

ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**AKCİĞER RÖNTGEN GÖRÜNTÜLERİNDEN DERİN ÖĞRENME MODELLERİ
KULLANILARAK SOLUNUM YOLU HASTALIKLARININ TEŞHİS EDİLMESİ**

BIYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

ANIL SEVER

OCAK 2025

ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**AKCİĞER RÖNTGEN GÖRÜNTÜLERİNDEN DERİN ÖĞRENME MODELLERİ
KULLANILARAK SOLUNUM YOLU HASTALIKLARININ TEŞHİS EDİLMESİ**

BIYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

Anıl SEVER

DANIŞMAN: Dr. Öğr. Üyesi Ceren KAYA

ZONGULDAK

Ocak 2025

KABUL:

Anıl SEVER tarafından hazırlanan “Akciğer Röntgen Görüntülerinden Derin Öğrenme Modelleri Kullanılarak Solunum Yolu Hastalıklarının Teşhis Edilmesi” başlıklı bu çalışma jürimiz tarafından değerlendirilerek Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Anabilim Dalında Yüksek Lisans Tezi olarak oybirliğiyle kabul edilmiştir. 24/01/2025

Danışman: Dr. Öğr. Üyesi Ceren KAYA

.....

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü

Üye: Prof. Dr. Ayşegül ALAYBEYOĞLU

.....

İzmir Kâtip Çelebi Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü

Üye: Dr. Öğr. Üyesi Tuğba PALABAŞ

.....

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü

ONAY:

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım.

....../....../20....

Prof. Dr. Fikret GÖLGELEYEN
Fen Bilimleri Enstitüsü Müdürü



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

Anıl SEVER

ÖZET

Yüksek Lisans Tezi

AKCİĞER RÖNTGEN GÖRÜNTÜLERİNDEN DERİN ÖĞRENME MODELLERİ KULLANILARAK SOLUNUM YOLU HASTALIKLARININ TEŞHİSİ

Anıl SEVER

Zonguldak Bülent Ecevit Üniversitesi

Fen Bilimleri Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Ceren KAYA

Ocak 2025, 123 sayfa

Solunum yolu hastalıkları geçmişten günümüze dünya çapında her yıl milyonlarca insanı etkileyen önemli sağlık sorunlarından. Bu hastalıkların doğru ve hızlı teşhis edilmesi, hastaların tedaviye başlama aşamasında kritik rol oynamaktadır. Geleneksel yöntemlerde radyologların subjektif yorumlarına bağlı olarak ortaya çıkabilecek hataları ve uzun teşhis süreleri hastaların tedavi süreçlerini olumsuz etkilemektedir. Özellikle pandemi dönemlerinde sağlık sistemleri üzerindeki yükü azaltmak için hızlı ve doğru teşhis kritik önem taşımaktadır. Bu çalışma, hızla gelişen derin öğrenme teknolojilerini kullanarak akciğer röntgen görüntülerinden solunum yolu hastalıklarının otomatik olarak teşhis edilmesi amacıyla gerçekleştirilmiştir. Çalışmada, EfficientNetB1 mimarisi temel alınarak, COVID-19 Radiography Database veri seti üzerinde eğitilmiş bir derin öğrenme modeli geliştirilmiştir. Verinin ön işleme aşamalarında, görüntülerin boyutlandırılması, veri artırma teknikleri ve etiketleme işlemleri gerçekleştirilmiştir. EfficientNetB1 modeli, ImageNet veri kümesinden önceden eğitilmiş ağırlıkları öğrenme aktarımı yöntemiyle öğrenmiştir. Modelin son katmanı sistemden çıkarılıp sınıflandırma katmanı eklenmiş ve model yeni veri setine uyarlanmıştır. Modelin eğitim aşamasında Adamax optimizasyon algoritması ve “categorical_crossentropy”

ÖZET (devam ediyor)

kayıp fonksiyonu ile modelin performansını değerlendirmek için doğruluk metriği kullanılmıştır. Geliştirilen model, 23726 saniyelik eğitim süresiyle normal (sağlıklı), zatürre (pnömoni), COVID-19 ve akciğer opaklığı gibi dört farklı solunum yolu hastalığını %98,56 gibi yüksek bir doğruluk oranıyla sınıflandırmıştır. Model, özellikle diğer çoklu sınıflandırma modellerine göre yüksek doğruluk oranı yakalarken bunu hızlı bir eğitim süresiyle yakalamış olması geliştirilen modelin diğer modellere göre daha verimli olduğunu göstermiştir. Bu sonuçlar, modelin tıbbi görüntüleme alanında otomatik tanı sistemleri için güçlü bir aday olduğunu göstermektedir. Çalışma, solunum yolu hastalıklarının erken teşhisinde derin öğrenmenin potansiyelini ortaya koyarak sağlık hizmetlerinin kalitesini artırmaya yönelik önemli bir adım olarak değerlendirilebilir.

Anahtar Kelimeler: Derin Öğrenme, Göğüs Röntgeni, Hastalık Teşhisi, Evrimsel Sinir Ağları, EfficientNet, Sınıflandırma, Makine Öğrenmesi.

ABSTRACT

M. Sc. Thesis

DIAGNOSIS OF RESPIRATORY DISEASES FROM CHEST X-RAY IMAGES USING DEEP LEARNING MODELS

Anıl SEVER

**Zonguldak Bülent Ecevit University
Graduate School of Natural and Applied Sciences
Department of Biomedical Engineering**

Thesis Advisor: Assist. Prof. Dr. Ceren KAYA

January 2025, 123 pages

Respiratory diseases are important health problems that affect millions of people worldwide every year from past to present. Accurate and rapid diagnosis of these diseases plays a critical role in the initiation of treatment. In traditional methods, errors that may arise due to subjective interpretations of radiologists and long diagnostic times negatively affect the treatment processes of patients. Fast and accurate diagnosis is of critical importance to reduce the burden on healthcare systems, especially during pandemic periods. This study was carried out to automatically diagnose respiratory diseases from lung X-ray images using rapidly developing deep learning technologies. In the study, a deep learning model trained on the COVID-19 Radiography Database dataset was developed based on the EfficientNetB1 architecture. In the pre-processing stages of the data, image dimensioning, data augmentation techniques and labeling operations were performed. The EfficientNetB1 model learned the pre-trained weights from the ImageNet dataset by learning transfer. The last layer of the model was removed from the system, the classification layer was added and the model was adapted to the new dataset. In the training phase of the model, the Adamax optimization algorithm and the loss function ‘categorical_crossentropy’ and the accuracy metric were used to evaluate the performance of the

ABSTRACT (continued)

model. The developed model classified four different respiratory diseases such as normal (healthy), pneumonia, COVID-19 and lung opacity with a high accuracy rate of 98.56% with a training time of 23726 seconds. While the model achieved a high accuracy rate, especially compared to other multiple classification models, the fact that it achieved this with a fast training time showed that the developed model is more efficient than other models. These results show that the model is a strong candidate for automatic diagnosis systems in the field of medical imaging. The study can be considered as an important step towards improving the quality of healthcare services by revealing the potential of deep learning in early diagnosis of respiratory diseases.

Keywords: Deep Learning, Chest X-ray, Disease Diagnosis, Convolutional Neural Networks, EfficientNet, Classification, Machine Learning.

TEŞEKKÜR

Yüksek lisans tez çalışmamın her aşamasında sabır ve hoşgörü ile bilgisini ve tecrübesini paylaşan değerli hocam sayın Dr. Öğr. Üyesi Ceren KAYA'ya teşekkürlerimi sunarım.

Tez jüri üyeleri Prof. Dr. Ayşegül ALAYBEYOĞLU'na ve Dr. Öğr. Üyesi Tuğba PALABAŞ'a yapıcı tartışma ve yorumlarından dolayı teşekkürlerimi sunarım.

Hayatım boyunca her konuda desteklerini hissettiğim aileme sonsuz teşekkürlerimi sunarım.



İÇİNDEKİLER

	<u>Sayfa</u>
KABUL:	ii
ÖZET	iii
ABSTRACT	v
TEŞEKKÜR	vii
İÇİNDEKİLER.....	ix
ŞEKİLLER DİZİNİ.....	xv
ÇİZELGELER DİZİNİ	xix
SİMGELER VE KISALTMALAR DİZİNİ.....	xxi
 BÖLÜM 1 GİRİŞ.....	 1
1.1 ÇALIŞMANIN AMACI	2
1.2 LİTERATÜR ARAŞTIRMASI	3
 BÖLÜM 2 GENEL BİLGİLER	 13
2.1 SOLUNUM YOLU SİSTEMİ	13
2.2 SOLUNUM YOLU HASTALIKLARI	15
2.2.1 COVID-19.....	15
2.2.2 Zatürre (Pnömoni).....	17
2.2.3 Akciğer Opasitesi.....	18
2.3 TEŞHİS YÖNTEMLERİ.....	19
2.3.1 Fiziksel Muayene	19
2.3.2 Solunum Fonksiyon Testleri	20
2.3.2.1 Spirometri	20
2.3.2.2 Difüzyon Kapasitesi Testi	20
2.3.2.3 Egzersiz Testi	21

İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
2.3.3 Laboratuvar Testleri	21
2.3.3.1 Balgam Kültürü	21
2.3.3.2 Tam Kan Sayımı (Hemogram)	22
2.3.3.3 İmmünolojik Testler	22
2.3.3.4 Allerji (Prick) Testi	22
2.3.3.5 Torasentez	23
2.3.3.6 Plevra Biyopsisi	23
2.3.4 Görüntüleme Yöntemleri	23
2.3.4.1 Röntgen (X-Ray)	24
2.3.4.2 Bilgisayarlı Tomografi (BT)	24
2.3.4.3 Manyetik Rezonans Görüntüleme (MRG)	25
2.3.4.4 Pozitron Emisyon Tomografi (PET)	26
2.3.4.5 Ultrasonografi (USG)	27
2.3.4.6 Bronkoskopi	28
2.4 GÖĞÜS RÖNTGENİ	28
2.4.1 X Işını.....	29
2.4.2 Dijital Radyografi	31
2.4.3 Göğüs Röntgen Görüntüsünün Yorumlanması	32
2.4.4 Göğüs Röntgen Görüntüsünde Radyografik İşaretler ve Bulgular	33
 BÖLÜM 3 YAPAY ZEKA VE DERİN ÖĞRENME.....	 35
3.1 YAPAY ZEKA	35
3.2 MAKİNE ÖĞRENMESİ	35
3.2.1 Denetimsiz Öğrenme	36
3.2.1.1 K-Ortalamlar (K-Means)	37
3.2.1.2 Apriori	37
3.2.2 Denetimli Öğrenme.....	38
3.2.2.1 K-En Yakın Komşu (KNN)	38
3.2.2.2 Destek Vektör Makinesi (DVM)	40
3.2.2.3 Rastgele Orman (RO)	41

İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
3.2.2.4 Navie Bayes	42
3.2.2.5 Bagging	42
3.2.2.6 Lojistik Regresyon.....	43
3.2.2.7 Yapay Sinir Ağları (YSA)	43
3.2.3 Pekiştirmeli Öğrenme	45
3.3 DERİN ÖĞRENME	45
3.3.1 Derin Öğrenme Terminolojisi.....	46
3.3.2 Optimizasyon Metotları	50
3.3.2.1 Stokastik Gradyan İnişi (SGD)	50
3.3.2.2 Uyarlanabilir Gradyan Optimize Edici (AdaGrad)	51
3.3.2.3 Ortalama Karekök Yayılımı (RMSProp)	51
3.3.2.4 Uyarlanabilir Moment Tahmin Optimizasyonu (Adam)	51
3.3.2.5 Maksimum İle Uyarlanabilir Moment Tahmini (Adamax)	53
3.3.3 Aktivasyon Fonksiyonları	54
3.3.3.1 Rectified Aktivasyon Fonksiyonu (ReLU)	54
3.3.3.2 Leaky ReLU Fonksiyonu	55
3.3.3.3 Sigmoid Fonksiyonu	56
3.3.3.4 Swish Fonksiyonu	57
3.3.3.5 Softmax Fonksiyonu	57
3.3.4 Öğrenme Aktarımı (Transfer Learning)	58
3.3.5 L1 ve L2 Düzenlileştirme	59
3.3.6 Evrişimsel Sinir Ağları (ESA) ve Katmanları	59
3.3.6.1 Giriş Katmanı (Input Layer)	60
3.3.6.2 Evrişim Katmanı (Convolutional Layer)	61
3.3.6.3 Yığın Normalizasyon Katmanı (Batch Normalization Layer)	62
3.3.6.4 Aktivasyon Katmanı (Activation Layer)	62
3.3.6.5 Havuzlama Katmanı (Pooling Layer)	63
3.3.6.6 Tam Bağlantı Katmanı (Fully Connected Layer)	64
3.3.7 Derin Öğrenme Modelleri	67
3.3.7.1 ResNet Modeli	67

İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
3.3.7.2 DenseNet Modeli	68
3.3.7.3 EfficientNet Modeli	69
BÖLÜM 4 ÖNERİLEN YÖNTEM	73
4.1 MODELİN OLUŞTURULMASI VE EĞİTİLMESİ	73
4.1.1 Donanım Gereksinimleri.....	73
4.1.2 Veri Seti	73
4.1.3 Ön İşlem.....	74
4.1.4 Modelin Oluşturulması	74
4.1.5 Modelin Eğitilmesi.....	76
BÖLÜM 5 PERFORMANS ÖLÇÜTLERİ VE DEĞERLENDİRME	79
5.1 PERFORMANS ÖLÇÜTLERİ	79
5.1.1 Karmaşıklık Matrisi (Confusion Matrix)	79
5.1.2 ROC Eğrisi (Receiver Operating Characteristic Curve)	80
5.1.3 Duyarlılık (Recall)	82
5.1.4 Kesinlik (Precision)	82
5.1.5 F1-Skoru (F1-Score)	82
5.1.6 Doğruluk (Accuracy)	82
5.2 MODEL SONUÇLARININ KARŞILAŞTIRMASI	86
5.2.1 Farklı Modellerin Karşılaştırılması.....	86
5.2.2 EfficientNet Model Ailesinin Karşılaştırılması	91
5.2.3 EfficientNetB1 Temelli Özgün Modellerin İkili ve Üçlü Sınıflandırma Sonuçları	98
5.2.4 Önerilen Modelin Literatürdeki Diğer Çalışmalarla Karşılaştırılması	106
BÖLÜM 6 SONUÇ VE ÖNERİLER.....	111
6.1 SONUÇ	111
6.2 ÖNERİLER	112

İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
KAYNAKLAR.....	113
ÖZGEÇMİŞ	123





ŞEKİLLER DİZİNİ

No	Sayfa
Şekil 2.1 Solunum sistemi ve akciğerlerin yapısı	14
Şekil 2.2 Üç adet akciğer X-ray görüntüsündeki COVID-19 bölgeleri	16
Şekil 2.3 Göğüs X-ray (a) normal, (b) bakteriyel pnömoni ve (c) viral pnömoni	18
Şekil 2.4 Göğüs X-ray görüntüsünde akciğer opasite örnekleri.....	19
Şekil 2.5 Göğüs röntgeni (X-ray) görüntüsü	24
Şekil 2.6 Göğüs bilgisayarlı tomografi (BT) görüntüsü.....	25
Şekil 2.7 Göğüs manyetik rezonans (MRG) görüntüsü	26
Şekil 2.8 Göğüs pozitron emisyon tomografi (PET) görüntüsü.....	27
Şekil 2.9 Göğüs ultrasonografi (USG) görüntüsü	27
Şekil 2.10 Göğüs bronkoscopi görüntüleme	28
Şekil 2.11 İlk X ışını görüntüsü	29
Şekil 2.12 X ışın tüpü sistemi.....	30
Şekil 2.13 Dijital X-ray sisteminin ana bileşenleri	31
Şekil 3.1 Makine öğrenmesi hiyerarşisi	36
Şekil 3.2 K en yakın komşu algoritması	39
Şekil 3.3 DVM algoritması	40
Şekil 3.4 Lojistik sigmoid fonksiyonu	43
Şekil 3.5 Yapay sinir ağları gösterimi	45
Şekil 3.6 Yetersiz öğrenme, ideal öğrenme, aşırı öğrenme gösterimleri	49
Şekil 3.7 ReLU aktivasyon fonksiyonu grafiği	55
Şekil 3.8 Leaky ReLU aktivasyon fonksiyonu grafiği	55
Şekil 3.9 Sigmoid aktivasyon fonksiyonu grafiği	56
Şekil 3.10 Swish aktivasyon fonksiyonu grafiği	57
Şekil 3.11 Softmax aktivasyon işlevi gösterimi	58
Şekil 3.12 Softmax aktivasyon fonksiyonu grafiği	58
Şekil 3.13 ESA mimarisi	60
Şekil 3.14 Konvolüsyon işlemi gösterimi	61
Şekil 3.15 Maksimum havuzlama yöntemi gösterimi	63
Şekil 3.16 Tam bağlantı katmanı gösterimi	64
Şekil 3.17 Altı katmandan oluşan basit bir ESA mimarisi gösterimi	65
Şekil 3.18 Dropout işlemi gösterimi	67
Şekil 3.19 ResNet50 mimarisinin gösterimi	68
Şekil 3.20 DenseNet121 mimarisinin gösterimi	68

ŞEKİLLER DİZİNİ (devam ediyor)

No	Sayfa
Şekil 3.21 EfficientNet modeli için ölçeklendirmeler; (a) temel ağ (b)-(d) ağın sadece bir boyutunu artıran ölçeklendirme (e) önerilen bileşik (üç boyut arttıran) ölçeklendirme	70
Şekil 3.22 EfficientNetB0 modeli üzerinde ölçeklendirmeler	71
Şekil 3.23 EfficientNetB0 mimarisinin gösterimi.....	71
Şekil 3.24 EfficientNetB1 mimarisinin gösterimi.....	72
Şekil 4.1 Oluşturulan modelin özeti	75
Şekil 4.2 Optimum epok değerinin seçimi için epok sayısına göre kayıp ve doğruluk oranları grafikleri.....	76
Şekil 4.3 Her bir sınıf için sınıflandırma sonuç örnekleri	77
Şekil 4.4 Eğitim setinden rastgele seçilmiş bir grupluk (batch) görüntü örnekleri.....	77
Şekil 5.1 Oluşturulan özgün modelin karmaşıklık matris sonuçları	80
Şekil 5.2 Oluşturulan özgün modelin ROC eğrisi ve AUC değerleri	81
Şekil 5.3 Oluşturulan modelin eğitim ve doğrulama için kayıp ve doğruluk grafikleri	83
Şekil 5.4 Oluşturulan modelin eğitim sürecindeki metrik sonuçlarının değişimi	84
Şekil 5.5 EfficientNetB1 temelli oluşturulan modelin 10 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri	86
Şekil 5.6 EfficientNetB1 temelli oluşturulan modelin 10 epokluk karmaşıklık matris sonuçları	87
Şekil 5.7 ResNet50 temelli oluşturulan modelin 10 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri	87
Şekil 5.8 ResNet50 temelli oluşturulan modelin 10 epokluk karmaşıklık matris sonuçları	88
Şekil 5.9 DenseNet121 temelli oluşturulan modelin 10 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri	88
Şekil 5.10 DenseNet121 temelli oluşturulan modelin 10 epokluk karmaşıklık matris sonuçları	89
Şekil 5.11 EfficientNetB0 temelli oluşturulan modelin 15 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri	91
Şekil 5.12 EfficientNetB0 temelli oluşturulan modelin 15 epokluk karmaşıklık matris sonuçları	92
Şekil 5.13 EfficientNetB1 temelli oluşturulan modelin 15 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri	92
Şekil 5.14 EfficientNetB1 temelli oluşturulan modelin 15 epokluk karmaşıklık matris sonuçları	93
Şekil 5.15 EfficientNetB2 temelli oluşturulan modelin 15 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri	93
Şekil 5.16 EfficientNetB2 temelli oluşturulan modelin 15 epokluk karmaşıklık matris sonuçları	94

ŞEKİLLER DİZİNİ (devam ediyor)

No	Sayfa
Şekil 5.17 EfficientNetB3 temelli oluşturulan modelin 15 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri	94
Şekil 5.18 EfficientNetB3 temelli oluşturulan modelin 15 epokluk karmaşıklık matris sonuçları	95
Şekil 5.19 EfficientNetB4 temelli oluşturulan modelin 15 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri	95
Şekil 5.20 EfficientNetB4 temelli oluşturulan modelin 15 epokluk karmaşıklık matris sonuçları	96
Şekil 5.21 EfficientNetB1 temelli oluşturulan ikili sınıflandırma (COVID-19 ve Normal) modelinin 25 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri.....	99
Şekil 5.22 EfficientNetB1 temelli oluşturulan ikili sınıflandırma (COVID-19 ve Normal) modelinin 25 epokluk karmaşıklık matris sonuçları	99
Şekil 5.23 EfficientNetB1 temelli oluşturulan ikili sınıflandırma (Akciğer Opasitesi ve Normal) modelinin 25 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri	100
Şekil 5.24 EfficientNetB1 temelli oluşturulan ikili sınıflandırma (Akciğer Opasitesi ve Normal) modelinin 25 epokluk karmaşıklık matris sonuçları.....	100
Şekil 5.25 EfficientNetB1 temelli oluşturulan ikili sınıflandırma (Pnömoni ve Normal) modelinin 25 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri...	101
Şekil 5.26 EfficientNetB1 temelli oluşturulan ikili sınıflandırma (Pnömoni ve Normal) modelinin 25 epokluk karmaşıklık matris sonuçları	101
Şekil 5.27 EfficientNetB1 temelli oluşturulan üçlü sınıflandırma (COVID-19, Akciğer Opasitesi ve Normal) modelinin 25 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri.....	102
Şekil 5.28 EfficientNetB1 temelli oluşturulan üçlü sınıflandırma (COVID-19, Akciğer Opasitesi ve Normal) modelinin 25 epokluk karmaşıklık matris sonuçları	102
Şekil 5.29 EfficientNetB1 temelli oluşturulan üçlü sınıflandırma (COVID-19, Pnömoni ve Normal) modelinin 25 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri	103
Şekil 5.30 EfficientNetB1 temelli oluşturulan üçlü sınıflandırma (COVID-19, Pnömoni ve Normal) modelinin 25 epokluk karmaşıklık matris sonuçları.....	103
Şekil 5.31 EfficientNetB1 temelli oluşturulan üçlü sınıflandırma (Akciğer Opasitesi, Pnömoni ve Normal) modelinin 25 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri.....	104
Şekil 5.32 EfficientNetB1 temelli oluşturulan üçlü sınıflandırma (Akciğer Opasitesi, Pnömoni ve Normal) modelinin 25 epokluk karmaşıklık matris sonuçları.....	104



ÇİZELGELER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Çizelge 5.1 Oluşturulan özgün model için sınıflara göre değerlendirme metrik sonuçları.....	83
Çizelge 5.2 Oluşturulan özgün model için eğitim, test ve doğrulama için kayıp ve doğruluk sonuçları.	85
Çizelge 5.3 EfficientNetB1, ResNet50 ve DenseNet121 modellerinin 10 epokluk değerlendirme sonuçları	89
Çizelge 5.4 EfficientNetB1, ResNet50 ve DenseNet121 modellerinin 10 epokluk eğitim süreleri ve parametrik sonuçları	90
Çizelge 5.5 EfficientNetB0, EfficientNetB1, EfficientNetB2, EfficientNetB3 ve EfficientNetB4 modellerinin 15 epokluk değerlendirme sonuçları	96
Çizelge 5.6 EfficientNetB0, EfficientNetB1, EfficientNetB2, EfficientNetB3 ve EfficientNetB4 modellerinin 15 epokluk eğitim süreleri ve parametrik sonuçları	98
Çizelge 5.7 EfficientNetB1 temelli oluşturulan özgün ikili sınıflandırma modellerinin 25 epokluk değerlendirme sonuçları	105
Çizelge 5.8 EfficientNetB1 temelli oluşturulan özgün üçlü sınıflandırma modellerinin 25 epokluk değerlendirme sonuçları	106
Çizelge 5.9 Önerilen EfficientNetB1 temelli özgün modelin literatürdeki ikili sınıflandırma modelleriyle karşılaştırılması	107
Çizelge 5.10 Önerilen EfficientNetB1 temelli özgün modelin literatürdeki çoklu sınıflandırma modelleriyle karşılaştırılması	108



SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

w	: weight (ağırlık)
b	: bias (sapma)

KISALTMALAR

Adam	: Uyarlanabilir Moment Tahmin Optimizasyonu
Adamax	: Maksimum ile Uyarlanabilir Moment Tahmini
AdaGrad	: Uyarlanabilir Gradyan Optimize Edici (AdaGrad)
ADC	: Analog Dijital Dönüştürücü
AUC	: Eğri Altındaki Alan
BT	: Bilgisayarlı Tomografi
CXR	: Akciğer Röntgen Görüntüsü
DenseNet	: Yoğun Evrişimsel Ağlar
DSÖ	: Dünya Sağlık Örgütü
DVM	: Destek Vektör Makinesi
EfficientNet	: Efektif Evrişimsel Ağlar
ESA	: Evrişimli Sinir Ağları
FLOP	: Kayan Nokta Operasyonları
FN	: Yanlış Negatif
FP	: Yanlış Pozitif
IgE	: Total Immünoglobulin E Testi
KNN	: K En Yakın Komşu Algoritması
KOAH	: Kronik Obstrüktif Akciğer Hastalığı
K-Means	: K Ortalama Algoritması
MERS	: Orta Doğu Solunum Sendromu
MRG	: Manyetik Rezonans Görüntüleme

SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)

PCR	: Polimeraz Zincir Reaksiyonu
PET	: Pozitron Emisyon Tomografisi
ReLU	: Doğrultulmuş Lineer Birim
ResNet	: Artık Ağlar
RMSProp	: Ortalama Karesel Yayılım Kökü
RNA	: Ribonükleik Asid
RO	: Rastgele Orman Algoritması
SARS	: Şiddetli Akut Solunum Sendromu
SARS-CoV-2	: Şiddetli Akut Solunum Sendromu Koronavirüsü-2
SGD	: Stokastik Gradyan İnişi
TÜİK	: Türkiye İstatistik Kurumu
TN	: Gerçek Negatif
TP	: Gerçek Pozitif
USG	: Ultrasonografi
VGG	: Görsel Geometri Grubu Algoritması
X-Ray	: X Işını
YSA	: Yapay Sinir Ağları

BÖLÜM 1

GİRİŞ

Solunum yolu hastalıkları, solunum sisteminin üst solunum yollarında yer alan burun, burun boşluğu, sinüsler, ağız, yutak, gırtlak ve alt solunum yollarında yer alan akciğer ve soluk borusu gibi organlarda meydana gelen olumsuzluklar sonucu ortaya çıkan sağlık sorunlarıdır [1]. Küresel çapta demografik eğilimler sonucu solunum yolu hastalıklarının yaygınlığı ve önemi her geçen gün artmaktadır. Dünya Sağlık Örgütü (DSÖ) tarafından 2000 yılında yapılan tahminlerine göre, solunum yolu enfeksiyonları her yıl dünya çapında 1.4 milyon ölüme yol açmaktadır [2]. Ayrıca, dünya genelinde toplamda yaklaşık 700 milyon insan bu tür solunum yolu hastalıklarından etkilenmektedir [3]. Türkiye’de ise bu sayı yaklaşık 10 milyon kişiyi bulmaktadır. Solunum yolu hastalıkları arasında kronik obstrüktif akciğer hastalığı (KOAH), astım, zatürre (pnömoni), koronavirüs (SARS-CoV-2), verem, bronşit, solunum yetmezliği, akciğer kanseri ve sertleşmesi gibi hastalıklar, Türkiye’deki tüm ölümler arasında sık görülme oranında üçüncü sırada yer almaktadır. Türkiye İstatistik Kurumu’nun (TÜİK) 2022 yılı verilerine göre, solunum sistemi hastalıkları nedeniyle 70 bine yakın kişi hayatını kaybetmiştir.

Solunum yolu hastalıkları yalnızca yetişkinler ve yaşlı bireylerde değil, aynı zamanda çocuklarda da sıkça rastlanılan sağlık sorunları arasındadır. TÜİK’in 2022 yılına ait araştırmasında, son altı ay içerisinde 0-14 yaş aralığındaki çocuklar arasında en yaygın görülen hastalık türünün solunum yolu enfeksiyonları olduğu belirtilmiştir. Çocuklarda görülen hastalıkların genel dağılımı incelendiğinde, 0-6 yaş grubundaki çocuklarda %38,2 oranında, 7-14 yaş grubu çocuklarda ise %32,4 oranında üst ve alt solunum yolu enfeksiyonlarına rastlanılmaktadır [4].

Solunum yolu hastalıkları, her yaş grubunda görülen yaygın hastalık türleri olup hasta ve hastaların yaşamlarında yer alan çevrelerini de olumsuz yönde etkilerken aynı zamanda sağlık hizmetleri ve maliyetler de göz önünde bulundurulduğunda ülke ekonomisini de olumsuz yönde etkilemektedir. Yapılan araştırmalarda, solunum yolu hastalıklarının bireylerde psikolojik sorunlara da yol açtığı saptanmaktadır. Bu hastalıklara yakalanan kişiler, sağlıklı bireylere göre

daha yüksek oranda anksiyete bozukluğu tanısına maruz kalmaktadır [5]. Solunum yolu hastalıkları, çeşitli yönlerden ele alındığında birçok alanda olumsuz etkilere sebep olmasından dolayı bu hastalıkların tedavisinin yanı sıra tedavi öncesi erken, hızlı, düşük maliyetli ve en önemlisi doğru teşhis edilmesi kritik önem taşımaktadır.

Solunum yolu hastalıklarının teşhisinde, hastanın tıbbi geçmişi dikkate alınarak fiziksel muayene, solunum fonksiyon testleri, çeşitli sürüntü ve laboratuvar testleri ile akciğerlerin görüntülenmesi üzerine röntgen (X-Ray), bilgisayarlı tomografi (BT) ve manyetik rezonans görüntüleme (MRG) gibi görüntüleme yöntemleri kullanılmaktadır. Bu yöntemler arasında, Röntgen teknolojisi erişim kolaylığı, düşük radyasyon dozu içermesi ve hızlı sonuç özellikleri nedeniyle en çok tercih edilen yöntem olma özelliğini korumaktadır [6].

Röntgen görüntüleri aracılığıyla solunum yolu hastalıklarının teşhisini gerçekleştiren uzman radyolog sayısının yetersizliği ve zaman zaman radyologlar tarafından yapılan hatalı teşhisler, hastalara yanlış tedavi yöntemlerinin uygulanmasına yol açmaktadır [7]. Bu nedenlerle, hastalara daha hızlı, pratik ve doğru teşhisler sunabilmek amacıyla bilgisayar destekli sistemlerin entegrasyonuna ihtiyaç doğmuştur. Hastalık teşhisi için geliştirilen birçok bilgisayar destekli sistemler arasında en öne çıkanı, derin öğrenme tabanlı sınıflandırma modelleridir. Bu modellerin temeli, özellikle görüntü işleme uygulamalarına özgü, yaygın olarak kullanılan algoritmaların başında gelen evrimsel sinir ağları (ESA) modelleridir [6].

1.1 ÇALIŞMANIN AMACI

Solunum yolu hastalıklarında erken ve doğru teşhis, tedavi sürecini de olumlu yönde etkilemektedir. Uzman radyologların yetersiz kaldığı durumlarda karar verme süreçlerine destek olabilmesi amacıyla geliştirilen sistem, solunum yolu hastalıklarının teşhisinde ve tedavisinde önemli bir rol oynayacaktır.

Bu tez çalışmasında, ESA algoritmaları kullanılarak göğüs röntgen görüntüleri üzerinden solunum yolu hastalıklarının teşhis edilmesine yardımcı olabilecek bir çoklu sınıflandırma modeli oluşturulmuştur. Çalışmada önerilen ESA modelinin oluşturulmasında Python kütüphanelerinden Keras kullanılmıştır. Geliştirilen ESA modeli aracılığıyla normal, zatürre (pnömoni), COVID-19 ve akciğer opaklığı olmak üzere dört farklı solunum yolu hastalığının çoklu sınıflandırılması hedeflenmiştir. İlerleyen dönemlerde daha fazla hastalığın çoklu

sınıflandırılabilceğı sistemlerin geliştirilmesiyle, hastaların en kısa sürede, kolay ve doğru teşhisler sayesinde uygun yöntemlerle tedavi edilebilmeleri sağlanacaktır.

1.2 LİTERATÜR ARAŞTIRMASI

Göğüs röntgeni görüntülerinin sınıflandırma problemi, tıbbi tanı alanında uzun süredir araştırılan ve üzerine birçok çalışma gerçekleştirilen bir konudur. Yapay zekâ teknolojisinin gelişmesiyle birlikte, makine öğrenmesi ve derin öğrenme modelleri kullanılarak akciğer hastalıklarının teşhisi için çeşitli algoritmalar ve teknikler geliştirilmiştir. Geliştirilen bu tekniklerin büyük bir kısmı, dikkate değer başarılar elde etmiştir. Literatürde yer alan bu çalışmalarla ilişkin yayınlanan makaleler, yıllara göre sıralanarak bu başlık altında sunulacaktır.

Öztürk ve arkadaşları, ham göğüs röntgen görüntüleri üzerinde otomatik COVID-19 teşhisi için yenilikçi bir derin öğrenme modeli geliştirmişlerdir. Geliştirilen bu model, hem COVID-19'un varlığını ya da yokluğunu (ikili sınıflandırma) hem de COVID-19, normal ve zatürre gibi farklı durumları ayırt etme (çoklu sınıflandırma) görevlerinde başarılı sonuçlar elde etmiştir. Özellikle, ikili sınıflandırmada %98,08 gibi yüksek bir doğruluk oranına ulaşılmıştır. Çalışmada, DarkNet isimli derin öğrenme mimarisi temel alınarak 17 farklı evrişimsel katmanın kullanıldığı bir model oluşturulmuştur. Bu katmanlara uygulanan çeşitli filtreleme teknikleri sayesinde, model röntgen görüntülerindeki ince ayrıntıları daha iyi yakalayarak daha doğru teşhisler ortaya koymuştur [8].

Nour ve arkadaşları, COVID-19 tanısında radyologlara yardımcı olabilmek amacıyla göğüs röntgen görüntülerini analiz edebilen yeni bir derin öğrenme modeli geliştirmişlerdir. Model, özel olarak tasarlanmış bir evrişimli sinir ağı mimarisi kullanarak röntgen görüntülerindeki COVID-19'a özgü özellikleri otomatik olarak tespit etmekte ve hastalığın doğru teşhisinde önemli bir rol oynamaktadır. Çalışmada, önceden eğitilmiş modeller yerine sıfırdan tasarlanan bir ESA mimarisi kullanılmış ve bu modelin çıkış katmanından elde edilen derin özellikler, çeşitli makine öğrenimi algoritmaları ile birleştirilmiştir. Bayes optimizasyonu yöntemi kullanılarak algoritmaların hiperparametreleri optimize edilmiş ve en iyi performans elde edilmiştir. Halka açık bir veri seti üzerinde gerçekleştirilen deneylerde, destek vektör makinesi sınıflandırıcısı %98,97 gibi yüksek bir doğruluk oranı elde ederek modelin etkinliğini kanıtlamıştır. Bu çalışma, derin öğrenmenin tıbbi görüntüleme alanında, özellikle pandemi süreçlerinde hızlı ve doğru teşhis koyma konusunda önemli bir potansiyele sahip olduğunu göstermektedir [9].

Sethy ve arkadaşları, COVID-19 tanısında X-ışını görüntülerini kullanarak etkili sonuçlar elde eden bir yöntem önermişlerdir. Bu yöntemde, derin öğrenme ile geleneksel makine öğrenmesi teknikleri bir araya getirilmiştir. İlk olarak, bir evrişimli sinir ağı modeli aracılığıyla X-ışını görüntülerinden derin ve anlamlı özellikler çıkarılmıştır. Ardından, bu özellikler destek vektör makinesi gibi güçlü bir sınıflandırma algoritmasına aktarılmış ve COVID-19, zatürre ve normal durumlar arasında ayırım yapılmıştır. Çalışmada, farklı ESA modelleri test edilmiş ve ResNet50 modelinin DVM ile birlikte kullanılması sonucunda %98,66 gibi yüksek bir doğruluk oranı elde edilmiştir. Bu sonuç, önerilen yöntemin COVID-19 tanısında önemli bir yer edineceğini göstermiştir [10].

Ravi ve arkadaşları, göğüs röntgen görüntülerini kullanarak akciğer hastalıklarını (pnömoni, tüberküloz ve COVID-19) sınıflandırmak için yenilikçi birçok kanallı derin öğrenme tabanlı bir yaklaşım önermektedir. Önerilen yöntem, EfficientNet modellerinin özelliklerini birleştirerek bunları bir yığılmış topluluk öğrenme sınıflandırıcısına besleyerek çalışır. Deneysel sonuçlar, yöntemin diğer yöntemlere kıyasla daha yüksek doğruluk oranları elde ettiğini göstermiştir. Çalışma, üç hastalık grubunu ikili sınıflandırma yaklaşımlarıyla %98-%99 seviyesinde başarı oranı yakalayarak akciğer hastalıklarının otomatik teşhisi konusunda önemli yer edineceğini göstermiştir [11].

Toğaçar ve arkadaşları, koronavirüs hastalığının X-ışını görüntülerinden teşhis edilmesi amacıyla yeni bir derin öğrenme modeli geliştirmişlerdir. Bu modelde, COVID-19, zatürre ve normal gibi farklı sınıflardaki X-ışını görüntüleri, Bulanık Renk tekniği ile zenginleştirilerek daha sağlam bir veri seti oluşturulmuştur. Ardından, MobileNetV2 ve SqueezeNet gibi hafif ve verimli derin öğrenme modelleri kullanılarak bu görüntülerden özellikler çıkarılmış ve sosyal taklit optimizasyon yöntemi ile birleştirilmiştir. Son olarak, birleştirilen özellikler destek vektör makineleri ile sınıflandırılmış ve %99,27 gibi yüksek bir doğruluk oranı elde edilmiştir. Bu çalışma, derin öğrenme ve görüntü işleme yöntemlerinin tıbbi teşhis alanında başarılı bir şekilde uygulanabileceğini ortaya koymuştur [12].

Türkoğlu ve arkadaşları tarafından geliştirilen COVIDetectionNet modeli, COVID-19 tanısında oldukça etkili sonuçlar elde eden bir derin öğrenme modelidir. Bu çalışmada, önceden eğitilmiş bir AlexNet mimarisi kullanılarak transfer öğrenme yaklaşımı benimsenmiştir. Bu sayede, model, geniş bir veri kümesi üzerinde daha önce öğrenilmiş olan görsel özellikleri doğrudan kullanarak COVID-19 tanısı için eğitilmiştir. Modelin tüm katmanlarından elde edilen özellikler, Relief algoritması ile seçilerek en etkili ve ayırt edici özellikler belirlenmiştir.

Seilen bu zellikler, daha sonra destek vektr makineleri sınıflandırıcısı aracılığıyla COVID-19, zatürre ve normal durumları birbirinden ayırt etmek için kullanılmıştır. Kapsamlı bir veri seti üzerinde gerekleştirilen deneylerde, model %99,18 gibi oldukça yüksek bir doğruluk oranı elde ederek nceki alışmalardaki modellere gre daha iyi performans gstermiştir. Bu bulgu, COVIDetectionNet modelinin COVID-19 tanısında gvenilir ve etkili bir araç olabileceğini gstermektedir [13].

Terzi alışmasında, derin ğrenme tabanlı bir evrişimsel sinir ağı modeli ortaya koymuştur. Tezinde nerilen ESA modeli ve literatrde sıklıkla kullanılan nceden eğitilmiş hazır modeller ulusal saėlık enstitlerinin yayınladığı 30.805 farklı hastanın 112.120 adet nden grnml gės rntgeninden oluřan Chest X-ray14 veri seti kullanılarak eğitilmiştir. Veri setindeki rntgenler, 14 farklı gės hastalığının bir veya birkaçını ya da saėlıklı bir bireyi temsil etmektedir. nerilen ESA modelinin eėitim sonrası elde edilen ortalama test sonularında hata deėeri 0,089 ve bařarı deėeri ise %91,04 olarak elde edilmiştir. Sınıf bazında yapılan deėerlendirmelerde, hastalık trleri arasından en yksek bařarı %99,80 ile fitıkta, en dřk bařarım ise %73,41 ile szlme hastalığında elde edilmiştir. Keras ktphanesinde, Python programlama dili kullanılarak geliřtirilen model ile nceden eğitilmiş modellerle gerekleştirilen deneysel alışmalar, literatrdeki oklu sınıflandırma modellerine oranla daha bařarılı sonular ortaya koymuştur [6].

Gldalı alışmasında, gės rntgen grntlerini kullanarak COVID-19 tanısı koymak için derin ğrenme ve makine ğrenmesi yntemlerini birleřtiren yeni bir yaklařım nermektedir. Derin ğrenme modelleri ile elde edilen grsel zellikler, makine ğrenmesi algoritmaları ile entegre edilerek tanı doğruluėunun artırılması hedeflenmiştir. alışmada, eřitli derin ğrenme modelleri (AlexNet, ResNet, VGG) ve makine ğrenmesi algoritmaları (Destek Vektr Makinesi, Lojistik Regresyon, K-En Yakın Komřu) kullanılmış ve bu modellerin performansları farklı optimizasyon yntemleri ve dzenleyiciler ile deėerlendirilmiştir. Ayrıca, hastaların demografik bilgileri de modele eklenerek, tanı doğruluėuna katkısı arařtırılmıştır. Elde edilen sonulara gre, derin ğrenme ve makine ğrenmesi yntemlerinin birlikte kullanılması, COVID-19 tanısında nemli sonular vermiştir. Ancak, daha geniř ve eřitli bir veri seti ile alışmanın, modelin performansını daha da artırabileceėi belirtilmiştir [14].

Korkmaz alışmasında, COVID-19 hastalığının erken teřhisi için yeni bir yntem geliřtirmiřtir. Geliřtirdiėi bu yntem, gės rntgen grntlerini analiz ederek COVID-19 ve zatrre gibi akciėer hastalıklarının %97 gibi yksek bir doğruluk oranıyla ayırt edebilme yeteneėine sahiptir.

Yöntem, yedi adet evrişim katmanı ve bir adet tam bağlantı katmanından oluşmaktadır. Beş katlamalı çapraz doğrulama yöntemi uygulanmıştır. Bu yaklaşım, PCR testlerine göre daha hızlı ve daha düşük maliyetli olması nedeniyle, özellikle acil durumlarda hastaların hızlı bir şekilde değerlendirilmesinde kullanılabilir [15].

Narin ve arkadaşları, koronavirüs (COVID-19) pnömonisi teşhisini göğüs röntgen görüntüleri üzerinden otomatikleştirmek amacıyla kapsamlı bir çalışma gerçekleştirmişlerdir. Bu çalışmada, ResNet50, ResNet101, ResNet152, InceptionV3 ve Inception-ResNetV2 gibi önceden eğitilmiş beş farklı evrişimli sinir ağı modeli kullanarak, COVID-19'u normal durumlardan ve diğer pnömoni türlerinden (viral ve bakteriyel) ayırt etmeye yönelik bir sınıflandırma sistemi geliştirmişlerdir. Çalışmalarında, beş katlı çapraz doğrulama yöntemi ile model performansının güvenilirliğini yükseltmişlerdir. Elde edilen sonuçlar, farklı veri setleri üzerinde yapılan deneylerde ResNet50 modelinin, diğer modellerle kıyaslandığında, COVID-19'u en yüksek doğrulukla (%96,1, %99,5 ve %99,7) sınıflandırdığı gözlemlenmiştir. Bu bulgu, ResNet50 modelinin COVID-19 teşhisinde oldukça başarılı olduğunu ve tıbbi görüntüleme alanında önemli bir potansiyele sahip olduğunu göstermektedir [16].

Talukder ve arkadaşları, COVID-19 gibi akciğer hastalıklarının göğüs röntgen görüntülerinden hızlı ve doğru bir şekilde teşhisi için derin öğrenme tabanlı bir yaklaşım önermektedir. Çeşitli transfer öğrenme modelleri üzerinde yapılan deneyler, EfficientNetB4 modelinin en yüksek başarıyı elde ettiğini göstermiştir. İnce ayarlanmış EfficientNetB4 modeli, COVID-19, pnömoni, akciğer opasitesi ve normal sınıfları içeren çoklu hastalık sınıflandırma tespitinde %99,17 seviyesindeki yüksek doğruluk değeri elde ederek tıbbi görüntüleme yoluyla hastalık teşhisinde yeni bir çığır açma potansiyeline sahiptir. Çalışma, derin öğrenmenin tıbbi görüntü analizindeki gücünü vurgulamakla birlikte, daha geniş veri setleri ve farklı hastalık türleri üzerindeki çalışmaların gelecekteki araştırma alanları olduğunu da belirtmektedir [17].

Kassania ve arkadaşları, COVID-19 tanısında X-ışını ve Bilgisayarlı Tomografi (BT) görüntülerini kullanarak derin öğrenme modelleri ile otomatik sınıflandırma yapmak amacıyla kapsamlı bir çalışma gerçekleştirmişlerdir. MobileNet, DenseNet, Xception gibi popüler derin öğrenme mimarilerini kullanarak bu görüntülerden derin özellikler elde edilmiş ve bu özellikler farklı makine öğrenimi sınıflandırıcılarına aktarılmıştır. Sonuç olarak, DenseNet121 mimarisi ile Bagging ağacı sınıflandırıcısının birleşimi sayesinde %99 gibi oldukça yüksek bir sınıflandırma doğruluğuna ulaşılmıştır. Bu çalışma, derin öğrenme yöntemlerinin COVID-19

teşhisinde ne kadar etkili olabileceğini göstermekte ve farklı mimarilerin ve sınıflandırıcıların karşılaştırılmasıyla alanına önemli bir katkı sağlamaktadır [18].

Tiwari ve arkadaşları, COVID-19 tanısında geleneksel ESA yöntemlerinin görüş değişmezliği ve bilgi kaybı gibi sorunlarını aşmak amacıyla yeni bir yaklaşım olan VGG-CapsNet modelini önermişlerdir. Kapsül ağları, nesnelerin farklı pozisyon ve ölçeklerdeki temsillerini daha etkili bir şekilde yakalayarak, ESA'lara kıyasla daha doğru ve güvenilir tanımlar yapma avantajına sahiptir. Araştırmacılar, VGG-CapsNet modelinin COVID-19'u diğer akciğer hastalıklarından ayırt etmede %97'ye varan yüksek bir doğruluk oranı elde ettiğini göstermişlerdir. Bu bulgular, VGG-CapsNet'in COVID-19 teşhisinde daha etkili ve güvenilir bir araç olabileceğini ortaya koymaktadır [19].

Das ve arkadaşları, göğüs röntgen görüntülerini kullanarak COVID-19, zatürre ve normal durumları ayırt edebilen bir otomatik tarama sistemi geliştirmişlerdir. Bu sistemde, ESA, VGG-16 ve ResNet-50 gibi farklı derin öğrenme mimarileri kullanılmıştır. Kaggle veri kümesinden elde edilen geniş bir göğüs röntgen görüntüsü veri seti üzerinde eğitilen modelin performansı değerlendirildiğinde, VGG-16 mimarisinin diğer iki mimariye göre daha başarılı olduğu gözlemlenmiştir. VGG-16 ile elde edilen model, %97,67 gibi oldukça yüksek bir doğruluk oranı ile birlikte hassasiyet, geri çağırma ve F1 skorlarında da iyi sonuçlar vermiştir. Bu bulgular, VGG-16 tabanlı modelin COVID-19 taramasında mevcut diğer modellere göre daha üstün bir performans sergilediğini göstermektedir [20].

Singh ve arkadaşları, derin öğrenme tekniklerinden faydalanarak pnömoni teşhisinde önemli bir adım atmaktadır. EfficientNet-B0 mimarisi temel alınarak geliştirilen model, geniş bir göğüs röntgeni veri seti üzerinde eğitilmiş ve pnömoni hastalığını yüksek doğrulukla tespit etme yeteneği göstermiştir. Modelin pnömoni hastalığını ikili sınıflandırma yaklaşımıyla yakaladığı %99,50'lik eğitim doğruluğu, %92,20'lik doğrulama doğruluğu ve %99,28'lik test doğruluğu gibi etkileyici sonuçları, modelin güvenilirliğini ve genellenebilirliğini desteklemektedir. Bu çalışma, tıbbi görüntü analizinde derin öğrenmenin potansiyelini vurgulayarak, pnömoninin erken teşhisinde önemli bir araç olarak kullanılabilir ve sağlık hizmetlerinin kalitesini artırabileceğini göstermektedir [21].

Chowdhury ve arkadaşları, COVID-19 teşhisi için derin öğrenme tabanlı yenilikçi bir model olan ECOVNet ismini verdikleri modeli sunmuşlardır. EfficientNet mimarisi üzerine inşa edilen model, büyük bir göğüs röntgeni veri seti üzerinde eğitilerek üç sınıftan oluşan akciğer hastalıklarını (COVID-19, pnömoni ve normal) %97,00 gibi yüksek doğrulukla tespit

edebilmektedir. Modelin performansı, sınıf aktivasyon haritaları ile desteklenen topluluk öğrenme stratejisi sayesinde daha da güçlendirilmiştir. ECOVNet, tıbbi görüntüleme alanında önemli bir adım atarak özellikle COVID-19 teşhisinde otomasyonu sağlayabilecek potansiyele sahiptir [22].

Kurt ve arkadaşları, COVID-19 pandemisinin başlarında, hastalığın erken teşhisi için etkili bir yöntem olarak bilgisayarlı tomografi (BT) taramalarının kullanılmasına odaklanmıştır. Özellikle, EfficientNet-B4 mimarisi temel alınarak geliştirilen bir derin öğrenme modeli, Bursa Yüksek İhtisas Eğitim ve Araştırma Hastanesi'nden elde edilen büyük bir COVID-19 BT taraması veri seti üzerinde eğitilmiştir. Model, KNN algoritması ile akciğer parankimi bölgelerinin segmentasyonu yapılarak ön işleme uygulanmış ve ardından EfficientNet-B4 mimarisi ile eğitilmiştir. Sonuç olarak, model %97,93 doğruluk oranı ve %97,33 F1-puanı ile COVID-19 vakalarını başarılı bir şekilde sınıflandırabilmiştir. Bu çalışma, derin öğrenme yöntemlerinin tıbbi görüntüleme alanında COVID-19 gibi bulaşıcı hastalıkların teşhisinde etkili bir araç olabileceğini göstermektedir [23].

Demir ve arkadaşları, çocuklarda pnömoni teşhisinde göğüs röntgen görüntülerini kullanarak yeni bir yaklaşım geliştirmişlerdir. AlexNet mimarisine ek katmanlar ekleyerek özgün bir evrişimli sinir ağı modeli tasarlamış ve bu modeli transfer öğrenme yöntemiyle eğitmişlerdir. Bu yaklaşım, sağlıklı ve pnömonili çocukları %96,31 gibi yüksek bir doğrulukla sınıflandırarak başarılı sonuçlar vermiştir [24].

Bakır ve arkadaşları, akciğer röntgen görüntülerini kullanarak derin öğrenme tabanlı bir sınıflandırma çalışması yürütmüşlerdir. Bu çalışmada, ResNet, Inception ve MobileNet gibi farklı evrişimli sinir ağı mimarileri, hem çoklu sınıflandırma (bakteriyel pnömoni, viral pnömoni ve sağlıklı) hem de ikili sınıflandırma (sağlıklı ve hasta) görevlerinde kullanılmıştır. Araştırmacılar, bu ESA mimarilerini hem özellik çıkarma hem de sınıflandırma amacıyla kullanmışlardır. Sonuçlara göre, ResNet mimarisi çoklu sınıflandırma görevinde %81,67 ile en yüksek doğruluk oranını elde ederken, MobileNet mimarisi ikili sınıflandırma görevinde %95,67 ile en yüksek doğruluk oranına ulaşmıştır. Bu çalışma, farklı ESA mimarilerinin farklı sınıflandırma görevlerindeki performans farklılıklarını ortaya koyarak, akciğer hastalıklarının bilgisayar destekli teşhisinde derin öğrenme yöntemlerinin potansiyelini göstermektedir [25].

Aljawarneh ve arkadaşları, akciğer röntgen görüntülerinden pnömoni teşhisi için farklı derin öğrenme modellerinin performanslarını karşılaştıran bir çalışma yürütmüşlerdir. Kendi geliştirdikleri evrişimli sinir ağı modelinde, VGG-19, ResNet-50 ve ince ayarlı ResNet-50 gibi

önceden eğitilmiş modelleri temel almışlardır. Kaggle'dan elde edilen geniş bir veri seti üzerinde yapılan deneylerde, geliştirdikleri model %92,4 ile en yüksek sınıflandırma doğruluğunu elde ederken, ResNet-50 modeli %82,8 ile en düşük doğruluk oranına sahip olmuştur. Bu sonuçlar, geliştirilen modelin pnömoni teşhisinde diğer modellere kıyasla daha başarılı olduğunu göstermektedir. Araştırmacılar, ilk dört katmanı 3x3 filtre boyutuna sahip yedi katmandan oluşan bu modelin, pnömoninin erken teşhisine katkı sağlayarak hastaların daha hızlı tedavi edilmesine olanak tanıyabileceğini belirtmişlerdir [26].

Kanawade ve arkadaşları, göğüs röntgen görüntülerinden pnömoni teşhisini otomatikleştirmek ve doktorlara daha doğru teşhis koymada yardımcı olmak amacıyla derin öğrenme tabanlı bir yaklaşım geliştirmişlerdir. Çalışmalarında, VGG16, VGG19, DenseNet121, DenseNet201, DenseNet169, InceptionResNet, MobileNet, MobileNetV2 ve Xception gibi çeşitli önceden eğitilmiş evrişimli sinir ağı modellerini inceleyerek pnömoni tespitindeki performanslarını karşılaştırmışlardır. Değerlendirme sonucunda, Xception, VGG16 ve DenseNet201 modellerinin diğerlerine göre daha başarılı olduğu gözlemlenmiştir. Araştırmacılar, bu üç modelin güçlü yönlerini birleştirerek yeni bir model oluşturmuş ve bu modelle %94,39 gibi yüksek bir doğruluk oranı elde etmişlerdir. Bu bulgu, derin öğrenme yöntemlerinin pnömoni teşhisinde etkili bir şekilde kullanılabileceğini ve tanı sürecinin iyileştirilmesine katkı sağlayabileceğini göstermektedir [27].

Ukwuoma ve arkadaşları, pnömoni teşhisi için evrişimli sinir ağları ve dönüştürücü kodlayıcı (Transformer) mekanizmalarının avantajlarını birleştiren hibrit bir derin öğrenme modeli geliştirmişlerdir. Bu model, hem pnömoninin varlığını/yokluğunu tespit etme (ikili sınıflandırma) hem de farklı pnömoni türlerini ayırt etme (çoklu sınıflandırma) görevlerinde başarılı sonuçlar elde etmiştir. Modelin mimarisi, DenseNet201, VGG16 ve GoogleNet gibi farklı ESA mimarilerini içeren iki ayrı topluluk öğrenme omurgası kullanarak ham röntgen görüntülerinden etkili özellikler çıkarır. Çıkarılan bu özellikler daha sonra Transformer mekanizması tarafından işlenerek nihai sınıflandırma kararları üretilir. Mendeley ve göğüs röntgeni veri setleri üzerinde yapılan testlerde, hibrit model ikili sınıflandırmada %99,21, çoklu sınıflandırmada ise %98,19 gibi yüksek doğruluk ve F1 skorlarına ulaşmıştır. Bu başarılı sonuçlar, hibrit modelin pnömoni teşhisinde yüksek bir potansiyele sahip olduğunu ve klinik uygulamalarda kullanılabileceğini göstermektedir [28].

Öter, COVID-19 tanısında X-ray görüntülerinin etkili bir şekilde kullanılmasını amaçlayan yeni bir teşhis metodolojisi geliştirmiştir. Bu yöntemde, SqueezeNet mimarisi kullanılarak X-ray

görüntülerinden derin özellikler çıkarılmaktadır. Daha sonra, Komşu Bileşen Analizi adı verilen bir yöntemle bu özellikler optimize edilerek gürültüden arındırılmakta ve böylece daha ayırt edici hale getirilmektedir. Son olarak, destek vektör makineleri kullanılarak bu optimize edilmiş özellikler sınıflandırılmakta ve COVID-19 tanısı konulmaktadır. Öter'in çalışmasının en önemli yönlerinden biri, geliştirdiği metodolojinin performansını farklı veri setleri ve yöntemlerle karşılaştırarak kapsamlı bir şekilde değerlendirmiş olmasıdır. Elde edilen sonuçlar, önerilen yöntemin COVID-19 teşhisinde yüksek doğruluk oranlarına ulaştığını göstermektedir. Bu çalışma, literatürde X-ray görüntülerinden COVID-19 teşhisi konusunda önemli bir boşluğu doldurmakta ve özellikle öznetelik seçimi aşamasına odaklanan sınırlı sayıda çalışmaya değerli bir katkı sağlamaktadır. Gelecekte, çalışmanın kapsamı bilgisayarlı tomografi görüntülerini de içerecek şekilde genişletilerek yöntemin genellenebilirliği ve uygulanabilirliği artırılabilir [29].

Hatipoğlu, akciğer grafisi görüntülerini kullanarak COVID-19 pnömonisi, lobar pnömoni ve sağlıklı durumları ayırt edebilen bir derin öğrenme modeli geliştirmiştir. Bu çalışmada, az katmanlı bir evrişimli sinir ağı mimarisi tercih edilerek hem yüksek doğruluk elde etmek hem de eğitim süresini kısaltmak hedeflenmiştir. Modelin performansı, VGG16 ve VGG19 gibi daha karmaşık ve derin ESA modelleriyle karşılaştırılmıştır. Ayrıca, tıbbi görüntülerde sıkça karşılaşılan düşük kontrast problemini ele almak için Kontrast Sınırlı Adaptif Histogram Eşitleme yöntemi ve çeşitli filtreler kullanılmıştır. Bu optimizasyonlar sayesinde, modelin hem eğitim süresi kısalmış hem de sınıflandırma doğruluğu artırılmıştır [30].

Al-Rawe, derin öğrenme tekniklerini kullanarak dijital göğüs röntgeni görüntülerinden COVID-19 hastalığını otomatik olarak tespit etmeyi amaçlayan bir çalışma yürütmüştür. Bu çalışmada, COVID-19 tanısı koymak için öncelikle görüntüler ön işleme ve segmentasyon adımlarından geçirilerek analiz için hazır hale getirilmiştir. Ardından, derin öğrenme modelleri kullanılarak görüntülerden anlamlı özellikler çıkarılmış ve bu özellikler COVID-19 hastalığının tespiti için sınıflandırma amacıyla kullanılmıştır. Al-Rawe, çalışmasında COVID-19 veri kümesi ve Göğüs X-ray (COVID-19 ve Pnömoni) veri kümesi şeklinde iki farklı veri seti kullanarak kapsamlı bir analiz gerçekleştirmiştir. Elde edilen sonuçlar, veri setinin kalitesi ve karmaşıklığının derin öğrenme modelinin performansını önemli ölçüde etkilediğini göstermiştir. Yüksek kaliteli ve çeşitli veri setleri kullanıldığında, modelin COVID-19 hastalığını tespit etmedeki başarısının arttığı gözlemlenmiştir [31].

Kadiroğlu, pnömoni teşhisi için ince ayarlı AlexNet modelinin etkinliğini değerlendirdiği çalışmasında %98,50 doğruluk, %97,0 kesinlik, %100 duyarlılık ve %98,48 F1 skoru gibi

yüksek performans metrikleri elde etmiştir. Bu başarının ardında, önceden eğitilmiş modellerin bilgilerinden yararlanarak daha az veriyle daha iyi sonuçlar elde etmeyi sağlayan transfer öğrenme yöntemi yatmaktadır. AlexNet modeli, uçtan uca öğrenme özelliği sayesinde görüntülerden otomatik olarak anlamlı özellikler çıkararak, elle hazırlanmış özelliklere olan ihtiyacı ortadan kaldırır. Bu çalışma, ince ayarlı AlexNet modelinin pnömoni teşhisi için etkili ve güvenilir bir araç olduğunu göstererek, literatürdeki diğer çalışmalardan ayrılmaktadır [32].

Rama ve arkadaşları, göğüs röntgenleri üzerinde derin öğrenme tekniklerini kullanarak tüberküloz hastalığını teşhis etmek amacıyla geliştirilen yeni bir yöntem önermektedir. Özellikle EfficientNet mimarisinin B2 varyantı, X-ışını görüntülerindeki karmaşık özellikleri etkili bir şekilde çıkararak yüksek doğrulukta tüberküloz tespiti sağlamaktadır. Çalışmada, toplanan göğüs röntgeni verileri üzerinde ön işleme, özellik çıkarma ve sınıflandırma adımları gerçekleştirilmiş ve beş katlı çapraz doğrulama ile modelin genellenebilirliği değerlendirilmiştir. Elde edilen sonuçlar, önerilen yöntemin yüksek doğruluk oranı (%96) ile tüberküloz teşhisinde başarılı olduğunu göstermektedir. Bu çalışma, derin öğrenme tabanlı yöntemlerin tüberküloz teşhisindeki potansiyelini vurgulayarak, radyologların iş yükünü azaltırken aynı zamanda hastaların daha erken ve doğru teşhis almalarına olanak tanımaktadır [33].



BÖLÜM 2

GENEL BİLGİLER

2.1 SOLUNUM YOLU SİSTEMİ

Solunum, canlıların yaşamlarını sürdürebilmeleri için gerekli olan bir süreçtir. Solunum süreci, dış ortamdan alınan oksijenin vücuttaki hücrelere taşınmasını ve bu hücrelerde enerji üretiminde kullanılmasını sağlar. Enerji üretimi sonucunda oluşan karbondioksit ise vücuttan atılır. İnsan vücudunda bu hayati görevi üstlenen solunum sistemi, bir dizi organ ve dokudan meydana gelir. Bu sistem, vücudun ihtiyaç duyduğu oksijeni alıp karbondioksiti dışarı atma işlemlerini gerçekleştirir. Solunum sisteminin başlıca organları arasında burun, yutak, gırtlak, soluk borusu, bronşlar ve akciğerler yer alır. Solunan hava, bu organlar tarafından temizlenir, ısıtılır ve nemlendirilir ve akciğerlere ulaştırılır. Akciğerlerde gerçekleşen gaz alışverişi, vücuttaki hücrelerin yaşamsal faaliyetlerini sürdürebilmeleri için gerekli olan oksijeni sağlar [34].

Burun: Solunum sisteminin başlangıç noktası olan burun, havanın nemlendirilmesi, ısıtılması ve filtrelenmesinde önemli rol oynar. Burun içindeki kıllar ve mukus, havadaki toz ve mikropların akciğerlere ulaşmasını engelleyerek solunum yollarının korunmasına yardımcı olur.

Yutak: Hem solunum hem de sindirim sistemine ait bir organdır ve burun boşluğunun arkasında yer alır. Yutak, havanın soluk borusuna, besinlerin ise yemek borusuna geçişini sağlayarak bu iki sistem arasında bir köprü görevi görür.


Gırtlak: Soluk borusunun üst kısmında bulunur ve ses tellerini içerir. Ses telleri, konuşma sırasında titreşerek ses oluşumunu sağlar.

Soluk Borusu: Gırtlığın altında yer alır ve akciğerlere kadar uzanır. Havanın akciğerlere taşınmasını sağlayan soluk borusu, solunum sisteminin önemli bir parçasıdır.

Bronşlar: Soluk borusunun akciğerlere girdiği noktada ikiye ayrılır ve her biri bir akciğere gider. Bronşlar, akciğer içinde daha küçük bronşçuklara ayrılır ve sonunda alveol adı verilen hava keseciklerine ulaşır.

Akciğerler: Göğüs boşluğunda yer alan iki organdır ve alveol adı verilen hava keseciklerini içerir. Alveollerde gerçekleşen gaz alışverişi sayesinde, havadaki oksijen kana geçerken kandaki karbondioksit havaya geçer [35].

Solunum sistemi, karmaşık bir yapıya sahip olup, temel olarak soluk alma (inspirasyon) ve soluk verme (ekspirasyon) olmak üzere iki aşamada gerçekleşir. İnspirasyon sırasında diyafram ve kaburgalar arası kaslar kasılır. Diyafram düzleşirken kaburgalar arası kaslar kaburgaları yukarı ve dışa doğru çeker. Bu hareketler, göğüs boşluğunun hacmini artırarak akciğerlerin genişlemesine neden olur. Genişleyen akciğerlere, burun ve ağız yoluyla hava dolar. Hava, boğaz, soluk borusu ve bronşlardan geçerek akciğerlere ulaşır ve alveol adı verilen hava keseciklerinde gaz alışverişi gerçekleşir. Alveoller, kandaki karbondioksiti alıp yerine oksijen verir. Ekspirasyon sürecinde ise diyafram ve kaburgalar arası kaslar gevşer. Diyafram kubbeleşirken kaburgalar aşağı ve içe doğru hareket eder. Bu durum, göğüs boşluğunun hacmini azaltarak akciğerlerin daralmasına yol açar. Daralan akciğerlerden karbondioksit, alveollerden başlayarak hava yolları aracılığıyla burun ve ağza doğru hareket eder ve vücuttan dışarı atılır [36]. İnsan vücudundaki solunum sistemi ve akciğerlerin yapısı Şekil 2.1’de gösterilmiştir.



Şekil 2.1 Solunum sistemi ve akciğerlerin yapısı [36].

Solunum sistemi, yaşam için temel bir gereksinim olan nefes alıp verme fonksiyonunun ötesinde pek çok önemli görevi yerine getirir. Konuşma, kokuları algılama ve vücut sıcaklığının düzenlenmesi gibi işlevler de solunum sistemi tarafından gerçekleştirilir. Ayrıca, solunum sistemi vücuda giren zararlı maddeleri ve mikroorganizmaları filtreleyerek savunma mekanizmasına katkıda bulunur. Kandaki oksijen ve karbondioksit seviyelerini düzenleyerek vücudun asit-baz dengesini korumasına yardımcı olur ve iç ortamın kararlılığını sağlar [35].

Solunum sistemini yaşıllık ve çeşitli dış etkenler olumsuz etkileyebilir ve bu da sistemi oluşturan organ ve dokuların zarar görmesine yol açabilir. Bu etkenlerin bazıları, solunan havadaki virüs ve bakteriler gibi enfeksiyon kaynaklı olabilirken, bazıları da hastalık veya yaşlanma sürecinin doğal bir sonucu olarak ortaya çıkabilir. Toz, küf ve polen gibi protein bazlı alerjenlerin solunması, solunum yollarında iltihaplanmaya ve alerjik reaksiyonlara neden olabilir. Enfeksiyonlar, zatürre (pnömoni) veya bronşit gibi ciddi solunum yolu hastalıklarına yol açabilir. Grip ve soğuk algınlığı gibi yaygın enfeksiyonlar da solunum sistemini etkileyebilir. Akciğer kanseri ve kronik obstrüktif akciğer hastalığı (KOAH) gibi solunum bozuklukları, solunum sisteminin işlevini ciddi şekilde bozarak vücuda oksijen verme ve atık gazları filtreleme yeteneğini azaltabilir. Yaşıllık, akciğer kapasitesinde doğal bir azalmaya neden olur ve bu durum, solunum sisteminde yaşa bağlı hasarlarla birleştğinde solunum problemlerine yol açabilir [37].

2.2 SOLUNUM YOLU HASTALIKLARI

Solunum sistemi hastalıkları, pulmonoloji adı verilen tıp dalının uzmanlık alanına girer. Göğüs hastalıklarıyla uğraşan bilimciler olan pulmonologlar solunum sistemini ilgilendiren zatürre, bronşit, astım ve akciğeri ilgilendiren insan sağlığı için tehlikeli birçok hastalığın teşhis, tedavi ve yönetimi üzerinde çalışmaktadırlar [38]. Bazı solunum yolu hastalıkları ve akciğer röntgen görüntüleri aşağıda verilmiştir.

2.2.1 COVID-19


COVID-19 (SARS-CoV-2), insanlarda solunum yolu enfeksiyonlarına yol açan bir virüstür. 2019 yılında ilk olarak Çin'in Wuhan kentinde tespit edilip tüm dünyaya yayılarak bir pandemiye neden olmuştur [39].

Koronavirüs ailesi, 1960'larda keşfedilmiş olup, daha önce 2003 yılında SARS ve 2012 yılında MERS salgınlarına yol açmıştır. 2019 yılında ortaya çıkan salgının kaynağının, Wuhan'daki deniz ürünleri ve hayvan pazarları olduğu düşünülmektedir. Virüsün, insandan insana solunum yoluyla bulaştığı bilinmektedir [40].

Sağlık Bakanlığı tarafından yayınlanan verilere göre, COVID-19'un en sık görülen belirtileri arasında yüksek ateş, tat ve koku kaybı, kuru öksürük ve nefes darlığı yer almaktadır. Hastalığın şiddetli seyrettiği durumlarda zatürre, ağır solunum yetmezliği, böbrek yetmezliği ve hatta ölümle sonuçlanabilecek ciddi komplikasyonlar gelişebilir [41].

COVID-19 salgınının kontrol altına alınması için virüsün yayılımının önlenmesi büyük önem taşımaktadır. Bu nedenle, hastalığın hızlı bir şekilde teşhis edilmesi ve enfekte bireylerin izole edilmesi kritik adımlardır. COVID-19 tanısı için yaygın olarak kullanılan polimeraz zincir reaksiyonu (PCR) testi, hastanın burnundan alınan sürüntü örneği ile gerçekleştirilir. Bu işlem sırasında hastanın başı geriye doğru eğilir ve steril bir çubuk yardımıyla burun deliğinden örnek alınır. Alınan örnek laboratuvar ortamında analiz edilir ve örnekte COVID-19 virüsüne ait RNA'nın varlığı tespit edilirse tanı doğrulanır [42].

PCR testi, COVID-19 tanısında yaygın olarak kullanılan bir yöntem olsa da bazı sınırlamaları vardır. Ölçüm yapan personelin hatası, virüsün mutasyon geçirmesi sonucu ölçüm kitlerinin geçerliliğini yitirmesi ve hastalığın erken dönemlerinde negatif sonuç verme olasılığı gibi faktörler, PCR testinin doğruluğunu etkileyebilir. Bu nedenle, röntgen cihazı, bilgisayarlı tomografi gibi tıbbi görüntüleme cihazları, COVID-19 tanısında PCR testine göre daha doğru ve güvenilir sonuçlar sağlayabilir. Ayrıca, sürüntü yöntemi hastanın yakın temasını gerektirirken, tıbbi görüntüleme yöntemleri temas gerektirmez, bu da sağlık çalışanları için bulaş riskini azaltır. COVID-19 teşhisinde en sık kullanılan görüntüleme yöntemi göğüs röntgenidir. Göğüs röntgeni, akciğerlerdeki iltihaplanma, sıvı birikmesi gibi COVID-19'un tipik belirtilerini gösterebilir ve tanı koymada yardımcı olabilir [40]. COVID-19 bölgelerinin işaretlendiği üç adet akciğer CXR görüntüsü Şekil 2.2'de gösterilmiştir.



Şekil 2.2 Üç adet akciğer X-ray görüntüsündeki COVID-19 bölgeleri [43].

2.2.2 Zatürre (Pnömoni)


Pnömoni, solunum yoluyla bulaşan ve alt solunum yollarını etkileyen bir enfeksiyon türüdür. Bu enfeksiyon, virüslerin akciğerlerde yayılıp çoğalması ve bunun sonucunda akciğer dokusunda iltihaplanmaya neden olmasıyla oluşur. Akciğerlerdeki bu iltihaplanma alanları, tıp literatüründe "tutulum" olarak adlandırılır. Viral zatürre enfeksiyonu sonucu oluşan tutulumlar, akciğer röntgen görüntüleri (CXR) veya bilgisayarlı tomografi (BT) görüntüleri ile tespit edilebilir. Bu görüntüler incelendiğinde farklı tutulum tipleri görülebilir. En yaygın tutulum tipleri olan lobar ve interstisyel tutulumlar, akciğer üzerindeki anatomik yerleşimlerine göre ayırt edilir [44].

Bakteriyel pnömoni, akciğer dokusunda iltihaplanmaya sebep olan bir enfeksiyon türüdür ve öksürük, ateş, göğüs ağrısı, terleme ve nefes darlığı gibi belirtilerle kendini gösterir. Enfeksiyon genellikle akciğerlerin "lob" adı verilen belirli bir bölümünde yoğunlaşır ve bu durum "lobar pnömoni" olarak adlandırılır. Bakteriler, akciğer dokusundaki hücrelere tutunarak çoğalır ve bu bölgede iltihaplanmaya yol açar. İltihaplanma, akciğerin farklı bölgelerinde eşit olmayan bir şekilde dağılabilirken bir lobda daha yoğunken diğerinde daha az belirgin olabilir. Bakteriyel pnömoni, akciğerlerde odaksal ya da yaygın iltihaplanmalara neden olabilir.

Viral pnömoni, genellikle bakteriyel pnömoniye göre daha hafif seyreden bir enfeksiyon türüdür ve yüksek ateş, öksürük, baş ağrısı ve halsizlik gibi belirtilerle karakterizedir. Virüsler, akciğer dokusunun derinliklerinde bulunan interstisyel bölgede iltihaplanmaya yol açar. Bu durum, akciğerlerin röntgen veya tomografi görüntülerinde "buzlu cam opaklığı" olarak adlandırılan tipik bir görünüme neden olur. Hücrelerin içine girerek çoğalan virüsler, akciğer dokusunda yaygın bir iltihap sürecini tetikler. Virüslerin, akciğer dokusunun derinliklerindeki hücreleri hedef alarak iltihaplanmaya neden olması, hastalığın karakteristik özelliklerinden biridir [45].

Pnömoni hastalığının radyolojik görüntülerdeki buzlu cam opaklığı gibi karakteristik özellikleri sebebiyle görüntüleme yöntemlerinden göğüs röntgeni ile akciğerlerdeki iltihaplanma veya sıvı birikmesi gibi belirtileri gözlemlenebilmektedir. Pnömoni hastalığının tespiti için göğüs röntgeni görüntüsü yaygın olarak kullanılan yöntemlerden biridir.

Normal, bakteriyel pnömoni ve viral pnömoni içeren üç adet CXR görüntüsü Şekil 2.3'te gösterilmiştir.




Şekil 2.3 Göğüs X-ray (a) normal, (b) bakteriyel pnömoni ve (c) viral pnömoni [46].

2.2.3 Akciğer Opasitesi

Akciğer opasitesi, radyolojik görüntülemelerde akciğerin belirli bir bölgesinin çevresine göre daha yoğun ve beyaz görünmesini ifade eder. Bu durum, o bölgede normalde bulunması gerekenden daha fazla doku, sıvı veya başka bir maddenin biriktiğini gösterir. Akciğer grafilerinde opasiteler, genellikle hava ile dolu olması gereken akciğer dokusunda yoğunluk artışı şeklinde görülür. Akciğer enfeksiyonları, tümörler veya diğer akciğer hastalıkları gibi çeşitli nedenlerle opasiteler oluşabilir. Opasiteler, akciğer grafisi üzerinde beyaz veya gri renkte görünen ve normal akciğer dokusundan daha yoğun olan alanlar olarak tanımlanabilir [47].

Akciğer opasiteleri, özellikle etiketli bölgelerde, net sınırları olmayan ve bulanık bir görünüme sahip olabilir. Bu durum, "buzlu cam opasitesi" olarak adlandırılır ve akciğerlerin normal sınırlarının kaybolduğu "konsolidasyon" ile birlikte görülebilir. Opasitelerin homojen bir yapıya sahip olmaması, görüntüden net bir şekilde ayrıştırılmalarını ve sınırlarının tam olarak belirlenmesini zorlaştırır. Bu durum, opasitelerin teşhisini ve değerlendirilmesini güçleştirebilir [48].

Akciğer opasiteleri genellikle iyi huyludur ve özellikle hafif seyreden hastalıklarda kendiliğinden iyileşme eğilimindedir. Ancak, akciğer grafisinde görülen opasiteler, akciğerlerde sıvı birikimi, hava yollarının duvarlarında kalınlaşma, akciğer dokusunda iltihap veya kanama gibi farklı durumların habercisi olabilir. Opasitelerin boyutu ve sayısı, tüberküloz, COVID-19, pnömoni gibi bulaşıcı hastalıkların erken teşhisinde önemli bir rol oynayabilir ve bu hastalıkların yayılımının önlenmesine yardımcı olabilir [47]. Akciğer opasite CXR görüntülerini içeren örnekler Şekil 2.4'te gösterilmiştir.



Şekil 2.4 Göğüs X-ray görüntüsünde akciğer opasite örnekleri [49].

2.3 TEŞHİS YÖNTEMLERİ

Solunum yolu hastalıklarının erken ve doğru teşhisi, hastalığın ilerlemesini önleme ve etkili bir tedavi planı oluşturma açısından büyük önem taşır. Teşhis yöntemleri, hastalığın türüne ve özelliklerine göre değişiklik gösterebilir. Bazı yöntemler belirli hastalık gruplarının teşhisinde daha etkili sonuçlar verirken, bazıları ise genel bir değerlendirme sağlar. Solunum yolu hastalıklarının teşhisi için yaygın olarak kullanılan yöntemler şunlardır:

2.3.1 Fiziksel Muayene

Fiziksel muayene, uygun bir ortamda ve hasta konforu sağlanarak yapılan, solunum yolu hastalıklarının teşhisinde ilk ve temel basamağı oluşturan bir değerlendirme yöntemidir. Muayene, standart bir sırayla inspeksiyon (görerek inceleme), palpasyon (elle muayene), perküsyon (vurarak muayene) ve oskültasyon (dinleyerek muayene) adımlarını içerir. Bu sırada, sternum orta çizgisi, spina orta çizgisi, klavikula orta çizgisi, skapula orta çizgisi ve aksilla çizgileri gibi anatomik referans noktaları kullanılarak göğüs duvarı üzerindeki

bulguların yerleri doğru bir şekilde belirlenir. Fiziksel muayene sırasında elde edilen veriler; hırıltı, nefes darlığı gibi solunum sesleri, kalp atış hızı, solunum hızı ve vücut sıcaklığı gibi hayati bulgular ve göğüs duvarının hareketleri, ses şiddeti ve niteliği gibi fiziksel bulguları kapsar. Doktor, tüm bu bulguları dikkatlice değerlendirerek hastalığın tanısında ve tedavi planının oluşturulmasında yol gösterici bilgiler elde eder [50].

2.3.2 Solunum Fonksiyon Testleri

Solunum fonksiyon testleri, akciğerlerin ne kadar iyi çalıştığını ölçmek amacıyla yapılan bir dizi tıbbi testtir. Bu testler, nefes alıp verme esnasında akciğerlerin ne kadar hava aldığını ve bu havayı ne hızla dışarı verdiğini ölçer. Elde edilen veriler, solunum sisteminin genel performansı hakkında bilgi sağlar. Nefes darlığı, öksürük ve hırıltı gibi solunum yolu şikayetleri olan hastalarda, akciğer hastalıklarının tanısı, takibi ve tedavinin etkinliğinin değerlendirilmesinde sıklıkla başvuru bir yöntemdir. Astım, KOAH ve interstisyel akciğer hastalığı gibi yaygın akciğer hastalıklarının teşhisinde solunum fonksiyon testlerinden yararlanılır. Bu testler, hastalıkların erken teşhis edilmesi ve kişiye özel tedavi planlarının oluşturulması açısından büyük öneme sahiptir [51].

2.3.2.1 Spirometri

Akciğerlerin nefes alıp verme kapasitesini ve hızını ölçen bir solunum testi olan spirometri, akciğer sağlığını değerlendirmede önemli bir araçtır. Spirometre adı verilen bir cihaz kullanılarak yapılan testte, hasta cihaza bağlı bir ağızlıktan nefes alıp verir ve cihaz akciğerlere giren ve çıkan havanın hacmini ve hızını kaydeder. Bu ölçümler, sağlıklı bireylerin verileriyle karşılaştırılarak akciğer fonksiyonları hakkında detaylı bilgi sağlar. Spirometri, nefes darlığı, öksürük ve hırıltı gibi solunum yolu şikayetleri olan hastalarda akciğer hastalıklarının teşhis ve takibinde kullanılır. Ayrıca, sigara kullanımı, mesleki risk faktörleri veya ameliyat öncesi değerlendirme gibi durumlarda da akciğer fonksiyonlarını değerlendirmek için spirometriye başvurulabilir. Spirometri sonuçları, akciğer sağlığı hakkında önemli ipuçları verse de tek başına kesin tanı koymak için yeterli değildir ve diğer tanı yöntemleriyle birlikte değerlendirilmelidir [52].

2.3.2.2 Difüzyon Kapasitesi Testi

Difüzyon kapasitesi testi, akciğerlerdeki gaz alışverişinin verimliliğini değerlendiren önemli bir solunum fonksiyon testidir. Bu test, akciğer zarından oksijenin kana, karbondioksitin ise kandan havaya geçiş hızını ölçerek akciğerlerin ne kadar etkili çalıştığını belirler. Özellikle amfizem ve interstisyel akciğer hastalıkları gibi akciğer dokusunda hasara neden olan

durumlarda, difüzyon testi bu hasarın boyutunu ve yaygınlığını anlamada önemli bilgiler sağlar. Test sırasında hasta, karbonmonoksit gibi özel bir gaz içeren havayı solur ve bu gazın akciğer zarından kana geçiş hızı ölçülür. Elde edilen sonuçlar, akciğer zarının yüzey alanındaki azalmaları, kalınlaşmaları veya gaz transferini engelleyen diğer faktörleri ortaya koyarak doktorlara tanı ve tedavi sürecinde rehberlik eder. Difüzyon kapasitesi testi, spirometri gibi diğer solunum fonksiyon testleriyle birlikte değerlendirildiğinde, akciğer hastalıklarının daha doğru bir şekilde teşhis edilmesine ve hastaların tedavi planlarının daha etkili bir şekilde oluşturulmasına yardımcı olur [53].

2.3.2.3 Egzersiz Testi

Egzersiz testi, solunum fonksiyonlarının dinlenme durumundaki değerlendirmesini tamamlayıcı nitelikte olup, kardiyopulmoner sistemin egzersize verdiği yanıtı değerlendirmek için kullanılan önemli bir yöntemdir. Özellikle KOAH, astım ve kalp yetmezliği gibi hastalıklarda, hastanın egzersiz kapasitesini, nefes darlığı eşiğini ve egzersiz sırasında ortaya çıkan fizyolojik değişiklikleri belirlemek amacıyla kullanılır. Egzersiz testi sırasında kalp atım hızı, kan basıncı, solunum sıklığı ve oksijen doygunluğu gibi parametreler sürekli olarak izlenir. Elde edilen veriler, hastanın günlük aktivitelerini ne kadar tolere edebildiği, hangi egzersiz yoğunluğunda nefes darlığı yaşadığı ve tedaviye yanıtının nasıl olduğu gibi önemli bilgiler sağlar. Ayrıca egzersiz testleri, egzersiz rehabilitasyon programlarının planlanması ve takibinde de büyük önem taşır, hastaların egzersiz kapasitelerini artırarak yaşam kalitelerini iyileştirmeye yardımcı olur [54].

2.3.3 Laboratuvar Testleri

Akciğerlerin durumunu gözlemleyebilmek için çeşitli laboratuvar testleri de bulunmaktadır.

2.3.3.1 Balgam Kültürü

Balgam kültürü, solunum yolu enfeksiyonlarının nedenini belirlemek için kullanılan önemli bir mikrobiyolojik tanı yöntemidir. Hastanın öksürükle çıkardığı balgam örneği, laboratuvarda özel besiyerlerine ekilerek enfeksiyona yol açan bakteri, virüs veya mantar gibi mikroorganizmaların üretilmesi ve tanımlanması sağlanır. Bu test, özellikle zatürre, KOAH alevlenmeleri ve tüberküloz gibi solunum yolu enfeksiyonlarının tanısında sıklıkla kullanılır. Balgam kültürü sonuçları, enfeksiyonun bakteriyel, viral veya fungal kökenli olduğunu belirleyerek doktorun doğru tanı koymasına, uygun antibiyotiği seçmesine ve tedavi sürecini izlemesine yardımcı olur. Ayrıca, antibiyotik direncinin tespitinde de önemli bir rol oynar. Bu

sayede, hem hasta için daha etkili bir tedavi planı oluşturulur hem de gereksiz antibiyotik kullanımının önüne geçilerek antibiyotik direnciyle mücadeleye katkı sağlanır [55].

2.3.3.2 Tam Kan Sayımı (Hemogram)

Tam kan sayımı (hemogram), solunum yolu hastalıklarının teşhisinde sıklıkla kullanılan bir laboratuvar testidir. Bu test, kandaki beyaz kan hücrelerinin (lökositler) sayısını ve türlerini inceleyerek enfeksiyon varlığını ve tipini (bakteriyel veya viral) belirlemeye yardımcı olur. Yüksek lökosit sayısı, özellikle nötrofil adı verilen beyaz kan hücrelerindeki artış, genellikle bakteriyel bir enfeksiyonu işaret ederken, lenfositlerde artış viral enfeksiyonlara işaret edebilir. Ayrıca, anemi (kırmızı kan hücresi eksikliği) gibi diğer kan parametrelerindeki değişiklikler de solunum yolu hastalıklarının şiddeti ve seyri hakkında önemli bilgiler sağlayabilir. Örneğin, KOAH gibi durumlarda anemi sıklıkla görülür. Kan sayımı testi tek başına kesin bir tanı koymasa da, diğer klinik bulgular ve görüntüleme yöntemleriyle birleştirildiğinde solunum yolu hastalıklarının teşhisinde önemli bir rol oynar [51].

2.3.3.3 İmmünolojik Testler

İmmünolojik testler, solunum yolu hastalıklarının teşhis ve takibinde önemli bir rol oynar. Vücudun bağışıklık sisteminin hastalığa karşı verdiği yanıtı ölçen bu testler, hastalığın nedenini belirleme, alerjik reaksiyonları değerlendirme ve hastalığın seyrini izleme gibi konularda bilgi sağlar. Örneğin, spesifik IgE testleri alerjik hastalıklarda hastanın belirli alerjenlere karşı duyarlılığını ölçerek teşhisi kolaylaştırırken, otoantikör testleri vücudun kendi dokularına saldırdığı otoimmün hastalıkların varlığını belirlemede kullanılır. Kompleman testleri ise, bağışıklık sisteminin bir parçası olan kompleman proteinlerinin seviyelerini ölçerek enfeksiyon veya iltihaplanma gibi durumları değerlendirir. İmmünolojik testler sayesinde hastalığın şiddeti değerlendirilebilir ve tedaviye yanıt takip edilebilir. Bu testler, diğer klinik bulgular ve görüntüleme yöntemleriyle birlikte değerlendirildiğinde, solunum yolu hastalıklarının daha doğru ve hızlı bir şekilde teşhis edilmesine olanak tanır [51].

2.3.3.4 Alerji (Prick) Testi

Alerji (prick) testi, astım ve alerjik rinit gibi solunum yolu hastalıklarının tanısında ve yönetiminde kritik bir rol oynar. Hastanın hangi maddelere alerjik olduğunu belirleyerek, hastalığı tetikleyen faktörleri ortaya koyar ve kişiye özel tedavi planı oluşturulmasını sağlar. Deri prick testi gibi hızlı yöntemlerle alerjenler tespit edilir ve tedaviye başlama süreci hızlandırılır. Cilde uygulanan alerjenler, kısa sürede reaksiyona neden olarak hastanın hangi maddelere karşı duyarlı olduğunu gösterir. Böylece, hasta alerjenlerden kaçınarak veya spesifik

immünoterapi gibi yöntemlerle tedavi edilerek hastalık kontrol altına alınır. Alerji testleri ayrıca hastalığın şiddetini değerlendirmeye ve tedaviye yanıtın izlenmesine de yardımcı olur. Özellikle astım, alerjik rinit ve atopik dermatit gibi atopik hastalıklarda alerjenin belirlenmesi, hastalığın daha etkili bir şekilde yönetilmesi için büyük önem taşır [51].

2.3.3.5 Torasentez

Torasentez, akciğerler ve göğüs duvarı arasındaki boşlukta (plevral boşluk) biriken fazla sıvının (plevral efüzyon) boşaltılması için uygulanan bir tıbbi işlemdir. Plevral efüzyon, solunum güçlüğü, göğüs ağrısı, öksürük ve göğüste ağırlık hissi gibi rahatsızlıklara yol açabilir. Torasentez işlemi, bu belirtileri hafifletmek ve aynı zamanda sıvı birikiminin nedenini teşhis etmek amacıyla yapılır. İşlem sırasında steril koşullar altında ince bir iğne kullanılarak plevral boşluğa girilir ve biriken sıvı dikkatlice dışarı çekilir. Elde edilen sıvı örnekleri laboratuvarda incelenerek, sıvı birikiminin nedeni belirlenir ve uygun tedavi planı oluşturulur [56].

2.3.3.6 Plevra Biyopsisi

Plevra biyopsisi, akciğerleri çevreleyen plevra zarından doku örneği alınarak mikroskop altında incelenmesini sağlayan bir işlemdir. Genellikle akciğer zarları arasında sıvı birikmesi (plevral efüzyon) gibi durumlarda, sıvı birikiminin nedenini anlamak için yapılır. Biyopsi, özel bir iğne kullanılarak, lokal anestezi altında ve genellikle görüntüleme yöntemlerinin rehberliğinde gerçekleştirilir. Bazı durumlarda ise, açık cerrahi yöntemlerle daha büyük doku örnekleri alınabilir. Alınan doku örnekleri patoloji ve mikrobiyoloji laboratuvarlarında incelenerek enfeksiyon, kanser veya diğer hastalıkların varlığı araştırılır. Plevra biyopsisi, plevral efüzyonun nedenini kesin olarak belirlemek ve uygun tedavi planını oluşturmak için başvuru olan önemli bir tanı yöntemidir [57].

2.3.4 Görüntüleme Yöntemleri

Teknolojinin ilerlemesi, radyoloji alanında önemli gelişmelere yol açmış ve bilgisayarlı tomografi (BT), röntgen (X-Ray), ultrasonografi, manyetik rezonans görüntüleme (MRG), pozitron emisyon tomografisi (PET) gibi gelişmiş görüntüleme yöntemlerinin yaygın olarak kullanılmasını sağlamıştır [58]. Bu yöntemler, hastalıkların teşhis ve tedavisinde daha detaylı ve doğru bilgiler sağlayarak tıp alanında önemli bir ilerleme kaydedilmesine katkıda bulunmuştur. Ayrıca, son yıllarda bu yöntemlerin birleştirilmesiyle oluşan hibrid görüntüleme teknikleri de kullanılmaya başlanmış ve tanısal doğruluk daha da artırılmıştır.

2.3.4.1 Röntgen (X-Ray)

Günümüzde tıp teknolojileri hızla ilerlese de basit akciğer grafisi hala birçok avantajıyla sağlık alanında önemli bir yere sahip. Düşük maliyetli, kolay erişilebilir ve hızlı sonuç veren bir yöntem olması, özellikle acil servisler ve rutin kontrollerde tercih edilmesini sağlıyor. Akciğer grafisinin sunduğu düşük radyasyon dozu da önemli bir avantaj. Göğüs ağrısı, nefes darlığı veya öksürük gibi şikayetlerle gelen hastalarda genellikle ilk yapılan tetkik akciğer grafisidir. Bu yöntemle akciğerlerin genel yapısı, boyutu ve olası anormallikler (kitleler, sıvı birikimi gibi) değerlendirilebilir. Ayrıca kalp ve kemik yapıları hakkında da bilgi sağlaması, akciğer grafisini ameliyat öncesi değerlendirme, akciğer metastazı taraması ve iş başvurularında rutin bir uygulama haline getirmiştir [58]. Göğüs röntgen görüntüsünü içeren örnek görüntü Şekil 2.5'te gösterilmiştir.




Şekil 2.5 Göğüs röntgeni (X-ray) görüntüsü [58].

2.3.4.2 Bilgisayarlı Tomografi (BT)

Bilgisayarlı tomografi (BT), özellikle göğüs hastalıklarının teşhisinde, geleneksel akciğer grafisine göre çok daha detaylı görüntüleme olanağı sunar. Spiral BT teknolojisi sayesinde akciğerlerin tamamı tek bir nefes tutma süresince taranabilir ve daha önceki yöntemlerle tespit edilemeyen küçük lezyonlar bile görüntülenebilir. BT cihazlarındaki dedektör sayısının artması, tarama süresini kısaltırken görüntü kalitesini de artırmıştır. Böylece hastalar daha az radyasyona maruz kalırken, radyologlar daha detaylı ve net görüntüler elde eder [59].

BT ile elde edilen hacimsel veriler, aksiyal, sagittal ve koronal düzlemde çoklu düzlem rekonstrüksiyonları yapılmasına, üç boyutlu görüntüler oluşturulmasına ve sanal bronkoskopi gibi işlemlerin gerçekleştirilmesine olanak tanır. Ayrıca, iş istasyonlarında kullanılan farklı pencere ayarları, akciğer parankimi, mediasten ve kemik yapılar gibi farklı dokuların daha iyi değerlendirilmesini sağlar. Sonuç olarak BT, akciğerlerin iç yapısı, kitlelerin boyutu, tümörlerin yayılımı gibi konularda daha detaylı bilgi sağlayarak, akciğer hastalıklarının tanısında, takibinde ve tedavisinde geleneksel radyografiye göre daha üstün bir yöntem olarak kabul edilir [59]. Göğüs bilgisayarlı tomografi görüntüsünü içeren örnek görüntü Şekil 2.6'da gösterilmiştir.




Şekil 2.6 Göğüs bilgisayarlı tomografi (BT) görüntüsü [59].

2.3.4.3 Manyetik Rezonans Görüntüleme (MRG)

Manyetik Rezonans Görüntüleme (MRG), vücuttaki hidrojen atomlarının manyetik alandaki davranışlarını analiz ederek detaylı görüntüler elde etmeyi sağlayan bir yöntemdir. Vücudumuzun büyük bir kısmı sudan oluştuğu ve hidrojen atomu bakımından zengin olduğu için MRG birçok organın görüntülenmesinde etkili bir araçtır. Ancak akciğer dokusu düşük su içeriğine sahip olduğundan, MRG akciğerlerin doğrudan görüntülenmesinde BT kadar etkili değildir. Yine de MRG akciğerlerdeki kitlelerin, mediastenin, toraks duvarının ve kalbin değerlendirilmesinde sıklıkla tercih edilir çünkü yumuşak doku kontrastını iyi gösterir ve iyonlaştırıcı radyasyon içermez. Ayrıca MRG, akciğer fonksiyonlarını değerlendirmek için kullanılabilen özel sekanslara da sahiptir. Dezavantajları ise, çekim süresinin uzun olması, maliyetinin yüksek olması ve bazı hastalar için uygun olmamasıdır. Sonuç olarak MRG, yumuşak dokuların görüntülenmesinde daha başarılıdır ve özellikle akciğerlerin çevresindeki

dokuların incelenmesinde yaygın olarak kullanılır [59]. Göğüs manyetik rezonans görüntüsünü içeren örnek görüntü Şekil 2.7’de gösterilmiştir.




Şekil 2.7 Göğüs manyetik rezonans (MRG) görüntüsü [60].

2.3.4.4 Pozitron Emisyon Tomografi (PET)

Pozitron emisyon tomografisi (PET), özellikle bilgisayarlı tomografi (BT) ile birleştirilmiş hali olan PET/BT, akciğer görüntülenmesinde son yıllarda önemli bir yere sahip olmuştur. Akciğer kanserinin tanısında, evrelemesinde ve tedaviye yanıtın değerlendirilmesinde invaziv yöntemlere olan ihtiyacı azaltarak önemli bir rol oynar. PET/BT'nin yüksek radyasyon dozu ve akciğer dokusunun düşük yoğunluğu gibi bazı sınırlamaları vardır. Bu nedenle manyetik rezonans görüntüleme (MR) ile birleştirilmiş PET/MR sistemleri geliştirilmiştir [61].

PET/MR, özellikle akciğer perfüzyon ve ventilasyonunun değerlendirilmesinde, yumuşak doku kontrastı gerektiren mediastinal ve göğüs duvarı tümörlerinin incelenmesinde ve uzak metastazların tespitinde potansiyel avantajlar sunar. Her ne kadar PET/MR teknolojisi gelişmekte olsa da PET/BT kısa çekim süresi, yaygınlığı ve yüksek tanısal doğruluğu nedeniyle akciğer görüntülemesinde standart yöntem olarak konumunu korumaktadır [61]. Göğüs pozitron emisyon tomografi görüntüsünü içeren örnek görüntü Şekil 2.8’de gösterilmiştir.



Şekil 2.8 Göğüs pozitron emisyon tomografi (PET) görüntüsü [59].

2.3.4.5 Ultrasonografi (USG)

Ultrasonografi (USG), ses dalgaları kullanarak vücut içindeki yapıların görüntüsünü elde eden bir yöntemdir. Akciğerlerin hava dolu yapısı nedeniyle ultrasonun akciğer görüntülenmesinde kullanımı uzun süre sınırlı kalsa da teknolojik gelişmeler sayesinde özellikle plevra sıvısı, pnömotoraks, konsolidasyon ve yüzeye yakın kitlelerin değerlendirilmesinde önemli bir yer edinmiştir. Non-invaziv, hızlı, ucuz ve taşınabilir olması gibi avantajlarının yanı sıra derinlemesine penetrasyonun sınırlı olması ve hava dolu bölgelerde görüntü kalitesinin düşmesi gibi dezavantajları da bulunur. Sonuç olarak ultrasonografi, akciğer hastalıklarının değerlendirilmesinde diğer görüntüleme yöntemlerini destekleyen tamamlayıcı bir yöntem olarak kullanılmaktadır [62]. Göğüs ultrason görüntüsünü içeren örnek görüntü Şekil 2.9'da gösterilmiştir.



Şekil 2.9 Göğüs ultrasonografi (USG) görüntüsü [62].

2.3.4.6 Bronkoskopi

Bronkoskopi, solunum yollarını (bronşlar) doğrudan incelemek, biyopsi almak ve çeşitli müdahaleler yapmak için kullanılan bir tanı ve tedavi yöntemidir. Bu işlemde, ucunda kamera ve ışık kaynağı bulunan ince, esnek bir tüp (bronkoskop) burun veya ağız yoluyla solunum yollarına ilerletilir. Anormal akciğer filmi, kronik öksürük, tekrarlayan pnömoniler, balgamda kan görülmesi (hemoptizi) ve açıklanamayan plevral efüzyon gibi durumlarda sıklıkla tercih edilir. Bronkoskopi sadece tanı koymak için değil, aynı zamanda tedavi amaçlı da kullanılır; hava yollarındaki yabancı cisimlerin çıkarılması, tümörlerin tedavisi ve solunum yollarındaki darlıkların stent ile açılması gibi işlemler bronkoskopi ile gerçekleştirilebilir. Hem tanısal kesinliği hem de tedavi başarısı yüksek olan bu yöntem, solunum sistemi hastalıklarının teşhis ve tedavisinde hekimlere bilgiler sunarak uygun tedavi planlarının oluşturulmasına katkı sağlar [51]. Göğüs bronkoskopi görüntüsünü içeren örnek görüntü Şekil 2.10'da gösterilmiştir.



Şekil 2.10 Göğüs bronkoskopi görüntüleme [63].

2.4 GÖĞÜS RÖNTGENİ


Göğüs röntgeni, akciğer hastalıklarının teşhisinde kullanılan en yaygın ve temel görüntüleme yöntemlerinden biridir. Bu yöntem, X-ışınlarının farklı dokulardan farklı oranlarda geçme özelliğinden yararlanarak göğüs boşluğunun iki boyutlu görüntülerini oluşturur. X-ışınları, kemik gibi yoğun dokulardan daha az geçtiği için film üzerinde beyaz görünürken, akciğerler gibi hava içeren dokulardan daha kolay geçtiği için siyah görünür. Bu kontrast sayesinde, radyologlar akciğerlerdeki anormallikleri, kalp büyümesini, kemik kırıklarını ve diğer göğüs hastalıklarını tespit edebilir ve hastalığın seyri hakkında önemli bilgiler elde edebilir [40].

Göğüs röntgeni, hızlı, nispeten ucuz ve radyasyon dozu düşük olması nedeniyle birçok klinik durumda başvurulmuş ilk görüntüleme yöntemidir. Özellikle acil servislerde, hastaların hızlı bir şekilde değerlendirilmesi gereken durumlarda ve rutin sağlık taramalarında sıklıkla kullanılır [31].

2.4.1 X Işını

X-ışınları, yüksek enerjili ve kısa dalga boylu elektromanyetik radyasyon türüdür. Maddelerin iç yapılarını görüntülemeye kullanılan bu ışınlar, 1895 yılında Wilhelm Röntgen tarafından tesadüfen keşfedilmiştir [40]. Röntgen, o dönemde elektriksel boşalmalar üzerine yaptığı çalışmalar sırasında bir katot tüpünde gözlemlenen floresan ışımının kaynağını araştırırken X-ışınlarına rastlamıştır. Bu keşif, tıp alanında devrim yaratarak tanı ve tedavi yöntemlerinde önemli ilerlemelere yol açmıştır [64].

Röntgen, katot tüpü deneyleri sırasında elektronların cama çarpmasıyla oluşan X-ışınlarının opak malzemelerden geçebildiğini ve floresan ekranı aydınlatıldığını gözlemlemiştir. Bu keşif, tıpta vücut içlerinin görüntülenmesini sağlayarak devrim yaratmıştır. Şekil 2.11’de gösterilen Röntgen’in eşi Anna Bertha Ludwig’e ait X-ışını görüntüsü, kemikleri ve yüzüğü net bir şekilde göstererek bu ışınların tıptaki kullanım potansiyelini kanıtlamıştır [40].




Şekil 2.11 İlk X ışını görüntüsü [40].

X-ışınları, yüksek enerjili ve kısa dalga boylu elektromanyetik radyasyon türüdür. Maddelerin iç yapılarını görüntülemeye kullanılan bu ışınlar, 1895 yılında Wilhelm Röntgen tarafından, elektriksel boşalmalar üzerine yaptığı çalışmalar sırasında tesadüfen keşfedilmiştir. Farklı yoğunluktaki dokulardan farklı oranlarda geçebilme özelliği sayesinde X-ışınları, vücudun iç yapısının iki boyutlu bir görüntüsünü oluşturur. Bu görüntüler, doktorların hastalıkları teşhis etmesine ve tedavi planları oluşturmaya yardımcı olur. X-ışınlarının keşfi, tıp alanında devrim niteliğinde bir gelişme olmuş ve bugün akciğer hastalıklarının teşhisinden kemik kırıklarının

tespitine, diş hekimliğinden kanser tedavisine kadar birçok farklı alanda yaygın olarak kullanılmaktadır [31]. X-ışınları, madde ile etkileşime girdiğinde iyonlaşmaya neden olan bir radyasyon türüdür. Bu nedenle, uzun süreli veya yüksek dozda X-ışınına maruz kalma canlı dokulara zarar verebilir ve kanser riskini artırabilir. Ancak, tıpta tanı amacıyla kullanılan X-ışınları genellikle düşük dozlardadır ve faydaları potansiyel risklerinden çok daha fazladır. Bilgisayarlı tomografi, anjiyografi, mamografi ve nükleer tıp gibi birçok tıbbi görüntüleme yöntemi, X-ışınlarını kullanarak hastalıkların erken teşhisini ve etkili tedavisini mümkün kılar. X-ışınlarının tıpta kullanımı, hastalıkların teşhis ve tedavisinde önemli bir rol oynar ve yaşam kurtarıcı olabilir [40].


X-ışını tüpü, X-ışınları üretmek için kullanılan, vakum ortamında çalışan bir cihazdır. Şekil 2.12’de gösterilen X-ışın tüpü, çerisinde katot adı verilen negatif bir elektrot ve anot adı verilen pozitif bir elektrot (hedef) bulunur. Katottan salınan elektronlar, yüksek gerilim altında hızlandırılarak anota doğru yönlendirilir. Elektronlar anot yüzeyine çarptığında, kinetik enerjilerinin bir kısmı X-ışını fotonlarına dönüşür. Bu şekilde üretilen X-ışınları, tıbbi görüntülemede ve diğer birçok alanda kullanılır [40]. X-ışını tüpünün anot kısmı, genellikle tungsten veya molibden gibi yüksek atom numarasına sahip bir metalden yapılır. Elektronların çarpmasıyla oluşan yüksek ısı nedeniyle anot sürekli soğutulmalıdır. Üretilen X-ışınları, farklı dokular tarafından farklı oranlarda emilir ve bu özellik tıbbi görüntüleme gibi alanlarda iç yapıların görüntülenmesini sağlar. X-ışını spektrumu, hedef malzemenin türüne ve tüp gerilimine bağlı olarak sürekli veya karakteristik spektrum şeklinde olabilir. Ayrıca, X-ışını demetinin kalitesini ve yönünü kontrol etmek için filtrasyon ve kollimatör gibi teknikler kullanılır [31].



Şekil 2.12 X ışın tüpü sistemi [40].

2.4.2 Dijital Radyografi

Dijital radyografi, geleneksel film tabanlı radyografiye kıyasla tıbbi görüntülemeye önemli bir ilerlemeyi temsil eder. Geleneksel yöntemlerde X-ışınları bir film üzerine düşerek görüntüyü oluştururken, dijital radyografide X-ışınları dijital sensörler tarafından algılanır ve bilgisayar ortamında işlenebilir hale getirilir [31]. Bu sayede görüntüler anında elde edilebilir, bilgisayar ortamında işlenerek görüntü kalitesi artırılabilir ve elektronik olarak saklanabilir veya paylaşılabilir. Ayrıca, dijital radyografi hastaların daha az radyasyona maruz kalmasını sağlar. Dijital radyografi sistemleri, X-ışınları kullanarak tıbbi görüntüler elde etmek için kullanılan modern cihazlardır. Bu sistemler, veri toplama, veri işleme ve görüntü işleme olmak üzere üç ana bölümden oluşur. Veri toplama aşamasında, X-ışınları hastanın vücudundan geçerek bir dijital dedektör tarafından algılanır ve analog bir sinyal oluşturulur. Bu sinyal daha sonra analog-dijital dönüştürücü (ADC) aracılığıyla dijital bir sinyale dönüştürülür. Dijital sinyal, görüntü işleme yazılımları kullanılarak işlenir ve tam bir tıbbi görüntüye dönüştürülür. Elde edilen dijital görüntü üzerinde radyolog tarafından kontrast ve parlaklık gibi parametreler ayarlanarak daha detaylı ve doğru bir teşhis sağlanabilir. Dijital radyografinin en önemli avantajlarından biri, görüntü işleme olanakları sayesinde radyasyon dozunun düşürülmesi ve tekrarlanan pozlama ihtiyacının azaltılmasıdır [65]. Dijital X-ray sistemi ve ana bileşenleri Şekil 2.13'te gösterilmiştir.



Şekil 2.13 Dijital X-ray sisteminin ana bileşenleri [65].

2.4.3 Göğüs Röntgen Görüntüsünün Yorumlanması

Göğüs röntgenleri, COVID-19 gibi enfeksiyonların teşhisinde ve göğüs kafesi içindeki organ ve yapıların değerlendirilmesinde kritik bir rol oynar. Radyoloji uzmanları ve klinisyenler, bu görüntülerde yer alan anatomik yapıları ve olası hastalık belirtilerini dikkatlice inceleyerek tanı koyma ve tedavi planlama aşamalarına önemli katkılarda bulunurlar. Bu nedenle, göğüs röntgen görüntülerinin doğru bir şekilde yorumlanması ve normal ile patolojik bulguların ayırt edilmesi, hastaların etkili bir şekilde yönetilmesi için temel bir beceridir [66].

Göğüs röntgeni, akciğerler, kalp ve torasik bölgedeki diğer yapıların anatomik ve patolojik özelliklerini değerlendirmek için sıklıkla kullanılan bir görüntüleme yöntemidir. Radyologlar, görüntü kalitesini ve hasta pozisyonunu değerlendirdikten sonra, kaburgalar, köprücük kemikleri ve omurga gibi anatomik referans noktalarını kullanarak anormallikleri tespit eder [67]. Akciğer opasiteleri, plevral efüzyon, nodüller, konsolidasyonlar, pnömotoraks ve kardiyomegali gibi patolojik bulgular, farklı akciğer ve kalp hastalıklarına işaret edebilir. Bu bulguların boyutları, şekilleri, yoğunlukları ve dağılımları, radyologların spesifik tanı koymasına yardımcı olur. Örneğin, akciğer opasiteleri, pnömoni veya tümör gibi çeşitli durumlara bağlı olarak farklı görünümde olabilir. Plevral efüzyon ise, akciğerleri saran zarlar arasında sıvı birikimi olduğunda, röntgende kostofrenik açılarda belirgin bir bulanıklık olarak gözlenir. Radyologlar, bu bulguları dikkatlice değerlendirerek, hastalıkların teşhisinde ve tedavi planlamasında önemli bilgiler sağlarlar [68].

Radyologlar, göğüs röntgenlerinde efüzyon (sıvı birikimi), nodül (küçük yuvarlak oluşumlar) ve lenfadenopati (lenf bezi büyümesi) gibi patolojik bulguları değerlendirerek enfeksiyon, kötü huylu tümör veya kalp yetmezliği gibi hastalıkların nedenini belirlemeye çalışırlar. Efüzyonun miktarı, yerleşimi ve yoğunluğu; nodüllerin boyutu, şekli, kenar özellikleri ve kalsifikasyon durumu; ve lenfadenopatilerin konumu ve boyutu gibi faktörler, tanı koymada önemli kriterlerdir. Radyologlar, bu bulguları normal anatomik yapılarla karşılaştırarak ve hastalıkların karakteristik görüntüleme özelliklerini göz önünde bulundurarak tanıya yönelik bir değerlendirme yaparlar ve gerektiğinde, daha kesin tanı için ek görüntüleme yöntemleri (BT, MRG gibi) veya invaziv işlemler (biyopsi gibi) önererek hastanın doğru yönetimine katkıda bulunurlar [69].

Göğüs röntgenleri, solunum sistemi hastalıklarının teşhis ve takibinde sıklıkla kullanılan bir görüntüleme yöntemidir. Bakteriyel, viral ve fungal pnömoniler gibi farklı nedenlere bağlı akciğer enfeksiyonlarının radyografik paterndeki farklılıkları, bu yöntemin tanısal değerini

artırır. Akciğer tümörlerinin erken teşhisi ve evrelendirilmesinde de önemli bir rol oynar. Nodüller, kitleler ve lenfadenopati gibi maligniteye işaret eden bulguların boyutu, şekli, marj özellikleri ve yerleşim yerleri, kötü huylu tümör olasılığını belirlemede dikkate alınır. KOAH gibi kronik solunum yolu hastalıklarının ve interstisyel akciğer hastalıklarının karakteristik bulguları da göğüs röntgenlerinde görülebilir. COVID-19 gibi pandemi süreçlerinde de sıklıkla kullanılan göğüs röntgenleri, hastalığın akciğerler üzerindeki etkilerini ve komplikasyonlarını değerlendirmede yardımcı olur. Ancak, iki boyutlu bir görüntüleme yöntemi olması nedeniyle bazı patolojik süreçlerin erken tanısında duyarlılığı sınırlı olabilir ve bu gibi durumlarda BT veya MR gibi daha detaylı görüntüleme yöntemlerine başvurulabilir [70].

2.4.4 Göğüs Röntgen Görüntüsünde Radyografik İşaretler ve Bulgular

Göğüs röntgenleri, toraks boşluğunun iç yapısı hakkında değerli bilgiler sunar ve çeşitli akciğer hastalıklarının varlığını gösterebilecek radyografik işaret ve bulguları ortaya çıkarabilir. Bu işaret ve bulguları doğru bir şekilde anlamak ve yorumlamak, hastalıkların teşhisi ve tedavi planlamasının oluşturulması için kritik öneme sahiptir. Aşağıda göğüs röntgenlerinde gözlemlenen bazı yaygın radyografik işaret ve bulgular yer almaktadır [71].

Akciğer opasiteleri, akciğer grafisinde normal akciğer dokusundan daha yoğun ve beyaz görünen bölgelerdir. Bu durum, o bölgede hava yerine sıvı, iltihap, doku veya kitle gibi başka bir maddenin biriktiğini gösterir. Enfeksiyon, iltihaplanma, ödem veya tümör gibi çeşitli nedenlerle ortaya çıkabilen akciğer opasiteleri, görüntüde sınırları belirsiz ve yaygın bir yoğunluk artışı şeklinde (bulanıklık), 3 cm'den küçük, genellikle yuvarlak veya oval şekilli ve sınırları keskin bir yoğunluk artışı şeklinde (nodül) veya akciğer dokusunun hava yerine sıvı ile dolması sonucu oluşan, sınırları nispeten belirgin ve homojen bir yoğunluk artışı şeklinde (konsolidasyon) görülebilir [72].

Akciğer konsolidasyonu, hava ile dolu olması gereken akciğer alveollerinin sıvı, iltihap hücreleri veya başka bir madde ile dolması sonucu oluşan bir durumdur. Bu, akciğer dokusunun o bölgesinin katılaşmasına ve hava geçişinin azalmasına neden olur. Konsolidasyonlar genellikle pnömoni gibi enfeksiyonlara bağlı olarak gelişir, ancak akciğer ödemi, akciğer kanaması ve tümör gibi başka nedenlerle de ortaya çıkabilir [72].

Plevral efüzyon, plevral boşlukta sıvı birikimi olduğunda ortaya çıkar. Göğüs röntgeninde, kostofrenik açının körelmesi ve menisküs işareti gibi karakteristik bulgularla kendini gösterir [73].

Pnömotoraks, akciğer ile göğüs duvarı arasındaki plevral boşlukta hava birikmesi sonucu akciğerin kısmen veya tamamen çökmesi durumudur. Röntgen görüntüsünde, bu durum akciğer kenarında hava dolu, hiperlüksan (daha koyu/siyah) bir alan ve akciğer dokusunda içe doğru çekilme (retraksiyon) olarak gözlemlenir [73].

Bu radyografik bulgular, hekimlere tanı koyma ve tedavi planlama sürecinde önemli bilgiler sağlar. Ancak, göğüs röntgenlerinin iki boyutlu bir görüntüleme yöntemi olması nedeniyle, bazı patolojik süreçlerin erken tanısında duyarlılığının sınırlı olduğu unutulmamalıdır. Bu nedenle, tanısal süreçte bilgisayarlı tomografi (BT) gibi diğer görüntüleme yöntemleriyle desteklenmesi gerekebilir. Özetle, göğüs röntgenleri, torasik hastalıkların tanısında ve takibinde önemli bir yere sahiptir. Radyografik bulguların doğru yorumlanması, hekimlerin hastalığın nedenini belirlemesine ve uygun tedaviyi planlamasına yardımcı olur.

BÖLÜM 3

YAPAY ZEKA VE DERİN ÖĞRENME

3.1 YAPAY ZEKA

Yapay zekâ, makine öğrenimi ve derin öğrenme gibi tekniklerle makinelere insan benzeri düşünme, öğrenme, problem çözme ve karar verme yetenekleri kazandırmayı hedefleyen bir bilim dalıdır. Bu disiplin, bilgisayar bilimleri, matematik, sinir bilimi, felsefe ve dilbilim gibi çok disiplinli bir yaklaşım gerektirir [74]. Yapay zekanın temel amacı, makinelere çevrelerini algılamalarını, verilerden öğrenmelerini ve bu öğrenmelerini kullanarak yeni durumlara uyum sağlamalarını sağlamaktır. Bu sayede, makineler karmaşık sorunları çözebilir, insanlarla etkileşime geçebilir ve hatta yaratıcı işler yapabilirler [75].

Yapay zekâ kavramı, ilk olarak Alan Turing tarafından ortaya atılmıştır. Turing, "Hesap Makineleri ve Zekâ" adlı çalışmasında makinelerin düşünme yeteneğine sahip olup olmadığı sorusunu sorarak yapay zekâ alanındaki ilk tartışmaları başlatmıştır. Geliştirdiği Turing testi ise bir makinenin insan düzeyinde düşünme yeteneğine sahip olup olmadığını belirlemek için kullanılan bir yöntemdir [75]. Yapay zekâ sistemleri, genel olarak zayıf yapay zekâ ve güçlü yapay zekâ olarak ikiye ayrılır. Zayıf yapay zekâ, belirli bir görevi yerine getirmek için tasarlanmış ve bu görevin dışına çıkmayan sistemlerdir. Örneğin, satranç oynayan bir bilgisayar programı veya bir yüz tanıma sistemi zayıf yapay zekâ örnekleridir. Güçlü yapay zekâ ise insan düzeyinde genel zekâ ve bilinç sahibi olan hipotetik bir sistemdir. Bu tür bir yapay zekâ, herhangi bir entelektüel görevi insan kadar iyi veya daha iyi yapabilir [74].


Yapay zekâ günümüzde başta sağlık, ekonomi, endüstriyel, eğitim, sosyal alanlar başta olmak üzere birçok alanda gelişmiş ve gelişmeye de devam etmektedir.

3.2 MAKİNE ÖĞRENMESİ

Makine öğrenimi, yapay zekanın bir alt dalı olup, bilgisayarların insan müdahalesi olmaksızın verilerden öğrenmesini ve bu verilerdeki örüntüleri kullanarak yeni verilere uygulanabilecek modeller oluşturmasını sağlar. Bu modeller, sınıflandırma, regresyon ve kümeleme gibi çeşitli

görevleri yerine getirmek için kullanılabilir. Günümüzde artan veri çeşitliliği ve erişilebilirliği, makine öğrenimi sistemlerinin daha büyük ve kapsamlı veri setleri üzerinde eğitilmesine olanak tanırken, bilgisayarların artan işlem gücü de daha karmaşık ve gelişmiş modellerin geliştirilmesini mümkün kılmaktadır. Bu sayede makine öğrenimi, sağlık, finans, eğitim ve pazarlama gibi birçok alanda uygulama alanı bulmaktadır [76].

Makine öğrenmesi literatürde genel anlamda denetimsiz öğrenme (unsupervised learning), denetimli öğrenme (supervised learning) ve pekiştirmeli öğrenme (reinforcement learning) şeklinde üç başlık altında incelenir [29]. Makine öğrenmesi başlıkları Şekil 3.1’de gösterilmiştir.



Şekil 3.1 Makine öğrenmesi hiyerarşisi [77].

3.2.1 Denetimsiz Öğrenme

Denetimsiz öğrenme, makine öğrenmesinin temel bir dalı olup, önceden etiketlenmiş veri kümeleri olmadan verilerdeki gizli yapıları ve örüntüleri keşfetmeyi amaçlar. Bu yöntemde, algoritmalar verilerdeki benzerlikleri ve farklılıkları kullanarak veri noktalarını doğal gruplara ayırır. Etiketlenmiş veriler olmadan, makine kendi kendine öğrenir. Bu, denetimsiz öğrenmeyi keşif ve keşif analizi için güçlü bir araç haline getirir; özellikle büyük ve karmaşık veri kümelerindeki bilinmeyen yapıları ortaya çıkarmak için idealdir. Denetimsiz öğrenme, veri madenciliği, müşteri segmentasyonu, anormallik tespiti gibi birçok alanda uygulama bulur. Bu yöntemin avantajları arasında etiketlenmiş veri ihtiyacının olmaması ve yeni bilgiler keşfetme potansiyeli sayılabilirken, dezavantajları arasında sonuçların yorumlanmasının zorluğu ve algoritma seçiminin önemi yer alır [32].

Denetimsiz öğrenme, makine öğrenmesinin temel bir dalı olup, önceden etiketlenmiş veri kümeleri olmadan verilerdeki gizli yapıları ve örüntüleri keşfetmeyi amaçlar. Bu yöntemde, algoritmalar verilerdeki benzerlikleri ve farklılıkları kullanarak veri noktalarını doğal gruplara ayırır. Etiketlenmiş veriler olmadan, makine kendi kendine öğrenir ve bu da onu keşif ve keşif analizi için güçlü bir araç haline getirir [29]. Denetimsiz öğrenme, kümeleme ve boyut indirgeme olmak üzere iki ana teknikten oluşur [15]. Kümeleme, veri noktalarını benzerliklerine göre gruplara ayırma işlemidir ve müşteri segmentasyonu, görüntü işleme gibi alanlarda kullanılır. Boyut indirgeme ise yüksek boyutlu veri kümelerini daha düşük boyutlu bir uzaya dönüştürerek veriyi görselleştirmeyi ve analiz etmeyi kolaylaştırır. Denetimsiz öğrenmenin diğer önemli uygulamaları arasında yoğunluk tahmini, özellik öğrenme ve ilişkilendirme kuralı bulma yer alır. Bu teknikler, verilerin yoğunlaştığı bölgeleri belirlemek, önemli özellikleri keşfetmek ve veri ögeleri arasındaki ilişkileri analiz etmek için kullanılır [32].

3.2.1.1 K-Ortalamlar (K-Means)

K-ortalamlar algoritması, verileri homojen alt gruplara ayırmayı hedefleyen, 1967 yılında MacQueen tarafından geliştirilmiş klasik bir kümeleme yöntemidir. Bu algoritma, veri kümesini önceden belirlenen k sayıda kümeye böler. Algoritma, rastgele seçilen küme merkezleri ile başlar ve her veri noktasını en yakın merkezine atar. Yeni küme merkezleri, kümedeki noktaların ortalaması alınarak hesaplanır ve bu işlem merkezlerde önemli bir değişiklik olmayana kadar tekrarlanır. K-ortalamlar algoritmasının temel amacı, küme içi varyansı en aza indirip kümeler arası ayrımı maksimize ederek benzer verileri aynı kümede toplamak ve farklı verileri farklı kümelere ayırmaktır. Algoritmanın başarısı, başlangıçtaki küme merkezlerinin konumuna ve kullanılan uzaklık ölçüsüne bağlıdır [29].

3.2.1.2 Apriori

Apriori algoritması, Agrawal ve Srikant tarafından 1994 yılında geliştirilen ve veritabanı madenciliğinde sıkça kullanılan bir algoritmadır. Adını, bir önceki adımda elde edilen bilgilerin sonraki adımlarda kullanılmasından alır. Bu algoritma, büyük veri kümeleri içinde sıkça birlikte görülen öge kümelerini (örneğin, market sepetlerinde birlikte alınan ürünler) bulmayı amaçlar. Apriori algoritması, aday öge kümelerini oluştururken sıklık ilkesini kullanır; yani, bir öge kümesi sık ise, o kümenin tüm alt kümeleri de sık olmalıdır. Bu ilkeden yola çıkarak, aday öge kümelerini sistematik bir şekilde üretir ve veri tabanında desteklenen öge kümelerini belirler. Bu sayede, veri setindeki gizli ilişkiler ve kalıplar ortaya çıkarılabilir. Ancak, algoritmanın veritabanını sık sık taraması, büyük veri kümeleri için performans sorunlarına neden olabilir [29].

3.2.2 Denetimli Öğrenme

Denetimli öğrenme, makine öğrenmesinin temel bir dalı olup, önceden etiketlenmiş veri kümeleri kullanılarak bir modelin eğitilip, etiketlenmemiş verilere uygulanması sürecidir. Bu yöntemde model, etiketli verilerdeki girdi-çıkı ilişkilerini analiz ederek, yeni bir girdi verildiğinde olası bir çıktı tahmininde bulunur [32]. Örneğin, bir e-postanın spam olup olmadığı durumu sınıflandırmak veya bir evin fiyatını tahmin etmek gibi görevler denetimli öğrenme ile çözülebilir. Bu süreçte, model, verilerdeki kalıpları ve ilişkileri öğrenerek gelecekteki veriler için tahminler yapabilecek bir yetenek kazanır [29].

Denetimli öğrenme, etiketlenmiş veriler kullanarak modellerin eğitildiği ve bu modellerin yeni veriler üzerinde tahminlerde bulunduğu bir makine öğrenmesi türüdür. Sınıflandırma ve regresyon olmak üzere iki ana teknik üzerine kuruludur. Sınıflandırma, verileri önceden belirlenmiş sınıflara atama işlemidir (örneğin, spam/spam değil, kanserli/kanserli değil). Destek vektör makineleri (DVM), k-En yakın komşu (kNN), karar ağaçları ve yapay sinir ağları gibi çeşitli sınıflandırma algoritmaları mevcuttur. Regresyon ise sürekli değerler (örneğin, ev fiyatları, sıcaklık) tahmin etmek için kullanılır ve doğrusal regresyon, Lasso regresyonu ve polinomsal regresyon gibi birçok regresyon algoritması bulunur [29].


Denetimli öğrenmenin uygulama alanları oldukça geniştir. Tıpta hastalık teşhisi, finans sektöründe risk analizi, pazarlamada müşteri segmentasyonu ve doğal dil işleme gibi birçok alanda denetimli öğrenme algoritmaları kullanılmaktadır. Bu algoritmalar, büyük veri kümelerinden anlamlı bilgiler çıkararak karar verme süreçlerini destekler ve otomatikleştirir [32].

Literatürde sıklıkla kullanılan bazı denetimli öğrenme algoritmaları şunlardır;

3.2.2.1 K-En Yakın Komşu (KNN)

K-En yakın komşu (KNN) algoritması, denetimli öğrenme yöntemleri arasında basitliği ve etkililiği ile öne çıkan, tembel öğrenme kategorisinde yer alan bir sınıflandırma algoritmasıdır. KNN'nin temel prensibi, yeni bir veri noktasının sınıfını belirlemek için en yakın komşularının sınıflarına bakmaktır [32]. Algoritma, eğitim verileri üzerinde herhangi bir model oluşturmaz; bunun yerine, yeni bir veri noktası sınıflandırılacağı zaman, eğitim verisindeki tüm noktalarla arasındaki mesafe hesaplanır. En kısa mesafeye sahip olan 'k' adet nokta, yeni noktanın komşuları olarak belirlenir ve bu komşuların çoğunluğunda bulunan sınıf, yeni noktaya atanır. Bu yöntem, yeni verilerin gelmesiyle birlikte sürekli güncellenebildiği için dinamik bir yapıya sahiptir [29].

KNN algoritması, basitliği, uygulanabilirliği ve yüksek doğruluk oranıyla öne çıkan bir makine öğrenmesi algoritmasıdır. Hiperparametre olarak sadece komşu sayısı (k) ve mesafe metrikleri gibi birkaç parametreye ihtiyaç duyması, kullanımını kolaylaştırır. Ancak, büyük veri kümeleri üzerinde çalışırken hesaplama maliyeti yüksek olabilir, çünkü her yeni veri noktası için tüm eğitim verileri ile karşılaştırma yapmak gerekir. Ayrıca, k değerinin uygun seçimi algoritmanın performansını etkiler; çok küçük bir k değeri aşırı öğrenmeye, çok büyük bir k değeri ise yetersiz öğrenmeye neden olabilir [29]. K en yakın komşu algoritmasını gösterimi Şekil 3.2’de gösterilmiştir.



Şekil 3.2 K en yakın komşu algoritması [29].

KNN algoritması, öncelikle eğitim verileri ve yeni bir veri noktası arasındaki mesafeyi hesaplar. Bu hesaplamada, Öklid, Manhattan veya Minkowski gibi çeşitli mesafe metrikleri (aşağıda sırasıyla verilen Denklem 3.1, Denklem 3.2 ve Denklem 3.3) kullanılabilir. Daha sonra, en kısa mesafeye sahip olan k adet komşu belirlenir. Bu komşuların sınıf dağılımı incelenerek, yeni veri noktasının sınıfı çoğunluk oylaması ile belirlenir. KNN algoritması, sınıflandırma problemlerinin yanı sıra regresyon problemlerinde de kullanılabilir. Regresyon durumunda, k en yakın komşunun ortalama değeri, yeni verinin tahmini değeri olarak alınır [32].

$$\sqrt{\sum_{i=1}^n (X_i - Y_i)^2} \quad (3.1)$$

$$\sum_{i=1}^n |X_i - Y_i| \quad (3.2)$$


$$\left(\sum_{i=1}^n |X_i - Y_i|^p \right)^{1/p} \quad (3.3)$$

KNN algoritmasının uygulama alanları oldukça geniştir. Tıpta hastalık teşhisi, finans sektöründe kredi risk değerlendirmesi, pazarlamada müşteri segmentasyonu ve görüntü tanıma

gibi birçok alanda KNN algoritması başarıyla kullanılmaktadır [32]. Özellikle, küçük ve orta ölçekli veri kümeleri üzerindeki sınıflandırma problemleri için KNN algoritması oldukça uygun bir seçenektir. Ancak, büyük veri kümeleri veya yüksek boyutlu veriler için daha karmaşık ve verimli algoritmalar tercih edilebilir [30].

3.2.2.2 Destek Vektör Makinesi (DVM)

Destek vektör makineleri (DVM), makine öğrenmesinde sınıflandırma ve regresyon problemlerinin çözümü için kullanılan güçlü bir algoritmadır [32]. DVM'nin temel amacı, farklı sınıflara ait veri noktalarını en iyi şekilde ayıran bir hiper düzlem (veya çok boyutlu uzaylarda hiper düzlem) bulmaktır. Bu hiper düzlem, veri noktalarını iki veya daha fazla sınıfa ayırmada maksimum marjı sağlayan bir sınır olarak düşünülebilir. Marj, hiper düzleme en yakın veri noktaları olan destek vektörleri tarafından belirlenir. Bu destek vektörleri, hiper düzlemin konumunu ve yönünü belirleyen en önemli noktalar. DVM'nin bu özelliği, overfitting (aşırı öğrenme) riskini azaltarak genelleme performansını artırır. DVM'in temel çalışma yapısı Şekil 3.3'te gösterilmiştir [30].



Şekil 3.3 DVM algoritması [14].

DVM, doğrusal olarak ayrılabilir veriler için oldukça etkilidir. Ancak, gerçek dünyadaki birçok veri seti doğrusal olarak ayrılmaz. Bu durumda, çekirdek (kernel) fonksiyonları kullanılarak veriler daha yüksek boyutlu bir uzaya dönüştürülür ve bu uzayda doğrusal bir ayırma hiper düzlemi bulunur [29]. Çekirdek fonksiyonları, verilerin iç çarpımını hesaplamak için kullanılan matematiksel fonksiyonlardır ve verilerin doğrusal olmayan ilişkilerini ortaya çıkarır. Hiper düzlemde her nokta Denklem 3.4'te olduğu gibi gösterilmektedir (w : ağırlık vektörü, x : giriş vektörü, b : sapma). İki doğru denkleminin gösterimi Denklem 3.5'te gösterilmiştir. Yaygın

olarak kullanılan çekirdek fonksiyonları arasında Gauss, polinom ve sigmoid çekirdekleri bulunmaktadır [32].

$$wx + b = 0 \quad (3.4)$$

$$y_i = \begin{cases} -1, & wx + b \leq -1 \\ +1, & wx + b \geq +1 \end{cases} \quad (3.5)$$

DVM, yüksek genelleme performansı, farklı çekirdek fonksiyonları ile çeşitli problemlere uygulanabilirlik ve az sayıda hiperparametre gibi avantajlara sahiptir. Ancak, büyük veri kümeleri için hesaplama maliyeti yüksek olabilir ve uygun çekirdek ve parametre seçimi model performansını önemli ölçüde etkiler [32].

Özetle DVM, sınıflandırma problemlerinde etkili bir çözüm sunan güçlü bir algoritmadır. Maksimum marj ilkesi ve destek vektörleri kullanarak aşırı öğrenme riskini azaltır ve genelleme yeteneğini artırır. Hem doğrusal hem de doğrusal olmayan problemlere uygulanabilmesi, DVM'yi farklı alanlarda tercih edilen bir yöntem haline getirir. Ancak, hiperparametre optimizasyonu ve hesaplama maliyeti gibi dezavantajları da dikkate alınmalıdır [29].

3.2.2.3 Rastgele Orman (RO)

Rastgele Orman algoritması, çok sayıda karar ağacını birleştirerek yüksek doğruluk sağlayan bir sınıflandırma yöntemidir. Her ağaç, eğitim verisinin rastgele bir alt kümesiyle oluşturulur, bu da çeşitliliği artırır ve aşırı öğrenmeyi azaltır. Yeni bir veri noktası sınıflandırılırken, her ağaç tahminini yapar ve nihai sınıf, tüm ağaçların oylarıyla belirlenir, bu da tek bir ağaca göre daha güvenilir sonuçlar sağlar [30].

Rastgele Orman algoritmasının başarısında, bir düğümdeki saflığı ölçen ve en iyi bölünme noktalarını belirlemede kullanılan Gini indeksi önemli bir rol oynar. Ağaçlar arasındaki düşük korelasyon, hataların diğer ağaçlar tarafından düzeltilmesini sağlayarak algoritmanın genelleme yeteneğini artırır. Bu özellikler, Rastgele Orman'ı birçok alanda başarılı bir şekilde kullanılan güçlü ve esnek bir sınıflandırma algoritması yapar [32].

Özetle Rastgele Orman algoritması birden fazla karar ağacını bir araya getirerek oluşturulan, yüksek doğruluk oranına sahip bir sınıflandırma algoritmasıdır. Gini indeksi ve ağaçlar arasındaki düşük korelasyon gibi özellikler, algoritmanın performansını artırır. Aşırı öğrenme riskini azaltması ve farklı veri türlerine uygulanabilirliği sayesinde birçok alanda tercih edilen bir yöntemdir [30, 32]

3.2.2.4 Naive Bayes

Naive Bayes algoritması, Bayes teoremine dayanan basit ve etkili bir sınıflandırma yöntemidir. Özellikle metin sınıflandırma gibi alanlarda kullanılan bu algoritma, bir sınıf içindeki özelliklerin birbirinden bağımsız olduğunu varsayar. Bu varsayım, hesaplamaları basitleştirerek algoritmanın hızlı çalışmasını sağlar [29]. Naive Bayes, eğitim verileri üzerindeki olasılık dağılımlarını inceleyerek bir model oluşturur ve yeni bir veri noktası geldiğinde bu model kullanılarak her sınıf için olasılık hesaplar. En yüksek olasılığa sahip sınıf, veri noktasının ait olduğu sınıf olarak tahmin edilir. Basit, hızlı ve az veriyle iyi sonuçlar vermesi avantajları arasında sayılabilir. Ancak, koşullu bağımsızlık varsayımı gerçek dünya verilerinde her zaman geçerli olmadığından algoritmanın performansını etkileyebilir [30].

3.2.2.5 Bagging


Bagging (Bootstrap Aggregating), birden fazla modeli bir araya getirerek daha iyi performans elde etmeyi amaçlayan bir topluluk öğrenmesi yöntemidir. Bu yöntemde, orijinal veri setinden rastgele örnekler alınarak birden fazla alt küme oluşturulur ve her alt küme üzerinde ayrı bir temel öğrenici eğitilir. Bu şekilde elde edilen farklı modellerin tahminleri birleştirilerek (oylama veya ortalama alma ile) nihai tahmin elde edilir. Bagging, modelin kararlılığını artırır, aşırı öğrenmeyi azaltır ve genelleme yeteneğini iyileştirir, özellikle karar ağaçları gibi yüksek varyanslı modellerde etkilidir [29].

Bagging, makine öğrenmesinde modelin genelleme yeteneğini artırmak ve aşırı öğrenmeyi önlemek için kullanılan bir topluluk öğrenmesi yöntemidir. Bu yöntemde, orijinal veri setinden rastgele örnekler alınarak birden fazla alt veri kümesi oluşturulur. Her alt veri kümesi üzerinde ayrı bir model eğitilir ve bu modellerin birbirinden bağımsız hatalar yapması beklenir. Böylece, bir modelin yaptığı hata diğer modeller tarafından telafi edilebilir ve topluluk olarak daha doğru ve kararlı bir tahmin elde edilebilir. Bagging, özellikle yüksek varyanslı modellerde (örneğin karar ağaçları) etkilidir ve düzensiz veri setlerinde de başarılı sonuçlar verir [29].

Bagging, makine öğrenmesinde birden fazla modelin tahminlerini birleştirerek daha güçlü ve güvenilir sonuçlar elde etmeyi hedefleyen bir topluluk öğrenmesi yöntemidir. Bu yöntemde, orijinal veri setinden rastgele örnekler alınarak birden fazla alt veri kümesi oluşturulur. Her bir alt veri kümesi üzerinde ayrı bir model eğitilir ve bu modellerin tahminleri bir araya getirilerek nihai tahmin elde edilir. Bagging, modelin genelleme yeteneğini artırarak yeni verilere daha iyi uyum sağlamasını sağlar, aşırı öğrenmeyi önler ve düzensiz veri setlerinde daha başarılı sonuçlar verir [30].

3.2.2.6 Lojistik Regresyon

Lojistik regresyon, makine öğrenmesinde iki sınıflı sınıflandırma problemlerini çözmek için kullanılan bir algoritmadır ve verilen bir girdi setine dayanarak, bir örneğin belirli bir sınıfa ait olma olasılığını 0 ile 1 arasında bir değer olarak tahmin eder. Bu olasılık hesabı için sigmoid fonksiyonu kullanılır. Sigmoid fonksiyonu, ağırlık (w) ve bias (b) parametreleri tarafından kontrol edilir; ağırlık parametresi sigmoid eğrisinin dikliğini belirlerken, bias parametresi eğrinin yatay ekseninde kaymasını kontrol eder. Model, eğitim verileri kullanılarak bu parametreleri öğrenir ve optimum bir sigmoid eğrisi oluşturur. Lojistik Regresyon, basitliği, yorumlanabilirliği ve verimliliği nedeniyle birçok uygulamada tercih edilen bir sınıflandırma algoritmasıdır [14]. Lojistik sigmoid fonksiyonu Şekil 3.4'te gösterilmiştir.



Şekil 3.4 Lojistik sigmoid fonksiyonu [14].

Lojistik regresyon'da modelin başarısını ölçmek için kullanılan kayıp fonksiyonu, tahmin edilen olasılıklar ile gerçek sınıf etiketleri arasındaki farkı hesaplar. Modelin amacı, bu kayıp fonksiyonunu en aza indirerek en iyi tahminleri elde etmektir. Kayıp fonksiyonu küçüldükçe, modelin gerçek sınıfları doğru tahmin etme performansı artar [14].

3.2.2.7 Yapay Sinir Ağları (YSA)

Yapay sinir ağları, İnsan beynindeki nöronların çalışma prensiplerinden esinlenerek geliştirilen yapay sinir ağları, McCulloch ve Pitts'in 1943 yılında önerdiği basit yapay nöron modeliyle önemli bir adım atmıştır. Bu araştırmacılar, yapay sinir ağlarının mantıksal işlemleri gerçekleştirebileceğini göstermişlerdir. Yapay sinir ağları, insan beyninin bilgi işleme, öğrenme ve genelleme gibi karmaşık bilişsel yeteneklerini taklit etmeyi amaçlar ve bu sayede geleneksel

programlama yöntemleriyle çözümü zor olan problemlerde başarılı bir şekilde kullanılmaktadır [29].

Yapay sinir ağları, insan beyninden esinlenerek geliştirilmiş ve giriş, gizli ve çıkış katmanlarından oluşan hesaplamalı modellerdir. Giriş katmanı, ağa verilen ham verileri alırken, gizli katmanlar bu verileri işleyerek özellik çıkarımı yapar ve çıkış katmanı ise elde edilen çıktıları sunar. Katmanlar arasındaki bağlantılar, ağırlık adı verilen parametrelerle belirlenir ve bu ağırlıkların güncellenmesiyle ağ, verilerdeki kalıpları öğrenerek genelleme yeteneği kazanır. Yapay sinir ağlarının öğrenme algoritmaları, ağırlıkların belirlenmesi ve güncellenmesi için kullanılan matematiksel yöntemlerdir [29].


Yapay sinir ağlarında veri girdileri ağırlıkları ile çarpılarak elde edilen değerler bir araya getirilir. Bu değere bilgi değeri eklenerek aktivasyon fonksiyonu uygulanır. Fonksiyon uygulaması sonucunda çıktı değerine ulaşılır. Bu ulaşılan değer bir sonraki katmandaki nöronların girişi olarak kullanılır ve bu süreç öğrenme başarılı olana kadar devam eder [40]. Yapay sinir ağları matematiksel olarak Denklem 3.6'da gösterilmiştir.

$$y(x) = \sum_{i=1}^N (w_i x_i + b) \quad (3.6)$$

Denklemde belirtilen parametreler aşağıdaki gibi ifade edilebilir.

- x: Giriş değerleri (input)
- w: Ağırlık (weight)
- b: Sapma (bias)
- N: Toplam adım (step)
- y: Çıkış değeri (output)

Özetle, yapay sinir ağları, insan beyninin bilgi işleme yeteneğinden ilham alan ve karmaşık problemleri çözmek için büyük veri kümelerindeki kalıpları öğrenen güçlü bir hesaplama modelidir. Giriş, gizli ve çıkış katmanlarından oluşan bu ağlar, katmanlar arasındaki bağlantıların ağırlıklarla belirlendiği bir yapıya sahiptir. Ağırlıkların güncellenmesiyle ağ, verilerdeki örüntüleri öğrenir ve genelleme yeteneği kazanır [29]. Yapay sinir ağlarının şematik gösterimi Şekil 3.5'te gösterilmiştir.



Şekil 3.5 Yapay sinir ağları gösterimi [29].

3.2.3 Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, bir ajanın çevresiyle etkileşim kurarak uzun vadeli bir ödülü maksimize etmeyi hedeflediği bir makine öğrenmesi yaklaşımıdır. Ajan, her adımda gerçekleştirdiği eylem sonucunda bir ödül veya ceza alarak, deneme yanılma yoluyla en yüksek toplam ödüle ulaşmayı amaçlayan bir politika geliştirir. Bu yöntem, belirsizlik ve kısmi bilgi koşullarında karar verme gerektiren problemler için etkili bir çözüm sunar ve oyun oynama, robot kontrolü, finansal piyasalar gibi çeşitli alanlarda başarıyla uygulanmaktadır [29].

3.3 DERİN ÖĞRENME

Derin öğrenme, yapay sinir ağlarını çok katmanlı mimarilerle modelleyerek ve büyük veri setleri üzerinde eğiterek karmaşık veri yapılarından yüksek seviyede soyutlama ve özellik çıkarma yeteneği kazanan bir makine öğrenmesi yaklaşımıdır. Görüntü tanıma, doğal dil işleme ve ses tanıma gibi birçok alanda başarılı sonuçlar elde eden derin öğrenme, özellikle tıbbi görüntüleme alanında hastalık teşhisinde önemli bir araç haline gelmiştir. Büyük miktarda tıbbi görüntü verisi üzerinde eğitilen derin öğrenme modelleri, radyolojik görüntülerdeki anormallikleri yüksek doğrulukla tespit edebilmektedir [30]. Derin öğrenme, yapay sinir ağlarının bir alt kümesi olup, büyük miktarda veri kullanarak karmaşık problemleri çözmek için kullanılır. Derin öğrenme modelleri, çok sayıda katmandan oluşan yapay sinir ağları ile temsil edilir ve bu katmanlar, verilerdeki özellikleri hiyerarşik bir şekilde öğrenir. Büyük veri kümeleri üzerinde eğitildiğinde, derin öğrenme modelleri geleneksel yapay sinir ağlarına göre daha hızlı ve daha doğru sonuçlar üretebilir. Bunun nedeni, derin öğrenme modellerinin verilerdeki karmaşık örüntüleri daha iyi yakalayabilmesidir [15]. Makine öğrenimi algoritmaları genellikle problemleri parçalara ayırıp her bir parçayı çözerek nihai sonuca

ulaşırken, derin öğrenme problemleri bütüncül bir şekilde ele alır ve baştan sona çözmeye çalışır. Bu, derin öğrenmenin daha karmaşık ve soyut problemleri çözme yeteneğini artırır [78].

Derin öğrenme, geleneksel makine öğrenme yöntemlerine göre, özellikle büyük ve karmaşık veri setlerinde daha iyi performans gösterme potansiyeli sunar. Özellik çıkarma mühendisliği gerektirmeden, verilerden otomatik olarak anlamlı özellikler çıkarabilme yeteneği, derin öğrenmenin en önemli avantajlarından biridir [32]. Bu sayede, domain uzmanlığına olan ihtiyaç azalır ve model geliştirme süreci hızlanır. Derin öğrenme, görüntü ve video işleme, doğal dil işleme, ses tanıma, öneri sistemleri, otonom araçlar ve oyun oynama gibi birçok alanda başarılı uygulamalara sahiptir. Özellikle son yıllarda görüntü ve video işlemede, derin öğrenme modelleri, nesne tanıma, yüz tanıma ve görüntü segmentasyonu gibi görevlerde insan seviyesine yakın performans göstermeye başlamıştır. Medikal görüntü işleme konusundaki gelişimiyle de tıbbi veri setleriyle çalışma alanında, derin öğrenme yaygın olarak kullanılan yöntemdir. Röntgen, manyetik rezonans ve bilgisayarlı tomografi gibi tıbbi görüntüleme yöntemlerinden sağlanan görüntü ve sinyal verileri, çeşitli derin öğrenme mimarileri kullanılarak analiz edilebilir. Bu sayede cilt kanseri, meme kanseri, beyin tümörü ve çeşitli hastalık türlerinin tespiti ve teşhisi mümkün hale gelmektedir [40].

3.3.1 Derin Öğrenme Terminolojisi

Derin öğrenme hakkında detaylı bilgilere geçmeden önce temel terminolojik tanımlar aşağıda verilmiştir.

Sinir Ağları (Neural Network): İnsan beynindeki nöronların işleyişinden esinlenerek geliştirilmiş ve çok katmanlı yapılar aracılığıyla veri işleme ve öğrenme yeteneğine sahip yapay zekâ modelleridir. Girdi verileri, bir dizi katmandan geçerek istenen çıktıya dönüştürülür ve her katman, kendinden önceki katmanın çıktısını kullanarak daha soyut ve karmaşık özellikler üretir. Ağırlık ve eşik değerleri adı verilen parametreler, ağırlık öğrenme sürecini yönlendirir [14].

Nöronlar ve Bağlantılar (Nodes and Links): Yapay sinir ağları, nöron adı verilen ve birbirleriyle bağlantılar aracılığıyla iletişim kuran işlem birimlerinden oluşur. Her bağlantı, ağırlık ve bias adı verilen parametrelere sahiptir. Bir nöron, kendisine gelen bağlantılardan gelen ağırlıklı sinyalleri toplar, işler ve bir çıktı üretir. Bu yapı, insan beynindeki nöronların çalışma şeklini taklit eder ve ağırlık öğrenme ve bilgi işleme yeteneğini sağlar [14].

Ağırlık ve Sapma (Weight and Bias): Yapay sinir ağlarında ağırlık ve bias değerleri, ağırlık öğrenme sürecini kontrol eden kritik parametrelerdir. Ağırlıklar, nöronlar arasındaki

bağlantıların gücünü temsil ederken, bias terimi, bir nöronun aktivasyon eşiğini belirler. Başlangıçta rastgele veya sıfır olarak atanan bu parametreler, geri yayılım gibi öğrenme algoritmaları kullanılarak ağın performansını optimize etmek için iteratif olarak güncellenir [14].

İleri Yayılım (Forward Propagation): İleri beslemeli sinir ağları, bilgi akışının tek yönlü olduğu ve döngü veya geri besleme bağlantıları içermeyen yapay sinir ağı modelleridir. Bu ağlarda, girdi verileri giriş katmanı tarafından alınır ve bir veya daha fazla gizli katmandan geçerek işlenir. Her katmanın çıktısı, bir sonraki katmanın girdisi olarak kullanılır ve son olarak çıkış katmanı ağı nihai çıktısını üretir. Bu işlem sırasında ağırlık ve bias değerleri sabit kalır [14].

Geri Yayılım (Back Propagation): İleri beslemeli sinir ağlarında, geri yayılım algoritması öğrenme sürecini yönlendirir ve ağın performansını ölçen kayıp fonksiyonunun gradyanını hesaplayarak ağırlık ve bias değerlerinin güncellenmesini sağlar. Kayıp fonksiyonunun gradyanı, ağırlık ve bias değerlerinin hangi yönde ve ne kadar değiştirilmesi gerektiği konusunda bilgi verir, böylece ağ verilerdeki kalıpları öğrenerek daha iyi tahminler yapabilir. İlk iterasyonda, ağırlık ve bias değerleri genellikle rastgele olarak atanır veya sıfır olarak başlatılır [14].

Epoch: Yapay sinir ağlarının eğitiminde bir epok, tüm eğitim veri setinin ağ üzerinden bir kez geçirilmesi anlamına gelir. Bu geçiş sırasında, veriler önce ileri besleme ile ağda ilerletilir ve bir çıktı üretilir. Daha sonra, geri yayılım algoritması kullanılarak üretilen çıktı ile gerçek değerler arasındaki fark hesaplanır ve bu farka göre ağı ağırlıkları güncellenir. Eğitim verileri, öğrenme sürecini optimize etmek ve modelin genelleme yeteneğini artırmak için genellikle birden fazla epok boyunca ağ üzerinden tekrar tekrar geçirilir [14].

Batch: Yapay sinir ağlarının eğitiminde kullanılan veri seti, bir epokta ağı tek seferde işleyebileceği veri miktarından fazla olabilir. Bu durumda, eğitim verileri "batch" adı verilen daha küçük alt kümelere bölünür. Bir batch, eğitim verisinden rastgele seçilen bir grup veri örneğidir ve ağ her bir batch'i ayrı ayrı işleyerek öğrenme sürecini gerçekleştirir. Batch boyutları genellikle 2'nin kuvvetleri (örneğin, 32, 64, 128) olarak tercih edilir ve her epok başında verilerin sırası rastgele karıştırılarak ağı farklı veri kombinasyonları üzerinde öğrenmesi sağlanır [14].

Eğitim Verisi ve Eğitim Süreci (Train Data and Training): Makine öğrenmesinde, modelin eğitilmesi için kullanılan veri kümesine eğitim verisi denir ve genellikle toplam verinin %70-%80'i bu amaçla ayrılırken, geri kalanı test ve doğrulama verileri olarak kullanılır. Eğitim verisi, test ve doğrulama verilerinden tamamen bağımsız olmalıdır. Eğitim süreci, birden fazla epok adı verilen iterasyondan oluşur ve her epokta eğitim verileri sinir ağı üzerinden geçirilerek modelin ağırlık ve bias değerleri güncellenir. Batch kullanılıyorsa, her batch için ayrı ayrı hesaplanan kayıp değerleri ortalamalanarak epok sonundaki toplam kayıp değeri bulunur ve istenirse epok sonunda doğruluk oranı da hesaplanabilir [14].


Test Verisi ve Test Süreci (Test Data and Testing): Makine öğrenmesinde, eğitilmiş bir modelin gerçek performansını değerlendirmek için kullanılan ve eğitim aşamasında modele hiç gösterilmeyen bağımsız veri kümesine test verisi denir. Toplam veri setinin genellikle %20-%30'u test verisi olarak ayrılır. İdeal olarak, test süreci tüm eğitim epoklardan sonra gerçekleştirilir. Ancak, doğrulama verisi kullanılmıyorsa, her epok sonunda test verisi kullanılarak modelin performansı değerlendirilebilir. Bu, aşırı öğrenmenin erken tespiti ve eğitim sürecinin uygun bir noktada durdurulması için önemlidir [14].

Doğrulama Verisi ve Doğrulama Süreci (Validation Data and Validating): Yeterli miktarda eğitim verisi mevcut olduğunda, öğrenme sürecinin performansını düzenli olarak değerlendirmek ve aşırı öğrenmeyi engellemek amacıyla eğitim verisinden bağımsız bir doğrulama veri seti oluşturulması önerilmektedir. Doğrulama veri seti, genellikle eğitim verisinin %20-%30'u kadar bir büyüklüğe sahip olmalı ve eğitim verisinden kesinlikle ayrıştırılmalıdır. Doğrulama sürecinde, modelin ağırlık ve bias değerleri güncellenmez; sadece kayıp fonksiyonu ve doğruluk gibi performans metrikleri hesaplanır. Bu yaklaşım, modelin eğitim verilerine aşırı uyum sağlayıp sağlamadığını ve gerçek dünya verileri üzerindeki genelleme performansını değerlendirmek için kullanılır [14].

Yetersiz Öğrenme ve Aşırı Öğrenme (Under-fitting and Over-fitting): Bir makine öğrenmesi modelinin, eldeki verilerdeki karmaşıklıkla tam olarak yakalayamaması ve yeterince esnek olmaması durumunda ortaya çıkan "yetersiz öğrenme", modelin eğitim verilerine bile iyi bir şekilde uyum sağlayamaması ve düşük performans göstermesiyle sonuçlanır. Bu durum, genellikle modelin çok basit olması veya eğitim için yeterli veriye sahip olmaması gibi nedenlerden kaynaklanır ve eğitim sürecinde elde edilen doğruluk gibi metriklerin düşük olmasıyla kendini gösterir [14].

Bir makine öğrenmesi modeli, eğitim verilerine aşırı uyum sağlayarak gerçek dünya verileri üzerindeki genelleme yeteneğini kaybettiğinde "aşırı öğrenme" meydana gelir. Bu durumda, model eğitim verilerindeki gürültüyü ve rastgele dalgalanmaları bile öğrenerek, yeni ve görünmeyen veriler üzerinde başarısız olur. Aşırı öğrenme, modelin eğitim verilerini ezberlemesi ve gerçek dünya verilerine genelleme yapamaması anlamına gelir [14].

Şekil 3.6’da yetersiz öğrenme, ideal öğrenme ve aşırı öğrenme durumları gösterilmiştir.



Şekil 3.6 Yetersiz öğrenme, ideal öğrenme, aşırı öğrenme gösterimleri [14].

Doğrulama verisi, makine öğrenmesinde aşırı öğrenme problemi kontrol etmek ve modelin genelleme yeteneğini değerlendirmek için kullanılan kritik bir araçtır. Eğitim süreci boyunca, modelin performansı periyodik olarak doğrulama verisi üzerinde değerlendirilerek, modelin eğitim verilerine aşırı uyum sağlayıp sağlamadığı ve yeni, görünmeyen verilere ne kadar iyi genelleme yapabildiği kontrol edilir. Bu değerlendirme hem aşırı öğrenmeyi önlemek hem de yetersiz öğrenmeyi aşmak için eğitim sürecini optimize etmede önemli bir rol oynar [14].

Kayıp Fonksiyonu (Loss Function): Kayıp fonksiyonu, bir makine öğrenmesi modelinin tahminleri ile gerçek değerler arasındaki farkı ölçen ve modelin performansını değerlendirmede kullanılan bir fonksiyondur. Bu fonksiyon aynı zamanda optimizasyon problemlerinde maliyet (cost) fonksiyonu olarak da adlandırılır ve modelin amacı bu maliyeti minimize etmektir [14].

Çapraz Entropi Kayıp Fonksiyonu (Cross Entropy Loss Function): Çapraz entropi, sınıflandırma problemlerinde kullanılan bir kayıp fonksiyonudur ve modelin tahmin ettiği sınıf olasılıkları ile gerçek sınıf etiketleri arasındaki farkı ölçer. Log-softmax fonksiyonu kullanılarak hesaplanan sınıf olasılıklarının negatif logaritması üzerinden hesaplanır ve gerçek sınıfın tahmin edilen olasılığı ne kadar düşükse, çapraz entropi değeri o kadar yüksek olur. Başka bir tanımla çapraz entropi, modelin gerçek sınıfları ne kadar iyi tahmin ettiğinin bir

ölçüsüdür ve modelin amacı bu değeri minimize etmektir [14]. Çoklu sınıflandırma metotlarında kayıp fonksiyonu hesaplanması Denklem 3.7’de verilmiştir.

$$f(q) = - \sum_{i=1}^n y_i \log(p_i) \quad (3.7)$$

Denklemde belirtilen parametreler aşağıdaki gibi ifade edilebilir.

- q : Tahmini sınıf olasılığı
- y_i : Gözlenen sınıf etiketi
- p_i : Modelden elde edilen ağırlık
- n : Toplam sınıf sayısı

3.3.2 Optimizasyon Metotları

Derin öğrenme modellerinde, öğrenme sürecini yönlendiren ve modelin performansını optimize eden temel unsurlardan biri kayıp fonksiyonudur. Kayıp fonksiyonu, modelin tahminleri ile gerçek değerler arasındaki farkı ölçer ve bu farkı minimize etmek, modelin doğruluğunu artırmak anlamına gelir. İşte bu kayıp fonksiyonunu minimize etmek için kullanılan algoritmalara en iyileyici (optimizer) denir. Literatürde sıkça kullanılan ve farklı özelliklere sahip birçok en iyileyici algoritma bulunmaktadır [15].

3.3.2.1 Stokastik Gradyan İnişi (SGD)

Stokastik gradiyent inişi (SGD), gradiyent inişi optimizasyonunun stokastik bir yaklaşımıdır [79]. Bu iteratif yöntem, uygun düzgünlük özelliklerine sahip bir amaç fonksiyonunu optimize etmek için kullanılır. Momentum, her iterasyonda ağırlık güncellemesinin bir kısmını "hafızada" tutar ve bir sonraki güncellemeyi, gradiyent ile önceki güncelleme bir doğrusal kombinasyonu olarak belirler [14]. Stokastik gradyent inişi hesaplaması Denklem 3.8’de verilmiştir.

$$q_{(t)} = q_{(t-1)} - \text{öğrenme hızı} * \nabla_w J(z + w_{(t)}) \quad (3.8)$$

Denklemde belirtilen parametreler aşağıdaki gibi ifade edilebilir.

- $q_{(t)}$: t anındaki algoritmanın mevcut adımında modelin ağırlıklarını temsil eden vektör
- z : Kayıp fonksiyonunun hesaplanması için seçilen veri kümesi
- J : Kayıp fonksiyonu

3.3.2.2 Uyarlanabilir Gradyan Optimize Edici (AdaGrad)

AdaGrad (adaptive gradient algorithm), her bir ağırlık değeri için farklı bir öğrenme oranı kullanarak öğrenme sürecini optimize eden bir optimizasyon algoritmasıdır. Bu, öğrenme oranının manuel olarak ayarlanması ihtiyacını ortadan kaldırır ve daha hızlı ve güvenilir bir yakınsama sağlar [80]. Ancak, yineleme sayısı arttıkça öğrenme oranı azalabilir, bu da öğrenme hızının düşmesine neden olabilir. Bu durum, AdaGrad'ın bazı durumlarda erken durmasına ve optimum noktaya ulaşamamasına sebep olabilir [15].

Uyarlanabilir gradyan optimize edici (AdaGrad) hesaplaması Denklem 3.9'da verilmiştir.

$$G_{(t)} = G_{(t-1)} + \nabla J(q_{(t-1)})^2 \quad (3.9)$$

Denklemde belirtilen parametreler aşağıdaki gibi ifade edilebilir.

- $G_{(t)}$: t anındaki hesaplanan gradyan kareleri toplamı
- $q_{(t)}$: t anındaki hesaplanan parametre vektörü
- J: Kayıp fonksiyonu

3.3.2.3 Ortalama Karekök Yayılımı (RMSProp)

Eğimlerin büyüklüğü, farklı ağırlıklar için farklı değerler alabilir ve öğrenme sırasında değişebilir, bu da tek bir küresel öğrenme katsayısı seçmeyi zorlaştırır [81]. RMSProp (root mean square propagation), eğimlerin karesinin hareketli bir ortalamasını tutarak ve ağırlık güncellemelerini bu büyüklüğe göre ayarlayarak bu sorunu çözer [15].

Ortalama karekök yayılımı (RMSProp) hesaplaması Denklem 3.10'da verilmiştir.

$$q_{(t)} = q_{(t-1)} - \left(\frac{\text{adım boyutu}}{\sqrt{E[g^2]_{(t)} + \varepsilon}} \right) * g_{(t)} \quad (3.10)$$

Denklemde belirtilen parametreler aşağıdaki gibi ifade edilebilir.

- $q_{(t)}$: t anındaki hareketli ortalama kare gradyan
- $g_{(t)}$: t anındaki gradyan
- ε : Çok küçük bir değer (bölme hatasını önlemek için)
- $E[g^2]_t$: t anındaki gradyanın karesinin hareketli ortalaması

3.3.2.4 Uyarlanabilir Moment Tahmin Optimizasyonu (Adam)

Adaptif Moment Tahmini (Adam), derin öğrenme modellerinde yaygın olarak kullanılan bir optimizasyon algoritmasıdır. Gradyanların birinci ve ikinci momentlerinin hareketli

ortalamalarını kullanarak öğrenme oranını dinamik olarak ayarlar. Bu sayede, Adam algoritması hem hızlı hem de kararlı bir şekilde optimum noktaya yakınsayabilir. Her adımda, kayıp fonksiyonunun gradiyenti hesaplanır ve bu gradiyentin tersi yönünde bir adım atılır. Bu işlem, L2 düzenlemesi ile birlikte uygulandığında Adam optimizasyonu olarak adlandırılır. L2 düzenlemesi, ağırlıkların aşırı büyümesini önleyerek aşırı öğrenmeyi azaltmaya yardımcı olur. Adam optimizasyonu, hızı, verimliliği ve hafıza gereksiniminin düşük olması nedeniyle derin öğrenme modellerinde sıkça tercih edilir [82].

Uyarlanabilir moment tahmin optimizasyon (Adam) algoritmasında ilk olarak birinci moment tahmini hesaplama işlemi gerçekleştirilir. Birinci moment hesaplaması Denklem 3.11’de verilmiştir.

$$m_{(t)} = \beta_1 * m_{(t-1)} + (1 - \beta_1) * g_{(t)} \quad (3.11)$$

Denklemden belirtilen parametreler aşağıdaki gibi ifade edilebilir.

- $m_{(t)}$: t anındaki gradyanın birinci moment tahmini
- β_1 : Birinci moment için unutma faktörü (hiperparametre)
- $g_{(t)}$: t zamanındaki gradyanın ifadesi

Sonraki aşamada ikinci moment tahmini yapılır. İkinci moment tahmini hesaplaması Denklem 3.12’de verilmiştir.

$$v_{(t)} = \beta_2 * v_{(t-1)} + (1 - \beta_2) * g_{(t)}^2 \quad (3.12)$$

Denklemden belirtilen parametreler aşağıdaki gibi ifade edilebilir.

- $v_{(t)}$: t anındaki gradyanın ikinci moment tahmini
- β_2 : İkinci moment için unutma faktörü (hiperparametre)
- $g_{(t)}$: t anındaki gradyan

Son olarak moment tahminleri kullanılarak bir parametre güncelleme hesaplaması yapılır. Parametre güncelleme hesaplaması Denklem 3.13’te verilmiştir.

$$q_{(t)} = q_{(t-1)} - \left(\frac{\text{adım boyutu}}{\sqrt{v_{(t)}} + \epsilon} \right) * m_{(t)} \quad (3.13)$$

Denklemden belirtilen parametreler aşağıdaki gibi ifade edilebilir.

- $q_{(t)}$: t anındaki parametre değeri
- ϵ : Çok küçük bir değer (bölme hatasını önlemek için)

Bu adımlar tüm veri kümesi boyunca adımlar devam edene kadar tekrarlanır. Bu şekilde Adam optimizasyonu gradyanların ölçeğini ve hareketini hesaplayarak her bir parametrenin öğrenme hızını adaptif şekilde ayarlar ve verimli bir şekilde optimize eder [30].

3.3.2.5 Maksimum İle Uyarlanabilir Moment Tahmini (Adamax)

Adamax (adaptive moment estimation with maximum) optimizasyon algoritması, derin öğrenme modellerini eğitmek için kullanılan bir optimizasyon algoritmasıdır. 2014 yılında Diederik P. Kingma ve Jimmy Ba tarafından Adam optimizasyon algoritmasıyla birlikte önerilmiştir [83]. Adamax, temelde gradyan inişi yöntemine dayanan iteratif bir optimizasyon algoritmasıdır. Adam algoritmasına benzer şekilde öğrenme oranını her bir parametre için ayrı ayrı ayarlar ve gradyanların hareketli ortalamasını hesaplamada L2 normunu kullanırken, Adamax algoritması L-sonsuz normunu kullanır. Bu şekilde öğrenme oranını güncellerken daha kararlı ve daha az hassas olmasını sağlar [84].

Maksimum ile uyarlanabilir moment tahmini (Adamax) hesaplaması sırasıyla Denklem 3.14, Denklem 3.15 ve Denklem 3.16’da verilmiştir.

$$m_{(t)} = \beta_1 * m_{(t-1)} + (1 - \beta_1) * g_{(t)} \quad (3.14)$$

$$v_{(t)} = \max(\beta_2 * v_{(t-1)}, |g_{(t)}|) \quad (3.15)$$

$$w_{(t)} = w_{(t-1)} - \left(\frac{n}{\sqrt{v_{(t)}} + \varepsilon} \right) * m_{(t)} \quad (3.16)$$

Denklemden belirtilen parametreler aşağıdaki gibi ifade edilebilir.

- $m_{(t)}$: t anındaki birinci momentin tahmini
- $v_{(t)}$: t anındaki sonsuz normun tahmini
- β_1 : Birinci moment için unutma faktörü (genellikle 0.9 gibi bir değer)
- β_2 : İkinci moment için unutma faktörü (genellikle 0.999 gibi bir değer)
- $g_{(t)}$: t anındaki gradyan
- $w_{(t)}$: t anındaki ağırlık
- n : Öğrenme oranı
- ε : Çok küçük bir değer (bölme hatasını önlemek için)

Gradyanların hareketli ortalamalarının hesaplanması Denklem 3.14’te gösterilmiştir. β_1 ile önceki adımda hesaplanan ortalama değer bir kısmı alınır ve $(1-\beta_1)$ ile güncel gradyanın bir kısmı eklenir. Bu sayede son gradyanların etkisi daha yüksek olurken eski gradyanların etkisi azalır [83, 84].

Gradyanların mutlak değerin hareketli maksimumun hesaplanması Denklem 3.15'te gösterilmiştir. β_2 ile önceki adımda hesaplanan maksimum değerin bir kısmı alınır ve güncel gradyanın mutlak değeri ile karşılaştırılır. En büyük değer, güncel maksimum olarak belirlenir. Bu, Adam algoritmasında kullanılan ikinci momentin (varyans) yerine sonsuz normun kullanılmasını sağlar [84, 85].

Son olarak ağırlıkların güncellenmesinin hesaplanması Denklem 3.16'da verilmiştir. Öğrenme oranı, hareketli ortalama gradyanın kareköküne bölünerek normalize edilir. Bu normalizasyon, her bir parametre için öğrenme hızını otomatik olarak ayarlar. Büyük gradyanlara sahip parametreler için öğrenme hızı küçülürken, küçük gradyanlara sahip parametreler için öğrenme hızı artar [84, 85].

Özetle Adamax, derin öğrenme modelleri için güçlü ve verimli bir optimizasyon algoritmasıdır. Adam'ın avantajlarını korurken, sonsuz normu kullanarak daha fazla kararlılık sağlar. Bu nedenle, özellikle seyrek verilerle çalışırken veya daha kararlı bir optimizasyon algoritması gerektiğinde Adamax algoritması iyi bir seçenek olabilir [85].

3.3.3 Aktivasyon Fonksiyonları


Derin öğrenme modellerinin başarısı, büyük ölçüde sinir ağlarının karmaşık ve soyut kavramları temsil etme yeteneğini artıran aktivasyon fonksiyonlarına dayanmaktadır. Bu fonksiyonlar, nöronların aldığı ağırlıklı toplamları belirli bir aralıkta sınırlandırarak veya biçimlendirerek ağırlıklı doğrusal olmayan davranışlar sergilemesini sağlar. Aktivasyon fonksiyonunun seçimi, modelin performansını doğrudan etkileyen kritik bir faktördür ve çözülmeye çalışılan problemin doğası, veri setinin özellikleri ve kullanılan mimari gibi çeşitli unsurlara bağlı olarak optimize edilmelidir. Sonuç olarak, uygun aktivasyon fonksiyonu, derin öğrenme modellerinin öğrenme kapasitesini artırarak karmaşık veri setlerini etkili bir şekilde işlemesini sağlar [30].

3.3.3.1 Rectified Aktivasyon Fonksiyonu (ReLU)

ReLU aktivasyon fonksiyonu, özellikle görüntü tanıma gibi derin öğrenme uygulamalarında yaygın olarak kullanılan ve yüksek performans gösteren bir fonksiyondur. Hesaplama verimliliği, büyük veri setlerinde kullanımını avantajlı hale getirirken, pozitif ve negatif girdilere farklı tepkiler vererek modelin öğrenme kapasitesini artırır. ReLU, girdi değerlerini doğrudan çıktı olarak iletirken negatif değerleri sıfırlar. Bu sayede, modelin daha hızlı ve etkili bir şekilde öğrenmesine katkıda bulunur. Matematiksel olarak, ReLU fonksiyonu Denklem 3.17'deki gibi tanımlanır [30].

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3.17)$$

ReLU aktivasyon fonksiyonu, bir nöronun girdisi olan "x" değerini alarak pozitif değerler için doğrusal bir çıktı üretirken, negatif değerleri sıfırlar. Bu davranış, Şekil 3.7'de gösterilen grafikte de açıkça gösterilmiştir. ReLU'nun bu özelliği, derin öğrenme modellerinde hesaplama verimliliğini artırırken, aynı zamanda modelin seyrekliğini de teşvik eder. Bu sayede, ReLU fonksiyonu, özellikle büyük ve karmaşık veri setlerinde eğitilen modellerde daha hızlı öğrenme ve daha iyi genelleme yeteneği sağlayabilir [86].




Şekil 3.7 ReLU aktivasyon fonksiyonu grafiği [30]

3.3.3.2 Leaky ReLU Fonksiyonu

Leaky ReLU aktivasyon fonksiyonu, ReLU'nun bir varyasyonu olarak karşımıza çıkar ve negatif girdi değerlerine sıfır yerine küçük bir eğim uygulayarak daha esnek bir yapı sunar. Bu esneklik, ReLU'nun "ölü nöron" problemini hafifletmeye yardımcı olabilir. "Ölü nöron" problemi, ReLU'nun negatif girdiler için sürekli sıfır çıktı üretmesi sonucu bazı nöronların etkinleşememesi ve öğrenme sürecine katkıda bulunamaması durumudur. Leaky ReLU, negatif girdiler için küçük bir eğim uygulayarak bu nöronların da bir miktar aktivasyon göstermesini ve öğrenmeye katılmasını sağlar. Bu sayede, modelin performansı ve öğrenme kapasitesi artırılabilir [87]. Denklem 3.18'de Leaky ReLU'nun matematiksel ifadesi verilmiştir.

$$f(x) = \begin{cases} x, & x \geq 0 \\ ax, & x < 0 \end{cases} \quad (3.18)$$

Leaky ReLU aktivasyon fonksiyonu grafiği Şekil 3.8'de verilmiştir.



Şekil 3.8 Leaky ReLU aktivasyon fonksiyonu grafiği [30]


3.3.3.3 Sigmoid Fonksiyonu

Sigmoid aktivasyon fonksiyonu, girdileri 0 ile 1 arasında bir değere dönüştürerek, genellikle olasılık tahmini veya ikili sınıflandırma problemlerinde kullanılan bir fonksiyondur. Çıktıyı belirli bir aralığa sınırlaması, modelin aşırı öğrenme riskini azaltmada ve tahminlerin daha kararlı olmasında etkilidir. Derin sinir ağlarında yaygın olarak tercih edilmesinin sebebi, gradyan tabanlı optimizasyon algoritmalarıyla uyumlu olması ve türevlenebilir bir yapıya sahip olmasıdır. Bu özelliği, modelin eğitimi sırasında ağırlıkların güncellenmesini ve modelin performansının iyileştirilmesini sağlar. Matematiksel olarak sigmoid aktivasyon fonksiyonu, Denklem 3.19'daki gibi tanımlanır [88].

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.19)$$

Burada, x giriş sinyallerinin toplamıdır ve f(x) çıktı değeridir. Sigmoid aktivasyon fonksiyonu, sıklıkla sinir ağlarında kullanılır çünkü bu fonksiyon, yüksek ve düşük giriş değerlerine karşılık gelen yüksek ve düşük çıktı değerleri verir. Bu, sigmoid aktivasyon fonksiyonunun, bir nöronun çıktısını açık veya kapalı (1 veya 0) olarak ayarlama yeteneği verir. Bu özellik, ikili sınıflandırma problemlerinde sıklıkla kullanılır [30].

Sigmoid aktivasyon fonksiyonu grafiği Şekil 3.9'da verilmiştir.



Şekil 3.9 Sigmoid aktivasyon fonksiyonu grafiği [30]

3.3.3.4 Swish Fonksiyonu


Swish aktivasyon fonksiyonu, girdinin bir sigmoid fonksiyonu ile çarpılmasıyla oluşturulur ve girdinin negatif değerlerine daha iyi cevap verir [30].

Swish aktivasyon fonksiyonunu Denklem 3.20'deki gibi tanımlanır.

$$f(x) = \frac{x}{1 + e^{-x}} \quad (3.20)$$

Swish aktivasyon fonksiyonu, ReLU gibi verimli bir yapıya sahip olmakla birlikte, negatif girdiler için sıfır yerine küçük değerler üreterek daha esnek bir aktivasyon sağlar. Bu sayede, ReLU'da karşılaşılabilen "ölü nöron" problemini azaltarak modelin öğrenme kapasitesini artırabilir. Ayrıca, sigmoid fonksiyonuna benzer şekilde, girdi değerlerine göre sürekli ve türevlenebilir bir çıktı üretmesi, gradyan tabanlı optimizasyon algoritmalarıyla uyumlu olmasını sağlar. Bu özellikler, Swish fonksiyonunu derin öğrenme modellerinde popüler bir seçenek haline getirir [30].


Swish aktivasyon fonksiyonu grafiği Şekil 3.10'da verilmiştir.



Şekil 3.10 Swish aktivasyon fonksiyonu grafiği [30]


3.3.3.5 Softmax Fonksiyonu

Softmax fonksiyonu, derin öğrenme modellerinde çok sınıflı sınıflandırma problemlerinin vazgeçilmez bir aracıdır. Nöron çıktılarını olasılıklara dönüştürerek, modelin bir girdinin hangi sınıfa ait olduğunu tahmin etmesini sağlar. Bu fonksiyon, her bir nöronun çıktısını diğer tüm nöronların çıktılarına göre normalize eder, böylece toplam olasılık değeri 1 olur. Bu sayede, modelin farklı sınıflar arasındaki ayrımı daha net bir şekilde öğrenmesine ve daha doğru tahminler yapmasına yardımcı olur [89]. Softmax aktivasyon fonksiyonu hesaplama işlevi Şekil 3.11'de gösterilmiştir.



Şekil 3.11 Softmax aktivasyon işlevi gösterimi [89]

Softmax fonksiyonu, çoklu sınıflandırma problemlerinde derin öğrenme modellerinin olmazsa olmaz bir parçasıdır. Çıkış katmanında yer alarak, her biri farklı bir sınıfı temsil eden nöronların girdi değerlerini olasılıklara dönüştürür. Bu dönüşüm, girdi değerlerini 0 ile 1 arasında normalize ederek ve toplamalarının 1 olmasını sağlayarak gerçekleştirilir. Böylece, modelin her bir sınıf için bir olasılık değeri üretmesi ve en yüksek olasılığa sahip sınıfı tahmin olarak belirlemesi mümkün olur. Örneğin, bir görüntü sınıflandırma modelinde, softmax fonksiyonu sayesinde bir görüntünün kedi, köpek veya kuş olma olasılıkları hesaplanabilir ve model en yüksek olasılığa sahip sınıfı tahmin eder. Bu nedenle, softmax fonksiyonu, çoklu sınıflandırma problemlerinde modelin karar verme yeteneğini güçlendiren ve tahmin doğruluğunu artıran önemli bir araçtır [30]. Softmax aktivasyon fonksiyonu grafiği Şekil 3.12’de gösterilmiştir.



Şekil 3.12 Softmax aktivasyon fonksiyonu grafiği [89]

3.3.4 Öğrenme Aktarımı (Transfer Learning)

Öğrenme aktarımı, makine öğrenmesi alanında verimliliği ve performansı artırmak için kullanılan güçlü bir tekniktir. İnsanların önceki deneyimlerinden yararlanarak yeni durumlara uyum sağlamasına benzer şekilde, öğrenme aktarımı da önceden eğitilmiş modellerin bilgisini yeni ama ilgili görevlere aktararak, daha hızlı öğrenme ve daha iyi genelleme yeteneği sağlar. Bu yaklaşım, özellikle veri kıtlığı yaşanan veya etiketleme maliyetlerinin yüksek olduğu durumlarda büyük önem taşır, çünkü daha küçük veri kümeleriyle etkili modeller oluşturulmasına olanak tanır [29].

3.3.5 L1 ve L2 Düzenleştirme

Düzenleştirme genel anlamda ağırlıkların cezalandırılması olarak tanımlanabilir. L1 (lasso regresyonu) ve L2 (ridge regresyonu), yapay sinir ağlarında ağırlık değerlerinin güncellenmesi esnasında bazı ağırlıkların aşırı önem kazanmasının ya da kaybolmasının önüne geçmek için geliştirilmiştir. L1 düzenleştirmesi bazı ağırlıkların katsayılarını sıfıra çekerek seyrekleştirilmesinde kullanılır. Genellikle önemsiz ağırlık değerleri çok olan durumlarda tercih edilir. L2 düzenleştirmesi ise katsayıları sıfıra indirgemez, makul tahminler üretmeye yardımcı olur ve L1'e göre daha yaygındır [15].

L1 ve L2 düzenleştirme fonksiyonlarının matematiksel ifadeleri Denklem 3.21 ve Denklem 3.22'de gösterilmiştir.

$$\beta_{L1} = \operatorname{argmin}_{\beta} (\sum_{i=1}^n (y_i - (\beta_0 + \beta_1 x_{i,1} + \dots + \beta_p x_{i,p}))^2 + k \sum_{j=0}^p |\beta_j|) \quad (3.21)$$

$$\beta_{L2} = \operatorname{argmin}_{\beta} (\sum_{i=1}^n (y_i - (\beta_0 + \beta_1 x_{i,1} + \dots + \beta_p x_{i,p}))^2 + k \sum_{j=0}^p |\beta_j|^2) \quad (3.22)$$

Denklemde belirtilen parametreler aşağıdaki gibi ifade edilebilir.

- β_{L1} : L1 düzenleştirme uygulanmış regresyon katsayıları (ağırlıkları)
- β_{L2} : L2 düzenleştirme uygulanmış regresyon katsayıları (ağırlıkları)
- β_0 : Sabit terim
- y_i : i'inci veri noktasının gerçek hedef değişken değeri
- $\beta_1, \beta_2, \dots, \beta_p$: Bağımsız değişkenlerin (özelliklerin) katsayılarıdır.
- $x_{(i,1)}, x_{(i,2)}, \dots, x_{(i,p)}$: i'inci veri noktasının bağımsız değişkeni
- k : Düzenleştirme katsayısı

3.3.6 Evrimsel Sinir Ağları (ESA) ve Katmanları

Evrimsel sinir ağları, çok katmanlı algılayıcıların bir evrimi olarak, görüntü işleme alanında büyük bir çığır açmıştır. Bu yapay sinir ağları, görüntülerdeki karmaşık özellikleri (kenarlar, doku, renk, şekiller) evrim ve havuzlama işlemleriyle otomatik olarak öğrenme yeteneğine sahiptir. Bu sayede, insanın görsel algılama sistemine benzer bir şekilde görsel verileri analiz edebilir ve sınıflandırabilirler [32]. ESA'nın temel yapısı, bir özellik çıkarma ağı ve bir sınıflandırma ağının seri olarak bağlanmasıdır. Özellik çıkarma ağı, evrim ve havuzlama katmanlarının tekrarlanan uygulamalarıyla görüntüyü daha anlamlı özelliklere dönüştürür. Sınıflandırma ağı ise, bu özellikleri kullanarak görüntünün hangi sınıfa ait olduğunu tahmin eder. ESA'nın en önemli avantajlarından biri, özellik çıkarma işlemini otomatikleştirmesi ve böylece manuel olarak özellik mühendisliği yapma ihtiyacını ortadan kaldırmasıdır [30].

ESA'lar, bir görüntü üzerinde kayan bir filtre gibi çalışan evrişim işlemi ile çalışır. Bu filtreler, görüntünün farklı bölgelerindeki özellikleri öğrenir. Evrişim işlemi sonucunda elde edilen özellik haritaları, havuzlama işlemi ile boyutları küçültülerek ağıın öğrenmesi gereken parametre sayısı azaltılır. Bu süreç, ağıın derinliklerine doğru tekrarlanır ve her katman daha soyut özelliklere odaklanır [15]. ESA'nın son katmanı, softmax fonksiyonu ile görüntünün ait olduğu sınıfın olasılığını hesaplar. ESA'ların en önemli avantajları arasında, büyük ölçekli görüntü veri setlerinde yüksek performans göstermeleri, özellikleri otomatik olarak öğrenmeleri ve derin öğrenme mimarilerinin esnekliği sayılabilir. Bu özellikler sayesinde ESA'lar, görüntü sınıflandırma, nesne tespiti, görüntü segmentasyonu gibi birçok görüntü işleme probleminde başarıyla kullanılmaktadır [32].

ESA modelinin mimarisi Şekil 3.13'te verilmiştir.



Şekil 3.13 ESA mimarisi [90].

3.3.6.1 Giriş Katmanı (Input Layer)

Giriş katmanı, görüntü verilerinin ağı ilk olarak sunulduğu yerdir. Giriş katmanı, ham görüntü verisini, her bir pikselin renk yoğunluğunu temsil eden sayısal değerlerden oluşan bir tensör (çok boyutlu matris) olarak alır [91]. Bu sayısal temsil, ağıın görüntüdeki özellikleri öğrenmesine olanak tanır. Giriş katmanındaki görüntü boyutunun, ağıın performansı üzerinde önemli etkileri vardır. Büyük boyutlu görüntüler, ağıın daha fazla detayı öğrenmesine yardımcı olsa da hesaplama maliyetini artırır ve ağıın öğrenme süresini uzatabilir [40]. Küçük boyutlu görüntüler ise hesaplama maliyetini düşürür ancak önemli detayların kaybolmasına neden olabilir. Bu nedenle, giriş görüntüsünün boyutunun, ağıın mimarisi ve çözülmek istenen problem dikkate alınarak dikkatlice belirlenmesi gerekmektedir [32].

Giriş katmanı, ESA'nın görüntü verilerini anlamasına ve işleyebilmesine olanak tanıyan ilk adımdır. Bu katman, görüntüdeki piksellerin yoğunluk değerlerini sayısal bir temsile dönüştürerek, ağın daha yüksek seviyedeki özellikleri öğrenmesine zemin hazırlar. Giriş katmanında yapılan ön işlemler, ağın performansını doğrudan etkileyebilir. Örneğin, görüntünün boyutlandırılması, normalleştirilmesi ve gürültü giderme gibi işlemler, ağın daha hızlı ve daha doğru öğrenmesini sağlayabilir. Ayrıca, giriş katmanına ek olarak kenar ve gradyan gibi bilgiler eklenerek, ağın görüntüdeki önemli özelliklere daha fazla odaklanması sağlanabilir. Bu sayede, ESA'lar görüntü sınıflandırma, nesne tanıma ve görüntü segmentasyonu gibi birçok farklı görüntü işleme görevinde başarıyla kullanılmaktadır [32].

3.3.6.2 Evrişim Katmanı (Convolutional Layer)

Evrişim katmanları, ESA'nın temel yapı taşlarıdır ve görüntü işleme alanında büyük bir öneme sahiptir. Bu katmanlar, girdi görüntüsünün özelliklerini çıkarmak için tasarlanmıştır. Evrişim işlemi, bir filtre (kernel) adı verilen küçük bir matrisin görüntü üzerinde kaydırılarak her noktadaki piksellerle çarpılması ve sonuçların toplanması şeklinde gerçekleşir. Bu işlem sonucunda elde edilen çıktı, özellik haritası (feature map) olarak adlandırılır ve orijinal görüntünün belirli özelliklerini (kenarlar, dokular, şekiller vb.) vurgular [91]. Farklı boyutlardaki filtreler (örneğin, 3x3, 5x5) kullanılarak, ağ farklı ölçekteki özellikleri öğrenilebilir. Evrişim katmanlarının ve filtrelerin ardışık olarak kullanılmasıyla, ağ daha karmaşık ve soyut özelliklere ulaşabilir [32].

Evrişim katmanındaki konvolüsyon işleminin nasıl yapıldığı Şekil 3.14'te gösterilmiştir.

7	2	3	3	8
4	5	3	8	4
3	3	2	8	4
2	8	7	2	7
5	4	4	5	4

*

1	0	-1
1	0	-1
1	0	-1

=

6	-9	-8
-3	-2	-3
-3	0	-2

$$\begin{aligned}
 &2x1 + 8x0 + 4x(-1) + \\
 &7x1 + 2x0 + 7x(-1) + \\
 &4x1 + 5x0 + 4x(-1) \\
 &= -2
 \end{aligned}$$

Şekil 3.14 Konvolüsyon işlemi gösterimi [92].

Evrişim katmanları, görüntü işleme görevlerindeki başarının temelini oluşturur. Bu katmanlar, görüntüleri sayısal temsillerden anlamlı bilgiye dönüştürerek, ağın görsel verileri anlamasını sağlar. Evrişim işlemi, ağırlıklı ortalama işlemine benzer bir şekilde çalışır ve filtrelerin katsayıları, ağın eğitimi sırasında güncellenerek en uygun özelliklerin çıkarılması sağlanır. Bu sayede, ağ, farklı türdeki görüntülerdeki ortak özellikleri öğrenerek genelleme yapabilir [40].

Evrişim işleminin matematiksel olarak hesaplanması Denklem 3.23'te gösterilmiştir.

$$s[i, j] = (I \times K)[i, j] = \sum_m (\sum_n I[m, n] K[i - m, j - n]) \quad (3.23)$$

Denklemde belirtilen parametreler aşağıdaki gibi ifade edilebilir.

- I: m x n boyutlu resim için giriş değeri
- K: kernel
- s: i ve j koordinatlarına sahip sonuç değeri

Evrişim katmanlarının bir diğer önemli özelliği de yerel bağlantılardır. Yani, her bir nöron sadece bir önceki katmandaki küçük bir bölgedeki nöronlarla bağlantılıdır. Bu sayede, ağın parametre sayısı azalır ve hesaplama maliyeti düşer. Sonuç olarak, evrişim katmanları görüntü işleme alanında kullanılan birçok modelin başarısı için kritik öneme sahiptir [32].

3.3.6.3 Yığın Normalizasyon Katmanı (Batch Normalization Layer)

Yığın normalizasyon, derin öğrenme modellerinde eğitim sürecini hızlandıran ve kararlılığını artıran bir tekniktir. Her katmanın girdilerini mini-batch'ler halinde normalize ederek, yani ortalamalarını 0'a ve standart sapmalarını 1'e ayarlayarak çalışır. Bu sayede model daha yüksek öğrenme oranları kullanabilir, ağırlıkların başlangıç değerlerine ve veri setindeki değişikliklere karşı daha az duyarlı hale gelir ve aşırı öğrenmeyi azaltarak daha iyi genelleme yapabilir [93].

Batch normalizasyon ayrıca gradyan kaybolmasını azaltarak daha derin ağların eğitimini mümkün kılar ve evrişimli sinir ağları, tekrarlayan sinir ağları ve çok katmanlı algılayıcılar gibi çeşitli derin öğrenme mimarilerinde kullanılabilir [93].

3.3.6.4 Aktivasyon Katmanı (Activation Layer)


Aktivasyon katmanları, ağa doğrusal olmayan bir özellik kazandırmak yani evrişim işleminde sahip olunan doğrusallığı kırmak için kritik bir role sahiptir. Bu katmanlar, evrişim işlemi sonucunda elde edilen lineer çıktılara bir aktivasyon fonksiyonu uygulayarak ağın daha karmaşık ve soyut özellikleri öğrenmesini sağlar. Aktivasyon fonksiyonları, nöronların ateşleme eşiğini belirleyerek, ağın belirli bir özelliği öğrenmesine olanak tanır [32]. En yaygın

kullanılan aktivasyon fonksiyonlarından biri ReLU (Rectified Linear Unit) olup, girdi değeri sıfırdan büyükse aynı değeri, sıfırdan küçükse sıfırı döndürür. ReLU'nun basit yapısı ve türevinin kolay hesaplanması, derin ağlarda tercih edilmesine neden olur [86].

ReLU gibi aktivasyon fonksiyonları, ağın öğrenme kapasitesini önemli ölçüde etkiler. Bu fonksiyonlar, ağın doğrusal olmayan ilişkileri öğrenmesini sağlayarak, daha karmaşık ve gerçek dünya problemlerine uygulanabilir hale gelmesini sağlar. Ayrıca, ReLU gibi fonksiyonlar, kaybolan gradyan problemi olarak bilinen, derin ağlarda gradyanların sıfıra yaklaşarak öğrenmenin durmasına neden olan bir sorunu azaltmaya yardımcı olur. Bu sayede, ağ daha derin katmanlarda bile etkili bir şekilde eğitilebilir [86]. Diğer aktivasyon fonksiyonları (sigmoid, tanh, vb.) de farklı özelliklere sahip olup, farklı uygulama alanlarında tercih edilebilir. Ancak, ReLU'nun basitliği, etkinliği ve yaygın kullanımı nedeniyle, derin öğrenme modellerinde en popüler aktivasyon fonksiyonlarından biri olarak kabul edilir [32].

3.3.6.5 Havuzlama Katmanı (Pooling Layer)

ESA'da evrişim işlemi sonucu elde edilen özellik haritaları, genellikle yüksek boyutludur. Bu yüksek boyutluluk, ağın karmaşıklığına ve hesaplama maliyetine neden olur [30]. Havuzlama katmanları, bu problemi çözmek için kullanılır. Havuzlama işlemi, özellik haritalarının boyutunu küçültürken, en önemli özellikleri koruyarak ağın öğrenme sürecini hızlandırır ve aşırı öğrenmeyi önler. Bu işlem, genellikle maksimum havuzlama veya ortalama havuzlama yöntemleri ile gerçekleştirilir. Maksimum havuzlama, Şekil 3.15'te de görüldüğü gibi belirlenen bir bölgedeki en büyük değeri alırken ortalama havuzlama, bölgedeki değerlerin ortalamasını alır. Havuzlama işlemi, ağın çevresel değişkenlere karşı daha dayanıklı olmasını sağlar ve özelliklerin daha genel bir temsilini elde etmeye yardımcı olur [32].



Şekil 3.15 Maksimum havuzlama yöntemi gösterimi [30].


Havuzlama katmanları, ESA'ların başarısı için kritik öneme sahiptir. Bu katmanlar, ağın öğrenme sürecini hızlandırırken, aynı zamanda veri özetleme işlemi de gerçekleştirir. Bu sayede, ağ daha az parametre ile daha iyi performans gösterir [32]. Özellikle büyük boyutlu

verilerde, havuzlama işlemi hesaplama maliyetini önemli ölçüde düşürür. Ayrıca, havuzlama işlemi, ağın overfitting (aşırı öğrenme) problemine karşı daha dirençli olmasını sağlar [30]. Ancak, havuzlama işlemi sırasında bilgi kaybı yaşanabilir. Bu kaybı minimize etmek için padding işlemi kullanılır. Padding işlemi, özellik haritalarının kenarlarına sıfır veya ortalama değer gibi sabit değerler ekleyerek, havuzlama işlemi sırasında boyut küçülmesinden kaynaklanan bilgi kaybını azaltır. Böylece, ağın performansı artırılabilir [40].

3.3.6.6 Tam Bağlantı Katmanı (Fully Connected Layer)

ESA'da evrişim ve havuzlama katmanları, girdi görüntüsünün önemli özelliklerini çıkararak yüksek seviyeli bir temsil oluşturur. Bu temsil, daha sonra tam bağlantı katmanlarına aktarılır. Tam bağlantı katmanı, adından da anlaşılacağı gibi önceki katmandaki tüm nöronlarla tam olarak bağlı olan bir katmandır [30]. Bu sayede ağ, öğrenilmiş özellikleri birleştirerek karmaşık kararlar verebilir. Tam bağlantı katmanları, genellikle ESA'nın son katmanında yer alır ve ağı nihai çıkışı oluşturur. Bu katman sınıflandırma, regresyon gibi çeşitli görevler için kullanılabilir. Örneğin, bir görüntü sınıflandırma görevinde tam bağlantı katmanı, görüntünün hangi sınıfa ait olduğunu tahmin etmek için kullanılır [32].

Şekil 3.16'da tam bağlantı katmanın akciğer röntgen görüntüsünü sınıflandırmasının gösterimi verilmiştir.




Şekil 3.16 Tam bağlantı katmanı gösterimi.

Tam bağlantı katmanlarında, önceki katmandan gelen çok boyutlu özellik haritası, tek boyutlu bir vektör haline getirilir. Bu vektör, tam bağlantı katmanındaki her bir nörona bağlanır. Her bir nöron, gelen verilerle ağırlıklandırılmış bir toplam alır ve bu toplam, bir aktivasyon

fonksiyonuna uygulanarak çıktı üretilir. Bu işlem, tüm nöronlar için tekrarlanır ve sonuç olarak bir çıktı vektörü elde edilir. Tam bağlantı katmanları, ağız öğrenme sürecinde geri yayılım algoritması ile eğitilir. Bu sayede, ağız, hata sinyalini kullanarak ağırlıklarını güncelleyerek daha doğru tahminler yapmayı öğrenir. Tam bağlantı katmanları, ESA'ların esnekliğini artırarak, farklı türdeki görevler için kullanılmalarını sağlar. Ancak, çok sayıda parametreye sahip olmaları nedeniyle, aşırı öğrenme problemine yol açabilirler. Bu nedenle, düzenleme teknikleri kullanarak bu problemin önüne geçmek önemlidir [32].

ESA'ların yapısı bilginin ağızdan yalnızca ileri yönde geçtiği ileri beslemeli ağların yapısıyla uyumludur. Geri yayılım algoritması ESA'larda genellikle ileri beslemeli bir ağız beslemek ve eğitmek için kullanılan algoritmalardır. Algoritma, $f(Q)$ kayıp fonksiyonunun değeri ve durumuna göre ileri beslemeli bir ağız ağırlıklarını hesaplamada yardımcı olur. Ağırlık matrisi (W), optimizasyon algoritmaları tarafından bu gradyanlar ile güncellenir. Her adımda güncellenen ağırlıkların sonucunda hesaplanan kayıp fonksiyonu minimum seviyeye ulaşana kadar ağırlık değerleri geri beslemeden aldığı bilgilere göre güncellenmeye devam eder [14]. Şekil 3.17'de biri giriş katmanı, dördü gizli katman ve biri de çıkış katmanı olan toplam altı katmanlı basit bir ESA mimarisi gösterilmiştir.



Şekil 3.17 Altı katmandan oluşan basit bir ESA mimarisi gösterimi [14].

Şekil 3.17’de gösterilen ESA mimarisinde $a^{(i)}$ ile $i = 1, 2, \dots, 6$ şeklinde belirtilen katman sayısıdır. $x = a^{(1)} = (x_1, \dots, x_n)$ şeklinde n boyutlu bir giriş katmanı vektörü olmak üzere n sayıda x_i başlangıç giriş düğümü olduğunu varsayalım. Ayrıca $a^{(i)}$ katmanları, $i = 2, \dots, 5$ gizli katmanları ifade eder. Son olarak kayıp fonksiyonunu besleyen çıkış katmanı ise $a^{(6)} = (a_1^{(6)}, a_2^{(6)})$ şeklindedir ve y değeri $a^{(6)}$ ’dan sınıf olasılıkları hesaplanarak belirlenir [14].

Daha sonra sabit ağırlık vektörü Q_t ’de kayıp fonksiyonunu gradyanının hesaplanması Denklem 3.24’te verilmiştir.

$$\nabla f(Q_t) = \left[\frac{\delta f(Q_t)}{\delta Q_1} \dots \frac{\delta f(Q_t)}{\delta Q_n} \right] \quad (3.24)$$

Sonrasında her bir adımda $a^{(i)} = h_i (W^{(i)} a^{(i-1)} + b^{(i)})$ tanımlanır. Bu tanımlamada $W^{(i)}$, i katmanından $i+1$ katmanına kadar olan bağlantıların ağırlıklarını temsil eder ve $b^{(i)}$ ise bu ağırlıklara eşlik eden sapma (bias) terimleridir. Kayıp fonksiyonunun ilk ağırlık matrisine ve sapma terimlerine göre geriye doğru yayılımı zincir kuralı ile sırasıyla Denklem 3.25, Denklem 3.26, Denklem 3.27 ve Denklem 3.28’de gösterilmiştir [14].

$$\frac{\delta f}{\delta W^{(1)}} = \frac{\delta f}{\delta a^{(6)}} \frac{\delta a^{(6)}}{\delta a^{(5)}} \frac{\delta a^{(5)}}{\delta a^{(4)}} \frac{\delta a^{(4)}}{\delta a^{(3)}} \frac{\delta a^{(3)}}{\delta a^{(2)}} \frac{\delta a^{(2)}}{\delta W^{(1)}} \quad (3.25)$$

$$\frac{\delta f}{\delta b^{(1)}} = \frac{\delta f}{\delta a^{(6)}} \frac{\delta a^{(6)}}{\delta a^{(5)}} \frac{\delta a^{(5)}}{\delta a^{(4)}} \frac{\delta a^{(4)}}{\delta a^{(3)}} \frac{\delta a^{(3)}}{\delta a^{(2)}} \frac{\delta a^{(2)}}{\delta b^{(1)}} \quad (3.26)$$

Örneğin $a_2^{(4)}$ ve $a_1^{(5)}$ arasındaki ileri geçiş bağlantısı $W_{2,1}^{(4)}$ ise bu değeri güncellemek adına geri geçiş gradyanı için Denklem 3.27’de gösterildiği gibi $\frac{\delta f}{\delta a^{(6)}}$ şeklinde yönlü türev kuralı kullanılır.


$$\frac{\delta f}{\delta W_{2,1}^{(4)}} = \frac{\delta f}{\delta a^{(6)}} \frac{\delta a^{(6)}}{\delta a_1^{(5)}} \frac{\delta a_1^{(5)}}{\delta W_{2,1}^{(4)}} = \left(\frac{\delta f}{\delta a_1^{(6)}} \frac{\delta a_1^{(6)}}{\delta a_1^{(5)}} + \frac{\delta f}{\delta a_2^{(6)}} \frac{\delta a_2^{(6)}}{\delta a_1^{(5)}} \right) \frac{\delta a_1^{(5)}}{\delta W_{2,1}^{(4)}} \quad (3.27)$$

Aynı şekilde $b^{(5)}$ gradyanı da Denklem 3.28’de gösterildiği gibi hesaplanır.

$$\frac{\delta f}{\delta b^{(5)}} = \frac{\delta f}{\delta a^{(6)}} \frac{\delta a^{(6)}}{\delta b^{(5)}} = \frac{\delta f}{\delta a_1^{(6)}} \frac{\delta a_1^{(6)}}{\delta b^{(5)}} + \frac{\delta f}{\delta a_2^{(6)}} \frac{\delta a_2^{(6)}}{\delta b^{(5)}} \quad (3.28)$$

Seyreltme (Dropout) İşlemi: Derin öğrenme modellerinde, özellikle evrişimli sinir ağlarında, aşırı öğrenme (overfitting) önemli bir problemdir [32]. Aşırı öğrenme, modelin eğitim verilerine aşırı uyum sağlayarak, yeni ve görülmemiş verilere genelleme yeteneğini kaybetmesi durumudur. Bu sorunu çözmek için kullanılan yöntemlerden biri olan Dropout yöntemi Şekil 3.18’de gösterildiği gibi sinir ağının eğitimi sırasında, belirli bir olasılıkla nöronların rastgele devre dışı bırakılması işlemidir [40]. Bu sayede, ağın farklı alt ağları üzerinde eğitim gerçekleşir

ve ağı daha genelleştirici bir yapıya sahip olması sağlanır. Dropout, ağırlık çürütmesi gibi diğer düzenleme tekniklerine göre daha etkili olduğu gösterilmiştir. Her bir eğitim adımında farklı bir alt ağ kullanıldığından, ağı belirli bir nörona veya küçük bir nöron grubuna aşırı bağımlılığı önlenir [32].



Şekil 3.18 Dropout işlemi gösterimi [94].

Düzleştirme (Flatten) İşlemi: Girişi tek boyutlu bir vektör haline dönüştürür. Tam bağlantılı katmanlara geçmeden önce uygulanır. Her feature görüntüsü vektör haline getirilerek tam bağlantılı katmanında giriş olarak kullanılır ve işleme sokulur [14].

3.3.7 Derin Öğrenme Modelleri


Literatürde birçok alana özgü farklı derin öğrenme modelleri geliştirilmiştir. Bu çalışmaya özgü olarak görüntüler üzerine geliştirilmiş ESA temelli yaygın derin öğrenme modelleri incelenecektir.

3.3.7.1 ResNet Modeli

ResNet (residual network), derin öğrenme modellerinde karşılaşılan aşırı öğrenme ve gradyan kaybolma gibi sorunları aşmak amacıyla geliştirilmiş bir sinir ağı mimarisidir. ImageNet gibi büyük veri setlerindeki görüntü tanıma görevlerinde elde ettiği başarılı sonuçlarla dikkat çekmiştir. ResNet'in temel özelliği, ağı katmanları arasında eklenen artık bağlantılar'dır. Bu bağlantılar, bir önceki katmanın çıktısını doğrudan sonraki katmanın çıktısına ekleyerek, bilginin daha iyi akmasını sağlar. Böylece, ağı daha derin katmanlarına bilgi iletimi kolaylaştır ve gradyan kaybolma problemi azalır [32]. ResNet'in farklı varyantları (ResNet18, ResNet50, ResNet101 vb.) bulunmakla birlikte, hepsinin ortak özelliği, artık bağlantılar sayesinde daha derin ve daha karmaşık yapıların öğrenilebilmesini sağlamasıdır [15]. ResNet mimarisi, derin

öğrenme alanında bir dönüm noktası olmuş ve birçok diğer modelin geliştirilmesinde ilham kaynağı olmuştur.

ResNet modellerinden biri olan ResNet50 mimarisinin gösterimi Şekil 3.19’da gösterilmiştir.




Şekil 3.19 ResNet50 mimarisinin gösterimi [95].

3.3.7.2 DenseNet Modeli

DenseNet (yoğun ağ), derin öğrenme modellerinde katmanlar arasındaki bağlantıları yoğunlaştırarak, geleneksel modellerin karşılaştığı gradyan kaybolma gibi sorunları aşmayı hedefleyen yenilikçi bir mimaridir [15]. Bu mimaride, her bir katman, kendinden önceki tüm katmanların çıktılarını doğrudan alır. Bu sayede, ağın bilgi akışı optimize edilir, özellik yeniden kullanımı maksimuma çıkarılır ve daha derin katmanlara bile düşük seviyeli özellikler aktarılır. DenseNet'in bu yoğun bağlantı yapısı, modelin daha karmaşık ve soyut kavramları öğrenmesini kolaylaştırırken, aynı zamanda parametre verimliliği sağlayarak daha az hesaplama maliyetiyle yüksek performans sunar [32].

DenseNet modellerinden biri olan DenseNet121 mimarisinin gösterimi Şekil 3.20’de gösterilmiştir.



Şekil 3.20 DenseNet121 mimarisinin gösterimi [96].

DenseNet'in yoğun bağlantı yapısı, modelin gradyan akışını iyileştirir, özellik çıkarımını güçlendirir ve parametre verimliliğini artırır. Bu sayede, DenseNet, görüntü sınıflandırma, nesne tespiti ve doğal dil işleme gibi çeşitli alanlarda başarılı sonuçlar elde etmiştir. Özellikle büyük veri setleri ve sınırlı hesaplama kaynakları olan durumlarda DenseNet, diğer derin öğrenme modellerine göre daha iyi performans gösterir. DenseNet'in bu avantajları, onu derin öğrenme araştırmalarında popüler bir model haline getirmiş ve birçok farklı alanda kullanılmasına olanak sağlamıştır [32].


3.3.7.3 EfficientNet Modeli

Evrişimsel sinir ağlarının performansını artırmak için yapılan çalışmalar, ağın derinlik, genişlik ve çözünürlük boyutlarının dengeli bir şekilde ölçeklendirilmesinin önemini ortaya koymuştur. Bu alandaki araştırmalar, 2019 yılında yeni bir temel ağ tasarımı ve ölçeklendirme yöntemiyle "EfficientNet" adlı bir model ailesinin oluşturulmasına yol açmıştır.

EfficientNet modelleri, önceki en iyi ESA'lara kıyasla daha yüksek doğruluk oranları ve daha düşük hesaplama maliyeti ile dikkat çekmektedir. Bu modeller, CIFAR-100 ve Flowers gibi farklı veri setlerinde de yüksek doğrulukla çalışarak ve daha az parametre kullanarak üstün performans göstermiştir [97].

EfficientNet model ailesi B0-B7 arasında 8 adet modelden oluşur ve sayı arttıkça hesaplanan parametre sayısı ve doğruluk oranı artar. EfficientNet modelinin diğer modellere göre en önemli özelliği daha yüksek doğruluk oranı ve daha hızlı çalışmasıdır. EfficientNet modelinin ana yapısı MobileNetV2 olarak bilinen ters çevrilmiş darboğaz MBConv modelidir [98]. EfficientNet modellerinin başarısının temel nedeni, ESA'ların derinlik, genişlik ve çözünürlük boyutlarının dengeli bir şekilde ölçeklendirilmesidir. Bu ölçeklendirme yöntemi, ağın hem kapasitesini hem de verimliliğini artırarak daha iyi sonuçlar elde edilmesini sağlar [97].

EfficientNet modelinde genişlik, derinlik ve çözünürlük olarak daha büyük ağlar daha yüksek doğruluk elde etme eğilimindedir ancak doğruluk kazanımı %80'e ulaştıktan sonra hızlı bir şekilde doyurulur ve bu da tek boyutlu ölçeklendirmenin sınırlandırılmasını gösterir [98]. Bu üç boyutun optimum seviyede belirlenebilmesindeki zorluk nedeniyle diğer yöntemlerde sadece bir boyut ölçeklendirilmesi yapılmaktadır [97]. EfficientNet modelinde bu üç ölçeklendirme tekniğinin optimum seviyede yapılmasına bileşik ölçeklendirme (compound scaling) denir [98]. EfficientNet modeli oluşturmak için yapılan ölçeklendirme işlemlerinin gösterimi Şekil 3.21'de gösterilmiştir.



Şekil 3.21 EfficientNet modeli için ölçeklendirmeler; (a) temel ağ (b)-(d) ağın sadece bir boyutunu artıran ölçeklendirme (e) önerilen bileşik (üç boyut arttıran) ölçeklendirme [97].


Şekil 3.21’de gösterilen ölçekleme yöntemlerine göre temel ağ, ölçeklendirme olmadan kullanılan temel ağıdır. Genişlik ölçeklendirme ağı, her katmandaki kanal sayısının artırılmasıdır. Derinlik ölçeklendirme ağı, katman sayısının artırılmasıdır. Çözünürlük ölçeklendirme ağı, giriş görüntüsünün çözünürlüğünü artırma yöntemidir. Tüm bunların ortak bir ölçeklendirme katsayısı (φ) ile dengeli olarak artırılması bileşik ölçeklendirme yöntemi olarak adlandırılır [99]. Ölçeklendirme katsayısının temel olarak hesaplanması Denklem 3.29’da gösterilmiştir.

$$\varphi = w * d^2 * r^2 \quad (3.29)$$

Denklemde belirtilen parametreler aşağıdaki gibi ifade edilebilir.


- φ : Ölçeklendirme katsayısı
- w : Genişlik (width)
- d : Derinlik (depth)
- r : Çözünürlük (resolution)

Efficient modelinin temel ağ modeli olan EfficientNetB0 modelinin ImageNet üzerinde ölçeklendirme performansı gözlemlenmiştir. EfficientNetB0 modeli üzerinde yapılan bileşik ölçeklendirme sonucu ve sırasıyla tek boyutta genişlik, derinlik ve çözünürlük ölçeklendirmelerinin sonuçları Şekil 3.22’de gösterilmiştir. Buna göre bileşik ölçeklendirme yöntemi %2,5’a kadar daha fazla iyileşme sağladığı görülmüştür [97].



Şekil 3.22 EfficientNetB0 modeli üzerinde ölçeklendirmeler [97]

EfficientNetB0 modeli mimarisinin gösterimi Şekil 3.23'te gösterilmiştir.




Şekil 3.23 EfficientNetB0 mimarisinin gösterimi [97].

ESA modeli olan EfficientNet modelinin ağ derinliği, genişliği ve çözünürlüğünün dikkatli bir şekilde dengelenmesinin, daha iyi doğruluk ve verimlilik için çok önemlidir. Bu bileşik ölçeklendirme yöntemiyle, mobil boyutlu bir EfficientNet modelinin oldukça etkili bir şekilde ölçeklendirilebileceğini ve ImageNet ile beş yaygın öğrenme aktarım veri seti üzerinde mevcut en iyi ESA'lerden çok daha az parametre ve FLOPS (Floating Point Operations) ile üstün doğruluk elde edebilmektedir [97].

EfficientNet model ailesinin bu çalışmada en verimli sonuçlar veren EfficientNetB1 varyantı mimarisi Şekil 3.24'te gösterilmiştir. Temel olarak yedi adet blok yapısına ayrılan EfficientNetB1 modeli toplam 24 adet katmandan oluşmaktadır. Standart konvolüsyon katmanı ile başlayan model çeşitli özelleştirilmiş MBConv katmanları ile devam etmektedir. Son

kısımda ise yine standart konvolüsyon ve ortalama havuzlama katmanı içerir. Ardından sınıflandırma için yaygın olarak kullanılan softmax aktivasyon fonksiyonu ile model tamamlanır [99].



Şekil 3.24 EfficientNetB1 mimarisinin gösterimi [100].

EfficientNet model ailesinin ölçeklendirme katsayılarıyla geliştirilen çeşitli varyantları bulunmaktadır. Bu varyantlar bileşik ölçekleme yaklaşımına bağlı olarak derinlik, genişlik ve çözünürlük açısından farklılık gösterir. EfficientNetB0 modeli, orta derinlik, orta genişlik ve orta seviyede çözünürlüğe sahip temel model olup EfficientNetB1-B7 modelleri ise bileşik ölçekleme katsayısına göre artırılmasıyla elde edilen daha büyük varyantlardır [99].

Sonuç olarak EfficientNet modelleri, yüksek doğruluk ve düşük hesaplama maliyeti ile derin öğrenme alanında önemli bir ilerleme kaydedilmesini sağlamıştır. Bu modeller, görüntü sınıflandırma, nesne tanıma ve diğer bilgisayarlı görme görevlerinde başarıyla kullanılmaktadır [97].

BÖLÜM 4

ÖNERİLEN YÖNTEM

4.1 MODELİN OLUŞTURULMASI VE EĞİTİLMESİ

Çalışmada Google tarafından geliştirilen evrişimli sinir ağı modeli olan EfficientNet model ailesi, önerilen modelin temeli olarak ele alınmıştır. EfficientNet modeli, model derinliği, genişliği ve çözünürlüğü gibi faktörleri dengeli bir şekilde ölçeklendirerek yüksek doğruluk oranı yakalayan ve hesaplama kaynaklarını verimli kullanan bir modeldir. EfficientNetB0, ilgili model ailesinin en temel modeli olmasına rağmen çok verimli sonuçlar vermiştir [98]. Bu bölümde modelin oluşturulma ve eğitim aşamalarından bahsedilecektir.

4.1.1 Donanım Gereksinimleri

Önerilen modelleri eğitmek için Python programlama dili kullanılmıştır. Akciğer röntgen görüntülerine yönelik tüm deneyler AMD Ryzen 5 7520U işlemci, 8 GB RAM AMD Radeon (TM) 610M ekran kartı ve 16 GB RAM'e sahip kişisel bilgisayarla Google Colaboratory (Colab) online bulut hizmeti sunucularının sağladığı 12 GB RAM ve 320 GB disk alanı özelliklerinde merkezi işlem birimi (CPU) kullanılarak ücretsiz gerçekleştirilmiştir.

4.1.2 Veri Seti

Çalışmada birden fazla kaynaklardan bir araya getirilerek oluşturulmuş ve açık kaynaklı olarak Kaggle'da yayınlanmış olan “COVID-19 Radiography Database” veri setinden yararlanılmıştır. İlgili veri setinde 3616 adet COVID-19, 6012 adet Akciğer Opasitesi, 1345 adet Viral Pnömoni ve 10200 adet Normal/Sağlıklı akciğer röntgen (CXR) görüntüsü ve her görüntüye ait akciğer bölümünün maskelenmiş görüntüleri bulunmaktadır. Bu çalışmada sınıflandırma dengesizliği engellenmek amaçlanıp dağılım dengesini koruyabilmek adına 1050 adet COVID-19, 1040 adet Akciğer Opasitesi, 1040 adet Viral Pnömoni ve 1030 adet Normal/Sağlıklı olmak üzere toplam 4160 adet akciğer röntgen (CXR) görüntüsü veri seti olarak kullanılmıştır.

4.1.3 Ön İşlem

Veri setindeki CXR görüntülerinin her biri 299x299 piksel boyutundadır. Kullanılacak algoritmanın girdi gereksinimleri 224x224 formatlarında olduğu için veri setindeki görüntüler yeniden boyutlandırma işlemi ile istenilen format haline getirilmiştir. Veri setinin %80'lik bölümü eğitim, kalan %20'lik bölümü ise test için ayrılmıştır. Test için ayrılan %20'lik bölümün yarısı da doğrulama için ayrılmıştır. Sonuç olarak toplam 4160 adet görüntüden 3328 adeti (%80) eğitim, 416 adeti (%10) doğrulama ve 416 adeti (%10) test için ayrılmıştır.

Veri setinde bulunan veriler sınıflandırıldıkları etiket (label) isimleriyle birlikte veri seti dosyasından okutularak sisteme kaydedilmiştir. Ardından Keras kütüphanesinin veri artırma için kullanılan “ImageDataGenerator” metodu ile ilgili veri setinden farklı örnekler oluşturulmuştur. Bu metod ile modelin aşırı öğrenme, yetersiz öğrenme gibi olumsuz durumları engellenerek veri seti, modelin eğitimi konusunda daha güçlü ve verimli hale getirilmiştir.

4.1.4 Modelin Oluşturulması

Model eğitimi için kullanılacak veri seti, uygun ön işleme adımlarından geçirildikten sonra model oluşturma aşamasına geçilir. Bu çalışmada oluşturulan modelin temeli, öğrenme aktarımı yöntemi kullanılarak EfficientNetB1 modelinden alınmıştır. EfficientNetB1 modeli, ImageNet gibi büyük bir veri seti üzerinde eğitilmiş ve genel görüntü özelliklerini öğrenmiş bir modeldir. Bu modelin önceden eğitilmiş ağırlıklarını kullanarak başlamak, modelin yeni veri setine daha hızlı uyum sağlamasına ve daha iyi performans göstermesine yardımcı olur.

Öğrenme aktarımı yapılırken, EfficientNetB1 modelinin son katmanı (sınıflandırma katmanı) kaldırılır ve yerine çalışmaya özgü yeni bir sınıflandırma katmanı eklenir. Bu sayede model, yeni veri setindeki sınıfları öğrenmeye odaklanır. Öğrenme işlemi sırasında, modelin ağırlık ve sapma değerleri güncellenerek modelin performansı optimize edilir. Ancak, öğrenme aktarımı sayesinde model genel özellikleri zaten öğrenmiş olduğundan, öğrenme süreci hızlanır ve daha az veri ile daha iyi sonuçlar elde edilebilir.

Modelin temeli EfficientNetB1 ile oluşturulduktan sonra, eğitim kararlılığını ve hızını artırmak amacıyla yığın normalizasyon (batch normalization) işlemi uygulanarak önceki katmanın aktivasyonları normalleştirilmiştir. Yığın normalizasyon tekniğinde momentum parametresi 0.99 ve epsilon parametresi 0.001 olarak belirlenmiştir. Ardından modele 256 nöronlu yeni bir gizli katman eklenmiştir. Bu katmanın ağırlık ve sapmalarına L1 ve L2 düzenleme teknikleri uygulanarak aşırı öğrenmenin önlenmesi hedeflenmiştir. L1 düzenleme parametresi 0.006 ve L2 düzenleme parametresi ise 0.016 olarak seçilmiştir. Modelin

karmaşık desenleri öğrenmesini sağlamak ve doğrusallığı kırmak için ReLU aktivasyon fonksiyonu kullanılmıştır. Ayrıca, Dropout yöntemi ile eğitim sırasında her epokta nöronların rastgele olarak %45'i devre dışı bırakılarak aşırı öğrenme engellenmeye çalışılmıştır.

Çalışmada dört sınıflı çoklu sınıflandırma (Viral Pnömoni, COVID-19, Akciğer Opasitesi ve Normal) yapılacağı için modelin çıkış katmanı dört nöronlu olarak tasarlanmış ve çoklu sınıflandırma modellerinde yaygın olarak kullanılan softmax aktivasyon fonksiyonu kullanılmıştır. Softmax fonksiyonu, her sınıf için olasılıklar üreterek bir girdi görüntüsü için en olası sınıfı tahmin etmektedir.

Modelin derlenmesi aşamasında Adamax optimizasyon fonksiyonu kullanılmıştır. Adamax, Adam optimizasyon algoritmasının bir varyantı olup, öğrenme oranını eğitim süreci boyunca otomatik olarak ayarlayabilen uyarlamalı bir algoritmadır. Öğrenme oranı çeşitli denemelerin sonucunda 0.001 değerine yakınsadığı için verimliliğin artması açısından öğrenme oranı başlangıç olarak 0.001 olarak belirlenmiştir. Adamax algoritması bu oranı eğitimin gidişatına göre otomatik olarak düzenlenmektedir.

Kayıp fonksiyonu olarak çok sınıflı sınıflandırma problemlerine uygun olan "categorical_crossentropy" metodu seçilmiştir. Kayıp fonksiyonu, modelin tahminlerinin gerçek etiketlerden ne kadar farklı olduğunu ölçer ve modelin eğitim sürecinde kendini geliştirmesi için bir geri bildirim mekanizması sağlar.

Modelin performansını değerlendirmek için ise "accuracy" (doğruluk) metriği kullanılmıştır. Doğruluk, modelin doğru tahminlerinin toplam tahminlere oranını ifade eder ve modelin genel başarısını ölçmek için yaygın olarak kullanılan bir metriktir.


EfficientNetB1 temeliyle oluşturulan modelin özeti Şekil 4.1'de verilmiştir.

Model: "sequential"		
Layer (type)	Output Shape	Param #
efficientnetb1 (Functional)	(None, 1280)	6575239
batch_normalization (Batch Normalization)	(None, 1280)	5120
dense (Dense)	(None, 256)	327936
dropout (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 4)	1028
Total params: 6,909,323		
Trainable params: 6,844,708		
Non-trainable params: 64,615		

Şekil 4.1 Oluşturulan modelin özeti.

4.1.5 Modelin Eğitilmesi

EfficientNetB1 temelli oluşturulan dört sınıflı modelin eğitim sürecini kontrol etmek ve optimize etmek için çeşitli parametreler kullanılmıştır. Modelin eğitiminde her adımda kaç örneğin modele gösterileceğini belirleyen grup boyutu (batch size) değeri 16 olarak seçilmiştir. Modelin tüm eğitim verilerini eğitim boyunca toplam kaç kez göreceğini belirleyen devir (epok) sayısı ise 10, 15, 20, 25, 30 ve üzeri değerler seçilerek eğitimler yapılmıştır. İlk çalışmalarda ezberlemeyi önlemek ve optimum epok değerini bulmak için epok sayısı yüksek tutulmuştur. En verimli sonuçları veren optimum epok değerinin seçimini yapmak için epok sayılarına göre kayıp değerleri ve doğruluk oranlarının grafiği Şekil 4.2’de gösterilmiştir.




Şekil 4.2 Optimum epok değerinin seçimi için epok sayısına göre kayıp ve doğruluk oranları grafikleri.

Şekil 4.2’de verilen grafiklere göre 15. epoktan sonra kayıp değeri ve doğruluk oranları doygunluk seviyesine ulaşmaya başlamış ve olumlu yönde ilerleme kaydedememiştir. Bu nedenle eğitimde kullanılmak üzere en verimli sonuçları veren değer olan 15 epok sayısı seçilmiştir.

Modelin öğrenme oranı başlangıçta 0.001 seçilip bu oranının kaç epokta bir güncelleneceğini belirleyen tahammül (patience) değeri ise 3 olarak belirlenmiştir. Modelin sınıflandırma eşik (threshold) değeri 0.9 seçilmiştir. Bu parametreye göre görüntünün sınıflandırma olasılık değeri 0.9’den büyük ise görüntü ilgili sınıfa ait olduğu tayini yapılmaktadır. Bu parametreler, eğitim süreci boyunca dikkatlice izlenmiş ve modelin en iyi performansı elde etmek için çeşitli ince parametre ayarları yapılmıştır.


Modelin sınıflandırma aşamasında kullanılan softmax fonksiyonu, görüntünün hangi sınıfa ait olduğunu olasılık olarak çıktısını vermektedir. Modelin görüntüleri olasılık oranları şeklinde sınıflandırma sonuçları Şekil 4.3'te gösterilmiştir.



Şekil 4.3 Her bir sınıf için sınıflandırma sonuç örnekleri.

Sınıflandırma sonuçlarının 0-1 arasındaki oranlar halinde çıktısı verilmesinin ardından eşik değeri 0.9 seçildiği için bu orandan yüksek olan değerler ilgili görüntünün o sınıfa ait olduğunu belirtmektedir. Buna göre Şekil 4.3'te ilk görüntü 0.95 oranı ile COVID-19, ikinci görüntü 0.91 oranı ile akciğer opasitesi, üçüncü görüntü 0.94 oranı ile pnömoni ve dördüncü görüntü ise 0.97 oranı ile normal (sağlıklı) sınıfına ait olduğunu göstermektedir.

Modelin eğitim setinden rastgele seçilip modelin eğitimi için gönderilecek bir batch uzunluğundaki 16 adet veri örnekleri Şekil 4.4'te gösterilmiştir.



Şekil 4.4 Eğitim setinden rastgele seçilmiş bir grupluk (batch) görüntü örnekleri.



BÖLÜM 5

PERFORMANS ÖLÇÜTLERİ VE DEĞERLENDİRME


5.1 PERFORMANS ÖLÇÜTLERİ

Modelin eğitimi tamamlandıktan sonra gerçek dünya performansını değerlendirmek için test ve doğrulama verileri kullanılır. Model, bu veriler üzerinde tahminlerde bulunur ve tahminlerin doğruluğu çeşitli metrikler (doğruluk, kesinlik, duyarlılık, F1-skoru, karmaşıklık matrisi gibi) kullanılarak değerlendirilir. Bu metrikler, modelin genelleme yeteneği ve gerçek dünya verileri üzerindeki başarısı hakkında bilgi sağlar [15].

5.1.1 Karmaşıklık Matrisi (Confusion Matrix)

Karmaşıklık matrisi, bir sınıflandırma modelinin performansını değerlendirmek için kullanılan bir görselleştirme aracıdır ve modelin tahminlerinin gerçek etiketlere göre dağılımını gösterir. Matrisin satırları gerçek sınıfları, sütunları ise modelin tahmin ettiği sınıfları temsil eder. Şekil 5.1'de gösterilen karmaşıklık matrisi, oluşturulan modelin eğitim ve test aşamalarından sonraki performansını özetlemektedir. Matrisin diyagonalindeki değerler modelin doğru tahminlerini, diyagonal dışındaki değerler ise modelin yaptığı hataları gösterir. Karmaşıklık matrisindeki değerler incelenerek modelin güçlü ve zayıf yönleri belirlenebilir. Ayrıca modelin performansını iyileştirmek için hangi alanlara odaklanması gerektiği konusunda bilgi edinilebilir [14].

Matrisin diyagonalindeki hücreler, modelin doğru tahminlerini (gerçek pozitifler - TP ve gerçek negatifler - TN) gösterirken, diyagonal dışındaki hücreler modelin hatalarını (yanlış pozitifler - FP ve yanlış negatifler - FN) temsil eder. Bu sayede, modelin hangi sınıfları doğru sınıflandırdığı, hangi sınıfları karıştırdığı ve hangi tür hataları yaptığı kolayca görülebilir [6].



Şekil 5.1 Oluşturulan özgün modelin karmaşıklık matris sonuçları.

Karmaşıklık matrisi, modelin genel doğruluğunu değerlendirmesinin yanı sıra duyarlılık (recall), kesinlik (precision) ve F1-skoru (F1-score) gibi daha spesifik metriklerin hesaplanmasında da kullanılır. Bu metrikler, modelin performansını farklı açılardan değerlendirerek güçlü ve zayıf yönlerini belirlemeye yardımcı olur. Özellikle dengesiz veri setlerinde, modelin azınlık sınıfını ne kadar iyi tahmin ettiğini anlamak için karmaşıklık matrisi oldukça faydalıdır [15].

5.1.2 ROC Eğrisi (Receiver Operating Characteristic Curve)

ROC (receiver operating characteristic) eğrisi, bir sınıflandırma modelinin performansını değerlendirmek için kullanılan grafiksel bir yöntemdir. Özellikle ikili sınıflandırmalarda sıklıkla kullanılan bu yöntem çoklu sınıflandırma modellerinde her sınıf için ayrı ikili sınıflandırma olarak gerçekleştirilmektedir. ROC eğrisi, modelin farklı eşik değerlerindeki doğru pozitif oranı ve yanlış pozitif oranını gösterir. Doğru pozitif oranı ve yanlış pozitif oranlarının hesaplanması Denklem 5.1 ve Denklem 5.2’de verilmiştir [15].


$$\text{Doğru Pozitif Oranı (TPR)} = \frac{TP}{TP + FN} \quad (5.1)$$

$$\text{Yanlış Pozitif Oranı (FPR)} = \frac{FP}{FP + TN} \quad (5.2)$$

Çoklu sınıflandırma modellerinde sınıf sayısı arttıkça hesaplama karmaşıklıklaşabilir. Bu nedenle her sınıfın ROC eğrisinin hesaplanıp ortalamaları alınarak tek bir eğrinin çizdirildiği makro-ortalama (macro-average) ROC eğrisi ile tüm gerçek ve tahmin edilen etiketlerin birleştirilerek tek bir eğrinin çizdirildiği mikro-ortalama (micro-average) ROC eğrileri hesaplanır [31].

Oluşturulan modelin ROC eğrileri ve eğrilerinin altında kalan alan olarak değerlendirilen AUC (area under curve) değerlerinin hesaplanması Denklem 5.3'te gösterilip grafiği Şekil 5.2'de verilmiştir.

$$AUC = \int_0^1 TPR(FPR^{-1}(x))dx = \int_{-\infty}^{\infty} TPR(t) * FPR'(t)dt \quad (5.3)$$



Şekil 5.2 Oluşturulan özgün modelin ROC eğrisi ve AUC değerleri.

ROC eğrisi oluşturulan modelin oldukça başarılı bir performans sergilediği göstermektedir. Hem genel performansı değerlendiren mikro-ortalama AUC değeri (0.99) hem de her bir sınıf için hesaplanan AUC değerleri (0.99 ve 1.00) modelin sınıfları yüksek doğrulukla ayırt edebildiğini ortaya koymaktadır. Bu sonuçlar modelin veri setindeki tüm sınıfları kapsayıcı ve dengeli bir şekilde sınıflandırabildiğini göstermektedir.

5.1.3 Duyarlılık (Recall)

Modelin pozitif olarak tahmin etmesi gerektiği işlemlerin ne kadarını pozitif olarak tahmin ettiğini gösteren metrik değerdir [14]. Duyarlılık metriği hesaplanması Denklem 5.4'te verilmiştir.

$$Duyarlılık = \frac{TP}{TP + FN} \quad (5.4)$$

5.1.4 Kesinlik (Precision)

Modelin pozitif olarak tahmin ettiği örneklerin gerçekte kaç tanesinin pozitif olduğunu gösteren metrik değerdir [14]. Kesinlik metriği hesaplanması Denklem 5.5'te verilmiştir.

$$Kesinlik = \frac{TP}{TP + FP} \quad (5.5)$$

5.1.5 F1 Skoru (F1 Score)

Modelin test doğruluğunun ölçüsüdür. Kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır. F1 Skor değeri, 0-1 arasında değer alıp 1 değerine en yakın değer verimli bir model olduğu anlamını taşır [15]. F1 Skoru metriği hesaplanması Denklem 5.6'da verilmiştir.

$$F1 Skoru = \frac{2 * Duyarlılık * Kesinlik}{Duyarlılık + Kesinlik} \quad (5.6)$$

5.1.6 Doğruluk (Accuracy)

Modelin doğru olarak sınıflandırdığı örneklerin yüzdesidir [14]. Doğruluk metriği hesaplanması Denklem 5.7'de verilmiştir.

$$Doğruluk = \frac{TP + TN}{TP + FP + TN + FN} \quad (5.7)$$


Oluşturulan modelin eğitimi ve test edilmesi sonucunda sınıflara göre hesaplanan değerlendirme metrik sonuçları Çizelge 5.1'de gösterilmiştir.

Çizelge 5.1 Oluşturulan özgün model için sınıflara göre değerlendirme metrik sonuçları.

Sınıflar (Classes)	Örnekler (Samples)	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skoru (F1-Score)
COVID-19	105	0.98	1.00	0.99
Akciğer Opasitesi	104	0.97	0.99	0.98
Normal / Sağlıklı	103	0.99	0.96	0.98
Viral Pnömoni	104	1.00	0.99	1.00
Ortalama Sonuçlar (Avg. Results):		0.9857	0.9856	0.9856
Ortalama Doğruluk (Accuracy):		0.9856 (%98,56)		

Modelin performans metrikleri incelendiğinde, tüm sınıflarda yüksek başarı oranları elde edildiği görülmektedir. Modelin pozitif olarak sınıflandırdığı örneklerin gerçekten pozitif olma oranını temsil eden kesinlik değeri 0.9857 olarak hesaplanmıştır. Bu, modelin pozitif sınıflandırmalarında çok az hata yaptığını göstermektedir. Modelin tüm pozitif örnekleri ne kadar doğru sınıflandırdığını gösteren duyarlılık değeri de 0.9856 ile oldukça yüksektir. Kesinlik ve duyarlılık değerlerinin harmonik ortalaması olan F1-skoru ise 0.9856 olarak hesaplanmış ve modelin genel performansının dengeli olduğunu göstermiştir. Son olarak, modelin tüm örnekleri ne kadar doğru sınıflandırdığını gösteren doğruluk oranı %98,56 olarak modelin çoklu sınıflandırma görevinde oldukça başarılı olduğunu kanıtlamaktadır.

Oluşturulan modelin eğitim ve doğrulama açısından kayıp ve doğruluk grafiklerinin gösterimi Şekil 5.3'te verilmiştir.



Şekil 5.3 Oluşturulan özgün modelin eğitim ve doğrulama için kayıp ve doğruluk grafikleri.

En verimli sonuçları veren optimum epok değeriyle eğitilen model sonuçları incelendiğinde, kayıp değerinin en düşük seviyesine 15. epokta ulaştığı ve bu noktadan sonra eğitim doygunluk seviyesine ulaşmıştır. Bu durum, modelin eğitim verilerine uyum sağlama sürecinin 15. epok seviyelerinde tamamlandığını göstermektedir.

Doğruluk oranı sonuçlarına bakıldığında ise, eğitim verilerinde en yüksek doğruluk oranına 15. epokta ulaşılırken, doğrulama verilerinde en yüksek doğruluk oranına 13. epokta ulaşılmıştır.

Bu sonuçlar, modelin eğitimi için optimum epok sayısının 13 ile 15 arasında bir değer olduğunu kanıtlamaktadır. Aşırı öğrenmeyi önlemek ve modelin genelleme yeteneğini maksimize etmek için epok sayısı bu aralıkta tutulmalıdır. Yapılan çalışmalarda ise en iyi sonuçları veren 15 epok değeri seçilmiştir. Oluşturulan modelin eğitim süreci boyunca her epokta eğitim metrik sonuçlarının değişimi Şekil 5.4'te gösterilmiştir.

Do you want model asks you to halt the training [y/n] ?
n

Epoch	Loss	Accuracy	V_loss	V_acc	LR	Next LR	Monitor	% Improv	Duration
1 /15	6.729	81.941	5.44421	82.933	0.00100	0.00100	accuracy	0.00	1689.43
2 /15	4.444	92.007	3.67831	93.750	0.00100	0.00100	val_loss	32.44	1473.33
3 /15	3.139	94.111	2.59440	96.875	0.00100	0.00100	val_loss	29.47	1472.65
4 /15	2.239	95.343	1.87488	95.673	0.00100	0.00100	val_loss	27.73	1479.67
5 /15	1.611	95.463	1.34665	96.154	0.00100	0.00100	val_loss	28.17	1475.74
6 /15	1.147	96.785	0.96700	95.913	0.00100	0.00100	val_loss	28.19	1486.80
7 /15	0.826	97.206	0.71556	96.635	0.00100	0.00100	val_loss	26.00	1480.74
8 /15	0.608	97.506	0.56384	95.673	0.00100	0.00100	val_loss	21.20	1483.78
9 /15	0.482	97.416	0.47043	94.712	0.00100	0.00100	val_loss	16.57	1486.42
10 /15	0.386	97.867	0.39131	95.913	0.00100	0.00100	val_loss	16.82	1494.23
11 /15	0.338	97.746	0.38586	96.154	0.00100	0.00100	val_loss	1.39	1490.16
12 /15	0.282	98.558	0.27572	96.635	0.00100	0.00100	val_loss	28.54	1490.66
13 /15	0.240	99.008	0.24916	97.356	0.00100	0.00100	val_loss	9.63	1488.50
14 /15	0.209	98.978	0.27748	95.673	0.00100	0.00100	val_loss	-11.36	1490.31
15 /15	0.212	98.648	0.21792	97.115	0.00100	0.00100	val_loss	12.54	1488.84

training elapsed time was 6.0 hours, 15.0 minutes, 26.32 seconds)

Şekil 5.4 Oluşturulan özgün modelin eğitim sürecindeki metrik sonuçlarının değişimi.

Oluşturulan modelin 15 epokluk eğitim süreci yaklaşık 23726 saniye (6 saat 15 dakika 26 saniye) seviyesindedir. Her epokta eğitim ve doğrulama için kayıp değerleri düşmeye devam etmiştir. Epok sayısı arttıkça doğruluk değerleri de artmış ancak 15. epok değerinden sonra doğruluk değeri yükselmesi yavaşlayıp eğitim doygunluk seviyesine ulaşmaya başlamıştır.

Oluşturulan modelin eğitim, test ve doğrulama için kayıp ve doğruluk oranları Çizelge 5.2'de verilmiştir.

Çizelge 5.2 Oluşturulan özgün model için eğitim, test ve doğrulama için kayıp ve doğruluk sonuçları.

Parametre (Parameters)	Doğruluk (Accuracy)	Kayıp (Loss)
Eğitim (Train)	1.0000	0.1518
Doğrulama (Validation)	0.9766	0.2241
Test (Test)	0.9856	0.2075

Derin öğrenme modelinin eğitim ve doğrulama sonuçları incelendiğinde, modelin başarıyla eğitildiği ve iyi bir performans gösterdiği görülmektedir. Eğitim setindeki kayıp değeri (train loss) 0.1518 gibi düşük bir değerde olup, modelin eğitim verilerini etkili bir şekilde öğrendiğini göstermektedir. Eğitim setindeki doğruluk değeri (train accuracy) ise 1.0 olarak elde edilerek modelin eğitim setindeki tüm örnekleri doğru sınıflandırabildiğini göstermektedir. Bu durum potansiyel bir aşırı öğrenme (overfitting) riskine işaret etse de diğer metrikler ve doğrulama sonuçları incelendiğinde bu riskin düşük olduğu görülmektedir.

Doğrulama setindeki kayıp değeri (validation loss) 0.2241 olarak hesaplanmıştır ve eğitim setindeki kayıp değerinden biraz yüksek olması beklenen bir durumdur. Önemli nokta eğitim ve doğrulama kayıpları arasındaki farkın çok büyük olmamasıdır ve bu durum modelin aşırı öğrenme yapmadığını göstermektedir. Doğrulama setindeki doğruluk değeri (validation accuracy) ise 0.9766 gibi yüksek bir değerdedir ve bu da modelin genelleme yeteneğinin iyi olduğunu göstermektedir.

Test setindeki kayıp değeri (test loss) 0.2075 ve doğruluk değeri (test accuracy) 0.9856 olarak hesaplanmıştır. Bu değerler, doğrulama sonuçlarına yakın olup modelin genel performansının tutarlı olduğunu ve modelin daha önce görmediği yeni verilere karşı da iyi bir performans sergileyeceğini göstermektedir.

Sonuç olarak, model %98,56 gibi yüksek bir doğruluk oranıyla dört farklı sınıfı (Viral Pnömoni, COVID-19, Akciğer Opasitesi ve Normal) çoklu sınıflandırma modeliyle başarıyla sınıflandırabilmektedir. Bu, modelin akciğer hastalıklarının otomatik teşhisinde kullanılabilecek potansiyel bir araç olduğunu gösteren önemli bir bulgu olmuştur.

Çoklu sınıflandırma problemlerinde, özellikle de tıbbi görüntü analizi gibi karmaşık ve kritik alanlarda bu denli yüksek bir doğruluk oranı elde etmek oldukça önemlidir. Bu başarı, modelin eğitildiği verilerin kalitesi, kullanılan EfficientNetB1 mimarisinin gücü ve modelin

hiperparametrelerinin (grup boyutu, epok sayısı, öğrenme oranı vb.) dikkatli bir şekilde ayarlanması gibi faktörlerin bir sonucudur.


5.2 MODEL SONUÇLARININ KARŞILAŞTIRMASI

Çalışmada geliştirilen modelin eğitimi "COVID-19 Radiography Database" veri seti kullanılarak gerçekleştirilmiştir. Farklı derin öğrenme modelleri (ResNet50, DenseNet121 ve EfficientNetB1) aynı veri setinden aynı sayıda ve aynı görüntüler (1050 adet COVID-19, 1040 adet Akciğer Opasitesi, 1040 adet Viral Pnömoni ve 1030 adet Normal/Sağlıklı) seçilerek eğitimleri gerçekleştirilecek ve sonuçları karşılaştırılacaktır. Bu modeller arasında, EfficientNet mimarisinin farklı versiyonları da yer alacak ve bu sayede optimum performansı sağlayan model belirlenmeye çalışılacaktır.


5.2.1 Farklı Modellerin Karşılaştırılması

Farklı modellerin karşılaştırılması amacıyla aynı veri seti (COVID-19 Radiography Database) farklı derin öğrenme modelleri ile eğitilmiş ve performansları karşılaştırılmıştır. Değerlendirmeye alınan modeller arasında, EfficientNetB1 mimarisi temel alınarak geliştirilen özgün bir model ile ResNet50 ve DenseNet121 mimarileri üzerine inşa edilen modeller bulunmaktadır. Tüm modeller 10 epok boyunca aynı veri seti üzerinde eğitilerek, performans metrikleri açısından detaylı bir karşılaştırma yapılmıştır.

Oluşturulan EfficientNetB1 temelli modelin eğitim ve doğrulama açısından kayıp ve doğruluk grafiklerinin gösterimi Şekil 5.5'te ve karmaşıklık matrisi Şekil 5.6'da verilmiştir.





Şekil 5.5 EfficientNetB1 temelli oluşturulan modelin 10 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri.




Şekil 5.6 EfficientNetB1 temelli oluşturulan modelin 10 epokluk karmaşıklık matris sonuçları.

Oluşturulan ResNet50 modelinin eğitim ve doğrulama açısından kayıp ve doğruluk grafiklerinin gösterimi Şekil 5.7’de ve karmaşıklık matrisi Şekil 5.8’de verilmiştir.




Şekil 5.7 ResNet50 temelli oluşturulan modelin 10 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri.




Şekil 5.8 ResNet50 temelli oluşturulan modelin 10 epokluk karmaşıklık matris sonuçları.

Oluşturulan DenseNet121 modelinin eğitim ve doğrulama açısından kayıp ve doğruluk grafiklerinin gösterimi Şekil 5.9’da ve karmaşıklık matrisi Şekil 5.10’da verilmiştir.



Şekil 5.9 DenseNet121 temelli oluşturulan modelin 10 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri.



Şekil 5.10 DenseNet121 temelli oluşturulan modelin 10 epokluk karmaşıklık matris sonuçları.

Üç farklı modelin sınıflara göre değerlendirme metrik sonuçları (kesinlik, duyarlılık, f1-skoru) ve doğruluk ve kayıp oranları Çizelge 5.3’te gösterilmiştir.

Çizelge 5.3 EfficientNetB1, ResNet50, DenseNet121 modellerinin 10 epokluk değerlendirme sonuçları.

Modeller (Models)	Sınıflar (Classes)	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skoru (F1-Score)
EfficientNetB1 Modeli (10 epok)	COVID-19	0.99	0.98	0.99
	Akciğer Opasitesi	0.98	1.00	0.99
	Normal / Sağlıklı	0.97	0.96	0.97
	Viral Pnömoni	0.99	0.99	0.99
	Doğruluk (Accuracy):	0.9832 (%98,32)		
	Kayıp (Loss):	0.397		
ResNet50 Modeli (10 epok)	COVID-19	0.91	0.95	0.93
	Akciğer Opasitesi	0.88	0.95	0.91
	Normal / Sağlıklı	0.99	0.77	0.86
	Viral Pnömoni	0.88	0.96	0.92
	Doğruluk (Accuracy):	0.9086 (%90,86)		
	Kayıp (Loss):	0.599		

Çizelge 5.3 (devam ediyor)

DenseNet121 Modeli (10 epok)	COVID-19	0.99	0.82	0.90
	Akciğer Opasitesi	0.79	0.99	0.88
	Normal / Sağlıklı	0.94	0.93	0.94
	Viral Pnömoni	0.99	0.92	0.96
	Doğruluk (Accuracy):	0.9159 (%91,59)		
	Kayıp (Loss):	0.407		

Çizelge 5.3'teki değerlendirme sonuçlarında gösterildiği gibi 10 epok boyunca eğitilen üç model arasından EfficientNetB1 mimarisi temel alınarak oluşturulan özgün model %98,32'lik başarı oranı elde ederek diğer modeller arasında öne çıkmıştır.

Çalışma kapsamında geliştirilen EfficientNetB1 temelli modelin, ResNet50 ve DenseNet121 mimarileri üzerine kurulu modellerle karşılaştırılmasında modellerin eğitim süreçlerindeki toplam parametre sayısı (total params), eğitilebilir parametre sayısı (trainable params) ve eğitilemeyen parametre sayısı (non-trainable params) gibi faktörler göz önünde bulundurulmuştur. Ayrıca modellerin 10 epokluk eğitim süresince modellerin eğitim süreçlerinin tamamlama süreleri kaydedilerek karşılaştırmalı bir değerlendirme yapılmıştır.

Çizelge 5.4 EfficientNetB1, ResNet50, DenseNet121 modellerinin 10 epokluk eğitim süreleri ve parametrik sonuçları.

Modeller (Models)	Eğitim Süreleri (sn)	Eğitilebilir Parametreler	Eğitilemeyen Parametreler	Toplam Parametreler
EfficientNetB1	14634	6844708	64615	6909323
ResNet50	28717	24064260	57216	24121476
DenseNet121	25668	7219332	85696	7305028

Çizelge 5.4'te gösterilen elde edilmiş bulgulara, EfficientNetB1 tabanlı modelin en yakın rakibi olan DenseNet121 modeline kıyasla 10 epokluk eğitim süresi karşılaştırmasında %42,98 daha hızlı bir eğitim süreci sunduğunu ortaya koymuştur. Bu sonuç, EfficientNetB1 mimarisinin, aynı veri seti üzerinde diğer modellere göre önemli ölçüde daha hızlı ve verimli bir eğitim sağladığını göstermektedir.


Solunum yolu hastalıklarının radyolojik görüntülerinin sınıflandırılması amacıyla gerçekleştirilen bu çalışmada, EfficientNetB1, ResNet50 ve DenseNet121 mimarileri kullanılarak üç farklı derin öğrenme modeli geliştirilmiş ve "COVID-19 Radiography

Database" veri seti üzerinde eğitilmiştir. Modellerin performansları, kesinlik, duyarlılık, F1-skoru ve doğruluk gibi metrikler kullanılarak değerlendirilmiştir. Elde edilen sonuçlar, EfficientNetB1 temelli modelin %98,32'lik doğruluk oranıyla en yüksek performansı gösterdiğini ortaya koymuştur. Ayrıca, EfficientNetB1 tabanlı model, eğitim süresi açısından da diğer modellere göre önemli bir avantaj sağlamış, en yakın rakibi olan DenseNet121'e kıyasla %42,98 daha hızlı eğitim süresi elde etmiştir. Bu bulgular, EfficientNetB1 mimarisinin solunum yolu hastalıklarının radyolojik görüntülerinin sınıflandırılması için hem doğruluk hem de verimlilik açısından üstün bir seçenek olduğunu göstermektedir.


5.2.2 EfficientNet Model Ailesinin Karşılaştırılması

EfficientNet model ailesinin farklı versiyonlarının karşılaştırılması amacıyla aynı veri seti (COVID-19 Radiography Database) kullanılarak modeller eğitilmiş ve performansları karşılaştırılmıştır. Değerlendirmede, EfficientNet model ailesinden EfficientNetB0, EfficientNetB1, EfficientNetB2 ve EfficientNetB3 modelleri temel alınarak geliştirilen derin öğrenme modelleri bulunmaktadır. Tüm modeller, 15 epok boyunca aynı veri seti üzerinde eğitilerek, performans metrikleri açısından detaylı bir karşılaştırma yapılmıştır.



Oluşturulan EfficientNetB0 modelinin eğitim ve doğrulama açısından kayıp ve doğruluk grafiklerinin gösterimi Şekil 5.11'de ve karmaşıklık matrisi Şekil 5.12'de verilmiştir.




Şekil 5.11 EfficientNetB0 temelli oluşturulan modelin 15 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri.




Şekil 5.12 EfficientNetB0 temelli oluşturulan modelin 15 epokluk karmaşıklık matris sonuçları. Oluşturulan EfficientNetB1 modelinin eğitim ve doğrulama açısından kayıp ve doğruluk grafiklerinin gösterimi Şekil 5.13'te ve karmaşıklık matrisi Şekil 5.14'te verilmiştir.




Şekil 5.13 EfficientNetB1 temelli oluşturulan modelin 15 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri.




Şekil 5.14 EfficientNetB1 temelli oluşturulan modelin 15 epokluk karmaşıklık matris sonuçları. Oluşturulan EfficientNetB2 modelinin eğitim ve doğrulama açısından kayıp ve doğruluk grafiklerinin gösterimi Şekil 5.15'te ve karmaşıklık matrisi Şekil 5.16'da verilmiştir.




Şekil 5.15 EfficientNetB2 temelli oluşturulan modelin 15 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri.



Şekil 5.16 EfficientNetB2 temelli oluşturulan modelin 15 epokluk karmaşıklık matris sonuçları. Oluşturulan EfficientNetB3 modelinin eğitim ve doğrulama açısından kayıp ve doğruluk grafiklerinin gösterimi Şekil 5.17’de ve karmaşıklık matrisi Şekil 5.18’de verilmiştir.




Şekil 5.17 EfficientNetB3 temelli oluşturulan modelin 15 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri.




Şekil 5.18 EfficientNetB3 temelli oluşturulan modelin 15 epokluk karmaşıklık matris sonuçları.

Oluşturulan EfficientNetB4 modelinin eğitim ve doğrulama açısından kayıp ve doğruluk grafiklerinin gösterimi Şekil 5.19’da ve karmaşıklık matrisi Şekil 5.20’de verilmiştir.



Şekil 5.19 EfficientNetB4 temelli oluşturulan modelin 15 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri.



Şekil 5.20 EfficientNetB4 temelli oluşturulan modelin 15 epokluk karmaşıklık matris sonuçları. Beş farklı modelin (EfficientNetB0-B4) dörtlü sınıflandırma için değerlendirme sonuçları (kesinlik, duyarlılık, f1-skoru) ve doğruluk ve kayıp oranları Çizelge 5.5’te gösterilmiştir.

Çizelge 5.5 EfficientNetB0, EfficientNetB1, EfficientNetB2, EfficientNetB3 ve EfficientNetB4 modellerinin 15 epokluk değerlendirme sonuçları.

Modeller (Models)	Sınıflar (Classes)	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skoru (F1-Score)
EfficientNetB0 Modeli (15 epok)	COVID-19	0.95	1.00	0.97
	Akciğer Opasitesi	0.99	0.96	0.98
	Normal / Sağlıklı	1.00	0.95	0.98
	Viral Pnömoni	0.98	1.00	0.99
	Doğruluk (Accuracy):	0.9784 (%97,84)		
	Kayıp (Loss):	0.232		
EfficientNetB1 Modeli (15 epok)	COVID-19	0.98	1.00	0.99
	Akciğer Opasitesi	0.97	0.99	0.98
	Normal / Sağlıklı	0.99	0.96	0.98
	Viral Pnömoni	1.00	0.99	1.00
	Doğruluk (Accuracy):	0.9856 (%98,56)		
	Kayıp (Loss):	0.207		

Çizelge 5.5 (devam ediyor)

EfficientNetB2 Modeli (15 epok)	COVID-19	0.99	1.00	1.00
	Akciğer Opasitesi	0.95	1.00	0.97
	Normal / Sağlıklı	0.99	0.92	0.95
	Viral Pnömoni	0.99	0.99	0.99
	Doğruluk (Accuracy):	0.9784 (%97,84)		
	Kayıp (Loss):	0.222		
EfficientNetB3 Modeli (15 epok)	COVID-19	0.97	1.00	0.99
	Akciğer Opasitesi	0.99	0.98	0.99
	Normal / Sağlıklı	0.99	0.92	0.95
	Viral Pnömoni	0.95	1.00	0.98
	Doğruluk (Accuracy):	0.9760 (%97,60)		
	Kayıp (Loss):	0.239		
EfficientNetB4 Modeli (15 epok)	COVID-19	0.99	0.98	0.99
	Akciğer Opasitesi	0.96	0.99	0.98
	Normal / Sağlıklı	0.97	0.92	0.95
	Viral Pnömoni	0.97	1.00	0.99
	Doğruluk (Accuracy):	0.9736 (%97,36)		
	Kayıp (Loss):	0.280		

Çizelge 5.5'teki değerlendirme sonuçlarından görüldüğü gibi 15 epok boyunca eğitilen beş model arasından EfficientNetB1 mimarisi temel alınarak oluşturulan özgün model %98,56'lık başarı oranı elde ederek diğer modeller arasında en öne çıkmış bulunmaktadır.

Çalışma kapsamında EfficientNet model ailesinden EfficientNetB0, EfficientNetB1, EfficientNetB2, EfficientNetB3 ve EfficientNetB4 temelli oluşturulan modellerin karşılaştırılmasında, modellerin eğitim süreçlerindeki toplam parametre sayısı (total params), eğitilebilir parametre sayısı (trainable params) ve eğitilemeyen parametre sayısı (non-trainable params) gibi faktörler göz önünde bulundurulmuştur. Ayrıca modellerin 15 epokluk eğitim süresince modellerin eğitim tamamlama süreleri kaydedilerek karşılaştırmalı bir değerlendirme yapılmıştır.

Çizelge 5.6 EfficientNetB0, EfficientNetB1, EfficientNetB2, EfficientNetB3 ve EfficientNetB4 modellerinin 15 epokluk eğitim süreleri ve parametrik sonuçları.

Modeller (Models)	Eğitim Süreleri (sn)	Eğitilebilir Parametreler	Eğitilemeyen Parametreler	Toplam Parametreler
EfficientNetB0	17000	4339072	44583	4383655
EfficientNetB1	23726	6844708	64615	6909323
EfficientNetB2	26590	8065542	70391	8135933
EfficientNetB3	30527	11093804	90375	11184179
EfficientNetB4	42744	18012236	128791	18141027


Çizelge 5.6'da gösterilen elde edilmiş bulgulara, EfficientNetB0 tabanlı modelin en yakın rakibi olan EfficientNetB1 modeline kıyasla %28,35 daha hızlı bir eğitim süreci sunduğunu ortaya koymuştur. Bu sonuç, EfficientNetB0 mimarisinin, aynı veri seti üzerinde diğer modellere göre daha hızlı bir eğitim sağladığını göstermektedir.

Solunum yolu hastalıklarının radyolojik görüntülerinin sınıflandırılması amacıyla gerçekleştirilen bu çalışmada, EfficientNet model ailesinin (B0, B1, B2, B3 ve B4) farklı versiyonları kullanılarak derin öğrenme modelleri geliştirilmiş ve "COVID-19 Radiography Database" veri seti üzerinde eğitilmiştir. Modellerin performansları, kesinlik, duyarlılık, F1-skoru ve doğruluk gibi metrikler kullanılarak değerlendirilmiş ve sonuçlar Çizelge 5.5 ve 5.6'da sunulmuştur. Elde edilen bulgulara göre, EfficientNetB1 temelli model %98,56'lık doğruluk oranıyla en yüksek performansı göstermiştir. Ancak, EfficientNetB0 modeli, EfficientNetB1 modeline göre %28,35 daha hızlı eğitim süresiyle en hızlı model olarak öne çıkmıştır. Sonuç olarak, EfficientNetB1 en yüksek doğruluk oranı olan modeli temsil ederken, EfficientNetB0 hız ve verimlilik açısından bakıldığında uygun seçenek olduğu gözlemlenmiştir.


5.2.3 EfficientNetB1 Temelli Özgün Modellerin İkili ve Üçlü Sınıflandırma Sonuçları

EfficientNet model ailesinin bu çalışmada en verimli varyantı olan EfficientNetB1 modeli üzerine ikili ve üçlü sınıflandırma modelleri oluşturulmuştur. Bu bölümde oluşturulan ikili ve üçlü sınıflandırma modellerinin sınıflandırma sonuçları değerlendirilecektir. Tüm modeller, 25 epok boyunca aynı veri seti üzerinde eğitilerek, performans metrikleri açısından detaylı bir karşılaştırma yapılmıştır.

Oluşturulan EfficientNetB1 temelli ikili sınıflandırma (COVID-19 ve Normal) modelinin eğitim ve doğrulama açısından kayıp ve doğruluk grafiklerinin gösterimi Şekil 5.21’de ve karmaşıklık matrisi Şekil 5.22’de verilmiştir.




Şekil 5.21 EfficientNetB1 temelli oluşturulan ikili sınıflandırma (COVID-19 ve Normal) modelinin 25 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri.




Şekil 5.22 EfficientNetB1 temelli oluşturulan ikili sınıflandırma (COVID-19 ve Normal) modelinin 25 epokluk karmaşıklık matris sonuçları.

Oluşturulan EfficientNetB1 temelli ikili sınıflandırma (Akciğer Opasitesi ve Normal) modelinin eğitim ve doğrulama açısından kayıp ve doğruluk grafiklerinin gösterimi Şekil 5.23'te ve karmaşıklık matrisi Şekil 5.24'te verilmiştir.




Şekil 5.23 EfficientNetB1 temelli oluşturulan ikili sınıflandırma (Akciğer Opasitesi ve Normal) modelinin 25 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri.




Şekil 5.24 EfficientNetB1 temelli oluşturulan ikili sınıflandırma (Akciğer Opasitesi ve Normal) modelinin 25 epokluk karmaşıklık matris sonuçları.

Oluşturulan EfficientNetB1 temelli ikili sınıflandırma (Pnömoni ve Normal) modelinin eğitim ve doğrulama açısından kayıp ve doğruluk grafiklerinin gösterimi Şekil 5.25'te ve karmaşıklık matrisi Şekil 5.26'da verilmiştir.




Şekil 5.25 EfficientNetB1 temelli oluşturulan ikili sınıflandırma (Pnömoni ve Normal) modelinin 25 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri.




Şekil 5.26 EfficientNetB1 temelli oluşturulan ikili sınıflandırma (Pnömoni ve Normal) modelinin 25 epokluk karmaşıklık matris sonuçları.

Oluşturulan EfficientNetB1 temelli üçlü sınıflandırma (COVID-19, Akciğer Opasitesi ve Normal) modelinin eğitim ve doğrulama açısından kayıp ve doğruluk grafiklerinin gösterimi Şekil 5.27’de ve karmaşıklık matrisi Şekil 5.28’de verilmiştir.




Şekil 5.27 EfficientNetB1 temelli oluşturulan üçlü sınıflandırma (COVID-19, Akciğer Opasitesi ve Normal) modelinin 25 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri.




Şekil 5.28 EfficientNetB1 temelli oluşturulan üçlü sınıflandırma (COVID-19, Akciğer Opasitesi ve Normal) modelinin 25 epokluk karmaşıklık matris sonuçları.

Oluşturulan EfficientNetB1 temelli üçlü sınıflandırma (COVID-19, Pnömoni ve Normal) modelinin eğitim ve doğrulama açısından kayıp ve doğruluk grafiklerinin gösterimi Şekil 5.29'da ve karmaşıklık matrisi Şekil 5.30'da verilmiştir.




Şekil 5.29 EfficientNetB1 temelli oluşturulan üçlü sınıflandırma (COVID-19, Pnömoni ve Normal) modelinin 25 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri.




Şekil 5.30 EfficientNetB1 temelli oluşturulan üçlü sınıflandırma (COVID-19, Pnömoni ve Normal) modelinin 25 epokluk karmaşıklık matris sonuçları.

Oluşturulan EfficientNetB1 temelli üçlü sınıflandırma (Akciğer Opasitesi, Pnömoni ve Normal) modelinin eğitim ve doğrulama açısından kayıp ve doğruluk grafiklerinin gösterimi Şekil 5.31’de ve karmaşıklık matrisi Şekil 5.32’de verilmiştir.



Şekil 5.31 EfficientNetB1 temelli oluşturulan üçlü sınıflandırma (Akciğer Opasitesi, Pnömoni ve Normal) modelinin 25 epokluk eğitim ve doğrulama için kayıp ve doğruluk grafikleri.



Şekil 5.32 EfficientNetB1 temelli oluşturulan üçlü sınıflandırma (Akciğer Opasitesi, Pnömoni ve Normal) modelinin 25 epokluk karmaşıklık matris sonuçları.

Üç farklı modelin sınıflara göre (ikili sınıflandırma) değerlendirme sonuçları (kesinlik, duyarlılık, f1-skoru) ve doğruluk ve kayıp oranları Çizelge 5.7’de gösterilmiştir.

Çizelge 5.7 EfficientNetB1 temelli oluşturulan özgün ikili sınıflandırma modellerinin 25 epokluk değerlendirme sonuçları.

Modeller (Models)	Sınıflar (Classes)	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skoru (F1-Score)
İki Sınıflı EfficientNetB1 Modeli (25 epok)	COVID-19	0.96	1.00	0.98
	Normal / Sağlıklı	1.00	0.96	0.98
	Doğruluk (Accuracy):	0.9808 (%98,08)		
	Kayıp (Loss):	0.156		
İki Sınıflı EfficientNetB1 Modeli (25 epok)	Akciğer Opasitesi	0.99	0.97	0.98
	Normal / Sağlıklı	0.97	0.99	0.98
	Doğruluk (Accuracy):	0.9808 (%98,08)		
	Kayıp (Loss):	0.127		
İki Sınıflı EfficientNetB1 Modeli (25 epok)	Pnömoni	0.98	0.99	0.99
	Normal / Sağlıklı	0.99	0.98	0.99
	Doğruluk (Accuracy):	0.9856 (%98,56)		
	Kayıp (Loss):	0.112		

Üç farklı modelin sınıflara göre (üçlü sınıflandırma) değerlendirme sonuçları (kesinlik, duyarlılık, f1-skoru) ve doğruluk ve kayıp oranları Çizelge 5.8’de gösterilmiştir.

Çizelge 5.8 EfficientNetB1 temelli oluşturulan özgün üçlü sınıflandırma modellerinin 25 epokluk değerlendirme sonuçları.

Modeller (Models)	Sınıflar (Classes)	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skoru (F1-Score)
Üç Sınıflı EfficientNetB1 Modeli (25 epok)	COVID-19	0.99	0.98	0.99
	Akciğer Opasitesi	0.98	0.99	0.99
	Normal	0.98	0.98	0.98
	Doğruluk (Accuracy):	0.9844 (%98,44)		
	Kayıp (Loss):	0.160		
Üç Sınıflı EfficientNetB1 Modeli (25 epok)	COVID-19	1.00	0.99	1.00
	Pnömoni	0.97	1.00	0.99
	Normal	0.99	0.97	0.98
	Doğruluk (Accuracy):	0.9871 (%98,71)		
	Kayıp (Loss):	0.112		
Üç Sınıflı EfficientNetB1 Modeli (25 epok)	Akciğer Opasitesi	0.96	0.98	0.97
	Pnömoni	1.00	0.97	0.99
	Normal	0.95	0.96	0.96
	Doğruluk (Accuracy):	0.9719 (%97,19)		
	Kayıp (Loss):	0.170		

5.2.4 Önerilen Modelin Literatürdeki Diğer Çalışmalarla Karşılaştırılması

Çalışmada önerilen EfficientNetB1 temelli oluşturulan modelin literatürdeki diğer çalışmalar ile karşılaştırılması Çizelge 5.9 ve Çizelge 5.10’da gösterilmiştir.

Çizelge 5.9 Önerilen EfficientNetB1 temelli özgün modelin literatürdeki ikili sınıflandırma modelleriyle karşılaştırılması

Çalışma	Modalite	Model ve Yöntem	Sınıf Sayısı	Sınıflar	Doğruluk Oranı (%)
Öztürk ve ark. [8]	CXR	DarkCovidNet	2	COVID-19 (+) COVID-19 (-)	98,08
	CXR	DarkCovidNet	2	Pnömoni (+) Pnömoni (-)	87,02
Ravi ve ark. [11]	CXR	EfficientNetB0 + B1 + B2	2	COVID-19 Normal	98,00
	CXR	EfficientNetB0 + B1 + B2	2	P. Pnömoni Normal	98,00
	CXR	EfficientNetB0 + B1 + B2	2	Tüberküloz Normal	99,00
Narin ve ark. [16]	CXR	ResNet50	2	COVID-19 Normal	96,10
	CXR	ResNet50	2	COVID-19 V. Pnömoni	99,50
	CXR	ResNet50	2	COVID-19 B. Pnömoni	99,70
Kassania ve ark. [18]	CXR ve BT	DenseNet121 + Bagging	2	COVID-19 Normal	99,00
Tiwari ve Jain [19]	CXR	VGG-CapsNet	2	COVID-19 Normal	97,00
Singh ve ark. [21]	CXR	EfficientNetB0	2	Pnömoni Normal	99,28
Kurt ve ark. [23]	BT	EfficientNetB4	2	COVID-19 Normal	97,93
Demir ve Bingöl [24]	CXR	AlexNet	2	Pnömoni Normal	96,31
Bakır ve ark. [25]	CXR	MobileNet + ANN	2	Pnömoni Normal	95,67
Aljawarneh ve Al-Quraan [26]	CXR	Özgün Model	2	Pnömoni Normal	92,40
Kanawade ve ark. [27]	CXR	Xception + VGG16 + DenseNet201	2	Pnömoni Normal	94,39
Ukwuoma ve ark. [28]	CXR	DenseNet201 + VGG16 + GoogleNet	2	Pnömoni Normal	99,21
Al-Rawe [31]	CXR	Özgün DenseNet Modeli	2	COVID-19 Normal	98,04
Kadiroğlu [32]	CXR	Özgün AlexNet Modeli	2	Pnömoni Normal	98,50
Rama ve ark. [33]	CXR	EfficientNetB2 (ENB2)	2	Tüberküloz Normal	96,00
Önerilen Çalışma	CXR	Önerilen EfficientNetB1 Temelli İki Sınıflandırma Özgün Model	2	COVID-19 Normal	98,08
Önerilen Çalışma	CXR	Önerilen EfficientNetB1 Temelli İki Sınıflandırma Özgün Model	2	Akc. Opasitesi Normal	98,08
Önerilen Çalışma	CXR	Önerilen EfficientNetB1 Temelli İki Sınıflandırma Özgün Model	2	Pnömoni Normal	98,56

Çizelge 5.9’da sunulan literatür taraması, göğüs hastalıklarının teşhisinde ikili sınıflandırma yaklaşımını benimseyen derin öğrenme modellerine dair örnek çalışmalar sunmaktadır. Bu çalışmada önerilen EfficientNetB1 temelli özgün modelin ikili sınıflandırmalardaki başarı oranı diğer çalışmaların başarı oranlarıyla karşılaştırılmıştır. Özgün modelin özellikle pnömoni ve normal hastalık gruplarını sınıflandırdığı ikili sınıflandırma modeli %98,56 seviyesindeki başarı oranı ile öne çıkmaktadır.

Çizelge 5.10 Önerilen EfficientNetB1 temelli özgün modelin literatürdeki çoklu sınıflandırma modelleriyle karşılaştırılması

Çalışma	Modalite	Model ve Yöntem	Sınıf Sayısı	Sınıflar	Doğruluk Oranı (%)
Terzi [6]	CXR	Özgün Model	15	Akciğer Hast. Normal	91,04
Nour ve ark. [9]	CXR	Özgün Model + DVM	3	COVID-19 Pnömoni Normal	98,97
Setyh ve ark. [10]	CXR	ResNet50 + DVM	3	COVID-19 Pnömoni Normal	98,66
Toğaçar ve ark. [12]	CXR	MobileNetV2 + SqueezeNet	3	COVID-19 Pnömoni Normal	99,27
Türkoğlu [13]	CXR	COVIDetectionNet + DVM	3	COVID-19 Pnömoni Normal	99,18
Korkmaz [15]	CXR	Özgün Model	3	COVID-19 Pnömoni Normal	97,00
Talukder ve ark. [17]	CXR	EfficientNetB4	4	COVID-19 Akciğer Opasitesi Pnömoni Normal	99,17
Tiwari ve Jain [19]	CXR	VGG-CapsNet	3	COVID-19 Pnömoni Normal	92,00
Das ve ark. [20]	CXR	TLCov+VGG16	3	COVID-19 Pnömoni Normal	97,67
Chowdhury ve ark. [22]	CXR	ECOVNet-Soft	3	COVID-19 Pnömoni Normal	97,00
Bakır ve ark. [25]	CXR	ResNet + ANN	3	V. Pnömoni B. Pnömoni Normal	81,67

Çizelge 5.10 (devam ediyor)

Çalışma	Modalite	Model ve Yöntem	Sınıf Sayısı	Sınıflar	Doğruluk Oranı (%)
Ukwuoma ve ark. [28]	CXR	DenseNet201 + VGG16 + GoogleNet	3	V. Pnömoni B. Pnömoni Normal	98,19
Hatipoğlu [30]	CXR	Özgün Model	3	COVID-19 B. Pnömoni Normal	98,13
Al-Rawe [31]	CXR	Özgün DenseNet Modeli	3	COVID-19 Pnömoni Normal	95,80
Aydın [40]	CXR	VGG19	3	COVID-19 Pnömoni Normal	93,71
Önerilen Çalışma	CXR	Önerilen EfficientNetB1 Temelli Üç Sınıflandırma Özgün Model	3	COVID-19 Akc. Opasitesi Normal	98,44
Önerilen Çalışma	CXR	Önerilen EfficientNetB1 Temelli Üç Sınıflandırma Özgün Model	3	COVID-19 Pnömoni Normal	98,71
Önerilen Çalışma	CXR	Önerilen EfficientNetB1 Temelli Üç Sınıflandırma Özgün Model	3	Akc. Opasitesi Pnömoni Normal	97,19
Önerilen Çalışma	CXR	Önerilen EfficientNetB1 Temelli Dört Sınıflandırma Özgün Model	4	COVID-19 Akc. Opasitesi Pnömoni Normal	98,56

Çizelge 5.10’da sunulan literatür taramasında ise göğüs hastalıklarının teşhisinde çoklu sınıflandırma yaklaşımını benimseyen derin öğrenme modellerine dair örnek çalışmalar sunulmuştur. EfficientNetB1 temelli özgün modelin üçlü sınıflandırma modellerinden COVID-19, pnömoni ve normal hastalık gruplarını sınıflandırdığı modeli %98,71 seviyesindeki başarı oranı ile üçlü sınıflandırma modellerinde öne çıkmıştır. Çoklu sınıflandırma modellerinden dört farklı hastalık grubunu (COVID-19, pnömoni, akciğer opasitesi ve normal) 15 epokluk eğitim sürecinde %98,56 seviyesindeki başarı oranı ile sınıflandıran özgün model, diğer çoklu sınıflandırma modellerine göre daha yüksek doğruluk oranı ve hızlı eğitim süresiyle verimli bir model olduğunu kanıtlamıştır.

Bu çalışmada önerilen çoklu sınıflandırma modelleri diğer çoklu sınıflandırma modellerine göre yüksek verimliliğe ulaşmıştır. Literatürdeki diğer çoklu sınıflandırma yaklaşımlarında da saptandığı gibi özellikle EfficientNet model ailesinin başarısı öne çıktığı gözlemlenmektedir.

Bu sonuçlar değerlendirildiğinde EfficientNet model ailesinin geliştirilmesiyle çok daha fazla hastalık sınıfı içeren çoklu sınıflandırma modelleri geliştirebileceğini işaret etmektedir.



BÖLÜM 6

SONUÇLAR VE ÖNERİLER

6.1 SONUÇLAR

Bu çalışmada, günümüzde hızla gelişen derin öğrenme teknolojilerinden yararlanarak akciğer röntgen görüntülerinden solunum yolu hastalıklarının otomatik olarak teşhis edilmesi amacıyla bir model geliştirilmiştir. Solunum yolu hastalıklarının erken ve doğru teşhisi, hastaların yaşam kalitesini artırmak ve tedavi sürecini optimize etmek açısından büyük önem taşımaktadır. Geleneksel yöntemlerle yapılan teşhislerde, radyologların subjektif yorumlarına bağlı olarak hatalar oluşabilmekte ve teşhis süreci uzayabilmektedir. Bu durum, özellikle pandemi süreçlerinde sağlık sistemleri üzerinde büyük bir yük oluşturmaktadır. Bu çalışmanın temel amacı, derin öğrenme tabanlı bir model kullanarak, akciğer röntgen görüntülerinden normal (sağlıklı), zatürre (pnömoni), COVID-19 ve akciğer opasitesi gibi farklı solunum yolu hastalıklarını hızlı ve doğru bir şekilde sınıflandırarak, radyologların iş yükünü azaltmak ve teşhis süreçlerini doğru bir yöntemle hızlandırmaktır. Bu sayede, hastalar daha kısa sürede doğru tedaviye ulaştırılarak sağlık hizmetlerinin kalitesinin artırılması hedeflenmiştir.

Bu çalışmada, EfficientNetB1 mimarisi temel alınarak, "COVID-19 Radiography Database" veri seti üzerinde eğitilen bir derin öğrenme modeli geliştirilmiştir. Modelin eğitiminde her adımda kaç örneğin modele gösterileceğini belirleyen grup boyutu (batch size) değeri 16 olarak seçilmiştir. Modelin tüm eğitim verilerini kaç kez göreceğini belirleyen devir (epok) sayısı ise çeşitli denemeler sonucu saptanan optimum epok değeri olan 15 değeri seçilmiştir. Modelin öğrenme oranı başlangıçta 0.001 seçilip bu oranın kaç epokta bir güncelleneceğini belirleyen tahammül (patience) değeri ise 3 olarak belirlenmiştir. Modelin sınıflandırma eşik (threshold) değeri 0.9 seçilmiştir. Bu parametreye göre görüntünün sınıflandırma olasılık değeri 0.9'dan büyük ise görüntü ilgili sınıfa ait olduğu tayini yapılmaktadır. Bu parametreler, eğitim süreci boyunca dikkatlice izlenmiş ve modelin en iyi performansı elde etmek için çeşitli ince parametre ayarları yapılmıştır. Bu şekilde belirlenen parametrelerle gerçekleştirilen eğitimin tamamlanma süresi 23726 saniye (6 saat, 15 dakika, 26 saniye) sürmüştür.

Geliştirilen EfficientNetB1 tabanlı derin öğrenme modeli, akciğer röntgen görüntülerini kullanarak normal (sağlıklı), zatürre (pnömoni), COVID-19 ve akciğer opaklığı gibi dört farklı solunum yolu hastalığını %98,56 doğruluk oranıyla sınıflandırma başarısı göstermiştir. Hem bu çalışmada yapılan diğer modellerle hem de literatürde yapılan çoklu sınıflandırma modellerinin karşılaştırmalarında, EfficientNetB1 modeli hem daha hızlı olan eğitim süresi hem de daha yüksek doğruluk oranlı başarısıyla üstün performans sergilemiştir. Bu sonuçlar, modelin tıbbi görüntüleme alanında otomatik tanı sistemleri için güçlü bir aday olduğunu göstermektedir.

6.2 ÖNERİLER

Bu çalışmada, derin öğrenme teknikleri kullanılarak akciğer röntgen görüntülerinden solunum yolu hastalıklarının sınıflandırılması konusunda önemli bir adım atılmıştır. Elde edilen sonuçlar, modelin özellikle belirli bir hastalık veya hastalık grubu gibi zorlu durumlarda bile yüksek doğrulukla tanı koyabildiğini göstermiştir. Ancak çeşitli şartların oluşması ve sağlanmasıyla günümüzde elde edilen bu sonuçlar gelişime açıktır.

Bu çalışmada geliştirilen model yüksek başarı oranında dört sınıflı çoklu sınıflandırma yapabilmektedir. Ancak modelin potansiyeli daha da artırılabilir. Öncelikle, sınıflandırma problemine daha geniş bir perspektifle yaklaşarak, modelin tanıyabileceği hastalık sayısı önemli ölçüde arttırılabilir. Solunum yolu hastalıkları için yeterli veri elde edilmesi durumunda, modelin sınıflandırma kapasitesi daha da genişletilebilir. İkinci olarak, modelin sadece hastalık sınıfını belirlemekle kalmayıp, hastalığın görüntü üzerindeki tam konumunu da belirlemesi, radyologlar için daha değerli bir araç haline gelebilir. Bu sayede radyologlar modelin tespit ettiği bölgeyi görsel olarak doğrulayarak teşhis güvenilirliğini artırabilirler.

Bu alandaki çalışmaların geleceği, farklı görüntüleme yöntemlerinin (röntgen, bilgisayarlı tomografi ve manyetik rezonans gibi) ürettiği görüntüler üzerinde ortak bir sınıflandırma modeli geliştirme potansiyelini barındırmaktadır. Bu yaklaşım, tek bir modelin çeşitli görüntü modalitelerini anlamasını sağlayarak, teşhis süreçlerinin standardizasyonuna ve daha doğru sonuçların elde edilmesine katkı sağlayabilir. Multimodal derin öğrenme teknikleri kullanılarak farklı görüntü özelliklerini birleştiren ve genelleyebilen daha güçlü modeller geliştirilebilir.

Bu gelişmelerin ışığında, geliştirilen modellerin tıbbi görüntüleme sistemlerine entegre edilmesiyle, sistemlerin hasta üzerindeki işlemi tamamlamasının ardından doktor ve radyologların müdahalesine gerek kalmaksızın, tanı sonuçlarının otomatik olarak üretilmesi ve kullanıcıya sunulması mümkün hale gelebilir. Bu sayede, tanı süreçleri önemli ölçüde kısalarak ve tıbbi hizmetlerin etkinliği artabilecektir.

KAYNAKLAR

- [1] **Yüzeren S** (2019) Solunum yolu hastalıklarında rol oynayan seçilmiş protein ve nükleik asitlerin dizi ve yapılarının moleküler modelleme yoluyla incelenmesi. *Yüksek Lisans Tezi*. Ege Üniversitesi, Sağlık Bilimleri Enstitüsü, Biyokimya Bölümü, İzmir, 110 s.
- [2] **Rafi I K** (2024) A review on pneumonia in children: Clear insights. *Mediterranean Journal of Pharmacy & Pharmaceutical Sciences*. 4(4): 48-57.
- [3] **Global Burden of Disease** (2019) Global Burden of Disease. Adres: <https://vizhub.healthdata.org/gbd-results/> (Erişim tarihi: 18.10.2024)
- [4] **Türkiye İstatistik Kurumu** (2022) Türkiye Sağlık Araştırması 2022. Adres: <https://data.tuik.gov.tr/Bulten/Index?p=Turkiye-Saglik-Arastirmasi-2022-49747> (Erişim tarihi: 17.09.2023)
- [5] **Alkan A, Erdem R ve Kuh Z** (2021) Solunum Yolları Hastalıklarının Toplumsal Görüngeleri Üzerine Nitel Bir Araştırma. *Anemon Muş Alparslan Üniversitesi Sosyal Bilimler Dergisi*. 9(5): 1353-1379.
- [6] **Terzi M S** (2021) Derin Öğrenme ile Göğüs Röntgenlerinden Hastalık Teşhisi. *Yüksek Lisans Tezi*. Necmettin Erbakan Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Bölümü, Konya, 62 s.
- [7] **Davies H D, Wang E E, Manson D, Babyn P and Shuckett B** (1996) Reliability of the chest radiograph in the diagnosis of lower respiratory infections in young children. *The Pediatric Infectious Disease Journal*. 15(7): 600-604.
- [8] **Öztürk T, Talo M, Yıldırım E A, Baloğlu U B, Yıldırım O and Acharya U R** (2020) Automated detection of covid-19 cases using deep neural networks with x-ray images. *Computers in Biology and Medicine*. 121(7), 103792.
- [9] **Nour M, Cömert Z and Polat K** (2020) A Novel Medical Diagnosis model for COVID-19 infection detection based on Deep Features and Bayesian Optimization. *Appl Soft Comput*. 97, 106580.
- [10] **Sethy P K, Behera S K, Ratha P K and Biswas P M** (2020) Detection of coronavirus disease (COVID-19) based on deep features and support vector machine. *Int. J. Math. Eng. Mana. Sci*. 5(4): 643–651.
- [11] **Ravi V, Acharya V and Alazab M** (2022) A multichannel EfficientNet deep learning-based stacking ensemble approach for lung disease detection using chest X-ray images. *Cluster Computing*. 26: 1181-1203.

KAYNAKLAR (devam ediyor)

- [12] **Toğaçar M, Ergen B and Cömert Z** (2020) COVID-19 detection using deep learning models to exploit Social Mimic Optimization and structured chest X-ray images using fuzzy color and stacking approaches. *Computers in Biology and Medicine*. 121, 103805.
- [13] **Türkoğlu M** (2021) COVIDetectionNet: COVID-19 diagnosis system based on X-ray images using features selected from pre-learned deep features ensemble. *Appl Intell*. 51: 1213-1226.
- [14] **Güldalı O** (2021) Göğüs Röntgeni Görüntülerinden Covid-19 Sınıflandırması Yapmak Amacıyla Derin Öğrenme Modellerinden Makine Öğrenmesi Algoritmalarına Derin Öznitelik Aktarımı. *Yüksek Lisans Tezi*. Yıldız Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Matematik Mühendisliği Bölümü, İstanbul, 115 s.
- [15] **Korkmaz A** (2021) Derin Öğrenme Teknikleriyle Akciğer Röntgeninden Covid-19 Hastalığının Tespit Edilmesi. *Yüksek Lisans Tezi*. Yıldız Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Bölümü, Karabük, 52 s.
- [16] **Narin A, Kaya C and Pamuk Z.** (2021) Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks. *Pattern Anal. Appl.* 24: 1207-1220.
- [17] **Talukder A, Layek A, Kazi M, Uddin A and Aryal S** (2024) Empowering COVID-19 detection: Optimizing performance through fine-tuned EfficientNet deep learning architecture. *Computer in Biology and Medicine*. 168, 107789.
- [18] **Kassania S H, Kassania P H, Weselowski M J, Scheneider K A and Deters R** (2021) Automatic Detection of Coronavirus Disease (COVID-19) in X-Ray and CT Images: A Machine Learning Based Approach. *Biocybern Biomed Eng.* 41(3): 867-879.
- [19] **Tiwari S and Jain A** (2021) Convolutional capsule network for COVID-19 detection using radiography images. *International Journal of Imaging Systems and Technology*. 31(2): 525-539.
- [20] **Das A, Kalam S, Kumar C and Sinha D** (2021) TLCoV-An automated Covid-19 screening model using transfer learning from chest X-ray images. *Chaos Solitons Fractals*. 144, 110713.
- [21] **Singh R, Sharma N, Rajput K and Kumar M** (2024) EfficientNet-B0-Based Classification of Pneumonic Lungs Using Chest X-Ray Dataset. *2024 4th International Conference on Intelligent Technologies (CONIT)*. pp: 1-6.
- [22] **Chowdhury N K, Kabir M A, Rahman M and Rezoana N** (2020) ECOVNET: An Ensemble of Deep Convolutional Neural Networks Based on EfficientNet to Detect COVID-19 From Chest X-Rays. *arXiv*. 2009.11850v2.

KAYNAKLAR (devam ediyor)

- [23] Kurt Z, Şahin I, Kaya Z, Anagün Y, Koca N and Çiçek S (2023) Evaluation of EfficientNet models for COVID-19 detection using lung parenchyma. *Neural Computing and Applications*. 35: 12121-12132.
- [24] Demir Y and Bingöl Ö. (2023) Detection of pneumonia from pediatric chest X-ray images by transfer learning. *Sigma Journal of Engineering and Natural Sciences*. 41(6): 1264-1271.
- [25] Bakır H, Oktay S and Tabaru E (2023) Detection Of Pneumonia From X-Ray Images Using Deep Learning Techniques. *Journal of Scientific Reports-A*. (052): 419-440.
- [26] Aljawarneh S and Al-Quraan R (2023) Pneumonia Detection Using Enhanced Convolutional Neural Network Model on Chest X-Ray Images. *Big Data*, 37074075.
- [27] Kanawade B R, Zaware S N, Nandre J, Mahale Y and Dhake K (2023) A Deep Learning Approach for Pneumonia Detection from X ray Images. *International Journal of Intelligent Systems and Applications in Engineering*. 11(2): 262-266.
- [28] Ukwuoma C C, Qin Z, Heyat B B, Akhtar F, Bamisile O, Muaad A Y, Addo D and Al-Antari M A (2023) A hybrid explainable ensemble transformer encoder for pneumonia identification from chest X-ray images. *Journal of Advanced Research*. 48: 191-211.
- [29] Öter G (2023) X-Ray Görüntülerinden Covid-19 Tespiti İçin Derin Öğrenme Tabanlı Modellerin Geliştirilmesi. *Yüksek Lisans Tezi*. Burdur Mehmet Akif Ersoy Üniversitesi, Sosyal Bilimler Enstitüsü, Yönetim Bilişim Sistemleri Bölümü, Burdur, 67 s.
- [30] Hatipoğlu B (2023) Akciğerin X-Ray Görüntülerinden Derin Öğrenme ile Pnömoni Tespiti. *Yüksek Lisans Tezi*. Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Bölümü, Ankara, 76 s.
- [31] Al-Rawe I A M (2024) Prediction of Covid 19 Disease Using Chest X-Ray Images Based on Deep Learning. *Yüksek Lisans Tezi*. Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Bölümü, Ankara, 109 s.
- [32] Kadiroğlu Z (2024) Sayısal Veri ve Göğüs Röntgen Görüntülerinden Derin Öğrenme Yaklaşımları ile Pnömoni Tespiti. *Doktora Tezi*. Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Bölümü, Elazığ, 97 s.
- [33] Rama A, Rajakumar M P, Mythili N, Arunmozhi S, Mohammed M A and Rajinikanth V (2023) Detection of TB from Chest X-ray: A study with EfficientNet. *2023 International Conference on System, Computation, Automation and Networking (ICSCAN)*. pp: 1-4.
- [34] Bartlett D (1989) Respiratory functions of the larynx. *Physiol Rev*. 69(1): 33-57.

KAYNAKLAR (devam ediyor)

- [35] **Mirici A, Babaoğlu E ve Mutlu P** (2019) Normal Akciğerin Yapı ve Fonksiyonu. *Göğüs Hastalıkları*, Kurdak S ve Coşkun F C (Ed.), Türkiye Solunum Araştırmaları Derneği Eğitim Kitapları Serisi 22, ISBN: 978-605-89519-4-5, Kare Yayıncılık, e-kitap, 1-70.
- [36] **Erdoğan Y E** (2022) Öksürük Akustik Sinyallerinde Geleneksel ve Derin Öznitelikler Yardımıyla Covid-19 Tespiti. *Yüksek Lisans Tezi*. Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Bölümü, Zonguldak, 79 s.
- [37] **Shiba K** (2010) Functions of larynx in breathing, vocalization and airway protective reflexes. *Handbook of Behavioral Neuroscience*. 19: 373-381.
- [38] **Lung Health** (2023) What is Pulmonology. Adres: <https://www.verywellhealth.com/what-is-pulmonology-5081298>, (Erişim tarihi: 15.07.2023)
- [39] **Zhou P, Yang X L, Wang X G, Hu B, Zhang L, Zhang W, Si H R, Zhu Y, Li B, Huang C L, Chen H D, Chen J, Luo Y, Guo H, Jiang R D, Liu M Q, Chen Y, Shen X R, Wang X, Zheng X S, Zhao K, Chen Q J, Deng F, Liu L L, Yan B, Zhan F X, Wang Y Y, Xiao G F and Shi Z L** (2020) A pneumonia outbreak associated with a new coronavirus of probable bat origin. *Nature*. 579(7798): 270-273.
- [40] **Aydın M M** (2023) X-Ray Görüntüleri ile Derin Öğrenme Kullanılarak Covid-19 Vakalarının Tespiti. *Yüksek Lisans Tezi*. Sakarya Uygulamalı Bilimler Üniversitesi, Lisansüstü Eğitim Enstitüsü, Biyomedikal Mühendisliği Bölümü, Sakarya, 59 s.
- [41] **T.C. Sağlık Bakanlığı COVID-19 Bilgilendirme Platformu** (2023) COVID-19 Nedir?. Adres: <https://covid19.saglik.gov.tr/tr-66300/covid-19-nedir-.html>, (Erişim tarihi: 10.03.2023)
- [42] **T.C. Sağlık Bakanlığı** (2020) COVID-19 (SARS-CoV-2 Enfeksiyonu). Adres: <https://covid19.saglik.gov.tr/Eklenti/39551/0/covid-19rehberigenelbilgilerepidemiyo lojivetanipdf.pdf>, (Erişim tarihi: 07.12.2020)
- [43] **Minaee S, Kafieh R, Sonka M, Yazdani S and Soufi G J** (2020) Deep-COVID: Predicting COVID-19 from chest X-ray images using deep transfer learning. *Medical Image Analysis*. 65, 101794.
- [44] **Gereige R S and Laufer P M** (2013) Pneumonia. *Pediatrics in Review*. 34(10): 438-456.
- [45] **King Saud University Medical Students Council** (2016) Pathology. Adres: http://ksumsc.com/download_center/Archive/1st/435/3.%20Respiratory%20block/435%20Teamwork/Pathology/Summaries/4-%20Summary%20and%20MCQs.pdf, (Erişim tarihi: 17.10.2024)
- [46] **Visual Intelligence/Image Deep Learning** (2022) Chest X-Ray Images (Pneumonia). Adres: <https://goatlab.tistory.com/entry/%EC%A4%9C%BC-%EC%A4%B8-%EC%A4%B8-Chest-X-Ray-Images-Pneumonia>, (Erişim tarihi: 27.08.2022)

KAYNAKLAR (devam ediyor)

- [47] **Türk F and Kökver Y** (2023) Detection of Lung Opacity and Treatment Planning with Three-Channel Fusion CNN Model. *Arab J Sci Eng.* 14: 1-13.
- [48] **Munden R F, Black W C, Hartman T E, MacMahon H, Ko J P, Dyer D S, Naidich D, Rossi S E, McAdams H P, Goodman E M (et al.)** (2021) Managing incidental findings on thoracic CT: lung findings. A white paper of the acr incidental findings committee. *J. Am. Coll. Radiol.* 18(9): 1267-1279.
- [49] **VinBigData Chest-X-ray: EDA + Fusing boxes** (2020) Lung Opacity. Adres: <https://www.kaggle.com/code/bryanb/vinbigdata-chest-x-ray-eda-fusing-boxes#Lung-Opacity>, (Erişim tarihi: 21.09.2024)
- [50] **Mirici A, Babaoğlu E ve Mutlu P** (2019) Göğüs Hastalıklarında Fizik Muayene. *Göğüs Hastalıkları*, Aydemir Y, Türkiye Solunum Araştırmaları Derneği Eğitim Kitapları Serisi 22, 978-605-89519-4-5, Kare Yayıncılık, e-kitap: 21-44.
- [51] **Başkent Hastaneleri** (2011) Solunum Hastalıkları Tanı Yöntemleri. Adres: <https://www.baskenthastaneleri.com/uploads/images/adana/solunum%20TANI%20YONTEM.pdf>, (Erişim tarihi: 16.08.2011)
- [52] **Mirici A, Babaoğlu E ve Mutlu P** (2019) Solunum Fonksiyon Testleri Spirometri, Reverzibilite ve Geç Reverzibilite Testi. *Göğüs Hastalıkları*, Diken Ö E, Türkiye Solunum Araştırmaları Derneği Eğitim Kitapları Serisi 22, 978-605-89519-4-5, Kare Yayıncılık, e-kitap: 125-136.
- [53] **Mirici A, Babaoğlu E ve Mutlu P** (2019) Difüzyon Testi: Akciğer Hacim Ölçüm Yöntemleri, Kardiyopulmoner Egzersiz Testleri. *Göğüs Hastalıkları*, Çoşkun F, Türkiye Solunum Araştırmaları Derneği Eğitim Kitapları Serisi 22, 978-605-89519-4-5, Kare Yayıncılık, e-kitap: 145-159.
- [54] **Mirici A, Babaoğlu E ve Mutlu P** (2019) Kardiyopulmoner Egzersiz Testleri. *Göğüs Hastalıkları*, Çoşkun F, Türkiye Solunum Araştırmaları Derneği Eğitim Kitapları Serisi 22, 978-605-89519-4-5, Kare Yayıncılık, e-kitap: 297-315.
- [55] **Testing** (2020) Sputum Culture, Bacterial. Adres: <https://www.testing.com/tests/sputum-culture-bacterial/>, (Erişim tarihi: 14.01.2020)
- [56] **CityofHope** (2023) Thoracentesis. Adres: <https://www.cancercenter.com/treatment-options/thoracentesis>, (Erişim tarihi: 07.04.2023)
- [57] **Hopkins Medicine** (2023) What is a pleural biopsy?. Adres: <https://www.hopkinsmedicine.org/health/treatment-tests-and-therapies/pleural-biopsy>, (Erişim tarihi: 19.06.2023)
- [58] **Mirici A, Babaoğlu E ve Mutlu P** (2019) Toraks Radyolojisi: Konvansiyonel Akciğer Grafisi. *Göğüs Hastalıkları*, Savaş R and Çinkoğlu A, Türkiye Solunum Araştırmaları Derneği Eğitim Kitapları Serisi 22, 978-605-89519-4-5, Kare Yayıncılık, e-kitap: 45-69.

KAYNAKLAR (devam ediyor)

- [59] **Mirici A, Babaoğlu E ve Mutlu P** (2019) Toraks Radyolojisi: BT ve MRG. *Göğüs Hastalıkları*, Savaş R and Çinkoğlu A, Türkiye Solunum Araştırmaları Derneği Eğitim Kitapları Serisi 22, 978-605-89519-4-5, Kare Yayıncılık, e-kitap: 70-94.
- [60] **Greater Waterbury Imaging Center** (2022) MR Chest With and Without IV Contrast. Adres: <https://greaterwaterburyimagingcenter.org/portfolio/mr-chest-with-and-without-iv-contrast/>, (Erişim tarihi: 09.11.2022)
- [61] **Mirici A, Babaoğlu E ve Mutlu P** (2019) Akciğer Lezyonlarında PET/MR ile Görüntüleme. *Göğüs Hastalıkları*, İlçe H T, Türkiye Solunum Araştırmaları Derneği Eğitim Kitapları Serisi 22, 978-605-89519-4-5, Kare Yayıncılık, e-kitap: 460-463.
- [62] **Mirici A, Babaoğlu E ve Mutlu P** (2019) Toraks Ultrasonografisi. *Göğüs Hastalıkları*, Cömert S Ş, Türkiye Solunum Araştırmaları Derneği Eğitim Kitapları Serisi 22, 978-605-89519-4-5, Kare Yayıncılık, e-kitap: 95-110.
- [63] **Pulmonary Practice Associates** (2023) Navigational Bronchoscopy. Adres: <https://pulmonarypracticeassociates.com/navigational-bronchoscopy/>, (Erişim tarihi: 09.03.2023)
- [64] **Wikipedia** (2024) X Işını. Adres: https://tr.wikipedia.org/wiki/X_ışını#:~:text=8%20Kasım%201895%27te%20Alman,Fiziksel-Tıp%20Derneği%20dergisine%20sundu., (Erişim tarihi: 23.11.2024)
- [65] **Polat M D** (2021) A Modular, Scalable Detector Acquisition System for Medical X-Ray Application. *Yüksek Lisans Tezi*. Boğaziçi Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Bölümü, İstanbul, 88 s.
- [66] **Dou H** (2019) Deep supervised active learning for chest x-ray lung disease classification. *IEEE Transactions on Medical Imaging*. 38(9): 2161-2172.
- [67] **Anthimopoulos M, Christodoulidis S, Ebner L, Christe A and Mougiakakou** (2016) Lung pattern classification for interstitial lung diseases using a deep convolutional neural network. *IEEE Transactions on Medical Imaging*. 35(5): 1207-1216.
- [68] **Rajpurkar P, Irvin J, Zhu K, Yang B, Mehta H, Duat T and Ng A Y** (2017) Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. *arXiv preprint arXiv*. 1711.05225.
- [69] **Cheng J Z, Ni D, Chou Y H, Qin J, Tiu C M, Chang Y C and Chen C M** (2016) Computer-aided diagnosis with deep learning architecture: applications to breast lesions in US images and pulmonary nodules in CT scans. *Scientific Reports*. 6(1): 24454.
- [70] **Wang X, Peng Y, Lu L, Lu Z, Bagheri M and Summers R M** (2017) Chestx-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. San Juan, 2097-2106.

KAYNAKLAR (devam ediyor)

- [71] Kauczor H U, Bonomo L, Gaga M, Nackaerts K, Peled N, Prokop M and European Society of Radiology (ESR) and the European Respiratory Society (ERS) (2015) ESR/ERS white paper on lung cancer screening. *European Radiology*. 25: 2519-2531.
- [72] MacMahon H, Naidich D P, Goo J M, Lee K S, Leung A N, Mayo J R and Vlahos I (2017) Guidelines for management of incidental pulmonary nodules detected on CT images: From the Fleischner Society 2017, *Radiology*. 284(1): 228-243.
- [73] Hansell D M, Bankier A A, MacMahon H, McLoud T C, Muller N L and Remy J (2008) Fleischner Society: glossary of terms for thoracic imaging. *Radiology*. 246(3): 697-722.
- [74] Pirim A G H (2006) Yapay Zeka. *Yaşar Üniversitesi E-Dergisi*. 1(1): 81-93.
- [75] [URL-16] Wikipedia (2024) Yapay zeka. Adres: https://tr.wikipedia.org/wiki/Yapay_zekâ, (Erişim tarihi: 07.12.2024)
- [76] Sarker I H (2021) Machine learning: Algorithms, real-world applications and research directions. *SN computer science*. 2(3): 160.
- [77] Medium (2019) Yeni Başlayanlar için Makine Öğrenmesi Algoritmaları. Adres: <https://merveenoyan.medium.com/yeni-başlayanlar-için-makine-öğrenmesi-algoritmaları-6b89b3a67750>, (Erişim tarihi: 17.09.2019)
- [78] Tiwari T, Tiwari T and Tiwari S (2018) How Artificial Intelligence, Machine Learning and Deep Learning are Radically Different?. *International Journal of Advanced Research in Computer Science and Software Engineering*. 8(2): 1.
- [79] Ruder S (2016) An overview of gradient descent optimization algorithms. Retrieved May 1, 1609.04747.
- [80] GeeksforGeeks (2020) Intuition behind Adagrad Optimizer. Adres: <https://www.geeksforgeeks.org/intuition-behind-adagrad-optimizer>, (Erişim tarihi: 26.11.2020)
- [81] Facebook AI (2021) RMSProp. Adres: <https://paperswithcode.com/method/rmsprop>, (Erişim tarihi: 06.08.2021)
- [82] Medium (2021) Why AdamW Matters. Adres: <https://towardsdatascience.com/why-adamw-matters-736223f31b5d>, (Erişim tarihi: 22.04.2021)
- [83] Kingma D P and Ba J (2014) Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- [84] Xiao B, Liu Y and Xiao B (2019) Accurate State-of-Charge Estimation Approach for Lithium-Ion Batteries by Gated Recurrent Unit With Ensemble Optimizer. *IEEE Access Digital Object Identifier 10.1109*, Volume 7: 54192-54202.

KAYNAKLAR (devam ediyor)

- [85] **ruđer.io** (2017) An overview of gradient descent optimization algorithms. Adres: <https://www.ruder.io/optimizing-gradient-descent/#adamax>, (Eriřim tarihi: 15.06.2017)
- [86] **Nair V and Hinton G E** (2010) Rectified linear units improve restricted boltzmann machines. *In Proceedings of the 27th International Conference on Machine Learning*, (ICML-10): 807-814.
- [87] **Maas A L, Hannun A Y and Ng A Y** (2013) Rectifier nonlinearities improve neural network acoustic models. *In Proceedings of the 30th International Conference on Machine Learning*, 30(1): 3.
- [88] **Han J and Moraga C** (1995) The influence of the sigmoid function parameters on the speed of backpropagation learning. *In International workshop on artificial neural networks*, 195-201.
- [89] **Medium** (2021) Yapay Sinir Ağlarında Aktivasyon Fonksiyonları. Adres: <https://medium.com/databulls/yapay-sinir-ağlarında-aktivasyon-fonksiyonları-11002b8ac522>, (Eriřim tarihi: 18.03.2021)
- [90] **Medium** (2018) Convolutional Neural Network (ConvNet yada CNN) nedir, nasıl çalışır?. Adres: <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad>, (Eriřim tarihi: 02.08.2018)
- [91] **Sing N and Sabrol H** (2021) Convolutional neural networks-an extensive arena of deep learning. A comprehensive study. *Archives of Computational Methods in Engineering*, 28(7): 4755-4780.
- [92] **Medium** (2021) Convolutional Neural Network Nedir?. Adres: <https://bartubozkurt35.medium.com/cnn-convolutional-neural-networks-nedir-a5bafc4a82a1>, (Eriřim tarihi: 30.09.2021)
- [93] **Medium** (2021) Batch Normalization, nasıl çalışır?. Adres: <https://zerzavot.medium.com/batch-normalization-b7d73c9cc6df>, (Eriřim tarihi: 31.01.2021)
- [94] **Medium** (2017) Applied Deep Learning – Part 4: Convolutional Neural Networks. Adres: <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2>, (Eriřim tarihi: 08.11.2017)
- [95] **Ali L, Alnajjar F, Jassmi H A, Gocho M, Khan W and Serhani M A** (2021) Performance evaluation of deep CNN-based crack detection and localization techniques for concrete structures. *Sensors*, 21(5): 1688.
- [96] **Sharma N, Saba L, Khanna N N, Kalra M K, Fouda M M and Suri J S** (2022) Segmentation-based classification deep learning model embedded with explainable AI for COVID-19 detection in chest X-ray scans. *Diagnostics*, 12(9): 2132.

KAYNAKLAR (devam ediyor)

- [97] **Tan M and Le Q V** (2019) EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *arXivabs*, 1905.11946.
- [98] **Medium** (2019) Ölçeklendirme ile CNN Modelinin Doğruluk ve Verimliliğini Arttırma: EfficientNet. Adres: <https://ayyucekizrak.medium.com/ölçeklendirme-ile-cnn-modelinin-doğruluk-ve-verimliliğini-arttırma-efficientnet-cb6f2b6512de>, (Erişim tarihi: 20.12.2019)
- [99] **Geeksforgeeks** (2024) Efficientnet Architecture. Adres: <https://www.geeksforgeeks.org/efficientnet-architecture/#efficientnet>, (Erişim tarihi: 03.06.2024)
- [100] **Adithya V K, Williams B M, Czanner S, Kavitha S, Friedman D S, Willoughby C E, Venkatesh R and Czanner G** (2021) EffUnet-SpaGen: An Efficient and Spatial Generative Approach to Glaucoma Detection. *Journal of Imaging*, 7: 92.



ÖZGEÇMİŞ

Anıl SEVER ilk ve orta öğretimini Bursa’da tamamladı. Lise eğitimini 2011-2015 yılları arasında Bursa Hürriyet Anadolu Lisesi’nde tamamladı. 2015-2019 yılları arasında Zonguldak Bülent Ecevit Üniversitesi Biyomedikal Mühendisliği bölümünde lisans eğitimini tamamladı. 2020 yılında Zonguldak Bülent Ecevit Üniversitesi Biyomedikal Mühendisliği Anabilim Dalı’nda yüksek lisans eğitime başladı. Eğitim geçmişinin dışında 2021 yılında Aselsan firmasının sağlık alanındaki projesinde Gömülü Yazılım Geliştirici unvanıyla proje bazlı olarak çalıştı. 2022-2023 yılları arasında askerlik görevini Yedek Subay unvanıyla tamamladı. 2023 yılında MLP Care bünyesinde olan Medical Park Ankara Hastanesi’nde Biyomedikal Uzmanı olarak çalıştı. Aktif olarak halen CCN Holding bünyesinde olan Ankara Bilkent Şehir Hastanesi’nde Biyomedikal Uzmanı olarak çalışmaya devam etmektedir.