sınıflı model için yapılan çalışmalar neticesinde en yüksek % 94 başarı oranı elde etmişlerdir. 3 sınıflı model için en yüksek % 97,05 ve 2 sınıflı model için % 100 başarı oranı elde etmişlerdir. Elde edilen başarı oranlarında CXGNet modelinin katkılarından bahsetmişlerdir (Gopatoti ve Vijayalakshmi, 2022). Urut ve Özdağ göğüs röntgen görüntüleri üzerinden derin öğrenme algoritması kullanarak

tekrarlayan sinir ağı metodu Recurrent Neural Network (RNN) ile COVID-19 tespiti yapmayı amaçlamışlardır. Çalışmalarında, hekimlerin tanı koyma yükünü azaltmayı amaçlamışlardır. Çalışmada kullanılan veri seti 576 pozitif vaka, 1.583 normal kişi görüntüsünden oluşmaktadır. Sınıflandırma işlemi yapacak olan sistem için Resnet, VGG, DenseNet gibi modeller üzerinde çalışmışlardır. En yüksek başarı oranını Resnet metodu ile % 97 olarak elde etmişlerdir (Urut ve Özdağ, 2022). Türkçetin ve Koç çalışmalarında BT ve X-Ray görüntülerinden oluşan bir veri seti üzerinde çalışmışlardır. Çalışmanın amacı ESA ağı mimarileri ile COVID-19 hastalığının tahminini gerçekleştirmek ve hızlı tanı koymaya yardımcı olmaktır. Kullanılan veri setinde X-Ray görüntü sayısı 7.256 adet, BT görüntü sayısı ise 3.647'dir. Verilerin % 80'ini eğitim % 20'sini test olarak kullanmışlardır. Tensorflow kullanılarak tamamlanan eğitimlerin ağırlık katsayıları kaydedilmiş. Sonrasında Colab ile aktivasyon haritaları oluşturmuşlardır. Deneysel çalışmalar neticesinde elde ettikleri en yüksek oran % 86 olmuştur (Türkçetin ve Koç, 2022). Çalışkan yaptığı çalışmada COVID-19 tespitinde bulunmayı amaçlayan bir ESA modeli önermiştir. Veri seti olarak Montreal Üniversitesi araştırmacıları tarafından açık erişime sunulan ve zatürre verileri içeren RSNA data sayfasındaki verileri kullanmıştır. Veri seti X-ışınli göğüs görüntülerinden oluşmaktadır. Veri setinde bulunan görüntüler mekânsal ve spektral olarak işlenmiştir. Modelde çok çözünürlüklü analiz adımları gerçekleştirilmiş ve dalgacık dönüşümü yöntemi kullanılarak tamamlanmıştır. Dalgacık ESA (D-ESA) adında ki bu önerilen yöntem ile % 98,48 oranında başarı oranı elde etmiştir (Çalışkan, 2023). Tüfekçi ve Gezici AlexNet ve GoogleNet ağı modelleri kullanılması ile hastanın COVID-19 hastası mı yoksa Viral Pnömoni hastası mı olduğunu tespit etmek için çalışmışlardır. Veri seti olarak COVID-19 Radiography Database kullanmışlardır. Veri setinin % 80'ini eğitim, % 20'sini ise test verisi olacak şekilde ayırmışlardır. Modeller üzerinde en yüksek doğruluk oranını elde etmek için çeşitli deneysel çalışmalar yapmışlar ve AlexNet mimarisinin uygulandığı model ile % 99,90 başarı oranı elde etmişlerdir (Tüfekçi ve Gezici, 2023). Doğan yapmış olduğu çalışmada, literatürde bulunan çalışmalarda kullanılan veri setlerinin genelde aynı etnik kökene sahip insanlara ait olduğunu, benzer veriler olduğunu savunmuştur. Bu durumun eğitim ve test aşamaları bittiğinde genelde % 97 üzeri başarı verdiğini dolayısıyla eğitim ve test çalışmalarının farklı veri setlerinden oluşması gerektiğini savunmuştur. Çalışmasında eğitim ve test işlemlerini farklı veri setleriyle


gerçekleştirmiştir. En yüksek başarı oranını ResNet50 modeli ile % 71,47 ile elde etmiştir (Doğan, 2023). Udayaraju ve ark. gerçekleştirdiği çalışmada GW-CNNDC isimli bir model önermişler ve diğer derin öğrenme modelleri ile bir karşılaştırma gerçekleştirmişlerdir. Çalışmada Covid-19 pozitif hastalarının tespiti için modeller üzerinde deneysel çalışmalar gerçekleştirmişlerdir. Çalışmada kullanılan veri setinde eğitim için 9.941 görüntü, test için 2.762 görüntü, doğrulama için ise 1.105 adet görüntü bulunmaktadır. Kullanılan görüntüler PNG formatında ve 256x256 piksel giriş değerine sahiptir. Modellere ait başarı oranları ANN % 90,98, CNN % 94,89 ve GW-CNNDC % 95,15 şeklindedir (Udayaraju ve ark., 2023). Silva ve ark. DenseNet121, DenseNet169, DenseNet201, VGG16, VGG19, Xception, ResNet50, ResNet50v2, InceptionV3, MobileNet ve MobileNetv2 ESA mimarileri üzerinde birleşimler yaparak çalışmalar gerçekleştirmişlerdir. Çalışmada Covid-19 tespiti yapmayı amaçlamışlardır. Halka açık erişimi bulunan veri seti kullanılmış ve 2.477 tomografi görüntüsünden faydalanmışlardır. En iyi sonuca EnsenbleDVX adı verilen üç ESA modelini içeren model ile % 97,7 doğruluğa ulaşmışlardır (Silva ve ark., 2023). Khan ve ark. COVID-19 tahmini yapmayı sağlayacak COVID-CB-RESeg isimli bir model üzerinde çalışmışlardır. Model ile pnömani bölgeleri işaretlenip renklendirme işlemi yapmışlar ve teşhis koyabilme yüzdesini artırmayı amaçlamışlardır. Veri seti olarak toplamda 2.684 görüntüden faydalanılmıştır. Verilerin % 80'ini eğitim için % 20'sini test için kullanmışlardır. Geliştirdikleri sistem ile % 98,21 doğruluk oranına erişmişlerdir (Khan ve ark., 2023).

3. MATERYAL VE METOTLAR

Bu bölümde yapay zeka, makine öğrenmesi, derin öğrenme kavramları hakkında ayrıntılı bilgiler verilmiştir. Makine öğrenmesi başlığı altında *Denetimsiz Öğrenme*, *Denetimli Öğrenme*, *Yarı Denetimli Öğrenme*, *Yapay Sinir Ağları* kavramları açıklanmıştır. Derin öğrenme başlığı altında ESA mimarisi hakkında bilgi verilmiştir. ESA mimarisinde bulunan Giriş Katmanı (Input Layer), Konvolüsyon Katmanı (Convolution Layer), Havuzlama Katmanı (Pooling Layer), Tam Bağlantılı Katman (Fully Connected Layer), Seyreltme Katmanı (Dropout), Sınıflandırma Katmanı (Classification Layer) gibi katmanlar hakkında bilgiler verilmiştir. Derin öğrenmede kullanılan ağ modelleri (AlexNet, ZF Net, VGGNet, GoogleNet, Microsoft ResNet, U-Net, DenseNet, EfficientNet) üzerinde durulmuştur. Tez çalışmasında kullanılan veri seti hakkında bilgiler verilmiş ve önerilen yöntem üzerinde yapılan çalışmalardan bahsedilmiştir.

3.1. Yapay Zeka

İnsan beyni düşünme ve yorumlama yeteneğiyle çok kısa süre içinde, bir sonraki hareketinin ne olacağına karar verebilmekte ya da sayısal bir işlemi kolaylıkla çözebilmektedir. İnsan daha önce edindiği tecrübelerden başına gelebilecekleri ve davranışlarının ne gibi sonuçlar doğuracağını yorumlayabilmektedir. Bilgisayarlar ise çok karmaşık işlemleri anında çözebilmesine rağmen yorumlama, karar verme gibi yeteneklere direkt olarak sahip değildirler (Yılmaz, 2021). Yapay zekanın gelişim süreci de, insan beyninin yapabildiği bu becerileri model edinerek çalışmalar yapılmasıyla başlamıştır. Yapay zeka bir makinenin, insana ait özellikleri taklit ederek bir problemi çözme, anlam çıkartma, çözüm yolu üretme gibi görevleri yerine getirmesi olarak tanımlanabilir. Sorunu bildiğimiz ama iyi bir çözüm önerisi sunamadığımız durumlar için yapay zeka kullanma fikrini ilk olarak Alan Turing dile getirmiştir (Köroğlu, 2017). Yapay zeka her zaman insanlarda merak uyandıran bir konu olmuştur. Herkesin bu denli merak ettiği bir konu olmasına rağmen ayrıntılı bilgi sahibi olan kişi sayısı o kadar da fazla değildir. Dil çevirisi, yüz tanıma sistemleri, haritalar, akıllı ev sistemleri, insansız tarım projeleri gibi birçok alanda kullanılan yapay zekanın, teknolojinin gelişmesi ile doğru orantılı olarak geliştiği söylenebilir. Şekil 3.1’de Yapay zekanın tarihsel olarak öğrenme yöntemleri açısından gelişim şeması verilmiştir.



Şekil 3.1. Yapay zekanın tarihsel gelişimi

3.2. Makine Öğrenmesi

Makine öğrenmesi veri setindeki nesnelerin bilinen özellikleri üzerinden tahminler yaparak bilinmeyenleri keşfetmeyi amaçlayan ve bu yönde tahminler oluşturan sistemlerdir. İnsan eliyle basit algoritmalar yazılarak bilgisayarın ne işlem yapacağı komutu verilebilir lakin büyük ve karmaşık görevler için bilgisayarın kendi tahmin algoritmasını geliştirmesi daha kuvvetli çözümler sunacaktır. Makine öğrenmesi 1959 yılından bu yana yapay zeka üzerinden yapılan çalışmalar neticesinde sayısal öğrenme ve model tanıma işlemlerini geliştirerek oluşan bir alt daldır (T. n. E. Platformu, 2023). Savunma sanayi, sağlık, tarım, eğitim, ekonomi, teknoloji gibi birçok alanda makine öğrenmesi ile geliştirilmiş sistemler kullanılmaktadır. Makine öğrenmesi görüntü tanıma ve nesne algılama işlemlerini bilgisayarlı görme, konuşma tanıma ve metin sınıflandırma işlemlerini doğal dil işleme başlıklarında incelenmektedir. Psikoloji, kuantum kimyası, yüksek enerji fiziği, materyal tasarımı, biyoinformatik, arama motorları gibi birçok alanda karışık problemleri derin öğrenme ve makine öğrenmesi yöntemleri ile çözüme ulaştırmak mümkündür (Murat, 2023). Makine öğrenmesi, *denetimsiz öğrenme*, *denetimli öğrenme*, *yarı denetimli öğrenme* gibi öğrenme yöntemleri kullanılmaktadır.

Denetimsiz Öğrenme: Denetimsiz öğrenme kümeleme, aykırılık tespiti, sinir ağları ve gizli değişken modeller öğrenilmesi gibi yaklaşımlar üzerinden çalışmaktadır. En çok kullanılan denetimsiz öğrenme yaklaşımı veri gruplaması yapabilen kümeleme yaklaşımıdır. Başarım oranını artırmak için veriler üzerindeki parazitlerin temizlenmesi

etkili bir yöntemdir (Polat, 2017). Bu öğrenme modelinde sisteme herhangi bir müdahale işlemi uygulanmaz.

Denetimli Öğrenme: Denetimli öğrenme, eğitim veri seti ve test veri setinin sisteme tanıtılması, verileri etiketleme işleminin uygulanması, girdi verileri ile çıktı verileri arasında ilişki kurulması mantığına dayanmaktadır. Uygulamanın amacı özellikleri bilinen veri setinden yapılan sınıflandırma ile sonucu bilinmeyen veri setine dair tahmin üretmesidir.


Yarı Denetimli Öğrenme: Az sayıda etiketlenmiş veri ve çok sayıda etiketlenmemiş veri sayısı üzerinden tahmin oluşturmak için kullanılan en yaygın öğrenme modelidir (Kızılkaya ve Oğuzlar, 2018). Konuşma analizi, internet içeriği sınıflandırması, protein dizisi sınıflandırması gibi kullanım alanları mevcuttur. Şekil 3.2’de makine öğrenmesine ait eğitim stratejileri verilmiştir.



Şekil 3.2. Makine öğrenmesi eğitim stratejileri


3.2.1. Yapay sinir ağıları

Biyolojik Sinir Ağları: İnsan beyni sonsuz bir araştırma konusu olup tam olarak nasıl çalıştığı hala anlaşılabilmiş değildir. Milyarlarca sinir hücresinin bu makinanın işleyişi için durmadan çalıştığı bilinmektedir. Beynin çalışma otoritesi bilgi girişi, sentezleme ve karşılaştırma, bilgi çıkışı ve eylem faaliyetlerinden oluşmaktadır. Bu faaliyetleri nöronlar yerine getirmektedir. Tipik bir nöron, hücre gövdesi ve ipliksi uzantılardan meydana gelmektedir. Dendritler, sayısı bir hayli fazla, saçığı andıran yapılardır. Akson ise çoğunlukta tek ve dendritlerden daha uzun yapılardır. Nöronlar arası sinyal iletişimi dendrit ve hücre gövdelerinde bulunan sinaps adı verilen özel yapılarla gerçekleştirilir. Beynin her bir milimetreküpünde 4 km nöral ağ bağlantısı bulunduğu düşünülmektedir (Doğan, 2020). Şekil 3.3’de sinir hücrelerinin bağlantı yapısına ait görsel verilmiştir.



Şekil 3.3. İnsan sinir hücrelerinin bağlantı yapısı (Doğan, 2020)

Yapay Sinir Ağları (YSA), insan beyninin depolama, öğrenme ve uygulama yeteneklerini modelleyerek görevleri yerine getirmek için tasarlanmış sistemlerdir. Aynı anda birçok hesaplama işlemini yürütebilecek birbiriyle haberleşebilen nöronlardan oluşur. Yapay sinir hücrelerinin (YSH) birbirlerine farklı tasarım modelleri ile bağlanması ile YSA oluşmaktadır. İşlevlerine bakıldığında zaman YSH biyolojik sinir hücreleri gibi birbirleriyle sinyaller aracılığı ile haberleşmekte ve bu sinyalleri başka hücrelere de aktarmaktadırlar. Yapay sinir hücresi, proses elemanları olarak adlandırılmakta ve girdiler (x_n), ağırlıklar (w_n), toplama fonksiyonu (Σ), aktivasyon fonksiyonu (gx), çıktılar (y) olmak üzere 5 önemli elemandan oluşmaktadır. Şekil 3.4’de bir YSH örneği gösterilmiştir.




Şekil 3.4. Yapay sinir hücresi (Nasip ve Zengin, 2018)

YSH'lerin birleşmesi ile basit ya da çok katmanlı YSA'lar meydana gelmektedir. YSA modelleri giriş katmanı, gizli katmanlar ve çıkış katmanından oluşmaktadır.


Giriş katmanı: Sisteme giriş olarak aktarılan verilerin bulunduğu katmandır. Girdi verileri bir değişikliğe uğramadan sonraki katman olan gizli katmana aktarılır. Gizli katman ile haberleşmeleri üzerindeki ağırlık katsayıları sayesinde gerçekleştirilir.

Gizli katman: Giriş katmanından transfer edilen veriler ile bu katmanda öğrenme işlemi gerçekleştirilir. Çıktı olacak verilerin işlemi yapay sinir ağının ağırlık değerleri üzerinden yapılır. Gizli katmandaki ağırlık sayısı problemin zorluğuna göre değişiklik gösterir.

Çıkış katmanı: Sisteme aktarılan giriş verileri artık öğrenilmiş ve çıkış değerleri bu katmanda oluşturulmuştur. Sistem çıktıları bu katmanda yer alır. Hesaplanan çıktı değerleri ile beklenen değerler arasındaki fark "hata hesaplama" fonksiyonuna göre bulunur. Bulunan farka "optimizasyon fonksiyonu" uygulanarak ağırlık değerleri yeniden düzenlenir ve öğrenme işlemi doğru sonuca daha yakınsamış olur (Koç ve ark., 2018). Şekil 3.5'de basit YSA, Şekil 3.6'da ise çok katmanlı YSA örneği gösterilmiştir.



Şekil 3.5. Basit yapay sinir ağı modeli




Şekil 3.6. Çok katmanlı yapay sinir ağı modeli

3.3. Derin Öğrenme

Derin öğrenme tarihi çok eskilere dayanmamasına rağmen uygulama alanları ve deneysel çalışmalar yönünden çok popüler bir konudur. İlk defa 2012 senesinde nesne tanımlama kategorisinde yapılan büyük ölçekli görsel tanıma yarışması (ImageNet. Large-Scale Visual Recognition Challenge / ILSVRC) sayesinde derin öğrenme kavramı dikkatleri üzerine çekmiştir (İnik ve Ülker, 2017). Derin öğrenmeyi makine öğrenmesinin alt dalı olarak gören bilim insanları olduğu kadar aksini savunan ve bambaşka bir çalışma alanı olduğunu savunan bilim insanları da mevcuttur. Derin öğrenme ile insanların yapması uzun zaman alabilecek görevler, gündelik hayattaki işler kolaylıkla yapılabilmekte ve ruhsal durum veya yorgunluk gibi insansı dezavantajlarla karşılaşılmamaktadır (Talan ve Aktürk, 2021). Derin öğrenme çok katmanlı yapay sinir ağlarından oluşmaktadır ve çok sayıda veriyi aynı anda işleyebilmektedir. Her geçen gün Big Data (Büyük Veri)’nin

artması, grafik kartı (GPU) özelliklerinin sürekli gelişmesi derin öğrenmenin yeteneklerini geliştirmiş ve 2000 yılından sonra giderek popüler olmuştur.

Big Data (Büyük Veri): Teknolojinin giderek artması ve internete bağlı cihaz sayısının giderek çoğalması ile insanlar için birçok teknolojik cihaz ihtiyaç hali almıştır. Bu durum neticesinde eskiye oranla milyonlarca kat veri üretilmeye başlanmıştır. Ortaya çıkan bu uçsuz bucaksız veri kümesini depolamak ve işleyerek mantıklı sonuçlar çıkarmak, devletler için, firmalar için çıkar sağlama noktasında önemli hale gelmiştir (Döven, 2023). Bu verileri işleyecek algoritmaların gelişmesi ile de Big Data kavramı ortaya çıkmıştır. Şekil 3.7’de dünya üzerindeki toplam veri sayısının yıllara göre artış grafiği verilmiştir.




Şekil 3.7. Dünya üzerindeki toplam veri sayısının yıllara göre artış hızı ve sonraki yılların tahmini boyutları (Yüksel, 2023)

Derin öğrenme görüntü işleme, yüz tanıma sistemleri, doğal dil işleme, ses tanıma, parmak izi okuyucular, robotik, gen analizleri, sürücüsüz arabalar gibi birçok alanda kullanılmaktadır. Derin öğrenmenin en çok kullanıldığı özellikler sınıflandırma, tanıma ve tespit işlemleridir (Ferdî ve Türkoğlu, 2018a).

3.4. Evrişimsel Sinir Ağları (ESA)

Evrişimsel Sinir Ağları (ESA) mimarisi bilgisayarla görme uygulamalarında sıklıkla kullanılmaktadır. ESA mimarisi giriş katmanı, konvolüsyon katmanı, havuzlama katmanı, tam bağlantılı katman, relu katmanı, ölçeklendirme katmanı, sınıflandırma katmanı gibi çeşitli katmanlardan oluşmaktadır. Şekil 3.8’de klasik bir ESA mimarisi verilmiştir.



Şekil 3.8. Klasik ESA mimarisi (Medium, 2023)

Girdi verisinde bulunan öznitelikler konvolüsyon işlemi ile elde edilip sonraki katmanlara gönderilir. Konvolüsyon ile bir görüntüde bulunan en belirgin özellikler tespit edilir. Özellikleri belirlenen görüntünün kenarları, kıvrımlı kısımları belirlenir. Çok katmanlı yapısından dolayı derin öğrenme, konvolüsyon sinir ağında bulunan her ayrı katmanda ayrı işlemleri yapmakta ve sonra gelen katmanlara verileri iletmektedir. Sonradan gelen her katman da kendi işlevini yerine getirerek problemleri çözüme ulaştırmayı amaçlar. ESA mimarisinde yer alan katmanlar ve bu katmanların görevleri aşağıda başlıklar halinde açıklanmıştır.

3.4.1. Giriş katmanı (Input layer):

Giriş katmanı ESA mimarisinin ilk katmanıdır. Veriler olduğu haliyle bu katmandan sisteme giriş yapar. Sisteme aktarılan verilerin boyutu önem arz etmektedir. Boyut küçük seçilirse bellek ihtiyacı azalır, yapılacak eğitim süresi azalır ama başarı oranı azalabilir. Büyük seçilirse data büyüyeceği için eğitim süresi artar, bellek ihtiyacı artar ve başarı

oranı ykselebilir. Sistemimiz iin mkemmek giriř boyutunu bulmak eēitim sresi ve bařarım oranı iin nemlidir.

3.4.2. Konvolsyon katmanı (Convolution layer):

ESA mimarisinde en temel bileřen olan bu katman evriřim katmanı veya dnřm katmanı olarak da bilinmektedir. Bu dnřmn en temel iřleyiři 3x3, 5x5, 7x7, 9x9 boyutundaki belirli bir filtreyi tm grnt zerinde gezdirerek yeni matrisler meydana getirmesi ile oluřur. Konvolsyon iřlemi uygulanan grntler ıktı verilerini meydana getirir (Liu ve ark., 2015). Bu iřlemin gerekleřmesi sonrasında grntlerin zellik haritası ıkartılmıř olur. Eēitim sırasında kullanılan filtrelerin katsayı deēerleri her bir yeni adımda yenilenir. Grntdeki en nemli kısımlar bylelikle tespit edilmiř olur. Ortaya ıkan bu grntler oluřurken uygulanan grnt boyutu, filtre boyutu, filtrenin ka adım ilerleyeceēi gibi parametreler de nem arz etmektedir. řekil 3.9’da filtre iřlemi uygulanmıř bir rnek verilmiřtir.



řekil 3.9. Evriřim katmanında filtre iřlemi uygulaması sonucu oluřan grnt

Görüldüğü üzere 3x3'lük bir filtre, 5x5'lik bir görsel üzerinde gezdiriliyor ve işlemler sonrasında ortaya 3x3 boyutunda yeni bir matris çıkıyor. Sol üst köşeye yerleştirilen filtre matrisi ile üst üste gelen değerler çarpılıp çıkan sonuçların toplanmasıyla yeni bir değer elde edilir. Elde edilen bu değer çıktı matrisinde en sol köşeye yazılır. Filtre matrisi bir adım kaydırılarak işlemler tekrarlanır ve yeni değer çıktı matrisinde ilgili yere yazılarak çıktı matrisi tamamlanana kadar devam eder. Uygulanan filtrenin matematiksel olarak örneğinin ilk aşaması Şekil 3.10'da gösterilmiştir.

GİRİŞ GÖRÜNTÜSÜ						FİTRE			MATEMATİKSEL İŞLEM						SONUÇ			ADIM SIRASI							
1	0	0	1	1		<table><tr><td>1</td><td>1</td><td>1</td></tr><tr><td>0</td><td>1</td><td>0</td></tr><tr><td>1</td><td>0</td><td>1</td></tr></table>	1	1	1	0	1	0	1	0	1	$(1 \times 1) + (0 \times 1) + (0 \times 1) + (0 \times 0) + (0 \times 1) + (1 \times 0) + (1 \times 1) + (1 \times 0) + (0 \times 1)$						2			1. ADIM
1	1	1																							
0	1	0																							
1	0	1																							
0	0	1	1	0																					
1	1	0	1	0																					
1	1	1	1	0																					
1	0	0	0	1																					

Şekil 3.10. Konvolüsyon işlemi 1. adım

İkinci adımda uygulanan filtre matrisi görüntü üzerinde bir adım sağ tarafa kaydırılır ve ilk adımdaki gibi üst üste gelen değerler çarpılıp değerler toplanır çıkan sonuç çıktı matrisinde ilk yazılan değerın bir adım sağına yazılır.

GİRİŞ GÖRÜNTÜSÜ					FİTRE			MATEMATİKSEL İŞLEM					SONUÇ			ADIM SIRASI										
1	0	0	1	1	<table><tr><td>1</td><td>1</td><td>1</td></tr><tr><td>0</td><td>1</td><td>0</td></tr><tr><td>1</td><td>0</td><td>1</td></tr></table>	1	1	1	0	1	0	1	0	1	$(0 \times 1) + (0 \times 1) + (1 \times 1) + (0 \times 0) + (1 \times 1) + (1 \times 0) + (1 \times 1) + (0 \times 0) + (1 \times 1)$	<table><tr><td>2</td><td>4</td><td></td></tr><tr><td></td><td></td><td></td></tr><tr><td></td><td></td><td></td></tr></table>	2	4								2. ADIM
1	1	1																								
0	1	0																								
1	0	1																								
2	4																									
0	0	1	1	0																						
1	1	0	1	0																						
1	1	1	1	0																						
1	0	0	0	1																						

Şekil 3.11. Konvolüsyon işlemi 2. adım

Filtre matrisi üçüncü adımı da tamamladığında satır sonuna gelmiş olunur ve bir alt satıra geçerek yine en soldan başlanarak devam edilir.

GİRİŞ GÖRÜNTÜSÜ					FİTRE			MATEMATİKSEL İŞLEM					SONUÇ			ADIM SİRASI										
1	0	0	1	1	<table><tr><td>1</td><td>1</td><td>1</td></tr><tr><td>0</td><td>1</td><td>0</td></tr><tr><td>1</td><td>0</td><td>1</td></tr></table>	1	1	1	0	1	0	1	0	1	$(0X1)+(1X1)+(1X1)+(1X0)+(1X1)+(0X0)+(0X1)+(1X0)+(0X1)$	<table><tr><td>2</td><td>4</td><td>3</td></tr><tr><td></td><td></td><td></td></tr><tr><td></td><td></td><td></td></tr></table>	2	4	3							3. ADIM
1	1	1																								
0	1	0																								
1	0	1																								
2	4	3																								
0	0	1	1	0																						
1	1	0	1	0																						
1	1	1	1	0																						
1	0	0	0	1																						

Şekil 3.12. Konvolüsyon işlemi 3. Adım

9. adımda sağ alt elemanda gerekli filtreleme işlemi ve matematiksel işlemler yapıldığında çıktı matrisi oluşmuş olur. Şekil 3.13’de dördüncü adımdan itibaren son adıma kadar olan işlemler sırasıyla görülmektedir.

GİRİŞ GÖRÜNTÜSÜ	FİTRE	MATEMATİKSEL İŞLEM	SONUÇ	ADIM SİRASI																																											
<table><tr><td>1</td><td>0</td><td>0</td><td>1</td><td>1</td></tr><tr><td>0</td><td>0</td><td>1</td><td>1</td><td>0</td></tr><tr><td>1</td><td>1</td><td>0</td><td>1</td><td>0</td></tr><tr><td>1</td><td>1</td><td>1</td><td>1</td><td>0</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>1</td></tr></table>	1	0	0	1	1	0	0	1	1	0	1	1	0	1	0	1	1	1	1	0	1	0	0	0	1	<table><tr><td>1</td><td>1</td><td>1</td></tr><tr><td>0</td><td>1</td><td>0</td></tr><tr><td>1</td><td>0</td><td>1</td></tr></table>	1	1	1	0	1	0	1	0	1	$(0X1)+(0X1)+(1X1)+(1X0)+(1X1)+(0X0)+(1X1)+(1X0)+(1X1)$	<table><tr><td>2</td><td>4</td><td>3</td></tr><tr><td>4</td><td></td><td></td></tr><tr><td></td><td></td><td></td></tr></table>	2	4	3	4						4. ADIM
1	0	0	1	1																																											
0	0	1	1	0																																											
1	1	0	1	0																																											
1	1	1	1	0																																											
1	0	0	0	1																																											
1	1	1																																													
0	1	0																																													
1	0	1																																													
2	4	3																																													
4																																															
<table><tr><td>1</td><td>0</td><td>0</td><td>1</td><td>1</td></tr><tr><td>0</td><td>0</td><td>1</td><td>1</td><td>0</td></tr><tr><td>1</td><td>1</td><td>0</td><td>1</td><td>0</td></tr><tr><td>1</td><td>1</td><td>1</td><td>1</td><td>0</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>1</td></tr></table>	1	0	0	1	1	0	0	1	1	0	1	1	0	1	0	1	1	1	1	0	1	0	0	0	1	<table><tr><td>1</td><td>1</td><td>1</td></tr><tr><td>0</td><td>1</td><td>0</td></tr><tr><td>1</td><td>0</td><td>1</td></tr></table>	1	1	1	0	1	0	1	0	1	$(0X1)+(1X1)+(1X1)+(1X0)+(0X1)+(0X1)+(1X1)+(1X0)+(1X1)$	<table><tr><td>2</td><td>4</td><td>3</td></tr><tr><td>4</td><td>4</td><td></td></tr><tr><td></td><td></td><td></td></tr></table>	2	4	3	4	4					5. ADIM
1	0	0	1	1																																											
0	0	1	1	0																																											
1	1	0	1	0																																											
1	1	1	1	0																																											
1	0	0	0	1																																											
1	1	1																																													
0	1	0																																													
1	0	1																																													
2	4	3																																													
4	4																																														
<table><tr><td>1</td><td>0</td><td>0</td><td>1</td><td>1</td></tr><tr><td>0</td><td>0</td><td>1</td><td>1</td><td>0</td></tr><tr><td>1</td><td>1</td><td>0</td><td>1</td><td>0</td></tr><tr><td>1</td><td>1</td><td>1</td><td>1</td><td>0</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>1</td></tr></table>	1	0	0	1	1	0	0	1	1	0	1	1	0	1	0	1	1	1	1	0	1	0	0	0	1	<table><tr><td>1</td><td>1</td><td>1</td></tr><tr><td>0</td><td>1</td><td>0</td></tr><tr><td>1</td><td>0</td><td>1</td></tr></table>	1	1	1	0	1	0	1	0	1	$(1X1)+(1X1)+(1X0)+(0X0)+(1X1)+(0X0)+(1X1)+(1X0)+(0X1)$	<table><tr><td>2</td><td>4</td><td>3</td></tr><tr><td>4</td><td>4</td><td>4</td></tr><tr><td></td><td></td><td></td></tr></table>	2	4	3	4	4	4				6. ADIM
1	0	0	1	1																																											
0	0	1	1	0																																											
1	1	0	1	0																																											
1	1	1	1	0																																											
1	0	0	0	1																																											
1	1	1																																													
0	1	0																																													
1	0	1																																													
2	4	3																																													
4	4	4																																													
<table><tr><td>1</td><td>0</td><td>0</td><td>1</td><td>1</td></tr><tr><td>0</td><td>0</td><td>1</td><td>1</td><td>0</td></tr><tr><td>1</td><td>1</td><td>0</td><td>1</td><td>0</td></tr><tr><td>1</td><td>1</td><td>1</td><td>1</td><td>0</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>1</td></tr></table>	1	0	0	1	1	0	0	1	1	0	1	1	0	1	0	1	1	1	1	0	1	0	0	0	1	<table><tr><td>1</td><td>1</td><td>1</td></tr><tr><td>0</td><td>1</td><td>0</td></tr><tr><td>1</td><td>0</td><td>1</td></tr></table>	1	1	1	0	1	0	1	0	1	$(1X1)+(1X1)+(1X0)+(1X0)+(1X1)+(1X0)+(1X1)+(0X0)+(0X1)$	<table><tr><td>2</td><td>4</td><td>3</td></tr><tr><td>4</td><td>4</td><td>4</td></tr><tr><td>4</td><td></td><td></td></tr></table>	2	4	3	4	4	4	4			7. ADIM
1	0	0	1	1																																											
0	0	1	1	0																																											
1	1	0	1	0																																											
1	1	1	1	0																																											
1	0	0	0	1																																											
1	1	1																																													
0	1	0																																													
1	0	1																																													
2	4	3																																													
4	4	4																																													
4																																															
<table><tr><td>1</td><td>0</td><td>0</td><td>1</td><td>1</td></tr><tr><td>0</td><td>0</td><td>1</td><td>1</td><td>0</td></tr><tr><td>1</td><td>1</td><td>0</td><td>1</td><td>0</td></tr><tr><td>1</td><td>1</td><td>1</td><td>1</td><td>0</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>1</td></tr></table>	1	0	0	1	1	0	0	1	1	0	1	1	0	1	0	1	1	1	1	0	1	0	0	0	1	<table><tr><td>1</td><td>1</td><td>1</td></tr><tr><td>0</td><td>1</td><td>0</td></tr><tr><td>1</td><td>0</td><td>1</td></tr></table>	1	1	1	0	1	0	1	0	1	$(1X1)+(0X1)+(1X1)+(1X0)+(1X1)+(1X0)+(0X1)+(0X0)+(0X1)$	<table><tr><td>2</td><td>4</td><td>3</td></tr><tr><td>4</td><td>4</td><td>4</td></tr><tr><td>4</td><td>3</td><td></td></tr></table>	2	4	3	4	4	4	4	3		8. ADIM
1	0	0	1	1																																											
0	0	1	1	0																																											
1	1	0	1	0																																											
1	1	1	1	0																																											
1	0	0	0	1																																											
1	1	1																																													
0	1	0																																													
1	0	1																																													
2	4	3																																													
4	4	4																																													
4	3																																														
<table><tr><td>1</td><td>0</td><td>0</td><td>1</td><td>1</td></tr><tr><td>0</td><td>0</td><td>1</td><td>1</td><td>0</td></tr><tr><td>1</td><td>1</td><td>0</td><td>1</td><td>0</td></tr><tr><td>1</td><td>1</td><td>1</td><td>1</td><td>0</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>1</td></tr></table>	1	0	0	1	1	0	0	1	1	0	1	1	0	1	0	1	1	1	1	0	1	0	0	0	1	<table><tr><td>1</td><td>1</td><td>1</td></tr><tr><td>0</td><td>1</td><td>0</td></tr><tr><td>1</td><td>0</td><td>1</td></tr></table>	1	1	1	0	1	0	1	0	1	$(0X1)+(1X1)+(0X1)+(1X0)+(1X1)+(0X0)+(0X1)+(0X0)+(1X1)$	<table><tr><td>2</td><td>4</td><td>3</td></tr><tr><td>4</td><td>4</td><td>4</td></tr><tr><td>4</td><td>3</td><td>3</td></tr></table>	2	4	3	4	4	4	4	3	3	9. ADIM
1	0	0	1	1																																											
0	0	1	1	0																																											
1	1	0	1	0																																											
1	1	1	1	0																																											
1	0	0	0	1																																											
1	1	1																																													
0	1	0																																													
1	0	1																																													
2	4	3																																													
4	4	4																																													
4	3	3																																													

Şekil 3.13. Konvolüsyon işlemi (4. Adımdan 9.adıma kadar olan işlemler)

3.4.3. Havuzlama katmanı (Pooling layer):

Havuzlama katmanı genellikle relu katmanından sonra gelir. Girdi verileri büyük boyutlarda veriler olabilir, bu büyüklük eğitim süresinin uzamasına ve karmaşıklığa neden olmaktadır. Havuzlama katmanı büyük boyutlardaki bu verileri aşamalı olarak azaltmayı amaçlar, özellik haritasının önemli kısımları korunurken ezberlemenin de önüne geçilmiş olur. Bu azalma uzunluk ve genişliği etkilerken derinliği etkilemez. Parametre sayısındaki bu azalmalar sistem karışıklığının da önüne geçmeyi sağlamaktadır. Havuzlama katmanında kullanılan ana yöntemler ortalama havuzlama ve maksimum havuzlama yöntemleridir. Ortalama havuzlama işlemi ile özellik haritasının aritmetik ortalaması hesaplanırken, maksimum havuzlama işlemi ile maksimum değerler çıktı olarak alınır. Şekil 3.14'te maksimum havuzlama işlemi, Şekil 3.15'te ortalama havuzlama işlemi görülmektedir.

		3	4	2					5		
		2	5	3							
		6	1	4							
		Özellik Haritası							Çıktı		


Şekil 3.14. Maksimum havuzlama işlemi

		3	4	2						3,5	
		2	5	3							
		6	1	4							
		Özellik Haritası							Çıktı		

Şekil 3.15. Ortalama havuzlama işlemi

3.4.4. Tam bağlantılı katman (Fully connected layer):


ESA mimarisinde konvolüsyon katmanı, relu katmanı ve havuzlama katmanından sonra tam bağlantılı katman gelmektedir. Bu katmandaki nöronlar, kendinden önce gelen katman nöronlarının tamamına bağlanmakta ve çıktılarını sonra gelen katmana aktararak çalışmaktadır (Büyükarıkan ve Ülker, 2020). Tam bağlantılı katman sınıflandırma işlemleri, doğal dil işleme, görüntü işleme gibi çalışmalarda kullanılmaktadır. Katmandaki öznelilik, matrislerinin bu katman üzerinde birbirine bağlanması ile elde edilir. Şekil 3.16'da Tam bağlantılı katman örneği verilmiştir.




Şekil 3.16. Tam bağlantılı katman

3.4.5. Seyreltme katmanı (Dropout):

Çok katmanlı sinir ağlarının ezberleme yapmaması için geliştirilmiş bir yöntemdir. Belirlenen bir eşik değeri sonrasında önemsiz sayılabilecek bilgiler unutulur. Sistemde aşırı zaman kaybının önüne geçilir ve ezberleme yapmaması sağlanır. Seyreltme işlemi rasgele bazı bağlantıların silinmesiyle gerçekleştirilir. Şekil 3.17'de seyreltme işlemine örnek bir yapay sinir ağı gösterilmektedir.



Standart Yapay Sinir Ağı



Seyreltme Uygulanmış Yapay Sinir Ağı

Şekil 3.17. Seyreltme işlemi (kırmızı çarpı atılan nöronlar ağdan çıkartılmıştır)


3.4.6. Sınıflandırma katmanı (Classification layer):

Sınıflandırma katmanında sınıflandırılacak öge sayısı kadar sonuç üretilir. Örneğin 4 farklı türde nesne sınıflandırılacaksa sınıflandırma katmanının çıkış değeri 4 olmalıdır. Son katman olarak uygulanan sınıflandırıcı katmanı için farklı sınıflandırma türleri kullanılmaktadır. Softmax için, en çok bilinen ve kullanılan sınıflandırıcı diyebiliriz (Ferdî ve Türkoğlu, 2018b).

3.5. Derin Öğrenme Ağ Modelleri

3.5.1. LeNet


Yann LeCun tarafından oluşturulan ve 1998 yılına kadar geliştirilen bu model, ESA mimarisi sınıflandırma işlemleri için kullanılan ilk model olarak bilinir (Şeker ve ark., 2017). 1998 yılında, banka çek evrakları üzerinde bulunan el yazısı ile yazılmış sayıları tanımlamak için geliştirilen bu ağa LeNet adı verilmiştir (Lecun ve ark., 1998). 0 ve 9 arasındaki rakamları sınıflandıran, yumuşatma katmanı bulunan 10 sınıflı bir modeldir. LeNet modelinin mimari yapısı Şekil 3.18’de gösterilmektedir.



Şekil 3.18. LeNet Mimarisi (Lecun ve ark., 1998).

3.5.2. AlexNet


2012 ILSVRC ImageNet büyük ölçekli görsel tanıma yarışmasında 1.2 milyon görüntü ve 1.000 farklı nesneyi sınıflandıran AlexNet birincilik elde etmiştir (Krizhevsky ve ark., 2012). Örüntü tanıma işleminde hata oranını % 15 seviyelerine düşürmesi sonrasında AlexNet en çok tanınan derin öğrenme modellerinden biri olmuştur. Mimari yapısı 5 evrişim katmanı, havuzlama katmanı ve 3 tam bağlantılı katmandan oluşmaktadır. 1.000 farklı nesneyi sınıflandırabilen AlexNet bu işlemi Softmax sınıflandırma katmanı ile gerçekleştirir (Nasip ve Zengin, 2018). AlexNet modelinin mimari yapısı Şekil 3.19’da gösterilmektedir.



Şekil 3.19. AlexNet Mimarisi (Krizhevsky ve ark., 2012).

3.5.3. ZFNet


Matthew Zeiler ve Rob Fergus 2013 yılı ILSVRC ImageNet büyük ölçekli görsel tanıma yarışması için ZFNet adında bir model geliştirmişlerdir. 2013 yılının birincisi olan bu ağ modeli başarı oranını % 88 seviyelerine taşımıştır (Ferdin ve Türkoğlu, 2018b). AlexNet mimarisini geliştirerek yapılan bu modelde 7x7 filtre boyutu, 2 adım sayısı bulunmaktadır. Tasarım zamanında ki teknolojik imkânlar ve GPU özelliklerine göre ağı eğitmek iki haftaya yakın sürmüştür. ZFNet modelinin mimari yapısı Şekil 3.20’de gösterilmektedir.



Şekil 3.20. ZFNet Mimarisi (Zeiler ve Fergus, 2013)

3.5.4. VGGNet

ESA mimarisinde VGG-16 mimarisi (Simonyan ve Zisserman, 2014) evrişim katmanı, havuzlama katmanı ve tamamen bağlı katmandan oluşmaktadır. Toplamda 21 ana katmana sahiptir ve modelin son katmanları özellik çıkarımı yapmakla görevlidir. VGG-19 mimarisinin ana katmanları 16 evrişimsel, 5 havuzlama ve 3 tam bağlantılı katman içermektedir. Bu mimari toplam 24 ana katmana sahiptir (Toğaçar ve ark., 2020). Modelin 2014 yılı ILSVRC ImageNet büyük ölçekli görsel tanıma yarışması'nda elde edilen başarı oranı % 92,7'dir. Modelde kullanılan filtre boyutlarının küçük olması parametre sayısını da azaltmıştır dolayısıyla performans ve başarı oranını doğru orantılı olarak artırmak amaçlanmıştır. Şekil 3.21'de VGGNet ağ mimarisi, Şekil 3.22'de ise katman parametre bilgileri gösterilmektedir.




Şekil 3.21. VGGNet ağ mimarisi (Rosebrock, 2023)

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64 LRN	conv3-64	conv3-64	conv3-64	conv3-64
maxpool					
conv3-128	conv3-128	conv3-128	conv3-128	conv3-128	conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

Şekil 3.22. VGG 16 katman parametre bilgileri (Simonyan ve Zisserman, 2014)

3.5.5. GoogLeNet


VGGNet ve AlexNet ağ modellerine göre katman sayısı daha fazla olan bu model sadece katman sayısını değil GoogLeNet Inception modeliyle de derinliği artırmıştır, neticesinde Inception mimarisi ile başarı oranını da artırmıştır (Gündüz ve Cedimoğlu, 2019). 2014 yılında yapılan ILSVRC yarışmasını % 5,7 hata oranı ile kazanan model olmuştur. Modelin eğitimini yapmak için 1.2 milyon, test aşaması için 100 bin görüntü kullanılmıştır. GoogLeNet mimarisi toplam 22 katmandan ve 5 milyon parametreden oluşmaktadır. Şekil 3.23'te GoogLeNet mimarisi gösterilmiştir (Szegedy ve ark., 2015).



Şekil 3.23. GoogLeNet Mimarisi (Szegedy ve ark., 2015)


3.5.6. Microsoft ResNet

ResNet mimarisi 2015 yılında yapılan ILSVRC yarışmasında % 96,4 başarı oranı ve % 3,6 hata oranı ile birincilik elde etmiştir (Yıldız ve ark., 2023). Toplamda 152 katmandan oluşan bu mimari tüm mimariler arasında derinlik konusunda da en önde gelmektedir. 2 adım kaydırmalı işlem uygulanan bu mimaride ara bağlantılar kurularak doğruluk oranları artırılmıştır. Mimarideki katman sayısına göre ResNet-18, ResNet-24, ResNet-50, ResNet-101 gibi türleri vardır. En çok kullanılan modeli ResNet-50 modelidir. Şekil 3.24'te ResNet mimarisi gösterilmiştir.



Şekil 3.24. Microsoft ResNet Mimarisi (He ve ark., 2016)

Şekil 3.25’de ise ILSVRC yarışmasında birincilik elde eden ağ mimarilerinin yıllara göre hata oranları gösterilmektedir.



Şekil 3.25. Yıllara göre ImageNet sınıflandırma hata oranları


3.6. Bilgisayarlı Tomografi (BT)

Tomografi kelimesi yunanca kesim, (hypatiabilim, 2023) dilim, kısım anlamı taşıyan “Tomos” kelimesi ile yazmak, kaydetmek anlamına gelen “Graphein” kelimelerinin birleşiminden oluşmaktadır (Memorial_Sağlık_Grubu, 2023). Tomografi, bir cisme ait farklı açılardan çekilen izdüşüm bilgilerinden, kesit görüntüler elde edilmesi ile oluşmaktadır. G. N. Hounsfield ve Alan Cormack tarafından 1972 yılında icat edilmesi sonrası ilk tomografik tarayıcılar kullanılmaya başlanmıştır (Ömeroğlu, 2003). Geçmişte X ışınları fiziksel filmlere aktarılıp yorumlanıyordu. BT, istenilen bölgeyi X-Ray ışınları ile tarayarak detaylı ve katmanlı bir görüntü serisi oluşturmaktadır. Bu görüntü katmanları bilgisayarda kesitlerden oluşan seriler halinde bulunmaktadır. Bilgisayarlar, oluşan bu dijital serileri kesitler halinde görüntülenmesine, yorumlanmasına imkân sağlamaktadır. Tomografi cihazları sayesinde kemikler, damarlar, yumuşak dokular, organlar hakkında insan gözüyle görülemeyecek ayrıntıda bilgiler elde edilebilmektedir. Hastalıkların tespitinde ve erken önlem alma konusunda tomografinin önemi büyüktür. Şekil 3.26’da bilgisayarlı tomografi cihazına ait bir görsel verilmiştir.



Şekil 3.26. Bilgisayarlı tomografi (BT) cihazı

Meydana gelen çeşitli rahatsızlıklar ve hastalıklar için teşhis koymada büyük önem taşıyan tomografi cihazları insan vücudunda birçok bölge için kullanılmaktadır. Şekil 3.27’de insan vücuduna ait değişik bölgelerden çekilmiş tomografi örnekleri verilmiştir.




Şekil 3.27. Bilgisayarlı tomografi (BT)çekilmiş organ görüntüleri.
(Hekimoğlu_ Görüntüleme, 2023), (Gümüş ve ark., 2012), (Erdoğan, 2023), (Koylan, 2023), (Anonim, 2023)

3.7. Veri Seti

Tokat Gaziosmanpaşa Üniversitesi Araştırma ve Uygulama Hastanesi Başhekimliği'ne “Derin Öğrenme ile Radyolojik Görüntüler Üzerinden COVID-19 Tespiti” başlıklı tez çalışmamızda kullanılmak üzere gerekli veri setini oluşturabilmek için veri talebinde bulunuldu. Verileri kullanırken 6698 Sayılı Kişisel Verilerin Korunması Kanunu'nun 3. maddesi uyarınca başka verilerle eşleştirilerek dahi hiçbir surette kimliği belirli veya belirlenebilir bir gerçek kişiyle ilişkilendirilemeyecek hâle getirilerek kullanılacağı kabul ve taahhüt edildi. Dilekçemizde belirttiğimiz kriterde ve sayıda hastaya ait görüntüler hastane pacs sunucularında sorgulandı. 250 sağlıklı kişi ve 250 COVID-19 teşhisi konulmuş hastaya ait akciğer BT görüntüleri teslim alındı.


Her hastanın kendi klasörü içerisinde bulunan çok sayıda görüntü hastane otomasyonu tarafından 1.2.392.200036.9123.100.11.15114374081370520159681132110.dcm şeklinde karmaşık olarak isimlendirilmiş haldeydi. Hastaların görüntü id'sini içeren klasörlerdeki bu serilerin kullanılabilir olması için görüntüler JPG görüntü formatına çevrildi.

Çeviri işlemi bir yardımcı program ile gerçekleştirilmiş olup çeviri işlemine ait görsel Şekil 3.28’de görülmektedir.




Şekil 3.28. BT kesitlerinin .dcm formatından .Jpg formatına dönüştürülmesi (Converter, 2023)

Her bir hastadan ciğer bölgesinin farklı kesitlerinden alınmış ortalama 300 adet görüntü elde edildi. Her hasta için verimli olacağı düşünülen en net 10 adet görüntü seçimi yapıldı. 250 sağlıklı kişiye ait 2.500 akciğer görüntüsü ve 250 COVID-19 teşhisi konulmuş hastaya ait 2.500 görüntü alınarak toplam 5.000 görüntülük veri seti elde edildi. Görüntüler vücudun üst kısmından aşağı kısma doğru kesitler halinde taranmış olarak ilerlemekteydi ve kesitlerin başlangıç ve bitiş görüntülerinde ciğerler net olarak görülmemekteydi, veri seti için kullanıma en uygun görüntüler seçilmiş oldu. Veri setinde bulunan COVID-19 pozitif ve COVID-19 negatif kişilere ait BT görüntü sınıflarını temsil eden görseller Şekil 3.29’da verilmiştir.



Şekil 3.29. COVID-19 pozitif ve COVID-19 negatif kişilere ait BT görüntüleri

Veri seti için COVID-19 pozitif ve COVID-19 negatif olmak üzere iki ayrı klasör oluşturuldu. Veriler sınıflarımızı temsil eden bu iki klasöre aktarıldı. Her klasördeki .jpg resimleri 1.2.392.200036.9123.100.11.15114374081370520158503239907984885.jpg şeklinde isimlendirildiği için yardımcı bir program ile yeniden isimlendirme işlemi yapıldı. Covid-19 pozitif sınıfındaki kişilere ait görüntüler Covid0001.jpg olarak, Covid-19 negatif sınıfındaki kişilere ait görüntüler Non-Covid0001.jpg şeklinde isimlendirildi. Uygulanan yeniden isimlendirme işlemine ait görsel Şekil 3.30’da verilmiştir.



Şekil 3.30. BT görüntülerinin yeniden isimlendirilmesi (Renamer, 2023)


Veri seti üzerinde yapılan ön işleme sonucunda eğitim için elde edilen verilere ait sayı tablosu Tablo 3.1’de verilmiştir. Tabloya bakıldığında verilerin % 70’i eğitim % 15’i doğrulama % 15’i ise test için kullanılmıştır. Toplamda eğitim için 3.500 görüntü, doğrulama için 750 görüntü, test için 750 görüntü hazırlanmıştır.

Tablo 3.1. Deneysel çalışmalarda kullanılan veri setine ait görüntü sayıları

Veri Seti Sınıfı	Eğitim (% 70)	Doğrulama (% 15)	Test (% 15)
Covid-19 Pozitif	1.750	375	375
Covid-19 Negatif	1.750	375	375
Toplam	3.500	750	750

4. ÖNERİLEN YÖNTEM


Bu tez çalışması kapsamında önerilen yöntemin metodolojisi görsel Şekil 4.1’de verilmiştir. İlk aşamada veri seti oluşturulmuştur, ikinci aşamada verilerin.dcm olan formatı.jpg görüntü formatına çevrilmiştir. Verilerin sınıflandırılması, isimlerin anlamlı olacak şekilde değiştirilmesi gibi ön işleme adımları gerçekleştirilmiştir. Üçüncü aşamada eğitim, doğrulama ve test için kullanılacak verilerin dağılımı belirlenmiştir. Dördüncü aşamada hangi derin öğrenme modellerinin eğitim için kullanılacağı belirlenmiştir. Son aşamada ise performans metriklerinin ve doğruluk oranlarının elde edilmesi ile sonuçların karşılaştırılmasına imkan sağlanmıştır.



Şekil 4.1. Tez kapsamında önerilen yöntemin metodolojisi

Literatürde yer alan derin öğrenme modellerine alternatif olarak yeni bir ESA modeli tasarlanmıştır. Bu ESA modeli toplamda 50 katmandan oluşmaktadır. ImageInputLayer katmanı ile giriş katmanı oluşturulmuş, relu katmanı, normalizasyon katmanı, ortaklama katmanı, batch normalization, depth concatenation, tam bağlantılı katman, softmax, sınıflandırma katmanı gibi katmanlar kullanılmıştır. Model tasarımı için sık kullanılan ağ mimarileri ayrıntılı olarak incelenmiş ve model oluşturma hakkında bilgi elde edilmiştir. Model tasarım çalışmaları esnasında 20’ ye yakın farklı model denenmiştir. Denemesi yapılan bu modellerin katman sayıları ve katman özellikleri sürekli değiştirilmiş ve başarı oranı en ideal olan, çalışmamızda da kullanılan model seçilmiştir. Önerilen modele ait ağ tasarımı Şekil 4.2’de görülmektedir. Model toplam 32.768 parametreden oluşmaktadır.

Önerilen modele ait her bir katmanın parametre değerlerini içeren bilgiler Tablo 4.1’de gösterilmiştir.



Şekil 4.2. Önerilen modele ait ağ tasarımı

Tablo 4.1. Önerilen modele ait katmanların parametre değerleri

Katman Sırası	Katman Adı	Boyut	Filtre Sayısı	Filtre Boyutu	Adım Sayısı	Parametreler	Toplam Parametre Sayısı
1	Giriş Katmanı	64x64x1	-	-	-	-	0
2	Evrişim Katmanı_1	64x64x1	8	3x3	1x1	64x64x8x1	32.768
3	Relu Katmanı	64x64x1	-	-	-	-	0
4	Evrişim Katmanı_2	64x64x1	8	3x3	1x1	64x64x8x1	32.768
5	Normalizasyon Katmanı	64x64x1	-	-	-	-	0
6	Ortaklama Katmanı	64x64x1	-	5x5	-	-	0
7	Evrişim Katmanı_3	64x64x1	32	3x3	1x1	64x64x32x1	131.072
8	Relu Katmanı_1	64x64x1	-	-	-	-	0
9	Ortaklama Katmanı_1	64x64x1	-	5x5	-	-	0
10	Evrişim Katmanı_4	64x64x1	32	3x3	1x1	64x64x32x1	131.072
11	Relu Katmanı_2	64x64x1	-	-	-	-	0
12	Ortaklama Katmanı_2	64x64x1	-	5x5	-	-	0
13	Batch Normalization	64x64x1	32	3x3	1x1	64x64x32x1	131.072
14	Evrişim Katmanı_5	64x64x1	32	3x3	1x1	64x64x32x1	131.072
15	Relu Katmanı_3	64x64x1	-	-	-	-	0
16	Evrişim Katmanı_6	64x64x1	32	3x3	1x1	64x64x32x1	131.072
17	Relu Katmanı_4	64x64x1	-	-	-	-	0
18	Ortaklama Katmanı_3	64x64x1	-	5x5	-	-	0
19	Evrişim Katmanı_7	64x64x1	32	3x3	1x1	64x64x32x1	131.072
20	Relu Katmanı_5	64x64x1	-	-	-	-	0
21	Ortaklama Katmanı_4	64x64x1	-	5x5	-	-	0
22	Batch Normalization_1	64x64x1	32	3x3	1x1	64x64x32x1	131.072
23	Evrişim Katmanı_8	64x64x1	32	3x3	1x1	64x64x32x1	131.072
24	Relu Katmanı_6	64x64x1	-	-	-	-	0
25	Evrişim Katmanı_9	64x64x1	32	3x3	1x1	64x64x32x1	131.072
26	Relu Katmanı_7	64x64x1	-	-	-	-	0
27	Ortaklama Katmanı_5	64x64x1	-	5x5	-	-	0
28	Evrişim Katmanı_10	64x64x1	32	3x3	1x1	64x64x32x1	131.072
29	Relu Katmanı_8	64x64x1	-	-	-	-	0
30	Ortaklama Katmanı_6	64x64x1	-	5x5	-	-	0
31	Batch Normalization_2	64x64x1	32	3x3	1x1	64x64x32x1	131.072
32	Evrişim Katmanı_11	64x64x1	32	3x3	1x1	64x64x32x1	131.072
33	Relu Katmanı_9	64x64x1	-	-	-	-	0
34	Depth Concatenation	64x64x1	96	-	-	-	0
35	Evrişim Katmanı_12	64x64x1	32	3x3	1x1	64x64x32x1	131.072
36	Ortaklama Katmanı_7	64x64x1	-	5x5	-	-	0
37	Relu Katmanı_10	64x64x1	-	-	-	-	0
38	Evrişim Katmanı_13	64x64x1	32	3x3	1x1	64x64x32x1	131.072
39	Ortaklama Katmanı_8	64x64x1	-	5x5	-	-	0
40	Relu Katmanı_11	64x64x1	-	-	-	-	0
41	Evrişim Katmanı_14	64x64x1	32	3x3	1x1	64x64x32x1	131.072
42	Ortaklama Katmanı_9	64x64x1	-	5x5	-	-	0
43	Relu Katmanı_12	64x64x1	-	-	-	-	0
44	Depth Concatenation	64x64x1	96	-	-	-	0
45	Evrişim Katmanı_15	64x64x1	32	3x3	1x1	64x64x32x1	131.072
46	Ortaklama Katmanı_10	64x64x1	-	5x5	-	-	0
47	Seyreltme Katmanı	1x1x2500	-	-	-	2500x96	240.000
48	Tam Bağlantılı Katman	1x1x2	1x1x2	-	-	2x2500	5.000
49	Softmax	1x1x2	-	-	-	-	0
50	Sınıflandırma Katmanı	1x1x2	-	-	-	-	0

5. DENEYSEL ÇALIŞMALAR

Deneysel çalışmalarda kullanılan donanım ve yazılımlara ait kaynakların bilgileri Tablo 5.1’de verilmiştir.

Tablo 5.1. Kullanılan donanım ve yazılımlara ait bilgiler

Eğitim İçin Kullanılan Donanım	Donanım Özellikleri
İşlemci:	Intel (R) Core (TM) i7-4770 CPU
İşlemci hızı:	3.40 GHz, 8 Çekirdek
Ram kapasitesi:	16 GB (Gigabyte)
Grafik Kartı:	AMD Radeon HD 5450 GPU
Eğitim İçin Kullanılan Yazılım:	Matlab R2023a 64 Bit

Yapılan tez çalışması kapsamında ilk defa kullanılacak özgün veri setine ait COVID-19 hastaları ve Sağlıklı insanların ciğer görüntüleri üzerinde çalışılmıştır. Bu görüntülerin sınıflandırılması için önerilen ESA modeli ile beraber 7 farklı model üzerinde çalışma yapılmıştır. Modeller ile 5.000 adet görüntüye sahip veri seti üzerinden eğitimler yapılmıştır. Eğitim işlemi için MATLAB R2023a (mathworks.com, 2023) yazılımı kullanılmıştır. Önerilen ağ modeline ait tasarım MATLAB R2023a programı Deep Network Designer modulünde yapılmıştır.

5.1. Performans Ölçütleri

Deneysel çalışmalar sonucunda elde edilen yakınsama grafikleri, performans değerleri ve çalışılan modellerden elde edilen sonuçların karşılaştırılması yapılmıştır. Karışıklık matrisleri tahmin sonuçlarının özetini yansıtmaktadır. Karışıklık matrisine ait görsel Tablo 5.2’de verilmiştir.

Tablo 5.2. Karışıklık matrisi

KARIŞIKLIK MATRİSİ		TAHMİN EDİLEN DEĞER	
		POZİTİF	NEGATİF
GERÇEK DEĞER	POZİTİF	DOĞRU POZİTİF (TP)	YANLIŞ POZİTİF (FP)
	NEGATİF	YANLIŞ NEGATİF (FN)	DOĞRU NEGATİF (TN)

TP: Pozitif örneğin doğru sınıflandırılması işlemidir.

TN: Negatif örneğin doğru sınıflandırılması işlemidir.

FP: Negatif örneğin yanlış sınıflandırılması işlemidir.

FN: Pozitif örneğin yanlış sınıflandırılması işlemidir.

$$\text{Doğruluk} = \frac{\text{Doğru Pozitif} + \text{Doğru Negatif}}{\text{Toplam Örnek Sayısı}} \times 100$$

$$\text{Kesinlik} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Pozitif}} \times 100$$

$$\text{Duyarlılık} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}} \times 100$$

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

Eğitimlerin başarı oranlarını grafiksel olarak roc eğrileri üzerinden de yorumlayabiliriz. ROC eğrisi, değişken eşik durumlarında yanlış pozitif oranına karşı, doğru pozitif oranı (Duyarlılık) çizerek meydana getirilir. ROC eğrisi eşiği altında kalan kısım AUC değerini meydana getirmektedir. AUC, ayırt edilebilirlik derecesini temsil etmektedir. Modelin sınıflar arasındaki ayırım yapma becerisini göstermektedir. AUC derecesi ne kadar yüksekse, modelin gerçek negatifleri negatif ve gerçek pozitifleri pozitif olarak tahmin etme becerisi de o derece iyidir.

Bu çalışma için dört adet sayısal hiperparametre üzerinde durulmuştur. Her model için kullanılan hiperparametre değerleri başlıklar altında tablolar halinde verilmiştir. Bu hiperparametreler şunlardır;


- a) Eğitim Adımı Sayısı (Epoch)
- b) Katman Sayısı (Layer Size)
- c) Öğrenme Katsayısı (Learning Rate)
- d) Mini-Batch Boyutu (Mini-Batch Size)

5.2. Derin Öğrenme Modellerinin Performansı

Veri seti, literatürde sıklıkla kullanılan 6 farklı ESA modeli ve önerilen ağ modeli üzerinde eğitilmiştir ve farklı başarı oranları elde edilmiştir. Eğitim aşamasında elde edilen yakınsama grafikleri, AUC değerleri, ROC eğrileri, karışıklık matrisleri modellerin performans değerlendirme başlıkları altında verilmiştir.


5.2.1. AlexNet modelinin performans değerlendirmesi

Veri setinin AlexNet modeli ile eğitim aşamasında elde ettiği yakınsama grafiği Şekil 5.1’de verilmiştir. Grafiğe bakıldığında aşamalı olarak 1.devir ile 4. devir aralığında % 78 doğruluğa, 4. devir ile 10. devir aralığında % 88 doğruluğa yakınsadığı görülmektedir. Modelin 14. devire kadar öğrenmesini gerçekleştirdiği ve bu devirden sonra çok düşük oranlarla öğrenim oranını artırdığı gözlemlenmiştir. Bu nedenle bu modelin yaklaşık 20 devir ile eğitim işlemini tamamlayabileceği anlaşılmıştır. Eğitim test süresi her devir için ortalama olarak 5 dakika sürmüştür ve toplam test süresi (devir sayısı x 5 dk.) olarak hesaplanmıştır. Alexnet modeli 90 devirden oluşmaktadır ve modelin ortalama 450 dakika ile eğitim testini tamamladığı görülmüştür.




Şekil 5.1. AlexNet modeline ait eğitim aşamasındaki yakınsama grafiği

AlexNet modeli ile test verisi üzerinde elde edilen karışıklık matrisi Şekil 5.2’de verilmiştir. Matrise bakıldığında 162 Covid-19 pozitif hastanın 145’i doğru sınıflandırılmış 17’si ise hatalı sınıflandırılmıştır. 168 sağlıklı örneğin 148’i doğru sınıflandırılmış 20’si Covid-19 pozitif olarak hatalı sınıflandırılmıştır.




Şekil 5.2. AlexNet modelinin test verisi üzerinde elde ettiği karışıklık matrisi

AlexNet modeli ile deneysel çalışmalar neticesinde elde edilen Roc eğrisi Şekil 5.3’de verilmiştir.



Şekil 5.3. AlexNet modeline ait Roc Eğrisi

AlexNet modeli ile eğitim aşamasında elde edilen AUC şeması Şekil 5.4’de verilmiştir.



Şekil 5.4. AlexNet modeline ait AUC Şeması

AlexNet modeli ile eğitim aşamasında elde edilen performans metrikleri Tablo 5.3’de verilmiştir. Tabloya bakıldığında % 88,81 doğruluk değeri elde edildiği görülmüştür.

Tablo 5.3. AlexNet modeli ile yapılan deneysel çalışmalar sonrası elde edilen performans metrikleri

Doğruluk (%) (Accuracy)	Kesinlik (%) (Precision)	Duyarlılık (%) (Recall)	F1-Skor (%)	Eğitim Süresi (dk.) (Training Time)
88,81	89,51	87,88	88,69	450


Alexnet modeli ile eğitim için kullanılan eğitim hiperparametreleri ve değerleri Tablo 5.4’ de verilmiştir.

Tablo 5.4. Alexnet modeline ait hiperparametre değerleri

Eğitim Adımı Sayısı (Epoch)	Katman Sayısı (Layer Size)	Öğrenme Katsayısı (Learning Rate)	Mini-Batch Boyutu (Mini-Batch Size)
90	8	0.001	32


5.2.2. DenseNet201 modelinin performans deęerlendirmesi

Veri setinin DenseNet201 modeli ile eęitim ařamasında elde ettięi yakınsama grafięi řekil 5.5’de verilmiřtir. Modele ait yakınsama grafięi incelendięinde 1. devirden 3. devire kadar olan sũreęte % 80 doęruluk oranına ve 3. devirden 6. devire kadar % 90 doęruluk oranına yakınsadıęı gũrũlmektedir. 7. devirde kayıp olduęu gũrũlse de 8. devirde en yũksek doęruluk oranına yakınsadıęı ve 26. devire kadar Ȕęrenmenin bu oranlarda seyrettięi gũrũlmektedir. Hata oranının aynı řekilde oransal olarak bu devirlerde giderek azaldıęı gũzlemlenmiřtir. Eęitim test sũresi her devir ięin ortalama olarak 5 dakika sũrmũřtũr ve toplam test sũresi (devir sayısı x 5 dk.) olarak hesaplanmıřtır. DenseNet201 modeli 78 devirden oluřmaktadır ve modelin ortalama 390 dakika ile eęitim testini tamamladıęı gũrũlmũřtũr.




řekil 5.5. DenseNet201 modeline ait eęitim ařamasındaki yakınsama grafięi

DenseNet201 modeli ile test verisi ȕzerinde elde edilen karıřıklık matrisi řekil 5.6’da verilmiřtir. Karıřıklık matrisi incelendięinde 225 Covid-19 pozitif hastanın 192’si doęru sınıflandırılmıř 33’ũ ise hatalı sınıflandırılmıřtır. 215 saęlıklı ȕrneęin 187’si doęru sınıflandırılmıř 28’i Covid-19 pozitif olarak hatalı sınıflandırılmıřtır. Modelin genel doęruluęuna baktıęımızda % 86,16’lũk doęruluk oranı elde ettięi gũrũlmũřtũr.




Şekil 5.6. DenseNet201 modelinin test verisi üzerinde elde ettiği karışıklık matrisi

DenseNet201 modeli ile deneysel çalışmalar neticesinde elde edilen Roc eğrisi Şekil 5.7’de verilmiştir.



Şekil 5.7. DenseNet201 modeline ait Roc Eğrisi

DenseNet201 modeli ile eğitim aşamasında elde edilen AUC şeması Şekil 5.8’de verilmiştir.



Şekil 5.8. DenseNet201 modeline ait AUC Şeması

DenseNet201 modeli ile eğitim aşamasında elde edilen performans metrikleri Tablo 5.5’de verilmiştir.

Tablo 5.5 . DenseNet201 modeli ile yapılan deneysel çalışmalar sonrası elde edilen performans metrikleri

Doğruluk (%) (Accuracy)	Kesinlik (%) (Precision)	Duyarlılık (%) (Recall)	F1-Skor (%)	Eğitim Süresi (dk.) (Training Time)
86,16	85,33	87,27	86,29	390


DenseNet201 modeli ile eğitim için kullanılan eğitim hiperparametreleri ve değerleri Tablo 5.6’ de verilmiştir.

Tablo 5.6. DenseNet201 modeline ait hiperparametre değerleri

Eğitim Adımı Sayısı (Epoch)	Katman Sayısı (Layer Size)	Öğrenme Katsayısı (Learning Rate)	Mini-Batch Boyutu (Mini-Batch Size)
78	201	0.001	32


5.2.3. EfficientNet modelinin performans deęerlendirmesi

Veri setinin EfficientNet modeli ile eęitim ařamasında elde ettięi yakınsama grafięi řekil 5.9’da verilmiřtir. Öğrenme iřleminin 1. devirden 5. devire kadar yüksek hızla geręekleřtięi görölmekle beraber % 95 seviyesine yakınsadıęı görölmektedir. 5. devirden sonra % 95 ile % 98 aralıęında devam etmiř ve en yüksek oran olarak % 98,31’e yakınsadıęı gözlemlenmiřtir. Eęitim test süresi her devir için ortalama olarak 5 dakika sürmüřtür ve toplam test süresi (devir sayısı x 5 dk.) olarak hesaplanmıřtır. EfficientNet modeli 123 devirden oluřmaktadır ve modelin ortalama 615 dakika ile eęitim testini tamamladıęı görölmüřtür.




řekil 5.9. EfficientNet modeline ait eęitim ařamasındaki yakınsama grafięi

EfficientNet modeli ile test verisi üzerinde elde edilen karıřıklık matrisi řekil 5.10’da verilmiřtir. Karıřıklık matrisine bakıldıęında 221 Covid-19 pozitif hastanın tamamı doęru sınıflandırılmıřtır ve hatalı sınıflandırma bulunmamaktadır. 237 saęlıklı örneęin 229’u doęru sınıflandırılmıř 8’i Covid-19 pozitif olarak hatalı sınıflandırılmıřtır. Modelin doęruluk tablosuna baktıęımızda % 98,31’lik doęruluk oranı elde ettięi görölmüřtür.




Şekil 5.10. EfficientNet modelinin test verisi üzerinde elde ettiği karışıklık matrisi

EfficientNet modeli ile deneysel çalışmalar neticesinde elde edilen Roc eğrisi Şekil 5.11’de verilmiştir.



Şekil 5.11. EfficientNet modeline ait Roc Eğrisi

EfficientNet modeli ile eğitim aşamasında elde edilen AUC şeması Şekil 5.12’de verilmiştir.



Şekil 5.12. EfficientNet modeline ait AUC Şeması

EfficientNet modeli ile eğitim aşamasında elde edilen performans metrikleri Tablo 5.7’de verilmiştir.

Tablo 5.7. EfficientNet modeli ile yapılan deneysel çalışmalar sonrası elde edilen performans metrikleri

Doğruluk (%) (Accuracy)	Kesinlik (%) (Precision)	Duyarlılık (%) (Recall)	F1-Skor (%)	Eğitim Süresi (dk.) (Training Time)
98,31	100	97	98	615


EfficientNet modeli ile eğitim için kullanılan eğitim hiperparametreleri ve değerleri tablo 5.8’ de verilmiştir.

Tablo 5.8. EfficientNet modeline ait hiperparametre değerleri

Eğitim Adımı Sayısı (Epoch)	Katman Sayısı (Layer Size)	Öğrenme Katsayısı (Learning Rate)	Mini-Batch Boyutu (Mini-Batch Size)
123	-	0.001	32


5.2.4. GoogleNet modelinin performans deęerlendirmesi

Veri setinin GoogleNet modeli ile eęitim ařamasında elde ettięi yakınsama grafięi řekil 5.13’de verilmiřtir. Modelin doęruluk yakınsaması 1. ve 3. devir aralıęında % 80’lerde iken, 3. devir ile 7. devir aralıęında yukselerek % 90 civarında geręekleřmiřtir. 8. devirde kayıp oranı artmıř olsa da bu devirden sonra doęruluk seviyesi yukseliřini devam ettirmiř ve son devirle beraber % 95,52 doęruluk oranına yakınsayarak tamamladıęı grlmřtr. Eęitim test sresi her devir iin ortalama olarak 5 dakika srmřtr ve toplam test sresi (devir sayısı x 5 dk.) olarak hesaplanmıřtır. GoogleNet modeli 84 devirden oluřmaktadır ve modelin 420 dakika ile eęitim testini tamamladıęı grlmřtr.




řekil 5.13. GoogleNet modeline ait eęitim ařamasındaki yakınsama grafięi

GoogleNet modeli ile test verisi zerinde elde edilen karıřıklık matrisi řekil 5.14’de verilmiřtir. Karıřıklık matrisine bakıldıęında 159 Covid-19 pozitif hastanın 150’si doęru sınıflandırılmıř 9’u ise hatalı sınıflandırılmıřtır. 151 saęlıklı rneęin 146’sı doęru sınıflandırılmıř 5’i Covid-19 pozitif olarak hatalı sınıflandırılmıřtır. Modelin genel doęruluęuna baktıęımızda % 95,52’lik doęruluk oranı elde ettięi grlmřtr.




Şekil 5.14. GoogleNet modelinin test verisi üzerinde elde ettiği karışıklık matrisi

GoogleNet modeli ile deneysel çalışmalar neticesinde elde edilen Roc eğrisi Şekil 5.15’de verilmiştir.



Şekil 5.15. GoogleNet modeline ait Roc Eğrisi

GoogleNet modeli ile eğitim aşamasında elde edilen AUC şeması Şekil 5.16’da verilmiştir.



Şekil 5.16. GoogleNet modeline ait AUC Şeması

GoogleNet modeli ile eğitim aşamasında elde edilen performans metrikleri Tablo 5.9’da verilmiştir.

Tablo 5.9. GoogleNet modeli ile yapılan deneysel çalışmalar sonrası elde edilen performans metrikleri

Doğruluk (%) (Accuracy)	Kesinlik (%) (Precision)	Duyarlılık (%) (Recall)	F1-Skor (%)	Eğitim Süresi (dk.) (Training Time)
95,52	94,34	96,77	95,54	420


GoogleNet modeli ile eğitim için kullanılan eğitim hiperparametreleri ve değerleri tablo 5.10’ de verilmiştir.

Tablo 5.10. GoogleNet modeline ait hiperparametre değerleri

Eğitim Adımı Sayısı (Epoch)	Katman Sayısı (Layer Size)	Öğrenme Katsayısı (Learning Rate)	Mini-Batch Boyutu (Mini-Batch Size)
84	22	0.001	32


5.2.5. Resnet-50 modelinin performans deęerlendirmesi

Veri setinin Resnet-50 modeli ile eęitim ařamasında elde ettięi yakınsama grafięi řekil 5.17’de verilmiřtir. Yakınsama grafięi incelendięinde 1. devir ile 7. devir aralıęında % 90 seviyelerine kadar yukselerek oęrenme devam etmiř ve 8. devirden itibaren oęrenme iřlemi duiřuk seviyelerde artarak ilerlemiřtir. Son devirle beraber oęrenme oranının % 94,02 seviyelerine yakınsadıęı gürulmektedir. Eęitim test süresi her devir için ortalama olarak 5 dakika sürmüřtür ve toplam test süresi (devir sayısı x 5 dk.) olarak hesaplanmıřtır. Resnet-50 modeli 84 devirden oluřmaktadır ve modelin 420 dakika ile eęitim testini tamamladıęı gürulmüřtür.




řekil 5.17. Resnet-50 modeline ait eęitim ařamasındaki yakınsama grafięi

Resnet-50 modeli ile test verisi üzerinde elde edilen karıřıklık matrisi řekil 5.18’de verilmiřtir. Karıřıklık matrisine bakıldıęında 171 Covid-19 pozitif hastanın 153’ü doęru sınıflandırılmıř 18’i ise hatalı sınıflandırılmıřtır. 139 saęlıklı örneęin 137’si doęru sınıflandırılmıř 2’si Covid-19 pozitif olarak hatalı sınıflandırılmıřtır. Modelin genel doęruluęuna baktıęımızda % 94,02’lik doęruluk oranı elde ettięi gürulmüřtür.




Şekil 5.18. Resnet-50 modelinin test verisi üzerinde elde ettiği karışıklık matrisi

Resnet-50 modeli ile deneysel çalışmalar neticesinde elde edilen Roc eğrisi Şekil 5.19’da verilmiştir.



Şekil 5.19. Resnet-50 modeline ait Roc Eğrisi

Resnet-50 modeli ile eğitim aşamasında elde edilen AUC şeması Şekil 5.20’de verilmiştir.



Şekil 5.20. Resnet-50 modeline ait AUC Şeması

Resnet-50 modeli ile eğitim aşamasında elde edilen performans metrikleri Tablo 5.11’de verilmiştir.

Tablo 5.11. Resnet-50 modeli ile yapılan deneysel çalışmalar sonrası elde edilen performans metrikleri

Doğruluk (%) (Accuracy)	Kesinlik (%) (Precision)	Duyarlılık (%) (Recall)	F1-Skor (%)	Eğitim Süresi (dk.) (Training Time)
94,02	89,47	98,71	93,87	420


Resnet-50 modeli ile eğitim için kullanılan eğitim hiperparametreleri ve değerleri tablo 5.12’ de verilmiştir.

Tablo 5.12. Resnet-50 modeline ait hiperparametre değerleri

Eğitim Adımı Sayısı (Epoch)	Katman Sayısı (Layer Size)	Öğrenme Katsayısı (Learning Rate)	Mini-Batch Boyutu (Mini-Batch Size)
84	50	0.001	32


5.2.6. VGG-16 modelinin performans deęerlendirmesi

Veri setinin VGG-16 modeli ile eęitim ařamasında elde ettięi yakınsama grafięi řekil 5.21’de verilmiřtir. Modele ait yakınsama grafięine bakıldıęında bařlangıçta % 30 civarında olan hata oranı 4. devir sonunda % 5 oranına gerilemiřtir. 5. devir ile beraber öğrenme oranının artarak % 92,53 doęruluk seviyelerine yakınsadıęı ve hata oranının giderek azaldıęı gözlemlenmiřtir. Eęitim test süresi her devir için ortalama olarak 5 dakika sürmüřtür ve toplam test süresi (devir sayısı x 5 dk.) olarak hesaplanmıřtır. VGG-16 modeli 90 devirden oluřmaktadır ve modelin 450 dakika ile eęitim testini tamamladıęı görölmüřtür




řekil 5.21. VGG-16 modeline ait eęitim ařamasındaki yakınsama grafięi

VGG-16 modeli ile test verisi üzerinde elde edilen karıřıklık matrisi řekil 5.22’de verilmiřtir. Karıřıklık matrisi incelendięinde 152 Covid-19 pozitif hastanın 145’i doęru sınıflandırılmıř 7’si ise hatalı sınıflandırılmıřtır. 174 saęlıklı örneęin 156’sı doęru sınıflandırılmıř 18’i Covid-19 pozitif olarak hatalı sınıflandırılmıřtır. Modelin genel doęruluęuna baktıęımızda % 92,53’lük doęruluk oranı elde ettięi görölmüřtür.




Şekil 5.22. VGG-16 modelinin test verisi üzerinde elde ettiği karışıklık matrisi

VGG-16 modeli ile deneysel çalışmalar neticesinde elde edilen Roc eğrisi Şekil 5.23’de verilmiştir.



Şekil 5.23. VGG-16 modeline ait Roc Eğrisi

VGG-16 modeli ile eğitim aşamasında elde edilen AUC şeması Şekil 5.24’de verilmiştir.



Şekil 5.24. VGG-16 modeline ait AUC Şeması

VGG-16 modeli ile eğitim aşamasında elde edilen performans metrikleri Tablo 5.13’de verilmiştir.

Tablo 5.13. VGG-16 modeli ile yapılan deneysel çalışmalar sonrası elde edilen performans metriklerinin sonuçları

Doğruluk (%) (Accuracy)	Kesinlik (%) (Precision)	Duyarlılık (%) (Recall)	F1-Skor (%)	Eğitim Süresi (dk.) (Training Time)
92,53	95,39	88,96	92,06	450


VGG-16 modeli ile eğitim için kullanılan eğitim hiperparametreleri ve değerleri tablo 5.14’ de verilmiştir.

Tablo 5.14. VGG-16 modeline ait hiperparametre değerleri

Eğitim Adımı Sayısı (Epoch)	Katman Sayısı (Layer Size)	Öğrenme Katsayısı (Learning Rate)	Mini-Batch Boyutu (Mini-Batch Size)
90	16	0.001	32


5.2.7. Önerilen ağ modelinin performans değerlendirilmesi

Veri setinin önerilen model ile eğitim aşamasında elde ettiği yakınsama grafiği Şekil 5.25’de verilmiştir. Önerilen model yakınsama grafiği incelendiğinde 17. devire kadar olan süreçte aşamalı olarak % 95 seviyelerine kadar yükselen bir grafik görülmektedir. 18. devir ve sonrasında 32. devire kadar düşük de olsa bir yükselme mevcuttur. 32. devir ve 35. devir aralığında hata oranı artsa da 36. seviye sonrası doğruluk oranı % 99,20 seviyelerine yakınsayarak tamamlandığı görülmektedir. Eğitim test süresi her devir için ortalama olarak 5 dakika sürmüştür ve toplam test süresi (devir sayısı x 5 dk.) olarak hesaplanmıştır. VGG-16 modeli 147 devirden oluşmaktadır ve modelin 735 dakika ile eğitim testini tamamladığı görülmüştür.




Şekil 5.25. Önerilen modele ait eğitim aşamasındaki yakınsama grafiği

Önerilen model ile test verisi üzerinde elde edilen karışıklık matrisi Şekil 5.26’da verilmiştir. Karışıklık matrisine bakıldığında 375 Covid-19 pozitif hastanın 372’si doğru sınıflandırılmış 3’ü ise hatalı sınıflandırılmıştır. 375 sağlıklı örneğin 372’si doğru sınıflandırılmış 3’ü Covid-19 pozitif olarak hatalı sınıflandırılmıştır. Modelin genel doğruluğuna baktığımızda % 99,20’lik doğruluk oranı elde ettiği görülmüştür.




Şekil 5.26. Önerilen modelinin test verisi üzerinde elde ettiği karışıklık matrisi

Önerilen model ile deneysel çalışmalar neticesinde elde edilen Roc eğrisi Şekil 5.27’de verilmiştir.



Şekil 5.27. Önerilen modele ait Roc Eğrisi

Önerilen model ile eğitim aşamasında elde edilen AUC şeması Şekil 5.28’de verilmiştir.



Şekil 5.28. Önerilen modele ait AUC Şeması

Önerilen model ile eğitim aşamasında elde edilen performans metrikleri Tablo 5.15’da verilmiştir.

Tablo 5.15. Önerilen model ile yapılan deneysel çalışmalar sonrası elde edilen performans metrikleri

Doğruluk (%) (Accuracy)	Kesinlik (%) (Precision)	Duyarlılık (%) (Recall)	F1-Skor (%)	Eğitim Süresi (dk.) (Training Time)
99,20	99,20	99,20	99,20	735


Önerilen model ile eğitim için kullanılan eğitim hiperparametreleri ve değerleri tablo 5.16’ de verilmiştir.

Tablo 5.16. Önerilen modele ait hiperparametre değerleri

Eğitim Adımı Sayısı (Epoch)	Katman Sayısı (Layer Size)	Öğrenme Katsayısı (Learning Rate)	Mini-Batch Boyutu (Mini-Batch Size)
147	50	0.001	32

6. SONUÇ VE ÖNERİLER


COVID-19 hastalığı küresel bir sorun haline gelmiş ve ciddi sorunlara sebebiyet vermiştir. Hastalığın teşhisi, hastaların izolasyonu, doğru tedavinin uygulanması ve bunların sonucunda pandeminin etkisini en aza indirmek tüm sağlık çalışanlarının ve sorumluluk hisseden herkesin ortak amacı olmuştur. Bu doğrultuda COVID-19 ile alakalı bilişim alanında da görüntü sınıflandırma çalışmaları yapılmış ve hastalık tahmini yapabilen deneysel çalışmalar gerçekleştirilmiştir. Bu tez çalışması da hastalık tespiti yapmak ve hekimlere yardımcı olmak amacıyla gerçekleştirilmiştir. Sağlıklı insanlar ve COVID-19 teşhisi konulmuş insanlara ait akciğer BT görüntüleri üzerinden 7 farklı ESA modeli ile deneysel çalışmalar yapılmıştır. Deneysel çalışmalarda kullanılan veri seti 5.000 adet görüntüden oluşmaktadır. Çalışma yapılan modellere ait performans metriklerinin karşılaştırılması Şekil 6.1’de verilmiştir. % 99,20 doğruluk, % 99,20 kesinlik, % 99,20 duyarlılık, % 99,20 F1-skor gibi parametreler incelendiğinde önerilen modelin diğer modellere göre en yüksek başarı oranını elde ettiği görülmektedir.



Şekil 6.1. Modellere ait deneysel sonuçların karşılaştırılması

Şekil 6.1’de verilen performans metriklerine ve doğruluk oranlarına bakıldığında EfficientNet modeli % 98,31, GoogleNet modeli % 95,52, ResNet-50 modeli % 94,02, Vgg-16 modeli % 92,53, AlexNet modeli % 88,81, Densenet201 modeli % 86,16 olarak hesaplanmıştır. Önerilen modelin doğruluk oranı % 99,20 olarak hesaplanmış ve deneysel çalışma yapılan modeller arasında en yüksek oran bu modelle elde edilmiştir.


Eğitim sürelerinin karşılaştırmasına bakacak olursak her modelin eğitim süresinin devir sayısı ile orantılı olarak arttığı görülmektedir. Önerilen model eğitimini 147 devir ile 735 dakikada, EfficientNet modeli 123 devir ile 615 dakikada, GoogleNet modeli 84 devir ile 420 dakikada, Resnet-50 modeli 84 devir ile 420 dakikada, VGG-16 modeli 90 devir ile 450 dakikada, Alexnet modeli 90 devir ile 450 dakikada, DenseNet201 modeli 78 devir ile 390 dakikada tamamlamıştır. Elde edilen bu değerler göz önünde bulundurulduğunda önerilen ağ modelinin COVID-19 tespitinde faydalı olacağını düşünmekteyiz. Ağ modellerin eğitim test süreleri ve devir sayıları şekil 6.2’de verilmiştir.



Şekil 6.2. Modellere ait eğitim test süreleri ve devir sayılarının karşılaştırılması

Roc eğrisi değişen sınıflandırma eşik noktalarına bakılarak doğru pozitiflerin sayısının, yanlış pozitiflerin bir fonksiyonu olarak çizilmesiyle oluşturulmaktadır. Klinik tanı koyma işlemlerinde sıklıkla kullanılan roc eğrisi işlemi COVID-19 tespiti yapmak amacıyla gerçekleştirilen deneysel çalışmaların her biri için oluşturulmuştur. Roc puanı 1 tepe noktasına eriştiğinde pozitifler, negatiflerden mükemmel şekilde ayrıştırılarak tahmin edilmiş demektir. Roc eğrisinin koordinat sisteminde oluşturacağı eğri Y ekseninde tanı testinin gerçek pozitif değeri (duyarlılık), X ekseninde ise yanlış pozitif değeri (1-özgüllük) yer almaktadır. Her devir noktasında doğru pozitif ile yanlış pozitiflerin kesiştiği noktalar birleştirilerek Roc eğrisi oluşturulur (Obuchowski, 2003).

Performanslarına göre Roc eğrileri Mükemmel bir sınıflandırıcı, tipik bir sınıflandırıcı ve rasgele tahmin yapan bir sınıflandırıcı ayrımıyla Şekil 6.3’de görülmektedir.




Mükemmel sınıflandırıcı


Tipik bir sınıflandırıcı

Rasgele sınıflandırıcı

Şekil 6.3. Sınıflandırma seviyelerine göre oluşan grafikler (mathworks.com, 2023)


Şekil 6.4’de deneysel çalışma yapılan modellere ait roc eğrileri yer almaktadır. Performans değerlerine bakıldığında en iyi ayrımı yapan modelin önerilen model olduğu görülmektedir. Yapılan çalışmada model performansları yüksekten düşüğe Önerilen Model, EfficientNet, GoogleNet, ResNet-50, Vgg-16, AlexNet, Densenet20 şeklinde sıralanmaktadır.





Şekil 6.4. Deneysel çalışma yapılan modellere ait roc eğrileri

Veri setinin eğitildiği modellere ait AUC şemalarının grafiksel gösterimi şekil 6.5’ te verilmiştir.



Şekil 6.5. Modellere ait AUC şemalarının grafiksel gösterimi

Bu tez kapsamında yapılan çalışmalar neticesinde görüntü sınıflandırma amacıyla ESA modelleri tasarlanabileceği anlaşılmıştır. Eğitilen veri seti ilk kez bir çalışmada kullanılmış olup, pnömoni sınıfı eklenip daha da geliştirilerek, bu doğrultuda pnömoni, Covid-19 pozitif, Covid-19 negatif sınıfları üzerinde çalışmalar yapılması hedeflenmektedir.

7. ETİK KURUL KARARI



8. KAYNAKLAR

- Anonim. (2023). <https://bembeyazdis.com/dis-hekimliginde-tomografi-kullanimi>; (11.12.2023).
- Aydoğan, M., & Şener, A. (2020). Covid-19 Dokümanları Üzerinde Geliştirilen Sağlıkta Bir Yapay Zekâ Uygulaması. *Journal of Health, Medicine and Nursing*, (75), 58-66.
- Bozkurt, F. (2021). Derin Öğrenme Tekniklerini Kullanarak Akciğer X-Ray Görüntülerinden COVID-19 Tespiti. *Avrupa Bilim ve Teknoloji Dergisi* (24), 149-156.
- Bütünler, B., & Calp, H. (2020). Derin Öğrenme ve Makine Öğrenmesi Yöntemleri Kullanılarak Akciğer Tomografi Görüntülerinden COVID-19 Tespiti. Technical report, EasyChair.
- Büyükarıkan, B., & Ülker, E. (2020). Aydınlatma Özniteliği Kullanılarak Evrişimsel Sinir Ağı Modelleri ile Meyve Sınıflandırma. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 25(1), 81-100.
- Ceylan, T., & İnik, Ö. (2022). COVID-19 Detection on Radiological Images with Deep Learning. 3rd International Conference on Applied Engineering and Natural Sciences, 1807-1811.
- Converter, D. (2023). <https://www.dicomapps.com/dicom-converter/index.html>; (11.09.2023).
- covid19.who. (2023). <https://covid19.who.int/>; (10.01.2024).
- Çalışkan, A. (2023). Dalgacık Evrişimsel Sinir Ağı Yöntemi ile Koronavirüs Hastalığının Tespiti. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 26(1), 203-212.
- Dayan, S. (2021). COVID-19 ve Aşı. *Dicle Tıp Dergisi*, (48), 98-113.
- Doğan, D. (2020). <https://doktorfizik.com/sinir-sistemi/norobilim/noron-ve-glia-hucreleri/>; (09.04.2023).
- Doğan, Y. (2023). Derin Öğrenme Yöntemleriyle Çapraz Veri Seti Değerlendirmesi Altında COVID-19 Tespiti. *Gazi Üniversitesi Gazi University Fen Bilimleri Dergisi*, 11(3), 813-822.
- Döven, S. (2023). Big Data And Applications. <https://www.researchgate.net/publication/367273034>; (03.01.2024).
- Durmaz Akyol, A. (2005). Şiddetli Akut Solunum Yetmezliği Sendromu (Sars) Ve Korunma Önlemleri. *Ege Üniversitesi Hemşirelik Yüksek Okulu Dergisi*, 21(2), 107-123.
- Erdoğan, T. (2023). <https://www.tibeterdogru.com/bobrek-tasi-tedavisi-oncesinde-en-iyi-degerlendirme-damarda-ilacsiz-bilgisayarli-tomografidir-uriner-sistem-bt/>; (11.12.2023).
- Euronews. (2023a). <https://tr.euronews.com/2023/09/15/bakan-koca-dokuz-kiside-eris-varyanti-goruldu>; (15.09.2023).
- Euronews. (2023b). <https://tr.euronews.com>. <https://tr.euronews.com/next/2023/08/18/covid-19un-yeni-varyanti-eg5-eris-nedir-ve-dunyada-ne-kadar-hizla-yayiliyor>; (15.09.2023).

- Ferdi, D., & Türkoğlu, İ. (2018a). Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması Sakarya University Journal of Computer and Information Sciences, (1), 1-21.
- Ferdi, D., & Türkoğlu, İ. (2018b). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. DÜMF Mühendislik Dergisi, 409-445.
- Gopatoti, A., & Vijayalakshmi, P. (2022). CXGNet: A tri-phase chest X-ray image classification for COVID-19 diagnosis using deep CNN with enhanced grey-wolf optimizer. Biomed Signal Process Control, (77).
- Gümüş, H., Kuday, S., Hamidi, C., Özdemir, M. S., Önder, H., Tekbaş, G., & Bilici, A. (2012). Abdomen çok kesitli bilgisayarlı tomografi ile saptanan kolonun anatomik varyasyonları. Dicle Tıp Dergisi 39(2), 234-237.
- Gündüz, G., & Cedimoğlu, İ. H. (2019). Derin Öğrenme Algoritmalarını Kullanarak Görüntüden Cinsiyet. Sakarya Üniversitesi Dergisi, (2), 1-17.
- He, K., Zhang, X., Ren, S., & J., S. (2016). DeepResidualLearningforImageRecognition. Proceedings of the IEEE conference on computer vision and pattern recognition, 770-778.
- Hekimoğlu Görüntüleme. (2023). <https://www.hekimoglugoruntuleme.com/beyin-tomografisi/>. <https://www.hekimoglugoruntuleme.com/beyin-tomografisi/>; (12.11.2023).
- Hemdan, E. E., Shouman, M. A., & Karar, M. E. (2020). COVIDX-Net: A Framework of Deep Learning Classifiers to Diagnose COVID-19 in X-Ray Images. Electrical Engineering and Systems Science, ArXiv, abs/2003.11055.
- hypatiabilim. (2023). hypatiabilim. <https://www.hypatiabilim.org/tibbin-akisini-degistiren-bilgisayarli-tomografi-nasil-calisir/>; (26.12.2023).
- İnik, Ö., & Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri Gaziosmanpaşa Bilimsel Araştırma Dergisi 85-104.
- JavadiMoghaddam, S., & Gholamalinejad, H. (2021). A novel deep learning based method for COVID-19 detection from CT image. www.sciencedirect.com.
- Kaya, B., & Önal, M. (2021). COVID-19 Tespiti için Akciğer BT Görüntülerinin Bölütlenmesi. Avrupa Bilim ve Teknoloji Dergisi 1296-1303.
- Khan, S. H., Iqbal, J., Hassnain, S. A., Owais, M., Mostafa, S. M., Hadjouni, M., & Mahmoud, A. (2023). COVID-19 detection and analysis from lung CT images using novel channel boosted CNNs. [sciencedirect.com](http://www.sciencedirect.com).
- Kızılkaya, Y. M., & Oğuzlar, A. (2018). Bazı Denetimli Öğrenme Algoritmalarının R Programlama Dili İle Kıyaslanması. dergipark.org.tr, 90-98.
- Koç, E., Çalışkan, S., Yazıcıoğlu, S. A., Demirci, U., & Kuş, Z. (2018). Yapay Sinir Ağları, Kelime Vektörleri Ve Derin Öğrenme Uygulamaları.
- Koylan, N. (2023). <https://nevrezkoylan.com>. <https://nevrezkoylan.com/2021/05/kalp-tomografisi/>; (11.12.2023).

- Köroğlu, Y. (2017). Yapay Zeka'nın Teorik ve Pratik Sınırları. Bogaziçi Üniversitesi.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. Advances in neural information processing systems.
- Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-Based learning applied to document recognition. Proceedings of the IEEE. Proceedings of the IEEE, 2278-2324.
- Liu, L., Shen, C., & Hengel, A. (2015). The treasure beneath convolutional layers: Cross-convolutional-layer pooling for image classification. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, USA.
- mathworks.com. (2023). mathworks.com.
https://www.mathworks.com/products/new_products/release2023a.html; (22.11.2023).
- Medium. (2023). Derin Öğrenme ve Evrimsel Sinir Ağları. <https://medium.com/deep-learning-from-deepest/deri-CC%87n-%C3%B6%C4%9Frenme-ve-evri-CC%87%C5%9Fi%CC%87msel-si-CC%87ni-CC%87r-a-%C4%9Flari-446dc8a8d2f>; (08.12.2023).
- Memorial Sağlık Grubu. (2023). www.memorial.com.tr. <https://www.memorial.com.tr/tani-ve-testler/bilgisayarli-tomografi-nedir-neden-ve-nasil-cekilir>; (23.11.2023).
- Murat, A. (2023). www.bezelyedergi.net/. Retrieved; (30.10.2023). from <https://www.bezelyedergi.net/post/biyoinformatik-yapay-zek%C3%A2-ai-makine-%C3%B6%C4%9Frenmesi-ml-derin-%C3%B6%C4%9Frenme-dl>
- Nasip, Ö. F., & Zengin, K. (2018). Derin Öğrenme Tabanlı Bakteri Sınıflandırma. In (pp. 1-5). Ankara, Türkiye: 2018 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT).
- Nemli, S. A., & Demirel, T. (2016). Ortadoğu Solunum Yetmezliği Sendromu Koronavirüsü. Kocatepe Tıp Dergisi, 17(2), 77-83.
- Obuchowski, N. A. (2003). Receiver Operating Characteristic Curves and Their Use in Radiology
- Oğuz, Ç. (2021). Covid-19 Olası Vakalarının Derin Öğrenme Teknikleri Kullanarak Tespiti. In.
- Ökçün, S., Kurnaz, M., Koçkaya, G., Acar, A., Şener, O., & Tecirli, G. (2020). Covid-19 Tanı Yöntemlerine Bakış: Hızlı Sistemik İnceleme. Eurasian Journal of Health Technology Assessment, 4(2), 10-35.
- Ömeroğlu, F. E. (2003). X-Işınlı Bilgisayarlı Tomografide Filtrelenmiş Geri İzdüşüm Algoritmalarının Paralel Ve Yelpaze Demet Açılı Uygulamaları. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- Özbay, E., & Altunbey Özbay, F. (2021). Derin Öğrenme ve Sınıflandırma Yaklaşımları ile BT görüntülerinden Covid-19 Tespiti Dicle Üniversitesi Mühendislik Dergisi, 12(2), 211-219.
- Panahi, A. H., Rafiei, A., & Rezaee, A. (2021). FCOD: Fast COVID-19 Detector based on deep learning techniques. Informatics in Medicine Unlocked, (22).

- Platformu, S. B. C.-B. (2023). Sağlık Bakanlığı Covid-19 Bilgilendirme Platformu. <https://covid19.saglik.gov.tr/Eklenti/43095/0/covid-19rehberieriskinhastayonetimivetedavi-12042022pdf.pdf>; (16.09.2023).
- Platformu, T. n. E. (2023). Türkiye'nin Endüstri Platformu. <https://www.endustri40.com/makine-ogrenimi-nedir/>; (30.10.2023).
- Polat, S. (2017). Yazılım Hata Kayıtlarının Makine Öğrenmesi Yöntemleriyle Kümelenecek, Hataya Sebep Olan Bileşenlerin Tespit Edilmesi. Ankara.
- Renamer, A. (2023). <https://www.advancedrenamer.com/>; (12.11.2023).
- Rosebrock, A. (2023). ImageNet: VGGNet, ResNet, Inception, and Xception with Keras. <https://pyimagesearch.com/2017/03/20/imagenet-vggnet-resnet-inception-xception-keras/>; (07.11.2023).
- Selçuk, E. B. (2020). Dünya ve Türkiye'de Pandemi Yayılım Süreci. İnönü Üniversitesi Tıp Fakültesi Klinik Tıp Aile Hekimliği Dergisi, 12(3), 87-91.
- Silva, L. F. J., Cortes, O. A. C., & Diniz, J. O. B. (2023). A novel ensemble CNN model for COVID-19 classification in computerized tomography scans. Results in Control and Optimization, 11, 1-13.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. Visual Geometry Group, Department of Engineering Science, 1409-1556.
- Singhal, T. (2020). A Review of Coronavirus Disease-2019 (COVID-19). The Indian Journal of Pediatrics, 87(4), 281–286.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & A., R. (2015). Going Deeper with Convolutions. Proceedings of the IEEE conference on computer vision and pattern recognition, 1-9.
- Şeker, A., Diri, B., & Balık, H. H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. Gazi Mühendislik Bilimleri Dergisi, 3(3), 47-64.
- Talan, T., & Aktürk, C. (2021). Bilgisayar bilimlerinde teorik ve uygulamalı araştırmalar. Efe Akademik Yayıncılık.
- Toğaçar, M., Ergen, B., & Özyurt, F. (2020). Evrişimsel Sinir Ağı Modellerinde Özellik Seçim Yöntemlerini Kullanarak Çiçek Görüntülerinin Sınıflandırılması. Fırat Üniversitesi Müh. Bil. Dergisi, 32(1), 47-56.
- Tüfekçi, P., & Gezici, B. (2023). Derin Öğrenme ile Göğüs Röntgeni Görüntülerinden COVID-19 ve Viral Pnömoni Tespiti. Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi, 23(1), 89-100.
- Türkçetin, A. Ö., & Koç, T. (2022). CNN Kullanılarak COVID-19 Hastalarının Akciğer Görüntülerinin Sınıf Aktivasyon Haritalarının (SAH) Çıkarılması ELECO 2022 Elektrik-Elektronik ve Biyomedikal Mühendisliği Konferansı, Bursa.

- Udayaraju, P., Narayana, T. V., Vemparala, S. H., Srinivasarao, C., & Raju, B. V. S. R. (2023). GW- CNNDC: Gradient weighted CNN model for diagnosing COVID-19 using radiography X-ray images. Measurement: Sensors, (27).
- Urut, S., & Özdağ, R. (2022). Tekrarlayan Sinir Ağları Kullanılarak Covid-19 Teşhisi Ve Özellik. International Informatics Congress (IIC2022), Batman, Turkey.
- Yıldız, E. N., Bingöl, H., & M., Y. (2023). Önerilen Derin Öğrenme ve Makine Öğrenmesi Tabanlı Hibrit Model ile Çevresel Atıkların Sınıflandırılması. Fırat Üniversitesi Müh. Bil. Dergisi, 35(1), 353-361.
- Yılmaz, A. (2021). Yapay Zeka (Kodlab Yayın Dağıtım Yazılım Ltd.şti. ed.). Kodlab. ; (01.08.2023).
- Yüksel, V. (2023). Veri Tabanı Eğitimleri <https://www.veritabaniegitimleri.com/2023/07/20/big-data-nedir-nereden-baslamali/>; (31.10.2023).
- Zeiler, M., & Fergus, R. (2013). Visualizing and Understanding Convolutional Networks. In Computer Vision–ECCV 2014: 13th European Conference, Zurich, Switzerland.