



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



YÜKSEK LİSANS TEZİ

**YÜKSEK ENERJİ FİZİĞİ PERSPEKTİFİNDEN EVRİŞİMLİ SINIR
AĞLARI İLE AKCİĞER X-IŞINI GÖRÜNTÜLERİNİN
SINIFLANDIRILMASI**

Şafak YASUN

Fizik Anabilim Dalı

Yüksek Enerji ve Plazma Fiziği Programı

**DANIŞMAN
Dr. Öğr. Üyesi Hale SERT**

Ocak, 2025

İSTANBUL

Bu alıřma 17.01.2025 tarihinde ařaęıdaki jüri tarafından Fizik Anabilim Dalı Yüksek Enerji ve Plazma Fizięi Programında Yüksek Lisans Tezi olarak kabul edilmiřtir.

Tez Jürisi

Dr. Öğr. Üyesi Hale SERT (Danıřman)
Üniversite
Fakülte

Prof. Dr. Suat ÖZKORUCUKLU
İstanbul Üniversitesi
Fen Fakültesi

Prof. Dr. Bora IřILDAK
Yıldız Teknik Üniversitesi
Fen Fakültesi



- **İntihal Programı Beyanı**

20.04.2016 tarihli resmi gazetede yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi'nin aboneli olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü'nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

- **Proje Destekleri**

Bu tez, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) - 2232-A Uluslararası Lider Araştırmacılar Programı 121C090 numaralı projesi ile desteklenmiştir.

ÖNSÖZ

Yüksek lisans eğitimim boyunca bilgi ve tecrübeleriyle her zaman yol gösteren ve beni bitiş çizgisine taşıyan değerli hocam Dr. Öğr. Üyesi Hale Sert'e teşekkürlerimi sunuyorum.

Bu zorlu süreçte pes etmeyip ihtiyaç duyduğum motivasyonu ve devam etmem gerektiğine olan inancımı sürekli hatırlatan, dünyanın en güzel ve en akıllı kadını sevgili anneme, bana öğrettikleri ve varlığı için tüm kalbimle minnettarım.

Abim Erhan'a ve dünyanın en neşeli kız kardeşi olan Sude'me, farkında olmadan bile hep destekledikleri ve her defasında beni güldürmeyi başardıkları için teşekkür ederim.

Ocak, 2025

Şafak YASUN

İÇİNDEKİLER

	Sayfa No
ÖNSÖZ	iv
İÇİNDEKİLER	vii
ŞEKİL LİSTESİ	xi
TABLO LİSTESİ	xii
SİMGE VE KISALTMA LİSTESİ	xiii
ÖZET	xv
SUMMARY	xvii
1. GİRİŞ	1
2. GENEL KISIMLAR	5
2.1. ELEKTROMANYETİK DALGALAR	5
2.2. TIBBİ GÖRÜNTÜLEME YÖNTEMLERİ	9
2.2.1. Röntgen (X-Işını)	9
2.2.2. Bilgisayarlı Görüntüleme (BT)	11
2.2.3. Manyetik Rezonans Görüntüleme (MRI)	12
2.3. MAKİNE ÖĞRENMESİ	14
2.3.1. Makine Öğrenmesi Yöntemleri	14
2.3.1.1. Denetimli Öğrenme	15
2.3.1.2. Denetimsiz Öğrenme	16
2.3.1.3. Pekiştirmeli Öğrenme	16
2.3.2. Temel Makine Öğrenmesi Algoritmaları	17
2.3.2.1. Regresyon Algoritmaları	17
2.3.2.2. Kümeleme Algoritmaları	18
2.3.2.3. Sınıflandırma Algoritmaları	19
2.4. YAPAY SİNİR AĞLARI	20
2.5. EVRİŞİMLİ SİNİR AĞLARI	23
2.5.1. Girdi Katmanı	24

2.5.2. Evrişim Katmanı	24
2.5.3. Havuzlama Katmanı	26
2.5.4. Genel Ortalama Havuzlama Katmanı	29
2.5.5. Yoğun Katman	30
2.5.6. Toplu Normalleştirme Katmanı	30
2.5.7. Aktivasyon Fonksiyonları	31
2.6. MODEL PERFORMANS DEĞERLENDİRMESİ	35
2.6.1. Doğruluk (Accuracy)	35
2.6.2. Kesinlik (Precision)	36
2.6.3. Duyarlılık (Recall)	36
2.6.4. F1 Skoru	37
2.6.5. ROC Eğrisi	37
2.6.6. Hata Matrisi (Confusion Matrix)	38
2.7. ÇAPRAZ DOĞRULAMA	39
2.8. LİTERATÜR TARAMASI	40
3. MALZEME VE YÖNTEM	44
3.1. VERİ SETİ	44
3.2. VERİ ÖN İŞLEME	45
3.2.1. Veri Ön İşleme Adımları	46
3.2.1.1. Yeniden Boyutlandırma	46
3.2.1.2. Histogram Normalizasyonu	47
3.2.1.3. Veri Artırımı	50
3.3. DENSENET MODELİ	51
3.3.1. Yoğun Bloklar	52
3.3.2. Geçiş Katmanı	53
3.3.3. Hibrit Evrişim Katmanı	55
3.4. MODEL HİPERPARAMETRELERİ	56
3.4.1. Eğitim Tur Sayısı	56
3.4.2. Küme Boyutu	57
3.4.3. Öğrenme Oranı	58
3.4.4. Optimizasyon Algoritması	58
3.4.5. Kayıp Fonksiyonu	59

4. BULGULAR	61
4.1. İKİLİ ÇAPRAZ ENTROPİ VE ODAK KAYIP FONKSİYONU SONUÇLARI ...	62
4.2. MONTGOMERY COUNTY VERİ SETİ SONUÇLARI	65
4.3. SHENZHEN VERİ SETİ SONUÇLARI	74
4.4. MONTGOMERY+SHENZHEN VERİ SETİ	84
4.5. TÜBERKÜLOZ (TB) GÖĞÜS RÖNTGENİ VERİ TABANI VERİ SETİ	93
4.6. 5 KATLI ÇAPRAZ DOĞRULAMA SONUÇLARI	102
5. TARTIŞMA VE SONUÇ	105
KAYNAKLAR	110
ÖZGEÇMİŞ	117

ŞEKİL LİSTESİ

	Page No
Şekil 2.1: Elektromanyetik Dalganın Elektrik ve Manyetik Alan Bileşenleri (1).....	7
Şekil 2.2: Elektromanyetik Spektrum (2)	8
Şekil 2.3: X-Işını Tüpü (3)	10
Şekil 2.4: X-ışını Görüntüleme Sistemi (4).....	11
Şekil 2.5: BT Çalışma Prensibi (4).....	12
Şekil 2.6: MRI Sistemi (5).....	13
Şekil 2.7: Pekiştirmeli Öğrenme Şeması (6).....	17
Şekil 2.8: Gradyan İniş Algoritması (7)	21
Şekil 2.9: Sinir Ağı Mimarisi (8)	22
Şekil 2.10: Evrişim İşlemi	26
Şekil 2.11: ReLU Aktivasyon Fonksiyonu (9).....	32
Şekil 2.12: Sigmoid Aktivasyon Fonksiyonu (10).....	34
Şekil 2.13: ROC eğrisi.....	38
Şekil 2.14: Hata Matrisi	39
Şekil 3.1: 1024x1024 piksel boyutuna sahip X-ışını görüntüsü	47
Şekil 3.2: 400x400 piksel boyutuna sahip X-ışını görüntüsü	47
Şekil 3.3: CLAHE Öncesi	50
Şekil 3.4: CLAHE Sonrası.....	50
Şekil 3.5: CLAHE öncesi piksel dağılımı	50
Şekil 3.6: CLAHE sonrası piksel dağılımı	50
Şekil 3.7: DenseNet201 Mimarisi (11).....	54
Şekil 3.8: Hibrit Evrişim Katmanı.....	56
Şekil 4.1: Montgomery County Veri Seti için Eğitim ve Doğrulama Doğruluk/Kayıp Sonuçları ..	63
Şekil 4.2: Shenzhen Veri Seti için Eğitim ve Doğrulama Doğruluk/Kayıp Sonuçları	63

Şekil 4.3: Montgomery+Shenzhen Veri Seti için Eğitim ve Doğrulama Doğruluk/Kayıp Sonuçları	64
Şekil 4.4: Tüberküloz Göğüs Röntgeni VT Veri Seti için Eğitim ve Doğrulama Doğruluk/Kayıp Sonuçları	64
Şekil 4.5: Ham MC Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri ..	66
Şekil 4.6: Ham MC Veri Setiyle Test Seti için Hata Matrisi	66
Şekil 4.7: Veri Artırımı Sonrası MC Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri	67
Şekil 4.8: Veri Artırımı Sonrası MC Veri Setiyle Test Seti için Hata Matrisi	68
Şekil 4.9: Veri Artırımı ve CLAHE Sonrası MC Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri	68
Şekil 4.10: Veri Artırımı ve CLAHE Sonrası MC Veri Setiyle Test Seti için Hata Matrisi.....	69
Şekil 4.11: Veri Artırımı ve Hibrit Evrişim Katmanı Sonrası MC Verisi Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri	70
Şekil 4.12: Veri Artırımı ve Hibrit Evrişim Katmanı Sonrası MC Veri Setiyle Test Seti için Hata Matrisi.....	70
Şekil 4.13: Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Sonrası MC Verisi Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri	71
Şekil 4.14: Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Sonrası MC Veri Setiyle Test Seti için Hata Matrisi	72
Şekil 4.15: Birleştirilmiş Hata Matrisi	73
Şekil 4.16: Tüm Durumlar İçin ROC Eğrileri	74
Şekil 4.17: Ham Shenzhen Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri	75
Şekil 4.18: Ham Shenzhen Veri Setiyle Test Seti için Hata Matrisi	75
Şekil 4.19: Veri Artırımı Sonrası Shenzhen Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri	76
Şekil 4.20: Veri Artırımı Sonrası Shenzhen Veri Setiyle Test Seti için Hata Matrisi	77
Şekil 4.21: Veri Artırımı ve CLAHE Sonrası Shenzhen Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri	77
Şekil 4.22: Veri Artırımı ve CLAHE Sonrası Shenzhen Veri Setiyle Test Seti için Hata Matrisi...	78
Şekil 4.23: Veri Artırımı ve Hibrit Evrişim Katmanı Sonrası Shenzhen Verisi Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri.....	79
Şekil 4.24: Veri Artırımı ve Hibrit Evrişim Katmanı Sonrası Shenzhen Veri Setiyle Test Seti için Hata Matrisi	80

Şekil 4.25: Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Sonrası Shenzhen Verisi Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri	81
Şekil 4.26: Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Sonrası Shenzhen Veri Setiyle Test Seti için Hata Matrisi	81
Şekil 4.27: Birleştirilmiş Hata Matrisi	82
Şekil 4.28: Tüm Veri Setleri İçin ROC Eğrileri	83
Şekil 4.29: Ham Montgomery+Shenzhen Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri	84
Şekil 4.30: Ham Montgomery+Shenzhen Veri Setiyle Test Seti için Hata Matrisi	85
Şekil 4.31: Veri Artırımı Sonrası Montgomery+Shenzhen Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri	86
Şekil 4.32: Veri Artırımı Sonrası Montgomery+Shenzhen Veri Setiyle Test Seti için Hata Matrisi	86
Şekil 4.33: Veri Artırımı ve CLAHE Sonrası Montgomery+Shenzhen Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri	87
Şekil 4.34: Veri Artırımı ve CLAHE Sonrası Montgomery+Shenzhen Veri Setiyle Test Seti için Hata Matrisi	88
Şekil 4.35: Veri Artırımı ve Hibrit Evrişim Katmanı Sonrası Montgomery+Shenzhen Verisi Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri	89
Şekil 4.36: Veri Artırımı ve Hibrit Evrişim Katmanı Sonrası Montgomery+Shenzhen Veri Setiyle Test Seti için Hata Matrisi.....	89
Şekil 4.37: Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Sonrası Shenzhen Verisi Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri	90
Şekil 4.38: Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Sonrası Shenzhen Veri Setiyle Test Seti için Hata Matrisi	91
Şekil 4.39: Birleştirilmiş Hata Matrisi	92
Şekil 4.40: Tüm Veri Setleri İçin ROC Eğrileri	93
Şekil 4.41: Ham TB Göğüs Röntgeni Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri	94
Şekil 4.42: Ham TB Göğüs Röntgeni Veri Setiyle Test Seti için Hata Matrisi	94
Şekil 4.43: Veri Artırımı Sonrası TB Göğüs Röntgeni Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri	95
Şekil 4.44: Veri Artırımı Sonrası TB Göğüs Röntgeni Veri Setiyle Test Seti için Hata Matrisi.....	95
Şekil 4.45: Veri Artırımı ve CLAHE Sonrası TB Göğüs Röntgeni Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri.....	96

Şekil 4.46: Veri Artırımı ve CLAHE Sonrası TB Göğüs Röntgeni Veri Setiyle Test Seti için Hata Matrisi.....	97
Şekil 4.47: Veri Artırımı ve Hibrit Evrişim Katmanı Sonrası TB Göğüs Röntgeni Verisi Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri	98
Şekil 4.48: Veri Artırımı ve Hibrit Evrişim Katmanı Sonrası TB Göğüs Röntgeni Veri Setiyle Test Seti için Hata Matrisi	98
Şekil 4.49: Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Sonrası TB Göğüs Röntgeni Verisi Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri	99
Şekil 4.50: Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Sonrası TB Göğüs Röntgeni Veri Setiyle Test Seti için Hata Matrisi.....	100
Şekil 4.51: Birleştirilmiş Hata Matrisi	101
Şekil 4.52: Tüm Veri Setleri İçin ROC Eğrileri	101
Şekil 4.53: Tüm Veri Setleri İçin Eğitim Doğrulukları.....	102
Şekil 4.54: Tüm Veri Setleri İçin Eğitim Kayıpları	103
Şekil 4.55: Tüm Veri Setleri İçin Doğrulama Doğrulukları.....	103
Şekil 4.56: Tüm Veri Setleri İçin Doğrulama Kayıpları	104
Şekil 4.57: Tüm Veri Setleri İçin ROC Eğrileri	104

TABLO LİSTESİ

	Page No
Tablo 3.1: Veri Setleri için Normal ve TB Görüntü Veri Sayıları ve Görüntü Boyutları	45
Tablo 3.2: Veri Artırımı Sonrası Örnek Sayıları	51
Tablo 4.1: Model Parametreleri	62
Tablo 4.2: Veri setleri için İkili Çapraz Entropi ve Odak Kaybı sonuçları	65
Tablo 4.3: Montgomery County Veri Seti Sonuçları.....	72
Tablo 4.4: Shenzhen Veri Seti Sonuçları	82
Tablo 4.5: Montgomery+Shenzhen Veri Seti Sonuçları.....	91
Tablo 4.6: Tüberküloz Göğüs Röntgeni Veri tabanı Veri Seti Sonuçları	100
Tablo 5.1: Tüm Veri Setleri İçin Elde Edilen En İyi Bulgular	107
Tablo 5.2: Literatür Sonuçları	109

SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
Hz	: Hertz
GHz	: Giga Hertz
h	: Planck Sabiti
c	: Işık Hızı
ρ	: Yük Yoğunluğu
ϵ_0	: Elektriksel Permittivite Sabiti
μ_0	: Manyetik Geçirgenlik Sabiti
J	: Elektriksel Akım Yoğunluğu
λ	: Dalgaboyu
f	: Frekans

Kısaltmalar	Açıklama
ESA	: Evrişimli Sinir Ağları
BCE	: Binary Cross Entropy
YSA	: Yapay Sinir Ağları
DL	: Deep Learning
ML	: Machine Learning
MC	: Montgomery County
AUC	: Area Under Curve
ROC	: Receiver Operating Characteristic
$CLAHE$	: Contrast Limited Adaptive Histogram Equalization
TB	: Tüberküloz
VT	: Veri Tabanı

ÖZET

YÜKSEK LİSANS TEZİ

YÜKSEK ENERJİ FİZİĞİ PERSPEKTİFİNDEN EVRİŞİMLİ SINIR AĞLARI İLE AKCİĞER X-IŞINI GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

Şafak YASUN

İstanbul Üniversitesi

Fen Bilimleri Enstitüsü

Fizik Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Hale SERT

Yapay zekâ araçlarının gelişmesi pek çok alana kayda değer katkılar sunmuştur. İnsan etkisine gerek kalmadan kendi kendine öğrenen ve gelişen algoritmalar büyük veri setlerinin analizinde ve modellenmesi zor problemlerde hızlı ve pratik çözümler sunmaktadır. Bu bağlamda yapay zekâ tekniklerinin son yıllardaki kanıtlanmış başarısı, görüntü sınıflandırmadan modern parçacık fiziği analizlerine kadar farklı alanlarda oldukça kullanışlı bir altyapı sunmaktadır. Bu tez çalışmasında, yapay zekâ yöntemlerinden biri olan evrişimli sinir ağı modelleri kullanılarak akciğerlere ait X-ışını görüntülerinin sınıflandırılması çalışılmıştır.

Görüntü sınıflandırma çalışmalarının temel amaçlarından biri hassas piksel farklılıkları içeren görüntüleri başarılı bir şekilde analiz edebilen yapılar geliştirmektir. Bu hedefe ulaşmak için veri ön işleme adımlarının ve model optimizasyonlarının doğru bir şekilde seçilmesi oldukça önemlidir.

Bu tez kapsamında Montgomery, Shenzhen, Montgomery+Shenzhen ve Tüberküloz Göğüs Röntgeni Veri Tabanı'ndan elde edilen akciğer görüntülerinin tüberküloz sınıflandırması DenseNet201 modeli ile incelenmiştir. Sınıflandırma performansını geliştirmek için veri artırımı ve normalizasyon teknikleri kullanılmıştır. Modele hibrit evrişim katmanı eklenerek tahmin başarılarına etkisi incelenmiştir.

Çalışılan metotların bireysel ve kombine durumlar için değerlendirmesi yapılmış, en iyi sınıflandırma başarısının hibrit evrişim katman ile geliştirilmiş modelde veri artırımı ve CLAHE normalizasyonu uygulanan görüntülerle elde edildiği görülmüştür. Bulgular dört veri seti için de normalizasyon ve optimizasyon yaklaşımlarının birlikte kullanıldığı durumda model başarısının %89 ile %99 arasında doğruluk skorlarıyla en yüksek seviyeye ulaştığını göstermiştir. Elde edilen bulgularla çalışılan metotların farklı disiplinlerdeki görüntü sınıflandırma problemlerine de uyarlanabileceği düşünülmektedir.

Ocak 2025, 135 sayfa.

Anahtar kelimeler: Tüberküloz, Evrişimli Sinir Ağları, CLAHE, DenseNet201.



SUMMARY

M.Sc. THESIS

CLASSIFICATION OF LUNG X-RAY IMAGES WITH CONVOLUTIONAL NEURAL NETWORKS FROM A HIGH ENERGY PHYSICS PERSPECTIVE

Şafak YASUN

İstanbul University

Institute of Graduate Studies in Sciences

Department of Physics

Supervisor: Asst. Prof. Hale SERT

The development of artificial intelligence tools has made significant contributions to various fields. Algorithms that can learn and evolve independently, without the need for human intervention, provide fast and practical solutions in analyzing large data sets and in problems that are difficult to model. In this context, the proven success of artificial intelligence techniques in recent years offers a highly useful infrastructure in areas ranging from image classification to modern particle physics analysis. In this thesis, lung X-ray image classification is studied using convolutional neural network models, which are one of the artificial intelligence methods.

One of the primary goal of image classification studies is to develop structures capable of successfully analyzing images that contain subtle pixel differences. To achieve this goal it is crucial to carefully select data preprocessing steps and model optimizations.

In this thesis, lung images obtained from the Montgomery, Shenzhen, Montgomery+Shenzhen, and Tuberculosis Chest X-ray Databases were analyzed for tuberculosis classification using the DenseNet201 model. Data augmentation and normalization techniques were used to improve classification performance. The impact of adding a hybrid convolutional layer to the model on prediction accuracy was also investigated.

The evaluation of the methods in individual and combined scenarios showed that the best classification performance was achieved with images augmented with data augmentation and CLAHE normalization in the model with the hybrid convolutional layer. The findings demonstrated that, for all four datasets, the model's performance reached its highest level with accuracy scores ranging from %89 to %99 when normalization and optimization approaches were used together. Based on these findings, it is believed that the methods studied can also be adapted to image classification problems in different disciplines.

January 2025, 135 pages.

Keywords: Tuberculosis, Convolutional Neural Networks, CLAHE, DenseNet201.



1. GİRİŞ

İnsan gibi düşünebilen makineler fikri çağımızın üzerine en çok uğraşılan ve geliştirilen konularından biri olmuştur. Özellikle son yıllarda popülerleşen yapay zekâ, bu alandaki çabaların bir sonucu olarak bilimden sağlığa, eğitimden sanata kadar pek çok sektörde kendine yer bulmuştur. Yıllar içindeki ilerlemeler makine öğrenmesi gibi alt alanların oluşmasına ve yüksek performans gösteren algoritmaların gelişmesini sağlamıştır.

Teknolojinin gelişmesiyle bilgiye olan erişim artmış ve yeni bulguların keşfi hızlanmıştır. Yapay zekâ uygulamalarının modern fiziğin yasalarını araştırmak için fizik bilimine entegrasyonu ise gün geçtikçe önem kazanmaktadır. Özellikle CERN bünyesinde yapılan deneylerden elde edilen büyük verilerin işlenmesi ve analiz edilmesi makine öğrenmesi ve derin öğrenme metotlarının kullanılmasıyla çok daha hızlı ve pratik hale gelmiştir. Parçacık izlerinin tanımlanması ve sinyal-arka plan ayrımının yapılması [12] gibi konularda bu uygulamaların kullanımı oldukça popülerleşmiştir.

2024 yılı Nobel fizik ödüllerinin sahipleri istatistiksel fizik kurallarını kullanarak makine öğrenmesi modellerinin geliştirilmesine yaptıkları katkıdan dolayı John Hopfield ve Geoffrey Hinton'a verilmiştir [13]. Fizikteki pek çok fenomenin yeni modeller geliştirmeye katkı sunabileceği fikri Hopfield ve Hinton'ın çalışmaları sayesinde önem kazanmıştır. O halde iki alandaki gelişmelerin birbirini tetikleyen ilerlemeler yaratabileceği düşüncesi kabul edilebilir.

Farklı disiplinlerdeki keşiflerin birbirine uyarlanabilmesi, mevcut uygulamaların gelişmesi için oldukça önemli bir kaynaktır. Yüksek enerji fiziği kapsamında kozmolojik veya parçacık fiziği analizlerinde kullanılan yöntemlerin sağlık gibi önemli diğer alanlara uyarlanması da bu bağlamda mümkün görünmektedir. Tam tersi olarak örneğin medikal görüntü analizleri için geliştirilen sinir ağı modellerinin gelecekteki bir takım astronomi veya fizik veri setlerini analiz etmede kullanılması da mümkündür. Örnek olarak literatürdeki Ayyar ve diğerleri tarafından [14] yapılan çalışma incelendiğinde parçacık dedektörlerinden elde edilen simüle edilmiş verilerle 2 ve 3 boyutlu görüntüler üzerindeki sinyal-arka plan ayrımı için %96 oranında bir genelleme başarısı elde edilmiş ve sonuçların farklı disiplinlerdeki görüntü

sınıflandırma problemlerine uyarlanabileceği tartışılmıştır.

Evrenin varoluş mekanizmasını anlayabilmek, az maliyet ile çok iş yapan teknolojileri geliştirmek, salgın hastalıkları önlemek ve doğal yaşam kaynaklarını korumak gibi soruların ortak noktası yapay zekâ yöntemleriyle cevap aranabilir olmalarıdır. Artan dünya nüfusu ve yakın geçmişte yaşanan pandemi göz önüne alındığında salgın hastalıkların yarattığı endişe hala devam etmektedir. Özellikle kronikleşmiş salgın hastalıkların etkili bir şekilde son bulmaması her yıl yüzbinlerce insanın ölümüne neden olmaktadır. Kronikleşmiş salgınlardan biri hala etkin bir şekilde sonlandırılmamış tüberküloz hastalığıdır. Dünya Sağlık Örgütü'nün (WHO) 2022 verilerine göre [15] dünya genelinde toplamda 1.3 milyon kişi tüberküloz sebebiyle hayatını kaybetti. WHO tarafından COVID-19'dan sonra en öldürücü bulaşıcı hastalık olarak kabul edilen tüberküloz 2022 yılında dünya genelinde 5.8 milyon erkek, 3.5 milyon kadın ve 1.3 milyon çocuk olmak üzere toplamda 10.6 milyon kişiyi etkilemiştir. Tedavi edilebilir ve önlenabilir bir hastalık olmasına rağmen 2022 yılında her 5 kişiden yalnızca 2'si tedaviye erişebildi. Dünya Sağlık Örgütü'nün yürüttüğü küresel çabalar sayesinde 2000 yılından bu yana tahminen 75 milyon kişi bu hastalıkla mücadelede iyileşmeyi başardı.

Birleşmiş Milletler Sürdürülebilir Kalkınma Hedefleri kapsamında 2030 yılına kadar tüberküloz salgınının tamamen ortadan kaldırılması hedeflenmiştir. Ancak bu hedefin gerçekleştirilebilmesi için her yıl yaklaşık 15 milyar dolarlık bir finansman ihtiyacının bulunduğu belirtilmektedir [15]. Tıbbi kaynaklar, maddi imkanlar ve insan gücü konusundaki yetersizlikler küresel ölçekte önemli bir sorun teşkil eden bulaşıcı hastalıkların tanı ve önleme süreçlerinde farklı teknolojik çözümlere duyulan ihtiyacı açıkça ortaya koymaktadır. Bu doğrultuda söz konusu ihtiyaçların yeni teknolojiler özellikle yapay zekâ tabanlı analiz ve görüntü işleme araçlarının geliştirilmesi yoluyla karşılanması amaçlanmaktadır.

Görüntü işleme için temel makine öğrenmesi yöntemleri ve daha ileri seviye olan derin öğrenme teknikleri olmak üzere farklı yapay zekâ tabanlı metotlar kullanılmaktadır. Verilerin analiz yöntemleri bakımından farklılık gösteren bu metotlar görüntü üzerindeki bilgileri öğrenmek ve bunları sınıflandırmak üzere tasarlanmıştır. Sınıflandırma problemlerinde kullanılan temel makine öğrenmesi modelleri görüntü üzerindeki bilgiyi dışarıdan bir uzmanın yardımıyla öğrenir. Derin öğrenme modelleri ise kendi kendine öğrenebilen ve

kararlar alabilen bir yapı sunduğundan dolayı özellikle büyük veri setlerinde daha elverişlidir [16]. Görüntü işleme için yaygın olarak derin öğrenme tekniklerinden biri olan Evrişimli Sinir Ağları (ESA) kullanılır. ESA'lar tüberküloz gibi tanı koymanın zor olduğu hastalıklarda uzman hekimlerin tanı süreçlerine destek olmak için çeşitli yapay zekâ modellerinin geliştirilmesini sağlamıştır. Son yıllarda yapılan çalışmalar ESA'ların evrişim işlemleri ile görüntüdeki detayları çıkarmada diğer makine öğrenimi modellerine göre daha efektif sonuçlar ürettiğini ortaya koymaktadır.

Sınıflandırma modellerinde performansı artırmak için veri setlerini hazırlamak ve model ile uyumlu hale getirmek oldukça önemlidir. Bunun için kullanılan ön işleme ve optimizasyon yöntemlerinin etkili bir şekilde seçilmesi gerekir. Görüntü verilerinde resimlerin kontrastını artırmak en önemli ön işleme adımlarından biridir. Bunun için normalizasyon teknikleri kullanılır ve görüntüdeki hedef piksellerin ön plana çıkması sağlanır. Veri örneklerindeki ayrıntıları ön plana çıkardıktan sonra ESA modelinin de bu özellikleri öğrenme kapasitesi geliştirilmelidir. ESA'larda özellik çıkarıcı olarak evrişim katmanları bulunur. Evrişim katmanlarının sayısını doğrudan artırmak yerine hibrit evrişim blokları geliştirmek parametre sayısını çoğaltmadan öğrenme işleminin gerçekleşmesini sağlar.

Bu tez kapsamında, ESA tabanlı DenseNet201 modeli kullanılarak akciğerlere ait X-ışını görüntüleri tüberküloz ve normal olarak sınıflandırılmıştır. Önerilen yaklaşımlar klasik optimizasyon yöntemleri olan veri artırımı ve normalizasyon işlemlerine ek olarak öğrenme süreçlerini daha efektif bir hale getirmek için mevcut DenseNet201 modelinin hibrit evrişim katmanıyla optimize edilmesini amaçlar. Çalışma farklı veri setleri kullanılarak gerçekleştirilmiş ve önerilen yöntemlerin veri setine bağlılığı araştırılmıştır. Tez çalışmasından elde edilen çıktılar karşılaştırıldığında, sonuçların yüksek enerji fizikçi uygulamalarına da katkı sunması hedeflenmektedir.

Tezin genel bölümünde ilk olarak elektromanyetik dalgaların yapısından ve bunların tıbbi görüntüleme alanındaki kullanımından bahsedilecektir. Ardından makine öğrenmesi modellerinin işleyişi ve veri setine bağlı olarak geliştirilen öğrenme yöntemleri açıklanacaktır. Bu yöntemlerin temel makine öğrenmesi algoritmaları ile olan ilişkisi detaylandırılacaktır. Sonraki kısım yapay sinir ağlarının genel yapısı ve evrişimli sinir ağlarını içermektedir. ESA'ların katman yapısı ve bu katmanların işleyişinden detaylı olarak bahsedilecektir. Son olarak model performansını değerlendiren metrikler açıklanacaktır.

Malzeme ve yöntem bölümünde tez kapsamında kullanılan halka açık veri setleri ve veri ön işleme adımları açıklanacaktır. Ardından DenseNet201 modelinin özel katmanları ve tez kapsamındaki kullanımı sunulacaktır. Sonraki kısımda çalışmanın hiperparametrelerinden detaylı bir şekilde bahsedilecektir. Bulgular kısmında veri setlerinin altı farklı durum için sonuçları karşılaştırmalı olarak incelenecektir. Tezin son kısmında ise elde edilen sonuçlar yorumlanacak ve literatüre olan katkısı tartışılacaktır.



2. GENEL KISIMLAR

Bu bölümde, tez kapsamında elektromanyetik dalga çeşitlerinden biri olan X-ışınları kullanılarak elde edilen görüntüler analiz edileceği için öncelikle elektromanyetik dalgaların keşfi ve bu dalgaların tıbbi görüntüleme alanındaki uygulamaları ele alınacaktır. Ardından tez çalışmasında kullanılan yöntemler ve teknikler ayrıntılı bir şekilde açıklanacaktır. Son olarak elde edilen bulguların değerlendirilmesinde kullanılan temel kavramlar üzerinde durulacak ve bu kavramların sonuçların analizindeki rolü tartışılacaktır.

2.1. ELEKTROMANYETİK DALGALAR

Elektromanyetik dalgalar elektrik yüküne sahip parçacıkların ivmeli hareketinden oluşan enine dalgalar olarak tanımlanırlar. Bu ışınlar boşlukta ışık hızı denilen saniyede 3×10^8 m/s'lik bir hızla ilerlerler [17]. Bir çeşit iletim kaynağı olan elektromanyetik ışınlar dalgaının sahip olduğu dalga uzunluğuna ve frekansına bağlı olarak farklı miktarda enerji taşırlar. Frekans, birim zamanda tekrarlayan dalga sayısıdır. Frekans arttıkça dalga boyunun uzunluğu azalır ve bu sebeple dalgaının enerjisi artar.

Elektromanyetik alan, elektrik ve manyetik alan bileşenlerinin bileşkesi olarak tanımlanan bir kuvvet alanıdır. Bu alan elektrik alan (E) ve manyetik alanın (B) birbirine dik doğrultuda olduğu elektromanyetik dalgaların taşınmasını sağlar. Elektrik ve manyetik alanlar ilk kez Clerk Maxwell tarafından elektromanyetizma yasaları olarak bilinen yasalar ile açıklanmıştır [18]. Buna göre elektrik ve manyetik alan bileşenlerinin var olabilmesi için ortamda hareketli bir elektriksel yükün olması gerekir. Temel olarak durgun bir elektrik yükü kendi elektrik alanına sahiptir ancak ivmeli bir hareketten sonra bu yük aynı zamanda bir manyetik alana da sahip olur [19]. Birinci ve dördüncü Maxwell yasaları bu ilişkiyi Denklem 2.1 ve Denklem 2.2'de verilen şekilde açıklamaktadır.

Denklem 2.1 birinci Maxwell yasasıdır. Gauss yasası olarak da bilinir ve bir yüzeyden geçen elektrik alan çizgilerinin elektrik akısı bağlamında toplam yük yoğunluğuyla ilişkili olduğunu söyler. Yük yoğunluğu (ρ) arttıkça elektrik alan (E) da artar. Boşluktaki elektriksel

permitivite sabiti (ϵ_0) ise bir malzemenin elektriksel özelliklerini ve malzemenin içindeki elektrik alanın yayılma hızının bir ölçüsüdür. Denklem, bir elektrik yükünün etrafındaki elektrik alanın nasıl oluştuğunu gösterir [20].


$$\nabla \times \mathbf{E} = \frac{\rho}{\epsilon_0} \quad (2.1)$$

$$\nabla \times \mathbf{B} = \mu_0 \mathbf{J} + \mu_0 \epsilon_0 \frac{\partial \mathbf{E}}{\partial t} \quad (2.2)$$

Denklem 2.2 Amper - Maxwell yasasıdır ve iki farklı manyetik alan kaynağı tanımlar. Amper yasasına göre denklemdeki ilk terim olan $\mu_0 \mathbf{J}$ elektrik akımının manyetik alanlar oluşturduğunu ifade eder. Burada μ_0 manyetik geçirgenlik sabiti, $\mathbf{J}$ ise elektrik akım yoğunluğunu temsil eder. Maxwell, bu ifadeyi $\mu_0 \epsilon_0 \frac{\partial \mathbf{E}}{\partial t}$ terimiyle genişletmiştir. Bu terim zamanla değişen elektrik alanların ($\frac{\partial \mathbf{E}}{\partial t}$) da manyetik alan oluşturduğunu gösterir; burada ϵ_0 , elektriksel geçirgenlik sabitidir. Maxwell $\mathbf{J}$ terimini yer değiştirme akımı olarak adlandırmıştır. Elektromanyetik dalgaların oluşumu ve yayılımı elektromanyetizmanın açıklanan Amper - Maxwell yasası ile ifade edilir [21].

Elektromanyetik dalgalar, elektromanyetik spektrumun farklı bölümlerinde yer alan farklı dalga boylarına ve frekanslara sahip olabilirler. Dalga boyları Şekil 2.1’de görüldüğü gibi iki dalga tepesi arasındaki mesafeyi tanımlar ve genellikle metre cinsinden ifade edilir. Elektromanyetizmada elektromanyetik ışınların karakteristiğini belirleyen büyüklükler olarak bilinir. Kısa dalga boyuna sahip dalgalar yüksek enerjiye, uzun dalga boyuna sahip dalgalar ise düşük enerjiye sahiptir [22]. Denklem 2.3’de gösterildiği gibi dalga hızının dalga frekansına oranı o dalgaya ait dalga boyunun büyüklüğünü verir. Bu dalgalar madde ile etkileştiklerinde dalga boyunun büyüklüğüne göre madde içinde sönümlenirler.


$$\lambda = \frac{c}{f} \quad (2.3)$$



Şekil 2.1: Elektromanyetik Dalganın Elektrik ve Manyetik Alan Bileşenleri [1]

Şekil 2.2’de foton enerjisinin dalga boyu ile olan ilişkisine bağlı olarak elde edilen elektromanyetik spektrum verilmiştir. Bir dalganın sahip olduğu enerji h Planck sabiti denilen fotonların taşıdığı enerji ve dalga frekansının arasındaki ilişkiyi ifade etmek için kullanılan büyüklükle hesaplanır. Birimi elektron volt cinsinden ifade edilir. Max Planck tarafından 1900’lerde hesaplanmıştır ve evrendeki temel büyüklüklerden biridir [23]. Denklem 2.4 bir fotonun enerjisinin ona eşlik eden elektromanyetik dalganın dalga boyu ile ters orantılı olduğunu göstermektedir.

$$E = \frac{hc}{\lambda} \quad (2.4)$$



Şekil 2.2: Elektromanyetik Spektrum [2]

Elektromanyetik spektrum, farklı dalga boyları ve frekanslara sahip geniş bir aralığı kapsar. Radyo dalgaları en düşük frekansa ve en uzun dalga boyuna sahiptir, genellikle frekansları 3 kHz ile 300 GHz arasındadır (10^3 Hz ile 10^{11} Hz). Görünür ışık bölgesi, insan gözünün algılayabildiği renklerin yer aldığı bölümdür ve dalga boyları yaklaşık 400 nanometreden (mavi) 700 nanometreye (kırmızı) kadar değişir. X ışınları, yüksek enerjili elektromanyetik dalgaları ifade eder ve frekansları 10^{16} Hz ile 10^{19} Hz arasında değişir. Gama ışınları ise en yüksek frekansa ve en kısa dalga boylarına sahiptir, frekansları 10^{19} Hz ile 10^{22} Hz arasındadır [2].

Bu tez çalışmasında, akciğerlere ait X-ışını görüntüleri kullanılmıştır. Görüntüleme teknikleri hakkında detaylı bilgi Bölüm 2.2’de açıklanacaktır.

2.2. TIBBİ GÖRÜNTÜLEME YÖNTEMLERİ

Günümüzde kullanılan tıbbi görüntüleme yöntemlerinin temelinde modern fiziğin kilometre taşlarından biri olmuş elektromanyetik dalgaların keşfi yatmaktadır. Teknolojinin gelişmesiyle fizik alanında kaydedilen ilerlemeler zamanla farklı disiplinlerde de kendine yer bulmuştur. Özellikle sağlık alanındaki gelişmelere sunduğu katkılar modern tıbbın gelişmesinde büyük rol oynamıştır. Örnek olarak tıbbi görüntüleme sistemlerindeki ilerlemeler bu gelişmelerden biridir. Günümüzde kullanılan tıbbi görüntüleme metodlarının temelinde elektromanyetik ışınlar vardır ve bu ışınların özellikleri kullanılarak farklı görüntüleme yöntemleri geliştirilmiştir. Bu bölümde en yaygın kullanılan görüntüleme tekniklerinden Röntgen (X-ışınları) ile görüntüleme, Bilgisayarlı Görüntüleme (BT) ve Manyetik Rezonans Görüntüleme (MRI) metodları açıklanacaktır.


2.2.1. Röntgen (X-Işını)

Elektromanyetik ışınların sağlık alanındaki ilk önemli uygulamalarından biri olan X-ışınları 1895 yılında Wilhelm Conrad Röntgen'in keşfiyle hayatımıza girmiştir [24]. Bu keşfin temelinde Röntgen'in deneylerinde kullandığı ve 1870'lerde William Crookes tarafından geliştirilen Crookes tüpleri yer almaktadır [25]. Röntgen, Crookes tüpleri ile yaptığı çalışmalar sırasında tüpten yayılan yüksek enerjili ışınların floresan özellikteki bir ekranın yüzeyindeki materyalle etkileşerek parıltılar oluşturduğunu gözlemlemiştir. Röntgen başlangıçta tanımlayamadığı bu ışınları "X-ışını" adını vermiştir.

Şekil 2.3'de X-ışını üretici olan X-ışını tüpünün yapısı gösterilmiştir. X-ışınları bir katot tüpünde katot (pozitif elektrot) ile anot (negatif elektrot) arasına uygulanan yüksek voltajın etkisiyle oluşur. Katotta bulunan tungsten flaman bir elektrik akımı sayesinde akkor haline getirilerek elektron yayması sağlanır. Bu elektronlar yüksek gerilim altında hızlanarak anottaki metal hedefe çarptırılır ve foton yayınlanır. Yayınlanan fotonlar elektronların metal yüzeye enerji aktararak metalde bulunan serbest elektronları koparmasına ve bu sırada bir ışıma yapmasına neden olur. Bu ışıma X-ışınması olarak adlandırılır [26].

Elektronların tungsten flamanından yayılması transformatörden gelen elektrik akımıyla doğru orantılıdır. Elektrik akımı sayesinde flaman ısınır ve tungsten atomlarının serbest haldeki elektronlarının enerjisi artar. Artan enerji elektronların maddeyi terk ederek flaman etrafında bir elektron demeti oluşturmaya neden olur. Bu süreç termiyonik emisyon olarak


adlandırılır ve X-ışınlarının enerjisini belirleyen bir etkiye sahiptir [26].



Şekil 2.3: X-Işını Tüpü [3]

X-ışınları 0.01-10 nm aralığında dalga boyuna sahiptir ve tıbbi görüntülemeler için kullanılan en yaygın ışın türüdür. Küçük dalga boyuna ve dolayısıyla yüksek enerjiye sahip olduğu için madde ile etkileşiminde oldukça girici özellik gösterir ve bu onları insan vücudundan kolayca geçebilir hale getirir. X-ışınları geçtiği dokulardaki atomların yörüngelerindeki serbest elektronları kopararak enerjilerini kaybederler. Bu enerji kaybı X-ışınlarının etkileşime girdikleri atomların elektron bağlanma enerjisini nötralize etmeleri sonucunda gerçekleşir. Bu süreçte ışınlar dokudan geçerken farklı miktarlarda sönümlenir. Sönümlenme miktarı görüntüdeki yumuşak ve sert dokuların birbirinden ayırt edilmesini sağlar. Görüntüdeki bu farklılıklar X-ışınlarının giricilik yani penetrasyon özelliği sayesinde oluşur. Maddenin yoğunluğu ve kalınlığı arttıkça X-ışınının penetrasyon özelliği azalır. Bir ışının penetrasyon yeteneği geçtiği maddenin atom yapısına, maddenin kalınlığına ve yoğunluğuna bağlı olarak değişir. Dalga boyu kısa olan ışınların penetrasyon özelliği yüksektir.

Şekil 2.4'te X-ışını görüntüsü elde etmenin temel bir şeması görülmektedir. Kaynaktan gelen X-ışını demeti belirlenen açıda toplanır ve hasta üzerine gönderilir. İnsan dokusundan geçen ışınların bıraktığı enerji bir dedektör tarafından toplanır. Görüntünün kontrastını artırmak için dedektörün önüne ayrıca bir toplayıcı ızgara yerleştirilir. X-ışınlarının sönümlenen enerjisine göre yumuşak ve sert dokulardan elde edilen parlak ve koyu bölgeler içeren bir görüntü oluşur. Bu görüntü ilgili dokunun X-ışınları ile elde edilmiş görüntüsüdür.




Şekil 2.4: X-ışını Görüntüleme Sistemi [4]

2.2.2. Bilgisayarlı Görüntüleme (BT)

Bilgisayarlı görüntüleme sistemi 1960'ların başında Allan MacLeod Cormack tarafından önerilmiştir [27]. İlerleyen yıllarda Godfrey Hounsfield ile birlikte X-ışınlarını temel alan bilgisayarlı tomografi cihazını geliştirmişlerdir. Yaptıkları bu çalışmayla 1979 yılında her iki bilim insanı da Nobel Fizyoloji veya Tıp ödülüne layık görülmüştür [28].

Düzlemsel olarak elde edilen görüntülerde üst üste binmiş dokuların analizi sınırlıdır. Bu yüzden farklı açılardan elde edilen çok boyutlu bir tarama bölütsel bir görüntüleme yapabilme olanağı sağlar. BT'de en önemli avantaj görüntünün katmanlara ayrılması ve görüntü hakkında en az kayıpla bilgi edinilebilmesidir. İki boyutlu X-ışını görüntülerini kullanarak nesneye ait üç boyutlu yapının görüntüsünü inşa etmek üzere tasarlanmıştır. Dokunun etrafında dairesel bir yörüngede ilerleyerek farklı açılardan düzlemsel görüntüler elde eder, ardından bu görüntüler birleşir ve işlenebilir hale getirilir.

Şekil 2.5'de BT çalışma prensibi gösterilmiştir. Bilgisayarlı tomografi uygulaması esnasında hasta, dedektör ve X ışını kaynağı arasına yerleştirilir. X ışını kaynağı ve dedektör belirlenen açılarla sarmal bir tarama yolunu izleyerek hasta etrafında döndürülür. X-ışını dedektörü dokudan geri yansıyan ışınların enerjilerini algılayarak bunları bilgisayar aracılığıyla birer görüntüye dönüştürür.



Şekil 2.5: BT Çalışma Prensibi [4]

2.2.3. Manyetik Rezonans Görüntüleme (MRI)


İlk kez 1980’lerde kullanılmaya başlanan manyetik rezonans görüntüleme sistemleri, manyetik alan ve radyo dalgaları sayesinde dokunun segmente görüntülerinin elde edilip kat kat birleştirilmesi prensibiyle çalışır. Görüntüyü elde etmek için dokudaki hidrojen atomlarına belirli enerjilerde radyo dalgaları gönderilerek atomların ilk konumlarından sapmaları sağlanır. Radyo frekansı kesildikten sonra atomların ilk konumlarına dönerken yayınladıkları fazla enerji alıcılar tarafından toplanarak bilgisayarda görüntü elde edilir. Hidrojen atomlarını hizalamak için manyetik alana ihtiyaç vardır ve bunun için süper iletken mıknatıslar kullanılır. Uygulanan manyetik alan başlangıçta radyo dalgalarına duyarlı olan insan dokusunu bu dalgalara duyarlı hale getirir [4].

Hidrojen protonları tıpkı gezegenler gibi kendi etrafında dönerler. Pozitif elektriksel yüke sahip oldukları için dönüşten kaynaklanan bir manyetik alan oluştururlar ve küçük birer mıknatıs gibi davranırlar. Normal koşullar altında vücutta bulunan hidrojen atomlarının protonları rastgele dağılmış şekilde bulunur. Tekdüze bir hizalama oluşturmak için protonların bir manyetik alana maruz kalması gerekir. Bu sebeple vücut MRI tarayıcısı gibi güçlü bir manyetik alana yerleştirildiğinde protonların eksenleri aynı hizaya gelir. Bu sayede MRI tarayıcısının yatay eksenini boyunca yönlendirilmiş manyetik bir vektör elde edilir. MRI tarayıcılarının manyetik alan güçleri genellikle 0,5 ile 1,5 Tesla arasında bir değere sahiptir.

Manyetik alanın enerjisi radyo dalgaları ile artırıldığında oluşturulan bu manyetik vektör eksen hizasından saptırılır. Hidrojen çekirdeklerinin rezonansa girmesine neden olan radyo

dalgası frekansı (RF), aranan elemente (bu durumda hidrojen) ve manyetik alanın gücüne bağlıdır.

Şekil 2.6’da MRI sisteminin temel çalışma şeması verilmiştir. Manyetik alanın gücü cihazda bulunan gradyan elektrik bobinleri aracılığıyla elektronik olarak ayarlanabilir. Bu bobinler manyetik alanın gücünü değiştirerek vücudun farklı bölgelerini hedef alır. Bu değişiklikler sayesinde belirli frekanslar uygulandığında vücudun farklı dilimleri rezonansa girer. Bu rezonans MRI cihazının vücudun belirli kesitlerinden ayrıntılı görüntüler elde etmesine olanak tanır. Radyofrekans kaynağının etkisi ortadan kalkınca protonların hizalanmasıyla oluşan manyetik vektör eski durumuna geri döner. Bu dönüş radyo dalgası olarak da adlandırılan bir sinyalin yayılmasına neden olur. MRI görüntülerini oluşturmak için kullanılan sinyal ise budur. Bu sinyalin tespiti ve kalitesini artırmak için alıcı bobinler ilgili vücut bölgesinin etrafında anten gibi yerleştirilir. Alınan sinyalin yoğunluğu daha sonra gri tonlamayla görüntülenir ve böylece vücudun kesit görüntüleri oluşturulur [29].



Şekil 2.6: MRI Sistemi [5]

2.3. MAKİNE ÖĞRENMESİ

Makine öğrenmesi kavramı ilk kez 1950'lerde bilgisayar bilimci ve matematikçi Alan Turing tarafından insan gibi düşünebilen bilgisayarlar fikriyle ortaya atılmıştır [30]. Aynı yıllarda yine matematikçi ve bilgisayar bilimci olan Arthur Samuel'in geliştirdiği dama oynama programı sayesinde dönemin oldukça popüler ve ilgi çekici konularından biri olmuştur. Samuel'in programı, dama oyunu boyunca programın yaptığı hataları güncellediği ve geçmiş hamlelerinden çıkarımlar yapabildiğinden ilk kez kendi kendine öğrenen bir algoritma olarak da bugün bilinen makine öğrenmesi modellerinin temeli olarak kabul edilir [30]. Günümüzde ise makine öğrenmesi, algoritmaların veri setleri üzerinden anlamlı bilgi çıkarımı yapması, bu bilgileri bir bütün haline getirip yeni bilgiler öğrenmesi ve kendini sürekli optimize etmesi süreci olarak tanımlanmaktadır. Makine öğrenmesi algoritmaları istatistiksel yaklaşımları merkeze alarak gerçek dünya verilerini modellemeyi mümkün kılmıştır.

Temel bir makine öğrenmesi modelinin görevi veri setindeki kural ve örüntüleri en iyi ifade eden hedef fonksiyonunu $f(x)$ bulmaktır [31]. Hedef fonksiyonları veri setinin cebirsel bir ifadesi olarak düşünülebilir. Eğitim verisi adı verilen bir veri kümesiyle modeller eğitilerek veriler arasındaki ilişki ağını temsil eden ve $\hat{y} = f(x) + e$ olarak ifade edilen bir hedef fonksiyonu elde edilir. Bu fonksiyon doğrulama verisi adındaki farklı bir veri kümesi üzerinden doğrulanır. Sonuçlar tatmin edici ise modelin, bu hedef fonksiyonu ile hiç görmediği başka bir veri kümesi üzerinden de yüksek doğrulukta tahminler yapabileceği anlamına gelir. Denklemdaki (e) modelin hata payını temsil eder. Hata payı ne kadar düşükse modelin o kadar başarılı olduğu kabul edilir. Algoritma gelecekteki her yeni x girdi değeri için $\hat{y}$ tahmin çıktısı elde ederken öğrendiği bu hedef fonksiyonunu baz alır.

2.3.1. Makine Öğrenmesi Yöntemleri

Makine öğrenmesi modelleri sınıflandırma veya regresyon problemlerinde kullanılmak üzere farklı istatistiksel metotlara göre tasarlanmıştır. Sıklıkla kullanılan makine öğrenmesi algoritmaları şunlardır; karar ağaçları, lojistik regresyon, k-ortalama, destek vektör makineleri, k-en yakın komşu algoritmaları ve yapay sinir ağları. Bu teknikler istatistiksel yaklaşımlarına göre regresyon, kümeleme ve sınıflandırma olarak ayrılırlar. Bu istatistiksel yaklaşımların öğrenme stratejileri ise denetimli, denetimsiz ve pekiştirmeli öğrenme olarak üç başlık altında incelenir. Öğrenme stratejileri ve makine öğrenmesi teknikleri ilerleyen

bölümlerde açıklanacaktır.

2.3.1.1. Denetimli Öğrenme

Denetimli öğrenme, bir makine öğrenmesi modelinin etiketlenmiş veri setiyle eğitilmesiyle gerçekleşir. Etiketlenmiş veriler her bir verinin gerçek değerinin önceden bilindiği verilerdir. Model veri seti hakkında genel hipotezler üretebilmek için gerçek etiket bilgisiyle eğitilir, diğer bir deyişle algoritmaya dışarıdan bilgi verilir. Örneğin hangi akciğer sağlıklı hangileri sağlıklı değil şeklinde derlenmiş bir klinik veri bu işe yarar. Algoritma bir uzman tarafından derlenmiş verilerden öğrenir ve kendisine verilen yeni bir veri üzerinden tahmin yapar [32]. Denklem 2.5’de denetimli öğrenme ile eğitilen modellerin tahmin çıktılarını ifade eden temel formülasyon verilmiştir.

$$\hat{y} = X \cdot \theta \quad (2.5)$$

Denklemdaki X özellik matrisidir. Denkleme göre modele girdi olarak verilecek özellikler, özellik matrisi X tarafından temsil edilir. Burada sütunlar özellikleri temsil eder ve satırlar veri setindeki her bir veri noktasına karşılık gelir. m özellik ve n veri noktası ile, X ’in boyutları $n \times m$ ’dir. Etiketler her bir veri noktasına karşılık gelen $\hat{y}$ vektörü tarafından temsil edilir (boyut $n \times 1$). Ve her bir özelliğin model ağırlıkları (veya önemi), θ vektörü tarafından ifade edilir (boyut $m \times 1$). Aşağıdaki matris işleminde hedef çıktılarının ağırlık ve özellik matrisi ile olan ilişkisi verilmiştir. Özellikler birer önem derecesi ile ilişkilendirilerek ağırlık değeri hesaplanır. Bu değerler hedef çıktının sınıflandırılmasını sağlayan belirleyicilerdir.

$$\begin{pmatrix} \hat{y}_1 \\ \hat{y}_2 \\ \hat{y}_3 \\ \vdots \\ \hat{y}_n \end{pmatrix} = \begin{pmatrix} x_{1,1} & x_{1,2} & x_{1,3} & \dots & x_{1,m} \\ x_{2,1} & x_{2,2} & x_{2,3} & \dots & x_{2,m} \\ x_{3,1} & x_{3,2} & x_{3,3} & \dots & x_{3,m} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{n,1} & x_{n,2} & x_{n,3} & \dots & x_{n,m} \end{pmatrix} \times \begin{pmatrix} \theta_1 \\ \theta_2 \\ \theta_3 \\ \vdots \\ \theta_m \end{pmatrix}$$

Modelin başarısı, denetimli öğrenme yoluyla eğitim yapıldıktan sonra test başarısı baz alınarak değerlendirilir. Gerçek değerler ve tahmin sonuçları arasındaki fark modelin

hata payını hesaplamayı sağlar. Düşük bir hata oranı modelin eğitim sırasında kayıp fonksiyonunun etkili bir şekilde minimize edildiğini ve dolayısıyla daha başarılı bir genel performans sergilediğini gösterir. Denetimli öğrenme sürecinde, kayıp fonksiyonunu minimize eden optimal model parametrelerini temsilen θ değerlerinin bulunması amaçlanır.

Denetimli öğrenme modelin tahmin etmeye çalıştığı ana değişken olan bağımlı değişkenin sürekli veya kategorik olmasına göre iki gruba ayrılır. Sürekli değişkenler, belirli bir aralıkta sonsuz sayıda değere sahip olabilir (örneğin, yaş, gelir gibi sayısal veriler), kategorik değişkenler ise sınırlı sayıda belirli kategorilere ayrılır (örneğin, cinsiyet veya renk gibi sınıflandırmalar). Sürekli değişkenler regresyon problemleri olarak bilinir. Kategorik değişkenler ise, etiket bilgisi kategorik bir değişkendir, sınıflandırma problemi olarak ele alınır.

2.3.1.2. Denetimsiz Öğrenme

İnsan gözetiminin olmadığı ve veri setinin etiketlenmediği durumda modeller denetimsiz öğrenme yoluyla eğitilir. Denetimsiz öğrenmede veri setindeki örüntülerin model tarafından keşfedilmesi ve genelleştirilmesi sağlanır. Hedef değişkenlerin $\hat{y}$ değerleri bilinmediği için eğitim boyunca hangi özelliklerin ne kadarlık bir ağırlığa θ (öneme) sahip olacağı hesaplanır. Bu aynı zamanda veri setindeki kalıpları veya sınıfsal özellik temsillerini ifade eder [33].


2.3.1.3. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenmede, bir makine öğrenmesi algoritmasının deneme-yanılma yoluyla hedef çıktıyı elde etmesi sağlanır. Denetimli öğrenme yöntemiyle benzer şekilde girdinin gerçek değeri ile tahmin çıktısı arasındaki ilişkiyi anlayan bir yol izler. Elde edilen çıkış bilgisi ile verilen giriş bilgisi arasında bir karşılaştırma yapar ve sonuç yanlış olarak üretildiyse eğitim devam eder. Denetimli ve denetimsiz öğrenme metodlarından farklı olarak pekiştirmeli öğrenmede eğitim ve test eş zamanlı yapılır. En iyi sonuçları elde edene kadar eğitim devam eder. Temel bir şekilde, bu kapalı-döngü problemleridir çünkü öğrenme sisteminin eylemleri sonraki girişlerini etkiler. Çalışma prensibi olarak insan beynini taklit eden bir öğrenme yöntemidir. Herhangi bir eğitim işlemi olmadan ürettiği çıktıların gerçek değerlerle olan ilişkisinden yola çıkarak veriye uyum sağlar.

Pekiştirmeli öğrenme terminolojisinde yer alan kavramların kullanım şeması Şekil 2.7’de verilmiştir. Bu yaklaşımda, öğrenen makine ya da ajan karşılaştığı durumlara tepki verir ve

bu tepkilerin sonucunda sayısal bir ödül alır. Amaç bu ödül sinyalini maksimize etmektir. Ajan çevresine bağlı olarak bir eylem gerçekleştirir ve ardından çevreden bir tepki bekler. Bu tepkiler önceden belirlenmiş bir ödül sistemine tabi tutulur. Elde edilen ödüle göre ajan eğitilir ve yaptığı eylemlerin doğruluğunu değerlendirir. Bu şekilde pekiştirmeli öğrenme modeli hedefe yönelik en iyi eylemleri öğrenmeyi sağlar [34].

Pekiştirmeli Öğrenme



Şekil 2.7: Pekiştirmeli Öğrenme Şeması [6]

2.3.2. Temel Makine Öğrenmesi Algoritmaları

Makine öğrenmesi problemleri sınıflandırma, regresyon ve kümeleme olarak üç başlık altında incelenir. Eğer veri setindeki sürekli değişkenler tahmin ediliyorsa bu bir regresyon problemidir. Veri seti sınıflara ayrılıyorsa bunlar sınıflandırma problemleri olarak ifade edilir. Eğer veri seti hakkında bilgi yoksa ve modelin veri setiyle ilgili örüntüyü keşfetmesi bekleniyorsa bunlar kümeleme problemleri olarak ele alınır. Bu bölümde regresyon, kümeleme ve sınıflandırma algoritmalarının detaylarından bahsedilecektir.

2.3.2.1. Regresyon Algoritmaları

Bağımlı değişkenin sürekli olduğu problemlerde bir veya daha fazla bağımsız değişken arasındaki ilişkiyi modellemek için regresyon algoritmaları kullanılır. Regresyon modelleri bağımsız değişkenlerin etkilerini ölçmek için ağırlıkları belirlemeyi amaçlayan bir mimariye sahiptir [35]. Bu ağırlıklar, modelin tahmin yeteneğinin gelişmesinde oldukça önemlidir.

Regresyon modelleri denetimli öğrenme yoluyla öğrenmektedir. Örnek olarak regresyon problemleri arasında sıcaklık tahminleri, gelir tahminleri ve fiyat tahminleri sayılabilir. Doğrusal regresyon, polinomial regresyon ve destek vektör regresyonu en çok bilinen regresyon modelleridir.

Bağımlı ve bağımsız değişkenler arasındaki ilişkiyi modellemek için en sık kullanılan model ise doğrusal regresyondur [36]. Doğrusal regresyonun amacı Denklem 2.6'da verildiği gibi θ katsayılarını belirlemek ve böylece Y bağımlı değişkeninin X bağımsız değişkenine göre nasıl değiştiğini tahmin etmektir. Buradaki katsayılar modelin her bir X değişkeni için hesaplanan ağırlık değerleridir ve yapılacak tahminler için baz alınır. Tahminlerin gerçek verilerle arasındaki fark modelin hata payını gösterir. Bu hata payını hesaplamak ve optimize etmek için genellikle ortalama kare hata metodu kullanılır. Denklem 2.7'de ortalama kare hata verilmiştir [37] n toplam veri sayısını, Y_i gerçek değeri, $\hat{Y}_i$ ise tahmin çıktısını temsil eder. Doğrusal regresyonda hedef ortalama kare hatayı minimize eden parametreleri bulmaktır. Hataların karelerini almak negatif değerlerden kurtulmayı ve büyük hataların daha fazla önemsenmesini ve optimize edilmesini sağlar.

$$Y = \theta_0 + \theta_1 X_1 + \theta_2 X_2 + \dots + \theta_n X_n + \varepsilon \quad (2.6)$$

$$\text{Ortalama Kare Hata} = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (2.7)$$

2.3.2.2. Kümeleme Algoritmaları

Veri setindeki hedef değişkenlerin bilinmediği durumda verileri korelasyon ilişkilerine göre sınıflandırmak için kümeleme algoritmaları kullanılır. Denetimsiz öğrenme yöntemiyle veri segmentasyonu yapılır ve veri seti belirli kalıplarla gruplara ayrılır [38]. Bu gruplar bir verinin diğer veri noktalarıyla ilişkisi baz alınarak oluşturulur. Kümeleme algoritmalarında ana hedef veri noktalarını sınıflandıracak ilişkileri belirlemektir. Örneğin geniş bir aralıkta sıcaklık değerleri içeren bir veri seti olsun. Model bu sıcaklık değerleri arasındaki ilişkiyi öğrenerek bu değerleri gruplandırabilir ve hangi mevsimleri temsil ettiğini tahmin edebilir.

K-ortalama kümeleme ve hiyerarşik kümeleme bu algoritma türüne örnek olarak verilebilir.

2.3.2.3. Sınıflandırma Algoritmaları

Sınıflandırma modelleri, veri örneklerini önceden belirlenmiş kategorilere atamak için tahmine dayalı olasılık hesaplamaları yapar. Sınıflandırıcılar denetimli öğrenme yoluyla eğitilir ve veri setinde hem bağımsız hem de bağımlı değişkenlerin olduğu durumda kullanılır. [39]. Sınıflandırıcı modellerde hedef, sınıfları tanımlayan özelliklerle sınıf etiketleri arasındaki ilişkiyi öğrenmek ve gelecekteki yeni bir veri kümesi için tahmin yapmaktır. Bu türdeki algoritmalar, çıkışları (Y) girişlere (X) eşler, burada $Y \in 1, \dots, C$ olup C sınıf sayısını temsil eder. Eğer $C = 2$ ise, buna ikili sınıflandırma denir ve eğer $C > 2$ ise bu, çoklu sınıflandırma olarak ifade edilir.

Yüksek enerji fiziği deneylerinde çarpışma sonucu oluşan jetlerin türlerinin sınıflandırılması, hastalık teşhisi ve istenmeyen postaları ayırt etme gibi uygulamalar sınıflandırmaya örnek verilebilir. En bilinen ve yaygın sınıflandırma algoritmaları arasında lojistik regresyon, karar ağacı sınıflandırıcısı, k-en yakın komşu ve destek vektör makineleri sayılabilir. Lojistik regresyon bir regresyon ismiyle bilinse de aslında tek katmanlı sinir ağı olarak en sık kullanılan sınıflandırma algoritmalarından biridir. Lojistik regresyonda çıktılar doğrusal regresyonda olduğu gibi üretilir fakat çıktı değerleri 0 ile 1 arasında sınıflandırma yapılacak şekilde birer olasılığa dönüştürülür.

$$h_{\theta}(x) = \sigma(z) = \frac{1}{1 + e^{-z}} \quad (2.8)$$

Denklem 2.8'de $z = \theta_0 + \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_n x_n = \theta^T x$ 'dir ve lojistik regresyon modelinin girdiler ve ağırlıklar arasında kurduğu doğrusal ilişkiyi ifade eder. θ , ağırlık değerleridir. Model bu doğrusal ilişkiyi tahmin yapmak için kullanır. Daha sonra bu doğrusallık sigmoid fonksiyonu olarak bilinen $\frac{1}{1+e^{-z}}$ ile birer olasılık değerine dönüştürülür. Ardından olasılık değeri $h_{\theta}(x)$ şeklinde bir çıktıyla ifade edilir. Lojistik regresyonun hedefi, girdilerle ilişkili en iyi θ parametrelerini hesaplamak ve bunları sınıflandırma için kullanmaktır. Sigmoid fonksiyonu bölüm 2.5.7'de ayrıntılı olarak açıklanmıştır.


2.4. YAPAY SİNİR AĞLARI

Son yıllarda bilgisayar teknolojilerindeki hızlı gelişim yapay zekâ tekniklerinin çeşitli alanlarda yaygın olarak kullanılmasına olanak sağlamaktadır. Özellikle görüntü işleme ve bilgisayarlı görü tekniklerinde makine öğrenmesi modellerine kıyasla Yapay Sinir Ağları (YSA) ile daha etkili sonuçlar elde edilmektedir. Sağlık sektöründe kullanılan X-ışını, MRI gibi medikal görüntüleme analizlerinde ise bu tekniklerin geliştirilmesi ve kullanımı önemli ölçüde artmıştır. YSA kullanılarak yapılan medikal görüntü analizlerinde hedef, insan öngörüsünün yetersiz veya eksik kaldığı alanlarda boşlukları doldurma amacıyla daha yüksek doğruluk ve hassasiyette teşhisler yapmaktır.

İnsan beyninin çalışma prensibini öğrenme, geliştirme ve değerlendirme olarak taklit eden yapay sinir ağları bu işlemleri cebirsel algoritmalar kullanarak yapar [40]. YSA'lar birbirine bağlı sinir hücrelerinden oluşan katmanlar halinde yapılandırılır ve bu katmanlar arasındaki bağlantılar θ denilen ağırlıklarla belirlenir. θ ağırlık değerleri katmanlar arasındaki bağlantı gücünü ve ağırlık taşıdığı bilgi miktarını belirtir [41]. Ağırlıkların ne kadar güncelleneceği öğrenme oranıyla ve nasıl güncelleneceği optimizasyon algoritmalarıyla tanımlanır. Bu parametrelerin seçimi önemlidir çünkü doğrudan ağırlık stabilizasyonunu ve tahmin sonuçlarının kesinliğini etkiler.

Optimizasyon algoritmaları, bir modelin öğrenme sürecini yöneten en önemli hiperparametrelerden biridir. Modelin gerçek değerler ve tahminler arasındaki hata payını minimum seviyeye indirmek için öğrenme sürecini düzenler. Bu algoritmaların temelinde kayıp fonksiyonundaki değişimi ifade eden gradyanlar bulunur ve gradyan iniş algoritması kullanılarak kayıp fonksiyonunu minimize edecek şekilde parametrelerin güncellenmesi sağlanır [42].

Derin öğrenme modellerinde parametre güncellemesi geriye yayılım işlemi ile yapılır. Şekil 2.8'de gradyan iniş algoritması ile kayıp fonksiyonu parametrelerinin (örneğin ağırlık) global minimum noktaya yakınsaması gösterilmiştir. Denklem 2.9'da gradyan iniş için parametrelerin nasıl güncellendiği açıklanmıştır. Geriye yayılım işleminde geriye doğru türev alınarak hata değerindeki fark hesaplanır ve bu değer öğrenme oranı parametresi ile çarpılır. Elde edilen sonuç ağırlık değerlerinden çıkarılarak yeni ağırlık değerleri hesaplanır.




Şekil 2.8: Gradyan İniş Algoritması [7]

$$\theta'_j := \theta_j - \alpha \frac{\partial J(\theta)}{\partial \theta_j} \quad (2.9)$$

Formülde α terimi öğrenme oranını ifade eder. Öğrenme oranı parametrelerin ne kadar hızlı güncelleneceğini ayarlar. θ_j modelin ağırlıklarıdır ve her biri için $J(\theta)$ 'nin θ_j 'ye göre türevi alınarak kayba olan etkisi hesaplanır. Türevin negatif olduğu durumlarda kayıp fonksiyonunun eğimi hızla azalır. Dolayısıyla gradyan iniş algoritması kaybı düşürmek için türevin negatif olduğu en büyük noktaya doğru ilerler. Bu bölge kaybın en küçük olduğu optimum değer olarak kabul edilir.

Sinir hücreleri gruplandıkça katmanlar oluşur. Bunlar veri giriş katmanı, gizli katmanlar ve çıktı katmanı olarak adlandırılır. Şekil 2.9'da sinir ağı mimarisi verilmiştir. Verilerin ağa girişi, gizli katmanlar aracılığıyla özellik temsillerinin çıkarılması ve nihai çıktıların üretilmesi aşamaları bu sinir ağı mimarisi kullanılarak elde edilir. Mimarinin katmanlardaki işleyişi aşağıda açıklanmıştır.

Veri giriş katmanı verilerin ağa girdi olarak sunulduğu başlangıç katmanıdır. Girdi katmanında bütün özellikler (x_n) bir nöron olarak ifade edilir. Başlangıçta her bir özellik için bu nöronlar ağırlıklandırılır. Ağırlıklandırma işlemi nöronun taşıdığı özellik bilgisinin ne kadar önemseneyeceğini belirler. Ağa gelen her yeni girdi verisi bu ağırlıklarla çarpılarak genelleştirici özelliklerin önemi artırılır [43].



Şekil 2.9: Sinir Ağı Mimarisi [8]

Girdi katmanında ağırlıklandırılan sinyaller gizli katmana iletilir. Gizli katmanlar her yeni giriş verisi için bu ağırlık değerlerini kullanarak girdiye ait özellikleri öğrenir. Yani giriş verisini temsil eden matris, ağırlık değerleri (θ) ile çarpılarak gizli katmanlardaki nöronların değerleri hesaplanır. Ardından bir aktivasyon fonksiyonu ile nöronun aktaracağı çıktı üretilir. Aktivasyon fonksiyonu, genellikle doğrusal olmayan bir fonksiyon olup modelin doğrusal olmayan ilişkileri öğrenmesini sağlar. Gizli katman ağı içsel işleyişini oluşturur ve girdi verilerinin karmaşık ilişkilerini öğrenmek için kullanılır [43].

Çıktı katmanı ağı nihai çıktıları üreten son katmandır. Her bir çıktı ağı sonucunu temsil eder. Örneğin bir sınıflandırma görevinde her bir çıktı sınıf etiketlerinden birine karşılık gelebilir. Çıkış katmanındaki aktivasyon fonksiyonu ikili veya çoklu sınıflandırma problemleri için farklılık gösterir. İkili sınıflandırmalar için tek nöron ile sigmoid fonksiyonu kullanılır. Çoklu sınıflandırma problemlerinde ise sınıf sayısı kadar nöronla softmax aktivasyon fonksiyonu kullanılmaktadır.

Standart yapay sinir ağlarında özellik çıkarımı ve ağırlıklandırma otomatik olarak yapılmaz. Bu nedenle ağı öğrenebilmesi için bir kullanıcı tarafından veri setinin özellikleri girdi katmanında belirlenir ve ağırlıklandırılır. Bu durum insan yapımı hatalara neden olabileceğinden geleneksel YSA'lar yerine özellik çıkarımını evrişim katmanlarıyla otomatik olarak yapan Evrişimli Sinir Ağları kullanılmaktadır.

2.5. EVRİŞİMLİ SINIR AĞLARI

Derin öğrenme modelleri yapay sinir ağlarında öne çıkan ağ türlerinden biridir ve birbiri ardına gelen ardışık katmanları ve hiyerarşik bir öğrenme yolunu ifade eder. Öğrenme işlemlerini insan müdahalesi gerektirmeden otomatik olarak yapabilme avantajını sunar. Bu avantajı en etkili şekilde kullanan modellerden biride görüntü verilerindeki örüntülerin keşfinde devrim yaratan Evrişimli Sinir Ağları (ESA)'dır [44].

Evrişimli sinir ağları peş peşe eklenmiş çok katmanlı derin sinir ağlarının görüntü analizleri için geliştirilmiş özel bir versiyonudur [45]. Evrişimli sinir ağlarında her katman verinin soyut bir temsilini öğrenirken, katmanlar ilerledikçe daha yüksek düzeyde özellikler öğrenilir. Bu yapısı sayesinde geleneksel makine öğrenmesi yöntemlerine göre daha büyük veri setleri ve karmaşık problemler üzerinde daha etkili sonuçlar verebilmektedir. Özellikle son yıllarda GPU'ların işlem gücündeki artış ve büyük veri kaynaklarının erişilebilirliği ESA'ların hızla gelişmesini ve popülerleşmesini sağlamıştır.

ESA mimarileri görsel nitelikler arasında bağ kurmaya ve buna göre sınıflandırma yapmayı amaçlar. Son yıllarda tıbbi görüntü analizi ve nesne tespiti gibi problemlerde gösterdiği başarısı sayesinde alanın ilerleyişine büyük bir katkı sağlamıştır. Görüntülerde insan gözüyle fark edilemeyen bilgileri öznitelikler olarak çıkarabilmesi ve bunu müdahale gerektirmeden yapabilmesi ESA mimarilerini önemli bir konuma taşımaktadır. Bu yüzden görüntü sınıflandırma işlemlerinde oldukça kullanışlı bir altyapı sunar.

Evrişimli ağlarda öznitelik çıkarımı iki farklı yoldan yapılabilir. İlk yol, ağın ağırlık matrislerini rastgele bir başlangıç değeriyle başlatarak veri setine özgü optimal ağırlıkları öğrenmesidir. Eğitim sürecinde ağırlıklar iteratif olarak güncellenir ve her iterasyonda kayıp fonksiyonu minimize edilerek optimum değerlere ulaşılır. İkinci yol, önceden eğitilmiş evrişimli sinir ağı modellerini kullanmaktır. Önceden eğitilmiş modeller Imagenet veri seti ile eğitilmiş modellerdir. Imagenet bilgisayarlı görü alanında sıkça kullanılan, 20 binden fazla kategoriye ve 14 milyondan fazla görüntüye sahip bir veri setidir. Önceden eğitilmiş ESA modelleri sınıf ağırlıklarını bilir ve bu ağırlıklar öznitelik çıkarma veya başka görevler için kullanılır. İlk yol veri seti yeterince büyük ve çeşitliyse kullanılabilir, ikinci yol ise derin sinir ağlarını eğitmek için yeterli sayıda veri olmadığı durumlarda tercih edilir.

ESA'lar, girdileri bazı evrişim filtreleri ile küçük parçalara bölen katmanlar içerirler ve

görüntülerdeki tüm özellikleri bulmak için farklı görevdeki katmanlarla sıralı bir ilişki kurarlar [46]. Girdi verisi ilk olarak girdi katmanı aracılığıyla ağa gelir ve sırasıyla evrişim, havuzlama ve tam bağlantı katmanından geçerek çıkış katmanında bir çıktı oluşturur.

Aşağıda Evrişimli Sinir Ağları'nda kullanılan temel katmanlar açıklanacaktır.

2.5.1. Girdi Katmanı

Girdi katmanı ağın başlangıç noktasıdır. Giriş verilerinin ayarlanmasını ve ağa sunulmasını sağlar. Görüntü sınıflandırma problemlerinde görüntünün boyutu ve kanal sayısı bu katmanda belirlenir. Kanal sayısı tek kanallı gri tonlamalı veya 3 kanallı RGB renkli görüntüler şeklinde olabilir. Bu tez çalışmasından gri tonlamalı yani tek kanallı ve 224×224 boyutunda olan görüntüler kullanılmış ve ağ boyunca ($224 \times 224 \times 1$) şeklinde bir tensör olarak iletilmiştir. Her bir görüntü için piksel sayısı $224 \times 224 \times 1 = 50176$ olur. Bu, her bir resmin 50176 pikselden oluştuğu anlamına gelir. Özellikle büyük veri setlerinde tüm örneklerin ağa aynı şekilde sunulması için elverişli bir yapı sağlar.

2.5.2. Evrişim Katmanı

ESA'larda görüntüler, o görüntüye ait piksel değerlerini içeren matrisler şeklindedir. Evrişim katmanı bu matrislere belirli boyutlarda filtreler uygulayarak yeni özellik matrisleri elde eder. Bu filtreler küçük boyutlu çekirdek matrislerdir (örneğin 3×3 veya 5×5) ve görüntüdeki belirli özellikleri çıkarmak için kullanılır. Her katman kendisinden önce gelen görüntüye bu filtreler aracılığıyla konvolüsyon işlemi uygular ve elde edilen matris özellik haritası olarak adlandırılır. Özellik haritası görüntüdeki belirli bir özelliğin (örneğin, kenarların, dokuların veya renk yoğunluklarının) matematiksel temsili olarak ifade edilmektedir. Her özellik haritası bir özelliği temsil eder; yani her filtre başka bir özelliği çıkarmak üzere kullanılır. Örneğin bir filtre kenarları çıkarırken, diğer bir filtre dokuları veya belirli renk yoğunluklarını yakalar [47].

Denklem 2.10'da evrişim filtresi ve görüntü arasında gerçekleşen işlemin cebirsel tanımı verilmiştir.

$$Y(i, j) = \left(\sum_{m=0}^{M-1} \sum_{n=0}^{N-1} X(i+m, j+n) \cdot K(m, n) \right) + b \quad (2.10)$$

Denklemdaki X konvolüsyon işlemi uygulanacak giriş görüntüsünü temsil eder, i ve j değişkenleri ise görüntünün her bir pikselinin konumunu gösterir. K görüntüye uygulanan filtreyi ifade eder. Bu filtre görüntünün belirli özelliklerini çıkarmak için kullanılır ve m ile n değişkenleri filtrenin boyutunu gösterir. Konvolüsyon işlemi görüntünün üzerindeki piksellerle bu filtrenin elemanlarının çarpılması ve bu çarpımların toplanmasıyla gerçekleşir. Toplam işlemi filtrenin tüm görüntü üzerinde kaydırılarak her bir pikselle etkileşime girdiğini ifade eder. Sonuçta $Y(i, j)$ çıktısı elde edilir, bu da her filtre uygulamasından sonra oluşturulan özellik haritasındaki bir pikseli temsil eder. Formüldeki b ise bias (sapma) terimidir ve çıkışı dengelemek için eklenir.

Evrişim katmanının diğer önemli parametreleri adım (stride) ve dolgulama (padding) değerleridir. Adım sayısı uygulanan filtrenin her seferinde görüntü üzerinde kaç piksel ilerleyeceğini belirler. Dolgulama ise filtrenin görüntü dışında kalan kenar kısımlarına eklenen kenar boşluklarını ifade eder. Bu dolgu işlemi filtrenin kenar pikselleri üzerinde daha iyi bir şekilde çalışabilmesi için gereklidir ve böylece görüntünün boyutunu koruyarak daha kapsamlı bilgi çıkarımı sağlar [48] .

Şekil 2.10'da piksel matrisi formatına dönüştürülmüş bir görüntünün 3x3 boyutunda bir filtre ile evrişim işlemi gösterilmektedir. Elde edilen özellik matrisinin boyutu Denklem 2.16'da olduğu gibi hesaplanır. P , dolgulama sayısını, K uygulanan filtrenin boyutunu ve S adım sayısını temsil eder. Şekil 2.12'de görüldüğü gibi 5x4'lük bir giriş matrisine 3x3 boyutunda filtre uygulanıyor ve adım sayısı 1 dolgulama sayısı 0 olarak belirleniyor. Elde edilen çıktı matrisinin boyutu Denklem 2.11'e göre 3x2 olarak hesaplanmaktadır.

$$\text{Çıkış Boyutu} = \left\lfloor \frac{\text{Giriş Boyutu} + 2P - K}{S} \right\rfloor + 1 \quad (2.11)$$

Görüntü Piksel Matrisi

4	1	9	6
7	5	0	2
1	6	3	8
8	2	4	7
0	8	7	5



Filtre (3x3)

1	2	4
7	5	9
1	2	5

=

Özellik Haritası

144	148

Şekil 2.10: Evrişim İşlemi

2.5.3. Havuzlama Katmanı

Havuzlama katmanı evrişim katmanının ardından gelen ve boyut indirgeme işlevi gören bir katmandır [49]. Bu katmanda bilgi çıkarımı yapılmaz yani ağırlıklar güncellenmez. Amaç öznitelik haritalarının boyutlarını küçültürerek modelin hesaplama yükünü azaltmaktır. Bunun için giriş matrisinin kanal sayısı sabit kalacak şekilde yatayda ve dikeyde boyut indirgemesi yapılır. Bunu yaparken tıpkı evrişim katmanında olduğu gibi havuzlama filtresi belirli adım ve dolgu değerlerinde kaydırılır. İstatiksel yaklaşıma göre en sık kullanılan havuzlama metotları maksimum havuzlama ve ortalama havuzlamadır. Sonraki kısımlarda bahsedilen havuzlama metotlarından detaylı bir şekilde açıklanmıştır.

Maksimum havuzlama işlemi: Evrişim katmanlarından çıkarılan özellik haritalarının belirli bir piksel aralığında en büyük değerlerin seçilmesiyle gerçekleşir. Elde edilen bu değerler yeni bir öznitelik matrisi oluşturur ve bu matrisler girdi verisini en iyi tanımlayan özellik bilgilerini içerir. Havuzlama işlemi sayesinde modelin veriye aşırı uyum sağlaması önlenir ve daha kompakt bir eğitim süreci gerçekleşmesini sağlar.

Maksimum havuzlama işleminde kullanılan istatiksel yaklaşım Denklem 2.12’de gösterilmiştir.

$$Y_{ij} = \max (X_{(i-1) \cdot s+1:(i-1) \cdot s+f, (j-1) \cdot s+1:(j-1) \cdot s+f}) \quad (2.12)$$

X değişkeni giriş matrisini yani özellik haritasını ifade ederken *max* fonksiyonu filtre içerisindeki en büyük değeri seçmeyi sağlar. Uygulanan filtrenin matris üzerinde ne kadar ilerleyeceğini belirten adım sayısı s ile, filtrenin boyutu ise f ile ifade edilir.

Maksimum havuzlama işleminde özellik haritası matrislerine belirlenen boyutlarda bir filtre uygulanır. Bu filtre seçilen aralıklarla matrisleri tarayarak yeni öznitelik matrisleri oluşturur. Model yeniden boyutlandırılmış bu matrislerden öğrenme işlemini gerçekleştirir. Aşağıda bu işlemin adımları bir örnek ile gösterilmektedir.

Giriş matrisi X 'in aşağıdaki gibi olduğunu kabul edersek:

$$X = \begin{bmatrix} 1 & 3 & 2 & 4 \\ 5 & 6 & 8 & 9 \\ 2 & 3 & 7 & 6 \\ 4 & 8 & 1 & 0 \end{bmatrix}$$

Bu matrise 2x2'lik bir filtre ve dolgulama adım sayısı 2 olacak şekilde maksimum havuzlama işlemi uygulanırsa:

$$\text{Birinci 2x2'lik bölge: } \begin{bmatrix} 1 & 3 \\ 5 & 6 \end{bmatrix} : \max = 6, \quad \text{İkinci 2x2'lik bölge: } \begin{bmatrix} 2 & 4 \\ 8 & 9 \end{bmatrix} : \max = 9,$$

$$\text{Üçüncü 2x2'lik bölge: } \begin{bmatrix} 2 & 3 \\ 4 & 8 \end{bmatrix} : \max = 8, \quad \text{Dördüncü 2x2'lik bölge: } \begin{bmatrix} 7 & 6 \\ 1 & 0 \end{bmatrix} : \max = 7,$$

$$\text{Sonuçta elde edilen çıktı matrisi } Y = \begin{bmatrix} 6 & 9 \\ 8 & 7 \end{bmatrix}$$

Ortalama havuzlama işlemi: Maksimum havuzlama işlemine benzer olarak belirli bir aralıktaki ortalama değerlerin alınması ile yapılan havuzlama işlemine ortalama havuzlama denir. Ortalama havuzlamanın amacı, belirgin özellikleri direkt olarak seçmek yerine tüm özellik bilgisini dikkate alarak modelin genel bir eğilim yakalamasını sağlamaktır. Tıpkı

maksimum havuzlamada olduğu gibi giriş matrisi üzerine kaydırmalı bir filtre uygulanır. Filtre boyutu içinde kalan değerlerin ortalamasını alır ve çıktıları bir öznitelik matrisine yerleştirir. Denklem 2.13 ortalama havuzlama işleminin istatistiksel yaklaşımını vermektedir.

$$Y_{ij} = \frac{1}{f \times f} \sum_{p=1}^f \sum_{q=1}^f X_{(i-1) \cdot s + p, (j-1) \cdot s + q} \quad (2.13)$$

Y_{ij} , girişteki özellik haritası matrisine uygulanan havuzlama işlemi sonucunda elde edilen bir çıkış matrisini temsil eder. Bu işlem, $f \times f$ boyutlarındaki bir filtre kullanılarak gerçekleştirilir. Toplam sembollerinde yer alan p ve q indeksleri, filtrenin satır ve sütun konumlarını belirtir. Çifte toplam, filtre bölgesindeki tüm piksellerin toplanarak işlem gördüğünü ifade eder. X , evrişim katmanından elde edilen özellik haritası matrisini temsil eder ve $(i-1) \cdot s + p$ ile $(j-1) \cdot s + q$ ifadeleri, filtrenin hangi satır ve sütunlardaki değerleri işleyeceğini gösterir. Havuzlama işlemi sonunda, filtre bölgelerindeki tüm değerlerin toplamı, filtre boyutuna ($f \times f$) bölünerek ortalama hesaplanır ve bu ortalama, çıkış matrisi olan yeni öznitelik matrisine atanır. Aşağıda ortalama havuzlama işleminin adımları bir örnek ile gösterilmektedir.

Giriş matrisi X 'in aşağıdaki gibi olduğunu kabul edersek:

$$X = \begin{bmatrix} 1 & 5 & 9 & 13 \\ 2 & 6 & 10 & 14 \\ 3 & 7 & 11 & 15 \\ 4 & 8 & 12 & 16 \end{bmatrix}$$

Bu matrise 2x2'lik bir filtre ve dolgulama adım sayısı 2 olacak şekilde maksimum havuzlama işlemi uygulanırsa:

2x2'lik filtre ile yapılan ortalama havuzlama şu şekilde olur:

$$\text{Birinci 2x2'lik bölge: } \begin{bmatrix} 1 & 5 \\ 2 & 6 \end{bmatrix}, \text{ ortalama} = \frac{(1+2+5+6)}{4} = 3.5$$

İkinci 2x2'lik bölge: $\begin{bmatrix} 3 & 7 \\ 4 & 8 \end{bmatrix}$, ortalama= $\frac{(3+4+7+8)}{4} = 5.5$

Üçüncü 2x2'lik bölge: $\begin{bmatrix} 9 & 13 \\ 10 & 14 \end{bmatrix}$, ortalama= $\frac{(9+10+13+14)}{4} = 11.5$

Dördüncü 2x2'lik bölge: $\begin{bmatrix} 11 & 15 \\ 12 & 16 \end{bmatrix}$, ortalama= $\frac{(11+12+15+16)}{4} = 13.5$

Elde edilen çıktı matrisi $Y = \begin{bmatrix} 3.5 & 5.5 \\ 11.5 & 13.5 \end{bmatrix}$

2.5.4. Genel Ortalama Havuzlama Katmanı

Evrişim katmanlarından elde edilen özellik haritaları iki veya üç boyutlu birer matris şeklinde tutulur. Özellikleri yoğun katmana veya doğrudan sınıflandırma katmanına iletmeden önce çok boyutlu matrislerin genel ortalama havuzlama katmanında tek boyutlu vektör haline getirilmesi gerekir. Düzleştirme veya genel ortalama havuzlama katmanı çıkış katmanından önce bu vektörleştirmeyi sağlayan katmandır. Özellik haritasının yüksekliği h , genişliği w olmak üzere n tane örnek ve k tane özellik haritası olmak üzere (n, w, h, k) boyutlarında bir matrisi genel havuzlama katmanına iletilir ve burada boyutu $n \times k$ olacak şekilde tek boyutlu bir vektöre dönüştürülür.

Genel havuzlama katmanı sınıflandırma problemlerinde her sınıf için o sınıfı temsil eden özelliklerin daha fazla ön plana çıkmasını sağlar. Bunun için özellik haritalarının ortalamasını alır ve kenar, doku gibi özelliklerin sınıf ayrımındaki belirleyiciliğini ölçeklendirir. Genel havuzlama katmanının en büyük avantajı sınıflar ve özellikler arasındaki bağlantıyı güçlendirmesidir. Bu sayede sınıflandırmaya olan güveni artırır. Diğer havuzlama katmanlarında olduğu gibi genel havuzlama sırasında da modelin ağırlıkları güncellenmez. Parametre sayısını azaltan uygulamalardan biri olduğu için aşırı uyumun da önlenmesi sağlanır [50].

2.5.5. Yoğun Katman

Yoğun katmanlar diğer adıyla tam bağlantı katmanları ağırlıklı veri seti üzerinden elde ettiği özelliklerin yüksek seviyeli temsillerini üretirler [51]. Yoğun katmanın girişleri $W \in \mathbb{R}^{1024 \times C}$ olan birer ağırlık matrisi ile işlenir. Burada 1024 yoğun katmandaki nöron sayısını, C ise kanal sayısını ifade eder. Her bir nöron bir grup özelliğin ağırlıklı toplamına dayalı olarak çıkış üretir. Bu sayede model veri setine ait kalıpları daha iyi öğrenir ve buna bağlı olarak genelleme yeteneğini geliştirir.

Örnek olarak modelin bir görüntüyü işlediğini ve ilk katmanda üç özellik (girdi) olduğunu kabul edelim: kenarlar, rengin yoğunluğu, ve şekillerin kenarları. Bir nöron bu üç özelliği alır ve her birine bir ağırlık verir (örneğin, kenarlara 0.2, renge 0.5 ve şekillere 0.3). Nöron, bu ağırlıklı toplamı alır ve sonunda bir çıkış üretir. Bu çıkış nöronun öğrendiği yeni bir özellik olabilir, örneğin "görüntüde belirgin bir kenar var mı?" gibi. Bu sayede veri setinin tamamı hakkında kullanacağı bilgiyi öğrenmiş olur. Yoğun katmanlar ayrıca kendisinden önceki katmanların aktivasyonlarına bağlıdır ve bu sayede ağ boyunca aktarılan ağırlıkların daha iyi önemlenmesini sağlar.

Bu tez çalışmasında kullanılan modele sınıflandırma katmanından hemen önce 512 nörona sahip bir yoğun katman eklenmiştir.

2.5.6. Toplu Normalleştirme Katmanı

Veri setindeki özelliklerin benzer bir dağılıma sahip olmadığı durumda toplu normalleştirme işlemiyle bu dağılımlar belirli bir aralıkta ölçeklendirilir [52]. İlk olarak verilerin belirli özellikler için ortalama ve standart sapma değerleri hesaplanır. Ortalama değeri her bir örnek için belirli bir özellik üzerindeki merkezi eğilimini gösterir. Standart sapma ise verilerin ortalama değerden ne kadar uzak olduğunu ifade eder. Her bir özellik için tüm örnekler üzerinden bu hesaplamalar yapılır. Denklem 2.14, alt kümenin ortalamasını, Denklem 2.15 ise standart sapmasını gösterir. Bu formüllerde m , alt kümedeki örnek sayısını, x ise her bir örneğin belirli bir özelliğini temsil eder.

$$\mu_B = \frac{1}{m} \sum_{i=1}^m x_i \quad (2.14)$$

$$\sigma_B^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2 \quad (2.15)$$

Ortalama ve standart sapma değerlerini kullanarak verilerin her biri yeniden ölçeklendirilir. Bunun için Denklem 2.16'da gösterildiği gibi her bir verinin ortalamadan olan uzaklığı bulunur ve standart sapma değerine bölünerek normalize edilir. Bu sayede ortalamanın 0 standart sapmanın ise 1 olduğu şekilde veriler ölçeklenir. Bu ölçeklendirme gradyanların daha stabil olarak yayılmasını ve modelin daha istikrarlı bir şekilde öğrenmesini sağlar.

$$x^i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \quad (2.16)$$

Görüntü verilerine normalleştirme işlemi uygulandığında piksel toplamaları 255'e bölünür ve piksel dağılımları 0-255 arasından 0-1 arasına yeniden ölçeklenir. Bu yöntemle sinir ağlarının eğitim hızı ve kararlılığı geliştirilebilir. Toplu normalleştirme genellikle YSA'ların yoğun bağlantı katmanlarında veya ESA'ların evrişim katmanında kullanılır. YSA'larda aktivasyon katmanından hemen önce yoğun katmanların çıktısına uygulanır.

2.5.7. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları veri setlerinin analizinde modelin doğrusal olmayan ilişkileri öğrenmesi için kullanılır. Aktivasyon işleminde hedef veri setindeki karmaşık yapıyı ortaya çıkarmaktır. Genellikle sinir ağı modellerinde ardı ardına gelen katmanlar yapılan işlemleri doğrusal bir yapıya sokar. Bu durum ağı derinliğinden yani katman sayısından bağımsız olarak modelin öğrenme sürecini basit bir doğrusal ilişki üzerinden devam etmesine neden olur. Sonuç olarak da algoritma sınırlı bir öğrenme potansiyeline sahip olur. Ağ boyunca elde edilen değerlerin doğrudan çıkış sinyali olarak iletilmesini önlemek için kullanılan en yaygın


aktivasyon fonksiyonları relu, sigmoid, tanh veya softmax'dir [53].

Aktivasyon fonksiyonları modelin hata fonksiyonunu azaltmak için yapılan geriye yayılım işleminde türevlenebilir bir fonksiyon olması sebebiyle ağırlıkların güncellenmesini sağlar. Diğer bir deyişle aktivasyon fonksiyonlarının türevleri ağırlıkların ne kadar değişeceğini belirler. Pozitif değerlere daha hızlı yakınsama sağladığı için derin öğrenme modellerinde genellikle relu aktivasyon fonksiyonu kullanılır [54].

Aşağıda, bu tez çalışmasında da kullanılan aktivasyon fonksiyonları açıklanacaktır.

ReLU (Rectified Linear Unit/Düzeltilmiş Doğrusal Birim): ReLU aktivasyon fonksiyonu, girdilerin negatif ve pozitif olması durumuna göre iki farklı şekilde davranır. Şekil 2.11'de görüldüğü gibi negatif giriş değerlerinde ReLU fonksiyonu çıkışı sıfıra eşitlerken, pozitif girişlerde ise çıktıyı olduğu gibi bırakır. Negatif değerlerin sıfıra eşitlenmesi bu değerlerin türevlerinin sıfır olmasından kaynaklanır. Türevin sıfır olduğu noktalarda ağırlık öğrenme süreci durur. ReLU fonksiyonu negatif değerlerin etkisini ortadan kaldırdığı için modelin hesaplama yükünü de azaltmış olur [55].

Denklem 2.17'ye göre ReLU fonksiyonundan elde edilen en yüksek değer z olmak üzere, 0 ile z arasında bir aralığı kapsar



Şekil 2.11: ReLU Aktivasyon Fonksiyonu [9]

$$f(z) = \max(0, z) \quad (2.17)$$

$$f(z) = \begin{cases} z & \text{eğer } z > 0 \\ 0 & \text{eğer } z \leq 0 \end{cases}$$

Bu tez çalışmasında evrişim katmanlarında aktifleştirme fonksiyonu olarak ReLU fonksiyonu kullanılmıştır.

Sigmoid Aktivasyon Fonksiyonu: Sigmoid aktivasyon fonksiyonu genellikle modelin son katmanında ikili sınıflandırma problemlerinde nihai tahmini oluşturmak için kullanılır. Bu fonksiyon ağıın ürettiği ham değerleri 0 ile 1 arasında bir olasılığa dönüştürür. Çoğunlukla çıkış katmanında sadece bir nöronla çalışır ve bu nöronun çıktısı bir skaler değer olan olasılık değeri olarak tutulur [10]. Sigmoid aktivasyonunun temel amacı veri örneklerinin pozitif sınıfa ait olma olasılığını hesaplamaktır. Örneğin tüberküloz teşhisi için bir akciğer X-ışını görüntüsü ele alındığında, ağıın bu görüntü için tahmin olasılığı 0.8 olsun. Bu durumda görüntünün pozitif sınıfa (tüberküloz) ait olma olasılığı 0.8, negatif sınıfa (sağlıklı) ait olma olasılığı ise otomatik olarak $1 - 0.8 = 0.2$ olarak hesaplanır.

$$P(y = 1 | X) = \frac{1}{1 + e^{-(\theta_0 + \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_n x_n)}} \quad (2.18)$$

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (2.19)$$


Denklem 2.18’de $P(y = 1 | X)$ terimi, giriş verisi X ’in 1 etiketli sınıfa ait olma olasılığını ifade eder. Bu olasılık, doğrusal kombinasyon olan $\theta_0 + \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_n x_n$ ifadesi üzerinden hesaplanır. Buradaki θ_0 , sabit terim (bias) olup, modelin giriş verilerine bağlı olmadan yaptığı tahminin temel değerini belirler. $\theta_1, \theta_2, \theta_3, \dots, \theta_n$ ise her bir özelliğin model üzerindeki etkisini gösteren ağırlıklardır. Özellikler $x_1, x_2, \dots, x_n$, modelin tahmin yapmak için kullandığı giriş verisidir ve her biri bir değişkeni temsil eder. Bu doğrusal çıktı daha sonra sigmoid fonksiyonu [55] olan Denklem 2.19’da gösterilen formül ile 0 ile 1 arasında bir olasılığa dönüştürülür, burada $z = \theta_0 + \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_n x_n$. z değeri büyükse Denklem 2.19’da e değeri sıfıra yaklaşır ve sonuç 1 olur, z küçükse bu defa e oldukça büyük bir sayı

olabilir ve fonksiyon 0 değerini alır. Yani sigmoid fonksiyonu ile elde edilen değerler 0 ile 1 arasında sınırlandırılmış olur. Ardından bu işlemde elde edilen olasılık değerleri bir eşikten geçirilir. Uygulanan eşik Denklem 2.20 ve 2.21'deki şartlardan birini sağlar.

$$\text{Eğer } P(y = 1 | X) \geq 0.5, \text{ veri 1. sınıfa ait olarak sınıflandırılır,} \quad (2.20)$$

$$\text{Eğer } P(y = 1 | X) < 0.5, \text{ veri 0. sınıfa ait olarak sınıflandırılır.} \quad (2.21)$$

Şekil 2.12'deki sigmoid fonksiyonu grafiğine göre, x ekseninde -6 ile 6 arasında olduğunda, y eksenindeki değişimlerin daha hızlı olduğu görülür. Ancak x çok büyük pozitif veya negatif değerlere yaklaştığında fonksiyonun eğimi azalır ve türev değerleri neredeyse sıfır olur. Bu durum modelin geri yayılım işlemi sırasında ağırlıkları etkili bir şekilde güncelleyememesine neden olur. Sonuç olarak öğrenme süreci yavaşlar veya tamamen durur [56]. Öte yandan x eksenindeki küçük değişimlerin y ekseninde büyük farklar yarattığı da görülmektedir. Bu özellik sigmoid aktivasyon fonksiyonunun ikili sınıflandırma problemlerinde pozitif ve negatif sınıfları ayırmak için uygun bir seçim olmasını sağlar. Ancak fonksiyonun uç değerlerde türevlerinin küçülmesi gibi sınırlamaları nedeniyle sigmoid genellikle yalnızca çıkış katmanlarında kullanılır.



Şekil 2.12: Sigmoid Aktivasyon Fonksiyonu [10]

Çalışmada ikili sınıflandırma problemi ele alındığından ağın çıkış katmanında sigmoid aktivasyon fonksiyonu tercih edilmiştir.

Bu tez çalışması kapsamında özel bir ESA modeli olan DenseNet201 modeli kullanılmıştır. Modelin detayları Malzeme ve Yöntem kısmında Bölüm 3.3'de açıklanacaktır.

2.6. MODEL PERFORMANS DEĞERLENDİRMESİ

Tahmine dayalı olasılık modelleri yapılan doğru ve yanlış tahminleri dört başlık altında toplar; doğru pozitifler, yanlış pozitifler, doğru negatifler ve yanlış negatifler. Modelin performansını ölçmeye yarayan metrikler bu değerlerle ifade edilir. Model metrikleri; doğruluk(accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skorudur [57].

Bu metriklerin hesaplanması için kullanılan değerler modelin tahmin başarısının istatistiksel bir yaklaşımıyla elde edilir. Doğru pozitifler ve doğru negatifler, modelin gerçek dünya verisiyle uyumlu sonuçlar ürettiği, yanlış pozitif ve yanlış negatifler ise tahminlerin yanlış olduğu durumları ifade eder. Örnek olarak, hastalık teşhisi almış bir vakanın model tarafından hasta olarak tahmin edilmesi doğru pozitif değerler altında toplanır, hasta olmayan bir vakanın hasta olmadığı şeklindeki bir tahmin ise doğru negatifler sınıfında toplanır. Öte yandan, hastalık teşhisi aldığı halde model tarafından hasta değildir olarak sınıflandırılan vakalar yanlış negatif durumları ifade eder. Benzer şekilde hasta olmadığı bilinen vakanın model tarafından hasta olarak nitelendirilmesi ise yanlış pozitifler sınıfına girer.

Bu tez çalışmasında önerilen model ve yaklaşımların başarısı, doğruluk, kesinlik, duyarlılık, F1 skoru ve AUC değerleri baz alınarak ölçülmüştür.

2.6.1. Doğruluk (Accuracy)

Doğruluk, makine öğrenmesi ve istatistiksel sınıflandırma analizlerinde yaygın olarak kullanılan bir performans ölçütüdür. Bir sınıflandırma modelinin ne kadar doğru tahminler yaptığını değerlendirmek için kullanılır. Denklem 2.22’de ifade edildiği gibi, modelin tahmin ettiği tüm doğru negatif ve doğru pozitif sınıfların toplam tahmin içindeki oranı şeklinde hesaplanır.

$$\text{Doğruluk} = \frac{\text{Doğru Pozitifler} + \text{Doğru Negatifler}}{\text{Toplam Tahmin Sayısı}} \quad (2.22)$$

Doğruluk metriği model performansını ölçmek için her zaman tek başına yeterli olmayabilir. Özellikle dengesiz veri setlerinde, model veri dağılımına karşı yanlılık gösterebilir. Bu durumda doğruluk performansı değerlendirmek için güvenilir bir ölçüt olmaz. Daha

kapsamlı bir değerlendirme yapabilmek için farklı metriklere de başvurulması gerekir.

2.6.2. Kesinlik (Precision)

Kesinlik (precision) bir modelin pozitif sınıfı ne kadar doğru tahmin ettiğini ölçen önemli bir metriktir. Denklem 2.23'de görüldüğü gibi tüm pozitif değerlerin doğru pozitiflere oranı şeklinde hesaplanır. Özellikle medikal görüntü sınıflandırma gibi hayati önem taşıyan problemler için kritik bir rol oynar. Yanlış pozitif tahminlerin en aza indirilmesi gereken durumlarda, kesinlik metriği öne çıkar. Yüksek bir kesinlik değeri modelin yaptığı pozitif tahminlerin büyük çoğunluğunun doğru olduğunu ve yanlış pozitiflerin az olduğunu gösterir. Buna ek olarak, kesinlik tek başına bir modelin genel performansını tam olarak yansıtmayabilir çünkü yanlış negatifler (yani gerçekte pozitif olan fakat model tarafından negatif olarak tahmin edilen durumlar) bu ölçüte dahil edilmez. Bu nedenle, kesinlik genellikle duyarlılık (recall) ve F1-Skoru gibi diğer metriklerle birlikte değerlendirilir, böylece modelin genel başarısı daha dengeli bir şekilde ölçülmüş olur. Modelin pozitif tahminlerde ne kadar isabetli olduğunu bilmek, sınıflandırma algoritmasının güvenilirliğini artırmak için son derece önemlidir.

$$\text{Kesinlik} = \frac{\text{Doğru Pozitifler}}{\text{Doğru Pozitifler} + \text{Yanlış Pozitifler}} \quad (2.23)$$

2.6.3. Duyarlılık (Recall)

Duyarlılık (recall) metriği, sınıflandırma modelinin gerçek pozitif örnekleri doğru bir şekilde tahmin etme yeteneğini ölçer. Kesinlik metriği ile benzer olarak pozitif sınıfların değerlendirilmesi için kullanılır. Aralarındaki temel fark Denklem 2.24'de de görüldüğü gibi, kesinlik, model tarafından pozitif olarak tahmin edilen örneklerin ne kadarının gerçekten pozitif olduğunu değerlendirirken; duyarlılık, tüm gerçek pozitif örneklerden kaç tanesinin doğru bir şekilde tahmin edildiğini ifade eder.

$$\text{Duyarlılık} = \frac{\text{Doğru Pozitifler}}{\text{Doğru Pozitifler} + \text{Yanlış Negatifler}} \quad (2.24)$$


2.6.4. F1 Skoru

F1 skoru, modelin genel performansını değerlendirmek için kullanılan, kesinlik ve duyarlılık metriklerinin birleştirilmiş bir ifadesidir. Bu metrik, modelin pozitif sınıfı doğru bir şekilde tahmin etme yeteneğini ve yaptığı pozitif tahminlerin doğruluğunu dikkate alarak daha kapsamlı bir değerlendirme sunar. F1 skorunun temel amacı, elde edilen sonuçların güvenilirliğini artırmaktır; böylece modelin rastgele bir şekilde yüksek performans gösterip göstermediği tespit edilebilir. Ayrıca, kesinlik ve duyarlılık arasında bir denge sağlayarak, dengesiz veri setleri ile çalışırken yanıltıcı sonuçların önüne geçer. Bu nedenle, tıbbi teşhis sistemleri, dolandırıcılık tespiti ve spam filtreleme gibi uygulamalarda sıklıkla kullanılır. F1 skoru, modelin başarısını değerlendirmeye olanak tanırken, gerçek dünyada nasıl performans göstereceği hakkında daha sağlam ve güvenilir bilgiler sunar.

$$F1 \text{ Skoru} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (2.25)$$

2.6.5. ROC Eğrisi

ROC (Receiver Operating Characteristic Curve) eğrisi, sınıflandırma modellerinin performansını görsel olarak değerlendiren bir araçtır. Temel amacı, kesinlik ve duyarlılık ölçütlerini kullanarak modelin tahmin sonuçlarını analiz edip sınıfları ayırt etme becerisini ölçmektir. Bu sayede, modelin genelleme yeteneği hakkında bilgi verir. Yani, sınıflandırma yaparken doğru ve yanlış tahminler arasındaki ilişkiyi ortaya koyar. Örneğin, hastalıklı ve normal olarak sınıflandırılan akciğer X-ışını görüntülerinde model, ikili bir sınıflandırma yapar. Hasta ve sağlıklı vakaların doğru ve yanlış tahminlerinin oranı iki sınıfın birbirinden ayırt edilme durumunu gösterir. Eğrinin yatay eksenini yanlış pozitif oranını, dikey eksenini ise doğru pozitif oranını temsil eder. Ayrıca, eğrinin altında kalan alan (AUC), modelin genel performansını sayısal bir değerle ifade eder; bu alan ne kadar büyükse, modelin başarısı o kadar yüksek kabul edilir. Şekil 2.13’de görüldüğü gibi grafiğin köşegenleri boyunca uzanan düz çizgi rastgele sınıflandırıcı olarak adlandırılır. Rastgele bir sınıflandırıcının AUC’si 0.5’tir.



Şekil 2.13: ROC eğrisi

2.6.6. Hata Matrisi (Confusion Matrix)

Hata matrisi, sınıflandırma modelinin yaptığı tahminler ve gerçek verileri karşılaştırmayı sağlayan görsel bir performans değerlendirme aracıdır. Hata matrisi diğer adıyla karışıklık matrisi doğru pozitif, yanlış pozitif, doğru negatif ve yanlış negatif bulgularından oluşturulur. Sadece hata matrisinden elde edilen sonuçların güvenilirliğini artırmak için buradaki bulgular kullanılarak kesinlik, duyarlılık, F1 skoru ve doğruluk gibi metrikler de hesaplanabilir.

Şekil 2.14’de ikili sınıflandırma için kullanılan matris boyutu gösterilmiştir. Örneğin 3 sınıflı bir çoklu sınıflandırma probleminde matrisin boyutu 3x3 olacak şekilde güncellenir. Bu sayede, her sınıf için modelin nasıl tepki verdiğini ve hangi sınıf için daha başarısız sonuçlar ürettiği açıkça görülebilir.

Bütün model metrikleri karışıklık matrisinden elde edilen tahmin istatistik bilgisi ile oluşturulur. Açıklanan metriklerin hiçbiri tek başına bir modelin başarısını ölçmek için yeterli değildir. Her birinin ayrı ayrı ve birbiri ile olan ilişkisi göz önüne alınarak bir modelin başarısı hakkında kesin bir çıkarım yapılabilir.

		Gerçek Değerler	
		Pozitif	Negatif
Tahmin Değerleri	Pozitif	Doğru Pozitifler	Yanlış Pozitifler
	Negatif	Yanlış Negatifler	Doğru Negatifler

Şekil 2.14: Hata Matrisi

2.7. ÇAPRAZ DOĞRULAMA

Geleneksel yaklaşımda tüm veriyi eğitim ve test seti olarak ayırdıktan sonra eğitim setini ağı eğitmek için, modelin performansının gerçek dünya verilerine ne kadar iyi uyarlandığını ölçmek için ise test setini kullanırız. Bunlara ek olarak eğitim verisinin küçük bir bölümüyle oluşturulan doğrulama verisi de modelin hiperparametrelerini ayarlamak ve genelleme performansını değerlendirmek için kullanılır.

Ağın performansını ve başarısını yorumlarken elde edilen sonuçların tesadüfi olup olmadığını veya rastgele tahminler yapılıp yapılmadığını anlamak için ağı pek çok kez eğitmek ve farklı doğrulama setleriyle test etmek, gerçek test sonuçlarının güvenilirliğini artırır. Bu sebeple kullanılan k-katlı çapraz doğrulama işlemi test verisi hariç tüm veri setini istenilen oranlarda eğitim ve doğrulama setlerine ve her defasında farklı varyasyonlarda bölerek, ağı yeniden bu verilerle eğitir ve doğrular [58].

Çapraz doğrulama işleminde veri kümesi belirlenen sayıda rastgele alt kümelere bölünür. Örneğin 5 katlı çapraz doğrulama için veri seti 5 eşit parçaya bölünür. Her bir iterasyonda rastgele seçilen 4 veri kümesi eğitim için kullanılırken kalan 1 adet veri seti doğrulama işlemi için kullanılır. Bu işlem, her alt kümenin doğrulama için kullanıldığı 5 farklı kombinasyon için tekrarlanır. Sonuçlar bu kombinasyonların ortalaması olarak elde edilir.

2.8. LİTERATÜR TARAMASI

Son yıllarda temel makine öğrenmesi (ML) ve daha ileri seviye olan derin öğrenme (DL) ile yapılan çalışmalar pek çok alanda olduğu gibi yüksek enerji fiziği ve medikal görüntü analizi gibi alanlarda da hız kazanmıştır. Geleneksel yöntemlere kıyasla daha düşük maliyetli ve yüksek verimli olan bu teknikler LHC gibi deneylerden elde edilen dedektör verilerinin yanı sıra sağlık sektörü gibi önemli bir alanda tıbbi görüntülerin analizini de kolaylaştırmıştır. Sinir ağları büyük ve karmaşık veri kümelerinin işlenmesinde etkili bir araç olarak sinyal-gürültü ayrımı, nadir olayların tespiti ve fiziksel ya da biyolojik süreçlerin modellenmesi gibi görevlerde yüksek başarı göstermektedir. Bu bölümde ilk olarak ML ve DL metodlarının yüksek enerji fiziğindeki uygulamalarını içeren literatür araştırması verilecektir. Bu bağlamda, yüksek enerji fiziği alanındaki yenilikçi yaklaşımlardan yola çıkarak daha sonra medikal görüntü analizlerinde yapılmış çalışmalar ele alınacaktır.

Kheddar ve diğerleri [59] tarafından yapılan çalışmada jet olaylarının sınıflandırılması için literatürde bulunan birden fazla sinir ağı tabanlı modelin performansı karşılaştırılmıştır. Hadron ve lepton parçacıklarının kinematiklerine göre sınıflandırarak nadir olayların tespiti ve jet izlerinin etiketlenmesi problemleri üzerinde durulmuştur. Sonuçlar umut vaad edici olsa da sınıflandırma performansı geliştirilmeye hala açıktır.

Derin öğrenme ve bilgisayarlı görü yöntemleri parçacık fiziği dedektörlerindeki olayları yeniden yapılandırma işleminde giderek önem kazanmaktadır. Abud ve diğerleri [60] tarafından yapılan çalışmada ProtoDUNE-SP verileri için Submanifold Sparse Convolutional Neural Networks (SparseNet) kullanılarak iz ve düş vuruşları sınıflandırılmıştır. Yöntem %90'ın üzerinde verimlilik ve saflık sunmuş, sinir ağlarına kıyasla daha az kaynak kullanımı ve daha yüksek hız sağlamıştır. Bu yaklaşım DUNE gibi büyük ölçekli nötrino dedektörleri için ölçeklenebilir bir çözüm sunmaktadır.

ESA'ların görüntü sınıflandırma alanındaki başarısı parçacık fiziği deneylerinden elde edilen verilerin sınıflandırılmasında da kullanılmalarını teşvik etmiştir. Ayyar ve diğerlerinin [14] çalışmasında, sinyal ve arka plan ayrımı için 2D ve 3D görüntü verileri üzerinde ESA'lar uygulanmıştır. IceCube nötrino gözlemevi ve ATLAS benzeri dedektörlerden elde edilen simüle edilmiş verilerle yapılan araştırmada kompakt ESA'lar %96 AUC değerine ulaşarak daha az parametreyle karmaşık ResNet modellerine benzer doğruluklar sağlamış ve daha düşük hesaplama gereksinimleri sunmuştur. Bu bulgular ESA'ların sadece parçacık fiziği için

değil diğer alanlardaki sınıflandırma problemleri için de potansiyel taşıdığını göstermektedir.

CMS araştırmacıları [61] tarafından yapılan çalışmada CMS dedektöründe tau leptonlarının hadronik bozunmalarını (τ_h) kuark/gluon jetleri, elektronlar ve müonlardan ayırt etmek için geliştirilmiş bir derin sinir ağı (DNN) tabanlı algoritma sunulmuştur. Algoritma τ_h adayının çevresindeki parçacıklardan elde edilen bilgileri evrişimli ve tam bağlı katmanlar içeren bir ağ yapısıyla işler. Giriş değişkenleri üç alt ağda (iç hücreler, dış hücreler, yüksek düzey özellikler) ayrı ayrı değerlendirilip birleştirildikten sonra beş tam bağlı katmandan geçirilerek bir parçacık adayının τ_h , elektron, müon veya jet olma olasılıkları hesaplanmıştır. İç ve dış hücrelerin ızgara yapıları evrişimli katmanlarla küçültülerek daha etkili bilgi çıkarımı sağlanmıştır. Algoritma sınıflandırma başarımı ve verimlilik açısından önceki yöntemlere göre %10-30 oranında daha iyi sonuçlar vermiştir.

Van ve diğerleri [12] çalışması HL-LHC gibi yüksek ışınım yoğunluğuna sahip deneylerdeki büyük parçacık çokluğu sorununa çözüm getiren öğrenilen bir iz yeniden yapılandırma yöntemi önermektedir. Transformer tabanlı vuruş filtreleme ağı ve MaskFormer modelinin birleşimi parçacık özelliklerini ve iz atamalarını optimize etmiştir. TrackML veri seti üzerinde yapılan testlerde model %97 verimlilik, %0.6 sahte oranı ve 100 ms çıkarım süresi ile başarı göstermiştir. Bu esnek model parçacık fiziği analizlerine yönelik yüksek enerji fiziği zorluklarına da uygulanabilir ve derin öğrenme mimarilerinin fiziksel analizlerdeki hassasiyeti koruyarak hesaplama sorunlarını çözme potansiyelini göstermektedir.

Yapay zekâ uygulamalarının yüksek enerji fiziğinde olduğu gibi farklı pek çok alandaki başarısı sağlık gibi önemli alanlarda da gelişmeleri hızlandırmış örneğin görüntü analizi gibi karmaşık sorunların çözümünde benzer yaklaşımların kullanılmasına olanak sağlamıştır. Aşağıda, sağlık alanında görüntü analizlerini temel alan ve gelişmiş sinir ağı modelleriyle yüksek başarılar elde eden bazı literatür çalışmaları açıklanacaktır.

Lopes ve diğerleri [62] tarafından yapılan çalışmada, frontal göğüs radyografilerinde tüberküloz tanısını kolaylaştırmak amacıyla önceden eğitilmiş GoogleNet, ResNet ve VggNet gibi evrişimli sinir ağı modelleri kullanılmıştır. Önerilen modelleri özellik çıkarıcı olarak kullanıp sınıflandırma için ise destek vektör makineleri (SVM) ile hibrit bir yapı sunulmuştur. Halka açık Montgomery+Sheznhen ve Ulusal Tüberküloz ve Solunum Hastalıkları Enstitüsü'nden alınan veri setlerinden 481 sağlıklı ve 472 tüberküloz teşhisli toplamda 953 veri kullanılarak elde edilen sonuçlarda tüberküloz tespitinde en iyi başarı

Montgomery County veri setinde %82 ve Shenzhen yaklaşık %85 setinde olarak elde edilmiştir.

Nafisah ve diğerleri [63] tarafından yapılan çalışmada önceden eğitilmiş ESA modelleri ile segmentasyon ve veri artırımı gibi ön işlemler uygulanarak Montgomery ve Shenzhen veri setleri hem bireysel hem de kombine olarak değerlendirilmiştir. Sonuçlar Montgomery+Shenzhen veri setinin EfficientNetB3 modeli ile %99,9 ROC eğrisi skoru ve %98,7 ortalama doğrulukla yüksek bir performans gösterdiğini ortaya koymuştur. Yapılan çalışmada segmente edilmiş X-ışını görüntülerinin ham görüntülere kıyasla model başarısında daha etkili olduğu tespit edilmiştir.

Rahman ve diğerleri [64] tarafından halka açık Montgomery+Shenzhen ve Tüberküloz Göğüs Röntgeni Veri tabanı'ndan alınmış verileri kullanılarak toplamda 3500 tüberküloz teşhisli ve 3500 sağlıklı akciğer görüntüsü kullanılarak segmentasyon yöntemiyle tüberküloz tespiti yapılmıştır. Bunun için önceden eğitilmiş ResNet18, ResNet50, ResNet101, ChexNet, InceptionV3, Vgg19, DenseNet201, SqueezeNet ve MobileNet modelleri kullanılmış ve en yüksek doğruluk segmentasyon yöntemiyle DenseNet201 modelinde %98,6 olarak elde edilmiştir.

Tummalapalli ve diğerleri [65] tarafından tüberküloz tespiti için ileri düzey derin öğrenme yaklaşımı olan DenseNet201 modeli kullanılmıştır. Tüberküloz Göğüs Röntgeni Veri tabanı'ndan alınan 700 tüberküloz teşhisli ve sağlıklı verilerle önceden eğitilmiş DenseNet201 modelinin test başarısı Montgomery veri setinde %96 olarak elde edilmiştir. Aynı yıl Chutia ve diğerleri [66] tarafından sunulan çalışmada akciğer hastalıklarının teşhisinde önceden eğitilmiş DenseNet201 modelinin başarısı test edilmiştir. DenseNet modelinin ilk maksimum havuzlama katmanı hibrit havuzlama katmanı ile değiştirilmiştir. X-ışını görüntülerine CLAHE uygulanmış ve halka açık verilerden NIH chest X-ışını veri setinden 9409 adet veri kullanılarak pnömotoraks sınıflandırmada test başarısı %95,34 olarak elde edilmiştir.

Showkatian ve diğerleri [67] Montgomery County veri setini kullanarak otomatik tüberküloz tanısı için sıfırdan özel bir evrişimli sinir ağı modeli eğitmeyi önerdi. Sonuçları beş önceden eğitilmiş modelle karşılaştırdılar ve rekabetçi sonuçlar elde ettiler. Önerilen ESA mimarisi %87 doğruluk elde ederken, Xception, ResNet50 ve VGG16 dahil olmak üzere önceden eğitilmiş modeller arasında tüberküloz tanısı için en yüksek sınıflandırma performansı %90

oldu.

Devasia ve diğerleri [68] CXR görüntülerinden akciğerlerdeki aktif tüberkülozu teşhis etmek ve hastalığı gösteren durumların olasılıklarını tahmin etmek için bir mimari önerdiler. Akciğer bölgesi segmentasyonu için U-Net ve tüberküloz semptom sınıflandırması için EfficientNetB4 modelini birleştiren bir hibrit çerçeve geliştirdiler. Elde edilen sonuçlar neredeyse mükemmeldi ve tüberküloz tanısında ve olası nedenlerinin belirlenmesinde mükemmel performans gösterdi.

Taşçı ve diğerleri [69] ince ayarlı InceptionV3 ve Xception tabanlı modeller kullanarak tüberküloz tespiti için bir topluluk ESA modeli önerdi. Çalışmada CLAHE (Kontrast Sınırlı Uyarlamalı Histogram Eşitleme) ve veri artırma teknikleri uygulandı, en iyi üç veya beş sınıflandırıcı model eğitilmek üzere seçildi ve Bayes optimizasyon tabanlı ağırlıklı oylama ve olasılık ortalama yöntemleri kullanıldı. Model sırasıyla Montgomery ve Shenzhen veri kümelerinde %97,500 ve %97,699 doğruluk oranlarına ulaştı.

Uçar [70], hiperparametrelerin Bayes optimizasyon yöntemi kullanılarak belirlendiği derin sinir ağı (DNN) modelinin geliştirilmesine dayalı olarak tüberküloz (TB) hastalığının teşhisi için yeni bir yaklaşım önerdi. Önerilen yaklaşımda, özellik çıkarma, VGG16, EfficientNetB0, ResNet101 ve DenseNet201 gibi önceden eğitilmiş derin öğrenme modelleri kullanılarak gerçekleştirildi. Daha sonra çıkarılan bu özellikler kullanılarak hiperparametreleri Bayes optimizasyonu ile seçilmiş dört DNN modelini eğitmek için kullanıldı. Modellerin sınıflandırma performansı karşılaştırıldı ve EfficientNetB0 modelinin %99,2857 doğrulukla en iyi performansı elde ettiği, ardından %97,9286 ile VGG16, %97 ile DenseNet201 ve %95,6429 ile en düşük doğrulukla ResNet101'in geldiği bulundu.

Fati Sm ve diğerleri [71] ESA ve yapay sinir ağlarını kullanarak tüberküloz (TB) tespiti için iki farklı yaklaşım önerdi. İlk yaklaşımda ResNet-50 ve GoogLeNet modelleri birleştirildi ve özellik boyutlarını azaltmak için temel bileşen analizi uygulandı ardından SVM algoritması kullanılarak sınıflandırma yapıldı. İkinci yaklaşımda ResNet-50 ve GoogLeNet modellerinden çıkarılan özellikler GLCM, DWT ve LBP özellikleriyle birleştirildi ve sınıflandırma yapay sinir ağları kullanılarak gerçekleştirildi. İkinci yaklaşım, Shenzhen veri seti için %99,2 doğruluk ve Tüberküloz Göğüs Röntgeni Veri tabanı'ndan alınan veri seti için %99,8 doğruluk elde etti.

3. MALZEME VE YÖNTEM

Bu bölümde tez çalışması kapsamında kullanılan veri setleri ve veri ön işleme adımları, kullanılan model ve parametreler detaylı bir şekilde açıklanacaktır.

3.1. VERİ SETİ

Bu tez çalışmasında kullanılan halka açık X-ışını akciğer veri setleri Tablo 3.1’de özetlenmiştir. Veriler, çeşitli ülkelerden farklı zamanlarda ve farklı görüntüleme cihazlarıyla elde edilmiştir. Görüntüler tüberküloz (TB) tanısı olanlar ve Normal olarak etiketlenmiş iki sınıftan oluşmaktadır.

İlk veri seti, Amerika Birleşik Devletleri’nin Maryland eyaletindeki Montgomery County Sağlık Bölümünden, ikinci veri seti ise Çin’deki Shenzhen Şehri Üçüncü Halk Hastanesi ve Guangdong Tıp Koleji iş birliğiyle Ulusal Tıp Kütüphanesi (National Library of Medicine, NLM) tarafından oluşturulmuştur. Montgomery County veri seti, 58 tüberküloz ve 80 normal olmak üzere resim boyutları 4020x4892 olan toplam 138 akciğer X-ışını görüntüsü içerir. Shenzhen veri seti ise 336 tüberküloz belirtileri gösteren ve 326 normal vaka içeren resim boyutları 3000x3000 olan toplam 662 görüntü sunmaktadır. Bu iki veri setinin birleştirilmesiyle elde edilen üçüncü veri seti Montgomery+Shenzhen seti, 394 tüberküloz tanısı almış ve 406 sağlıklı kabul edilen toplamda 800 veri içermektedir [72].

Dördüncü veri seti, Tüberküloz (TB) Göğüs Röntgeni Veri tabanı’ndan alınmıştır. Bu veri seti resim boyutları 1024x1024 olan 3500 normal ve 3500 tüberküloz tanısı almış X-ışını görüntüleri içerir [64]. Veri seti Katar Üniversitesi, Dakka Üniversitesi, Bangladeş ve Malezya’dan çeşitli araştırmacılarla Hamad Medical Corporation işbirliği ile oluşturulmuştur [73]. Tüberküloz verisinin 700 örneği, normal örneklerin ise tamamı halka açık şekilde sunulmuştur. TB vaka örneklerinin 306’sı BELARUS TB veri tabanından, 394 tanesi ise NLM’den alınarak oluşturulmuştur. Normal vakaların 406 örneği NLM veri tabanından, 3094’ü ise Kuzey Amerika Radyoloji Derneği (Radiological Society of North America, RSNA)’dan alınmıştır. Bu tez çalışmasında, 394 tüberküloz tanısı almış 406’sı ise

normal vakalar olmak üzere 800 adet örnek seçilerek yeni bir alt veri seti oluşturulmuştur.

Ön işleme yöntemleri uygulandıktan sonra tüm verinin %85'i eğitim, %15'i test olarak ayrılmıştır. Eğitim setinin %25 doğrulama seti olarak kullanılmıştır.

Tablo 3.1: Veri Setleri için Normal ve TB Görüntü Veri Sayıları ve Görüntü Boyutları

Veri Seti	Normal Görüntü Sayısı	TB Görüntü Sayısı	Toplam Görüntü Sayısı	Orjinal Resim Boyutu
Montgomery (ABD)	80	58	138	4020x4892
Shenzhen (Çin)	326	336	662	3000x3000
Tüberküloz (TB) Göğüs Röntgeni Veri tabanı	406	394	800	1024x1024

3.2. VERİ ÖN İŞLEME

Veri ön işleme süreci modelin performansı üzerinde doğrudan bir etkiye sahiptir. Veri seti içindeki örneklerin birbiriyle uyumsuzluğu, düşük piksel kalitesi veya yanlış veri örnekleri gibi durumlar veri setinin model tarafından yanlış öğrenilmesine neden olabilir. Hedef çıktı tahminlerini yaparken eğitim sırasında gerçek verilerle doğrudan ilişkili olmayan özelliklerin öğrenilmesi tahmin sırasında modelin değerlendirme kapasitesini düşürür ve performans üzerinde negatif bir etki yaratır. Bu etkiyi ortadan kaldırmak için kullanılacak verinin öncesinde bazı ön işlemlerden geçmesine veri ön işleme denir.

Veri ön işleme adımları temel olarak veri temizliği ve veri dönüşümü olarak ikiye ayrılır.

Veri temizliği, veri setindeki uyumsuz, tekrarlayan, aşırı gürültü içeren, eksik ya da yanlış veri tipine sahip verilerin tespit edilip düzeltilmesi veya çıkarılmasını içerir. Amaç, modelin hatalı ya da eksik bilgilerle eğitilmesini ve bu hataların genel tahmin performansını olumsuz etkilemesini önlemektir. Eksik değerler genellikle silinmek yerine ortalama, medyan veya diğer tekniklerle doldurulabilir. Örneğin cinsiyet kategorisine sahip bir veri setinde eksik bir veri varsa ve veri setindeki çoğunluk 'Kadın' ise bu eksik değer 'Kadın' olarak doldurulabilir. Gürültülü veriler de çeşitli filtreleme yöntemleriyle iyileştirilebilir. Görüntü işlemede veri örneklerindeki gürültüler Gaussian Filtreleme yöntemi ile giderilerek verinin daha anlamlı kalması ve bilgilerin korunması sağlanabilir.

Veri dönüşümü, veri setini modele daha uygun hale getirmek için yapılan işlemleri kapsar. Bu süreçte veriler ölçeklendirilir, kategorik veriler sayısal formata dönüştürülür veya farklı formatlardaki veriler birbiriyle uyumlu hale getirilir. Ayrıca veri setinin genel yapısıyla uyumsuz olan aykırı değerler tespit edilerek uygun şekilde işlenir ya da dönüştürülür.

Veri ön işleme derin öğrenme uygulamalarında modelin başarısını attırmada oldukça önemlidir. Tüm akciğer görüntülerinin aynı formatta, boyutta ve görüntü kanalında olması gerekir. Bu yüzden ham veriyi doğrudan modeli eğitmek için kullanmayız. Bu çalışmada kullanılan veri ön işleme metotları bölüm 3.2.1’de açıklanmıştır.

3.2.1. Veri Ön İşleme Adımları

Bu tez çalışmasında kullanılan akciğerlere ait X-ışını görüntülerine bazı ön işlemler uygulanmıştır. Bunlar sırasıyla; resimleri yeniden boyutlandırma, histogram normalizasyonu, CLAHE (Kontrast Sınırlı Uyarlamalı Histogram Eşitleme) ve veri artırmadır.

3.2.1.1. Yeniden Boyutlandırma

Derin öğrenme modelleri belirli bir boyutta girdiyle çalışmak üzere tasarlanmıştır. Eğer veri setindeki örneklerin giriş boyutları birbirinden farklı olursa modelin katmanları arasında uyumsuzluk ortaya çıkar. Bu durum modelin öğrenme sürecinde tutarsızlığa neden olabilir. Model büyük bir görüntüye kıyasla küçük boyutlu görüntüdeki nesneleri tanımada sorun yaşayabilir. Dolayısıyla görüntüleri aynı boyuta getirmek modelin eğitimini daha doğru bir hale getirmeyi sağlar.

Şekil 3.1 ve Şekil 3.2 farklı piksel boyutlarına sahip görüntüleri göstermektedir.

Görüntülerin doğal formunu korumak için genişlik ve uzunluk bakımından orantılı bir boyutlandırma yapmak önemlidir. Yanlış boyutlandırma görüntüdeki özelliklerin çarpıtılmasına ve kalitenin azalmasına neden olabilir. Eğitim veri setindeki görüntülerin aynı boyuta sahip olması modelin özellikleri daha iyi tanımasına ve sınıflandırmasına yardımcı olur.

Bu tez çalışmasında, tüm veriler literatürde yaygın olarak kullanılan 224x224 boyutunda yeniden ölçeklendirilmiştir.



Şekil 3.1: 1024x1024 piksel boyutuna sahip X-ışını görüntüsü



Şekil 3.2: 400x400 piksel boyutuna sahip X-ışını görüntüsü

3.2.1.2. *Histogram Normalizasyonu*

Histogramlar, bir görüntüyü oluşturan piksel değerlerinin dağılımını (frekansını) veren grafiklerdir. Renk piksellerinin belirli bir değerde toplanmasını önlemek için histogram eşitleme yani normalizasyon kullanılır. Hedef, pikselleri normalize ederek görüntü kontrastını artırmaktır. Tıbbi görüntülerin daha iyi analiz edilmesi için uygulanan oldukça yaygın bir ön işleme metodudur.

Histogram normalizasyonu, ilk olarak görüntüye ait histogramın elde edilmesi ve piksel değerlerinin dağılımının incelenmesi ile başlar. Ardından tüm piksel değerlerinin dengeli bir hale getirilmesi için normalizasyon işlemi uygulanır. Bunun için Kümülatif Dağılım Fonksiyonu (KDF) denilen bir fonksiyon hesaplanır. Fonksiyonun hedefi görüntüdeki piksel değerlerinin kümülatif toplamını almak ve her bir piksel değerinin bu toplamda ne kadar temsil edildiğini hesaplamaktır. Fonksiyon Denklem 3.1’de verilmiştir. (r_k) seçilen herhangi bir piksel değerinin kümülatif toplamını ifade eder. $p(r_i)$ bu piksel değerinin histogramdaki frekansdır. Fonksiyonun çıktısı bir piksel değerinin görüntüyü oluşturan diğer piksel değerleri içindeki oranıdır.

$$KDF(r_k) = \sum_{i=0}^k p(r_i) \quad (3.1)$$

$$KDF_{\text{norm}}(r_k) = \frac{KDF(r_k)}{N} \quad (3.2)$$

$$r'_k = \text{round}(KDF_{\text{norm}}(r_k) \times (L - 1)) \quad (3.3)$$

Belirli bir piksel için hesaplanan KDF değeri, görüntüyü oluşturan diğer tüm piksellerin sayısına bölünür. Bu işlem normalizasyon olarak adlandırılır ve genellikle piksel aralığını 0-1 arasında sınırlandırır. Kullanılan eşitlik Denklem 3.2'de verilmiştir. Bu işlem sayesinde histogram daha geniş bir aralığa yayılır.

Normalize edilmiş KDF kullanılarak piksellere yeni değerler atanır. Denklem 3.3'de verilen eşitlik, belirli aralığa sıkışmış piksel değerlerini daha geniş bir aralıkta hangi değerlere denk geleceğini hesaplar. Bu şekilde orjinal değerlerin genişletilmiş alandaki karşılıkları bulunur. Bu işlem görüntünün kontrastını artırır ve görüntüdeki küçük detayların ortaya çıkmasını sağlayarak modelin öğrenme sürecine ciddi katkı sunar.

Bu tez çalışmasında, verilerin kontrastını eşitlemek için histogram normalizasyonu uzantısı olan Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (CLAHE) metodu kullanılmıştır. Metodun uygulaması sonraki kısımda açıklanacaktır.


Kontrast Sınırlı Uyarlamalı Histogram Eşitleme (CLAHE): Geleneksel histogram eşitleme yöntemleriyle karşılaştırıldığında Kontrast Sınırlı Uyarlamalı Histogram Eşitleme (CLAHE), aşırı parlak veya karanlık bölgelerin yapısını bozmadan kontrastı daha etkili bir şekilde artırır. Bu yöntem özellikle düşük kontrastlı alanlarda daha ayrıntılı ve daha net görüntüler elde edilmesini sağlar. Görüntü belirtilen boyutta daha küçük bölümlere ayrılır ve her bir bölüme birbirinden bağımsız olarak histogram eşitleme uygulanır. Bu çalışmada görüntüleri bölümlendirmek için 8x8 piksellik bir ızgara kullanılmıştır. Daha sonra her bölümde histogram eşitleme aşağıdaki şekilde gerçekleştirilir:

$$H(v) = \text{round} \left(\frac{(L-1)}{N} \sum_{i=0}^v h(i) \right) \quad (3.4)$$

Denklem 3.4 her bir gri seviyesindeki piksel yoğunluklarını toplar (kümülatif dağılım), bu toplamı görüntü genelindeki piksel yoğunluğuyla karşılaştırır (normalize eder) ve ardından yeni gri seviye değerini oluşturur (ölçekleme). Şekil 3.3 ve Şekil 3.4’de sırasıyla normalizasyon uygulanmadan ve uygulandıktan sonraki akciğer görüntüleri verilmiştir. Şekil 3.5 ve Şekil 3.6 ise görüntülerin piksel dağılımlarını ifade etmektedir.

CLAHE uyarlamalı bir yöntem olduğu için histogram eşitleme tüm görüntü üzerinden değil de görüntünün bölünmüş alt parçalarına yapılır ve her bölge birbirinden bağımsız olarak normalize edilir. Bu alt parçalara kontrast sınırlama işlemi uygulanarak elde edilen kümülatif yoğunluk değerlerine karşılık bir tepe noktası belirlenir ve bu noktayı aşan pikseller yeniden ölçeklendirilir. Denklem 3.5’e göre, yerel histogram eşitlemesi sırasında hesaplanan kontrast değeri $H_R(v)$, T ’yi aşarsa, kontrast sınırlanır ve $H_R(v) = T$ olarak belirlenir. Bu sayede, görüntüdeki kontrast aşırı derecede artırılmadan görsel kalite korunmuş olur. Bu tez çalışmasında tepe noktası 2 olarak ayarlanmıştır.


$$H'_R(v) = \min(H_R(v), T) \quad (3.5)$$




Şekil 3.3: CLAHE Öncesi



Şekil 3.4: CLAHE Sonrası



Şekil 3.5: CLAHE öncesi piksel dağılımı



Şekil 3.6: CLAHE sonrası piksel dağılımı

3.2.1.3. Veri Artırımı

Veri setlerindeki orjinal örneklerin belirli kurallar çerçevesinde farklı yaklaşımlar kullanılarak çoğaltılmasına veri artırımı adını veriyoruz. Veri artırımı genellikle az sayıda örnek içeren veya örneklerin çeşitlilik bakımından yetersiz olduğu durumlarda model performansını artırmak için uygulanan en yaygın ön işlem tekniklerinden biridir.

Bu tez çalışmasında veri kümesi boyutunu artırmak için veri artırma yoluyla her bir veri setinde 600 artırılmış görüntü oluşturuldu. Montgomery+Shenzhen veri setinde örnek sayılarını eşitlemek için sadece Montgomery verisinde veri artırımı uygulandı. Uygulanan artırma teknikleri arasında yatay çevirme, rastgele 15 derece döndürme ve yakınlaştırma yer alıyor. Orijinal görüntüleri çeşitli açılardan döndürerek ve yakınlaştırarak oluşturulan yeni örnekler artırılmış veri olarak adlandırılır.

Derin öğrenme modellerinde segmentasyon genellikle kenar algılama kullanılarak gerçekleştirilir. Örneğin orijinal görüntüyü 15 derece döndürmek ağın öğrendiği kenar konumlarını değiştirir ve modelin daha geniş bir varyasyon aralığını tanımasını ve çeşitli verileri işleme yeteneğini iyileştirmesini sağlar. Tablo 3.2’de bahsedilen artırma

işlemlerinden sonra TB ve normal sınıf için elde edilen veri sayıları özetlenmiştir.

Tablo 3.2: Veri Artırımı Sonrası Örnek Sayıları

Veri Seti	Normal Görüntü Sayısı	TB Görüntü Sayısı	Veri Artırma Sonrası Normal Görüntü Sayısı	Veri Artırma Sonrası TB Görüntü Sayısı	Toplam Görüntü Sayısı
Montgomery County (ABD)	80	58	345	255	738
Shenzhen (Çin)	326	336	306	294	1262
Montgomery+Shenzhen	406	394	336	264	1400
Tüberküloz (TB) Göğüs Röntgeni Veri tabanı	406	394	303	297	1400

3.3. DENSENET MODELİ

Yoğun Bağlantılı Evrişimsel Ağları (Densely Connected Convolutional Networks - DenseNet) ilk kez 2017 yılında Gau Huang ve arkadaşları tarafından önerildi [74]. Geliştirilen model katman sayısı arttıkça modelin öğrenme sürecinde meydana gelen karmaşıklığı yoğun bağlantı metotlarını kullanarak çözmüştür. Diğer evrişimli sinir ağlarından farklı olarak DenseNet mimarisi yoğun blok denilen yapılara sahiptir. Yoğun bloklar, içerisinde bir veya daha fazla evrişim katmanını barındıran ve her katmanın birbirine doğrudan bağlı olduğu bir yapıda bulunur. Yoğun blokların bu yapısı sayesinde ilk katmandan son katmana kadar olan süreçte bilgi kaybı en aza iner. Ayrıca bu yapı kaybolan gradyan sorununa doğrudan bir çözüm sunmuştur. Kaybolan gradyan problemi modelin eğitim sırasında ağırlıklarının güncellerken gradyanın çok küçük değerlere inmesiyle ortaya çıkar. Bu, hatanın geriye yayılımında türev alma işleminin zorlaşması ve öğrenme sürecinin bir noktadan sonra devam etmemesine neden olur. DenseNet modeli derin sinir ağlarının avantajlarından yararlanırken derinliğin getirdiği zorlukların da üstesinden gelir.

DenseNet algoritmasında her katman diğer katmanlarla ileri beslemeli bir şekilde bağlıdır; bu her katmanın çıktılarını doğrudan sonraki katmanlara iletmesi anlamına gelir. Girdi verisi x_0 olarak ifade edilir ve girdi verisinin i -inci katmandaki çıktısı x_i 'dir. Denklem 3.6 bir katmanın çıktısının, katmanları temsil eden H fonksiyonu aracılığıyla kendisinden önceki tüm katmanların çıktılarının birleşimi kullanılarak hesaplandığını ifade eder. Bu sayede model kolektif bir bilgi oluşturmuş olur.

$$x_i = H([x_0, x_1, \dots, x_{i-1}]) \quad (3.6)$$

3.3.1. Yoğun Bloklar

Her yoğun blok belirli sayıda katmanın bir araya gelmesiyle oluşur. Yoğun blokların çıktısı genellikle veri örneklerine sırasıyla evrişim, toplu normalleştirme, aktivasyon fonksiyonu ve birleştirme işlemi uygulanmasıyla elde edilir. DenseNet'te bulunan yoğun bloklarda her katman önceki katmanlardan gelen çıktıları alır, bu çıktıları birleştirir ve yeni bir özellik haritası oluşturur [75].

$$x_{\text{çıktı}} = [x_1, x_2, \dots, x_n]$$

Elde edilen nihai özellik haritası bir sonraki katmana giriş verisi olarak aktarılır ve bu şekilde devam eder.

$$x_{\text{girdi}} = [x_1, x_2, \dots, x_n]$$

Her bir yoğun blok birkaç evrişim katmanından oluşur. Bu katmanlar genellikle küçük filtreler (3x3, 1x1) kullanarak özellik haritalarını üretir. Bloktaki evrişim katmanlarının çıktıları birleştirilerek sonraki katmanlara aktarılır. Her evrişim modülünde çıkarılan özellik haritası sayısı k ile ifade edilen büyüme oranı ile belirlenmiştir. Büyüme oranı modelin derinliğinin artması ile birlikte her konvolüsyon işlemi sonunda elde edilen özellik haritalarının kontrollü bir şekilde artmasını sağlamaktadır. k_0 , bir önceki katmandan gelen özellik sayısını ifade eder. Denklem 3.7'de i -inci katmanın çıktı özellik haritası sayısını ifade eden eşitlik verilmiştir.

$$n_{\text{özellik}} = k_0 + (i - 1) \times k \quad (3.7)$$

DenseNet'in en önemli avantajıda katman sayısı arttıkça parametrelerin gereksiz şekilde


çoğalmasını engellemektir. DenseNet mimarisindeki yoğun bloklar sayesinde öğrenme süreci daha etkin bir hale gelmektedir.

3.3.2. Geçiş Katmanı

Geçiş katmanı evrişim ve ortalama havuzlama katmanından oluşan, yoğun blok girişini ve çıkarılan tüm özellik bilgilerini sıkıştıran, özellik haritalarının boyutsallığını azaltan, yoğun blok parametrelerinin sayısını etkili bir şekilde azaltabilen komşu yoğun bloklar arasındaki yapıdır. Yoğun bloklar arasındaki özellik haritalarının boyutunu en aza indirerek ağırlık etkili bir şekilde büyümesini ve bloklar arasındaki geçişi sağlar. DenseNet modelinin parametre sayısını azaltma yeteneği bu katmanlardan gelir. Her yoğun bloğun sonunda özellik haritalarının sayısı, girdi özellikleri + (yoğun katman sayısı x büyüme oranı) kadar artar. Bu kanal sayısını azaltmak için iki yoğun blok arasına bir geçiş katmanı eklenir. Bu sayede yoğun bloklar arasındaki boyut uyumu sağlanmış olur.

DenseNet'in üç farklı versiyonu bulunmaktadır: DenseNet-121, genel amaçlı nesne tespiti için kullanılır, DenseNet-169, DenseNet121'e göre daha gelişmiş bir analiz imkanı sunar. DenseNet-201, ayrıntılı bilgiler çıkararak çok daha yüksek kesinlikte analizler yapar. Bu versiyonlardaki sayılar her modelin ağırlığında bulunan katman sayısını ifade etmektedir. Bu tez kapsamında DenseNet201 modeli çalışılmıştır. Modelin mimarisi Şekil 3.7'de verilmiştir.

Şekilden görüldüğü gibi birinci yoğun blok 6, ikinci yoğun blok 12, üçüncü yoğun blok 48 ve dördüncü yoğun blok 32 evrişim katmanına sahiptir. Her yoğun blokta iki farklı filtre boyutunda evrişim katmanı olduğundan toplam katman sayısı 196'dır. Bunlara ek olarak 5 adet havuzlama katmanı bulunur ve toplamda 201 katman elde edilir.



Şekil 3.7: DenseNet201 Mimarisi [11]


Model 64 filtreye sahip 4×4 boyutunda temel bir evrişim katmanı ile başlar. Adım sayısı 2 olan 3×3 boyutunda maksimum bir havuzlama katmanı eklenir. Temel yapı bir normalizasyon katmanı, aktivasyon katmanı ve bunları takip eden evrişim katmanı şeklindedir. Bu adımlar yoğun blok içinde de izlenir. Özellik haritalarını elde etmek için her yoğun blokta iki aşamalı bir evrişim işlemi gerçekleştirilir. İlk olarak genel özellikleri çıkarmak için giriş verilerine 1×1 evrişim filtresi uygulanır ardından daha derin özellikleri çıkarmak için 3×3 filtresi kullanılarak yeni bir özellik haritası matrisi oluşturulur. Elde edilen özellik haritaları yoğun bağlantılar aracılığıyla yoğun blok içinde birleştirilir. Sonraki yoğun katmana geçmeden önce geçiş katmanları aracılığıyla 1×1 evrişim filtresi ile bilgi kaybı olmadan özellik haritalarının boyutu azaltılır. Model iki dolgu katmanı içermektedir. İlk dolgu katmanı 4×4 evrişim katmanından hemen öncedir ve sıfır dolgu boyutu 3×3 'tür. Bu katman, çıktı boyutunu ayarlamak için eklenmiştir. İkinci sıfır dolgu katmanı maksimum havuzlamadan önce kullanıldı. Bu katman, ölçek küçültmeden önce kenar piksellerini korumak için eklendi. Modelde dört yoğun blok ve bunları takip eden üç geçiş katmanı bulunur. Son adımda model çıktıların elde edildiği bir sınıflandırma katmanı eklenmiştir.

3.3.3. Hibrit Evrişim Katmanı

ESA modellerinde üst düzey bilgilerin çıkarılması için geliştirilen modeller farklı sayıda evrişim katmanlarıyla donatılır. Katman sayısının artması modelin daha başarılı sonuçlar üreteceğine olan inancı arttırsa da bu aynı zamanda eğitilmesi gereken daha fazla parametre sayısı anlamına gelir. Bu durum genellikle yüksek işlem gücü gerektirmekle birlikte çoğu zaman modelin eğitim verisine aşırı uyum sağlaması şeklinde sorunlara neden olur. Aşırı uyum, modelin eğitim verisinde iyi sonuçlar elde etmesi fakat benzer başarıyı test verisinde gösterememesidir. Bu tez çalışmasında, DenseNet201 modeline, TB tespitindeki başarısını artırmak amacıyla evrişim katmanlarının faydalarından yararlanıldığı ve dezavantajlarının en aza indirildiği hibrit evrişim katmanı eklenmesi önerilmiştir.

Mevcut DenseNet201 modeli Bölüm 3.3'de açıklanmıştır. Şekil 3.7'de verilen yapıya 1.yoğun bloktan önce ve havuzlama katmanından sonra olmak üzere, 32 adet 3×3 ve 64 adet 5×5 filtreden oluşan hibrit bir evrişim katmanı eklenerek model optimize edilmiştir. Bu katman, birleştirme fonksiyonunu kullanarak iki evrişim katmanının çıktılarını birleştirmek ve bu birleştirilmiş çıktıyı sonraki katmana iletmek üzere ayarlandı. Evrişim filtrelerinin değerleri rastgele başlatılarak eğitim boyunca güncellenmiştir. Birleştirme fonksiyonu, iki

evrişim katmanından elde edilen özellik matrislerini toplayarak yoğun bloğa girdi olarak iletir. Amaç tüberküloz gibi zorlu tanı vakalarında hastalığı gösteren hedef pikselleri daha iyi ayırt etmektir. Birleştirme işlemi nedeniyle modeldeki parametre sayısı artsa da karmaşıklık hala kontrol edilebilir durumdadır. Hibrit evrişimsel katman sayesinde modelin sınıflar arasında ayırım yapma yeteneğinde bir iyileşme gözlemlenmiştir. Önerilen yapının mimarisi Şekil 3.8’de verilmiştir.



Şekil 3.8: Hibrit Evrişim Katmanı

3.4. MODEL HİPERPARAMETRELERİ

Derin öğrenme veya makine öğrenmesi tabanlı algoritmalarda modelin çarklarını döndüren tetikleyicilere model hiperparametreleri denir. Algoritmayı oluşturan kişi tarafından ayarlanan bu parametreler kullanılan veri setine ve problem türüne göre değişkenlik gösterir. En uygun parametre seçimleri deneme yanılma yoluyla veya çeşitli hiperparametre optimizasyonu algoritmalarıyla yapılır. Modelde kullanılan hiperparametreler; öğrenme oranı, optimizasyon algoritması, kayıp fonksiyonu, aktivasyon fonksiyonu, ağırlık başlangıç değerleri, eğitim ve test seti bölme oranı, küme boyutu ve eğitim tur sayısı şeklinde sıralanır. Bu bölümde çalışmada kullanılan parametreler açıklanacaktır.

3.4.1. Eğitim Tur Sayısı

Evrişimsel sinir ağı modellerinde eğitim süreci tüm veri seti üzerinden birden fazla kez gerçekleşir. Modelin tüm veri setini kaç defa işleyeceği belirlenen eğitim tur sayısı tarafından ifade edilir. Her eğitim turunda, veri setinin içeriği hakkında daha fazla bilgi çıkarılır, modelin veriyi yeteri kadar görmesi ve öğrenmesi sağlanır. Eğitim tur sayısının çok yüksek

veya çok düşük olması modelin test başarısına doğrudan etki eder. Bu nedenle uygun bir değerin belirlenmesi oldukça önemlidir. Düşük belirlenmiş bir eğitim tur değeri modelin veriyi tam olarak öğrenememesine sebep olurken yüksek tur sayısı modelin veriye aşırı uyum sağlamasına yol açar.

Bu tez çalışmasında, literatürdeki çalışmalar da göz önüne alınarak 100 eğitim tur sayısında eğitim gerçekleştirilmiştir.

3.4.2. Küme Boyutu

Tüm veri seti model tarafından tek seferde işlenmez. Bunun yerine veri seti belirli miktarda alt gruplara (kümelere) bölünerek öğrenme işlemi gerçekleştirilir. Eğitim sırasında model, her küme için bir kayıp fonksiyonu hesaplar ve bu fonksiyonun sonucuna göre modelin ağırlıkları güncellenir. Modelin her eğitim tur döneminde bu ağırlıkları güncellemesi küme boyutuna bağlı olarak belirli sayıda iterasyon sonucunda gerçekleşir. İterasyon sayısı veri boyutunun küme boyutuna bölünmesiyle bulunur. Örneğin 400 tane verinin olduğu bir veri setinde küme boyutu 100 olarak seçildiyse, model, her eğitim turu döneminde veri setini 100'er örnekten 4 gruba ayırarak eğitim işlemini gerçekleştirir. Bu durumda bir eğitim tur döngüsünde veri seti 4 iterasyonda işlenmiştir denir. Bu süreçte modelin ağırlıkları bir sonraki eğitim turuna geçmeden önce her iterasyon sonunda güncellenir.

Küçük küme boyutları (2,4) modelin her adımda daha fazla iterasyonda eğitilmesine neden olacağı için ağırlıkların daha sık güncelleneceği anlamına gelir. Bu, eğitimin daha dengesiz ilerlemesine ve modelin genelleme yeteneğinin gelişmemesine sebep olabilir. Büyük küme boyutlarında (örneğin 64, 128) ise daha az ağırlık güncellemesi yapılır. Ancak büyük küme boyutları oldukça fazla bellek kullanımı gerektirir ve eğitimin süresinin uzamasına yol açar. En uygun küme boyut değeri, veri setinin yapısına bağlı olarak deneme yanılma yoluyla veya optimizasyon algoritmaları ile belirlenir.

Tez çalışması kapsamında birden fazla küme boyutu değeri test edilmiş ve optimum değer olarak 8 seçilmiştir.

3.4.3. Öğrenme Oranı

Uygun bir şekilde ayarlanmış öğrenme oranı modelin kayıp fonksiyonunun minimum değere ulaşmasını sağlar. Başlangıç değeri olarak genellikle deneme yanılma yoluyla en uygun öğrenme oranı seçilir veya eğitim sırasında dinamik olarak değişen bir öğrenme oranı ayarlama metodu kullanılabilir. Bunu sağlamak için çeşitli algoritmalar geliştirilmiştir. Örneğin ReduceLRonPlateau metodu eğitim sürecinde modelin öğrenmeyi durdurduğu veya performans düşmeye başladığı anda eğitimle eş zamanlı olarak öğrenme oranını kademeli bir şekilde azaltır [76]. Hedef modelin daha küçük değişimlerle optimum noktaya yaklaşmasını sağlamaktır. Bunun için eğitim sırasında doğruluk veya kaybın gidişatını baz alarak faktör ve sabır parametrelerine göre öğrenme oranını günceller. Örneğin başlangıç öğrenme oranı değeri 0.1 olarak ayarlanmışsa ve sabır değeri kadar ilerleyen eğitim turu boyunca (örneğin 3 eğitim turu) eğitim kaybında herhangi bir değişiklik olmazsa, yani model öğrenmeye devam edemiyorsa, öğrenme oranı faktör değeri olan 0.1 gibi bir değer ile çarpılarak 0.01'e düşürülür. Bu sayede büyük adımlarla güncellenen ağırlıkların daha hassas güncellenmesi ve modelin öğrenmeye devam etmesi sağlanır. Beklenen durum eğer model ağırlıkları gerektiği gibi güncelleyemediği için optimum noktaya ulaşamıyorsa geçerlidir. Öte yandan modelin yetersizliği veya veri setiyle uyumsuzluğu gibi diğer etkenler modelin başarısının artmasına engel olabilir. Bu durumda ReduceLRonPlateau yöntemi başarıyı artırmada kesin çözüm olmaz.

Bu tez çalışmasında ReduceLRonPlateau yöntemi kullanılmıştır. Başlangıç öğrenme oranı 0.0001 ve en düşük 0.000001 olacak şekilde ayarlanmıştır. Eğitim sırasında kayıp fonksiyonu izlenmiş ve en fazla 2 eğitim turu (sabır) boyunca değişim gözlemlenmezse öğrenme oranı 0.1 (faktör) ile çarpılarak kademeli bir şekilde azaltılmıştır.

3.4.4. Optimizasyon Algoritması

Optimizasyon algoritmaları modelin eğitimi boyunca yaptığı hataların en düşük seviyeye gelmesi için kullanılır. Bunun için model ağırlıklarını eğitim döngüleri boyunca güncellenmesini sağlar. Sıklıkla kullanılan optimizasyon algoritmaları; Adam, RMSProp, Adagrad, SGD ve Adadelatadır [77]. Bu tez çalışmasında, aşağıda açıklanan avantajlar göz

önüne alındığından optimizasyon algoritması olarak Adam tercih edilmiştir.

Adam (Adaptive Moment Estimation): Adam optimizasyon algoritması verimli bellek tüketimi, büyük ve gürültülü veri setlerinde kullanıma uygun olması nedeniyle diğer optimizasyon algoritmalarına göre daha avantajlıdır. Adam öğrenme hızını her parametre için ayrı ayrı uyarlayarak hesaplar. Bu işlem için ilk moment olarak adlandırılan gradyanların (kayıp fonksiyonunun belirli noktalardaki değişimine gradyan denir) üstel ortalaması hesaplanır. Üstel ortalama önceki gradyanların bilgilerini taşır ancak daha yeni gradyanlara daha fazla ağırlık verir. Bu süreç momentum yöntemi olarak bilinir ve parametre güncellemelerini daha kararlı hale getirir. Momentum, dalgalanmaları azaltarak parametrelerin daha doğru bir yönde ilerlemesine olanak tanır ve bu sayede optimizasyon sürecinde daha hızlı yakınsama sağlanır [78].

3.4.5. Kayıp Fonksiyonu

Önceki bölümlerde de genel tanımı verilen kayıp fonksiyonu modelin tahmin hatalarını ölçen bir fonksiyon olarak tanımlanır. Gerçek değerler ve tahminler arasındaki farkı azaltmak için kayıp fonksiyonunun hesaplanması ve geriye yayılım algoritmaları gibi optimizasyon işlemleriyle birlikte kullanılması gerekir. Optimizasyon algoritmalarıyla en sık kullanılan kayıp fonksiyonları; ortalama kare hata, çapraz entropi kaybı ve Hinge kayıp fonksiyonlarıdır [79].

Bu tez çalışmasında ikili çapraz entropi ve odak kayıp fonksiyonları kullanılmıştır.

İkili Çapraz Entropi: İkili çapraz entropi sınıflandırma problemlerinde gerçek sınıfların ve tahmin sınıflarının arasındaki mesafeyi ölçer. Tahmin değerleri gerçek verilere ne kadar yakınsa ikili çapraz entropi kaybı o kadar düşük olur. Öte yandan doğru sınıf için tahmin edilen olasılık değerleri ne kadar düşükse uygulanan ceza o kadar büyük olur.

Denklem 3.8’de, logaritmik kayıp fonksiyonu olarak da bilinen ikili kayıp fonksiyonunu verilmiştir. y_i terimi verilerin gerçek etiketini ifade eder. $\hat{y}_i$ terimi ise model tarafından hesaplanan ve her bir örnek için pozitif sınıf olasılığını temsil eden değişkendir. Kayıp fonksiyonunun hesaplanması için Denklem 3.8’e logaritma fonksiyonu eklenmiştir. Logaritma fonksiyonu sürekli ve diferansiyellenebilir bir fonksiyondur ve kayıp fonksiyonunda parametreleri güncellerken türevin alınmasını sağlar. $(1 - y_i)$ ifadesinde eğer

tahmin sınıfı 1 ise bu ifade sıfır olur ve negatif sınıfın kayba etkisi ortadan kalkar. Aynı şekilde 0 etiketi için ifade 1 olur. Logaritma fonksiyonunda belirli sınıf için doğru tahmin olasılığı ne kadar yüksekse $\log(1 - \hat{y}_i)$ o kadar düşük olur.

$$L = -\frac{1}{n} \sum_{i=1}^n [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (3.8)$$

Dengesiz veri setlerinde her veri örneği için hesaplanan kayıp değeri modelin genel performansının anlaşılmasında yanıltıcı sonuçlar verir. Eğitilen model örnek sayısı bakımından daha fazla olan bir sınıf için bu sınıftaki örneklerle aşırı uyum sağlıyor ve azınlıktaki sınıf için hata payı yüksek tahminler yapıyorsa ikili çapraz entropinin yerine sınıf dengesizliğini ele alan Odak kayıp fonksiyonu kullanılmaktadır.

Odak Kayıp Fonksiyonu: Odak kaybı ikili çapraz entropinin özelleştirilmiş halidir. Denklem 3.9'da Odak kaybın formülü verilmiştir. (p_t) ifadesi gerçek sınıf etiketi için tahmin edilen etiketin olasılık değeridir. α_t ifadesi azınlık sınıfın genel performansa etkisini artırmak için ayarlanan bir parametredir. γ değişkeni doğru tahminlerin etkisini azaltıp hatalı tahminlere odaklanma kuvvetini belirten bir katsayıdır. Odak kaybı modelin yüksek doğrulukla yaptığı tahminler yerine sınıflandırmakta zorlandığı örneklerle odaklanılmasını sağlar. Bu sayede kayıp fonksiyonunu ikili çapraz entropiye göre daha fazla minimize eder [80].

$$(p_t) = -\alpha_t \cdot (1 - p_t)^\gamma \cdot \log(p_t) \quad (3.9)$$

4. BULGULAR

Tez çalışması kapsamında dört farklı veri seti ile altı farklı durum ele alınmış ve her bir durum tek tek incelenerek bulgular karşılaştırılmıştır. İlk olarak, mevcut DenseNet201 modeli ham verilerle eğitilmiştir. İkinci durumda, veri artırma yöntemleri uygulanarak model performansı değerlendirilmiştir. Üçüncü durum olarak, veri artırmanın yanı sıra görüntülere CLAHE normalizasyonu uygulanmış ve performans üzerinde yarattığı etkiler ölçülmüştür. Dördüncü durumda modelin performansını daha da optimize etmek amacıyla hibrit evrişim katmanı eklenmiş ve bu yeni yapı veri artırımı ile birlikte test edilmiştir. Beşinci durum olarak hibrit evrişim katmanı ile geliştirilmiş DenseNet201 modeli veri artırımı sonrası CLAHE uygulanmış görüntülerle eğitilmiştir. Son olarak altıncı durumda, beşinci durumdaki işlemlere 5 katlı çapraz doğrulama uygulanarak sonuçların güvenilirliği ve genelleme kapasitesi test edilmiştir.

Model 100 eğitim turu boyunca 8 küme boyutuyla eğitilmiştir. Veri setinin %85'i eğitim, %15'i test verisi olarak ayrılmış, ayrıca eğitim setinin %25'i doğrulama verisi olarak kullanılmıştır. Optimizasyon algoritması olarak Adam tercih edilmiş, kayıp fonksiyonu olarak odak kayıp fonksiyonu ve ikili çapraz entropi test edilmiştir. Sınıflandırma işlemi için sigmoid aktivasyon fonksiyonu kullanılmıştır. Öğrenme oranı ReduceLRonPlateau metoduyla başlangıçta 0.0001 olarak belirlenmiş ve kademeli bir şekilde 0.000001'e düşecek şekilde ayarlanmıştır. Model hiperparametreleri hakkında detaylı bilgilerden Bölüm 3.4'de bahsedilmiştir.

Tablo 4.1'de bu tez çalışmasında kullanılan parametrelerin özeti verilmiştir.

Bu bölümde, ilk olarak ikili çapraz entropi kayıp fonksiyonu ve odak kayıp fonksiyonu ile elde edilen sonuçlar karşılaştırılacaktır. Ardından odak kayıp fonksiyonu kullanılarak Montgomery County veri seti, Shenzhen veri seti, Montgomery+Shenzhen veri seti ve Tüberküloz Göğüs Röntgeni Veri Tabanı'ndan alınan veri seti için elde edilen sonuçlar açıklanacaktır. Veri setleri ile ilgili detaylı açıklamalar Bölüm 3.1'de verilmiştir. Çalışmanın performansı Bölüm 2.6'da bahsedilen model metrikleri kullanılarak değerlendirilmiştir.


Tablo 4.1: Model Parametreleri

HiperParametre	Değer
Öğrenme Oranı	0.0001 - 0.000001
Küme Boyutu	8
Eğitim Tur Sayısı	100
Eğitim/Test Oranı	%85/%15
Optimizer	Adam
Kayıp Fonksiyonu	İkili ÇE / Odak Kayıp
Aktivasyon Fonksiyonu	Sigmoid


4.1. İKİLİ ÇAPRAZ ENTROPİ VE ODAK KAYIP FONKSİYONU SONUÇLARI

Bu bölümde Montgomery, Shenzhen, Montgomery+Shenzhen ve TB Göğüs Röntgeni VT veri setlerinin ikili çapraz entropi ve odak kayıp fonksiyonuyla elde edilen sonuçları açıklanacaktır. Bölüm 3.4.5'te ikili çapraz entropi ve odak kayıp fonksiyonları detaylı bir şekilde açıklanmıştır. Şekil 4.1'de Montgomery County veri seti, Şekil 4.2'de Shenzhen veri seti Şekil 4.3'te Montgomery+Shenzhen veri seti ve Şekil 4.4'te Tüberküloz Göğüs Röntgeni VT'dan oluşturulan veri setinin her birine veri artırımı uygulandıktan sonra Densenet201 modelindeki eğitim ve doğrulama süreçlerine ilişkin performansı karşılaştırmalı olarak gösterilmektedir.


Dört veri seti için elde edilen doğrulama ve eğitim süreçlerine ilişkin grafikler incelendiğinde odak kayıp fonksiyonu sınıf dengesizliklerini daha etkili yönettiği ve parametre güncellemelerini daha tutarlı hale getirdiği için eğitim kaybını hızla minimize etmiş, doğrulama kaybını ise düşük tutmuştur. Bu durum doğrulama kümesindeki doğruluğun daha istikrarlı olmasını sağlamıştır. Öte yandan ikili çapraz entropi ile eğitim doğruluğu hızla daha yüksek seviyelere ulaşmış olsa da doğrulama kümesinde her iki fonksiyon da yakın seviyelere ulaşarak odak kaybının daha iyi genelleme sağladığını ortaya koymuştur. İkili çapraz entropi Shenzhen ve Montgomery+Shenzhen veri setleri için aşırı uyum belirtileri gösterirken, odak kaybı sınıf hatalarını ağırlıklandırarak bu sorunu çözmüştür.




Şekil 4.1: Montgomery County Veri Seti için Eğitim ve Doğrulama Doğruluk/Kayıp Sonuçları



Şekil 4.2: Shenzhen Veri Seti için Eğitim ve Doğrulama Doğruluk/Kayıp Sonuçları



Şekil 4.3: Montgomery+Shenzhen Veri Seti için Eğitim ve Doğrulama Doğruluk/Kayıp Sonuçları



Şekil 4.4: Tüberküloz Göğüs Röntgeni VT Veri Seti için Eğitim ve Doğrulama Doğruluk/Kayıp Sonuçları

Tablo 4.2: Veri setleri için İkili Çapraz Entropi ve Odak Kaybı sonuçları

Veri Setleri	İkili Çapraz Entropi Kaybı					Odak Kaybı				
	Kesinlik	Duyarlılık	F1 Skor	Doğruluk	AUC	Kesinlik	Duyarlılık	F1 Skor	Doğruluk	AUC
Montgomery	%88	%96	%92	%93	%96,3	%100	%85	%92	%93	%97,6
Shenzhen	%91	%77	%84	%85	%92	%87	%85	%86	%86	%95
Montgomery + Shenzhen	%73	%85	%79	%79	%88,8	%87	%83	%85	%87	%91,9
TB Göğüs Röntgeni VT	%99	%97	%98	%98	%99	%100	%94	%97	%97	%99,6

Tablo 4.2’de elde edilen sonuçlar özetlenmiştir. Bulgular, odak kayıp fonksiyonunun daha hızlı bir şekilde minimize olduğunu ve kesinlik bakımından daha iyi sonuçlar verdiğini göstermektedir. Odak kayıp fonksiyonu model performansını düşüren örnek tahminleri için daha spesifik çözümler sunduğundan büyük hataların modelin genel performansını etkisini azaltmayı başarır. Bu sayede ikili çapraz entropiye kıyasla aşırı uyumu engellemiş ve pozitif sınıf için daha güvenilir tahminler yapılmasını sağlamıştır.


4.2. MONTGOMERY COUNTY VERİ SETİ SONUÇLARI

Montgomery County (MC) veri seti 80 Normal ve 58 TB olmak üzere toplamda 138 görüntü içermektedir. Veri seti ile önerilen yaklaşımlar test edilmiş ve performanslar değerlendirilmiştir. Altı farklı durum için elde edilen bulgular sırasıyla tartışılacaktır.

Veri Artırımı Uygulanmadan Önce Elde Edilen Sonuçlar - Ön İşlemsiz


DenseNet201 modeli 138 örnek içeren MC veri seti ile eğitilmiştir. Modelin Tüberküloz (TB) ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performansı Şekil 4.5’de verilmiştir. Kayıp fonksiyonu grafiğinde eğitim kaybı 10.eğitim turundan itibaren 0’a yakınsarken doğrulama kaybı yüksek kayıp değerlerine çıkıp yaklaşık 50.eğitim turundan sonra ortalama 0.15’de stabilize olmuştur. Eğitim ve doğrulama doğruluğunda eğriler arasındaki mesafe modelin eğitim verisine aşırı uyum sağladığını göstermiştir. Her iki dağılım incelendiğinde modelin veri setindeki kalıpları öğrenemediği yani mevcut veri setinin modelin parametrelerini destekleyecek kadar bilgi içermediği anlaşılmıştır.

Tablo 4.3’de özetlenen metriklere göre ilk durumda pozitif sınıf için kesinlik ölçütü 1.0



Şekil 4.5: Ham MC Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri


iken duyarlılık 0.75 olarak elde edilmiştir. F1 skoru 0.86'dır. Test verisi için doğruluk değeri 0.90 olarak bulunmuştur. Ağın sınıfları birbirinden ayırt etme oranını ifade eden AUC değeri 0.856 olarak ölçülmüştür. Test verisindeki 21 örnek üzerinden yapılan tahminler için hata matrisi Şekil 4.6'da verilmiştir. Model, test verisindeki Normal tahminlerinin tümünde başarılı olmuştur ancak TB sınıfı için 2 tane hatalı tahmin yapmıştır. Bu sonuçlar, modelin duyarlılık açısından iyileştirme potansiyeli olduğunu göstermektedir. Modelin genel performansı literatürdeki benzer çalışmalara kıyasla rekabetçi bir başarı ortaya koysa da daha fazla optimizasyon çalışmasıyla duyarlılığın artırılabilceği öngörülmektedir.



Şekil 4.6: Ham MC Veri Setiyle Test Seti için Hata Matrisi


Veri Artırımı Uygulandıktan Sonra Elde Edilen Sonuçlar

DenseNet201 modeli, 138 örnek içeren Montgomery veri setine veri artırma uygulanmasının ardından eğitilmiştir. Veri artırımı sonucunda toplam veri sayısı 738'e yükselmiştir. Modelin veri artırma uygulandıktan sonra Tüberküloz (TB) ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performansı Şekil 4.7'de verilmiştir. Veri artırımı sonrası modelin veri örneklerinden elde edilen özellik temsillerini daha iyi genellediği görülmüştür. Eğitim ve doğrulama doğruluğu paralel bir şekilde artarken kayıp oranları tutarlı bir şekilde azalmıştır. Doğrulama kaybı başlangıçta yüksek olsa da yaklaşık ilk 10 eğitim turundan sonra 0'a yakınsaması modelin veri setine hızlı bir şekilde uyum sağladığını göstermiştir.



Şekil 4.7: Veri Artırımı Sonrası MC Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri


Tablo 4.3'de özeti sunulan metriklerin değerleri şu şekildedir: Pozitif sınıf için kesinlik metriği 1.0'dir. Duyarlılık veri artırma işleminden sonra %10 artarak 0.85'e ulaşmıştır. F1 skoru %6 iyileşme ile veri artırımı sonrası 0.92 iken modelin test verisindeki doğruluk değeri 0.93 olarak elde edilmiştir. Veri artırma işlemi sonucunda AUC değeri 0.976'ya yükselmiştir. Şekil 4.8'de test verisindeki 111 örnek üzerinden tahmin sonuçlarını gösteren hata matrisi verilmiştir. Model, Normal tahminlerinin tümünde başarılı olmuştur ancak TB sınıfı için 8 tane hatalı tahmin yapmıştır. Bu gelişmeler modelin genel performansında ve sonuçların güvenilirliğinde belirgin bir iyileşme sağlandığını göstermektedir. Özellikle duyarlılık ve F1 skorundaki artış modelin pozitif sınıfları daha tutarlı ve etkili bir şekilde tanımlayabildiğini ortaya koymaktadır.



Şekil 4.8: Veri Artırımı Sonrası MC Veri Setiyle Test Seti için Hata Matrisi


Veri Artırımı ve CLAHE Uygulanarak Elde Edilen Sonuçlar

Veri artırımı ile birlikte görüntülere CLAHE normalizasyonu uygulandıktan sonra mevcut DenseNet201 modeli eğitilmiştir. Modelin Tüberküloz (TB) ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performansı Şekil 4.9’da verilmiştir. Görüntülere CLAHE uygulandıktan sonra modelin sınıflar arası ayırım yeteneği eğitim verisinde başarılı sonuçlar göstermiştir. Ancak eğitim sırasında elde edilen optimum ağırlık parametreleri doğrulama setinde aynı seviyeye ulaşmamıştır. Sonuçlar, modelin veri setine iyi uyum sağladığını fakat genelleme yeteneğinin eğitim setindeki başarılarına kıyasla sınırlı bir aralıkta kaldığını göstermiştir.



Şekil 4.9: Veri Artırımı ve CLAHE Sonrası MC Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri


Pozitif sınıf için kesinlik değeri 0.97’dir. Ancak CLAHE metodunun duyarlılık, F1 skoru ve test doğruluk değeri üzerinde belirgin bir artış sağlamadığı gözlemlenmiştir. Bununla birlikte CLAHE normalizasyonu AUC değerinde %1.5 puanlık bir artış sağlayarak modelin sınıflar arasındaki ayırım gücünü bir miktar iyileştirmiş ve AUC değeri 0.981 olarak ölçülmüştür. Bu yaklaşımda elde edilen metrikler Tablo 4.3’de özetlenmiştir. Şekil 4.10’da test verisindeki 111 örnek üzerinden tahmin sonuçlarını gösteren hata matrisi verilmiştir. Model, Normal tahminlerinin 1 tanesinde hatalıyken, TB sınıfı için 8 tane hatalı tahmin yapmıştır. Bu sonuçlar CLAHE normalizasyonunun genel ayırım performansı üzerindeki etkisine işaret etmekte ancak diğer metriklerde katkı sağlamadığını göstermektedir.



Şekil 4.10: Veri Artırımı ve CLAHE Sonrası MC Veri Setiyle Test Seti için Hata Matrisi


Veri Artırımı ve Hibrit Evrişim Katmanı Eklenecek Elde Edilen Sonuçlar

Veri artırma işleminden sonra mevcut DenseNet201 modeline Bölüm 3.3.3’de açıklanan hibrit evrişim katmanı eklenerek model eğitilmiştir. Modelin Tüberküloz (TB) ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performansı Şekil 4.11’de verilmiştir. Hibrit katmanı ile modelin daha fazla özellik çıkardığını ve sınıf temsilleri için daha fazla seçeneğe sahip olduğu düşünülürse modelin doğrulama setindeki örnekleri bu temsillere göre başarılı bir şekilde genellediği görülmüştür. Doğrulama kaybı buna bağlı olarak hızlı bir şekilde eğitim kaybı seviyesine yaklaşmıştır.



Şekil 4.11: Veri Artırımı ve Hibrit Evrişim Katmanı Sonrası MC Verisi Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri


Test doğruluğu 0.94 olarak ölçülmüş ve Tablo 4.3’de de gösterildiği gibi pozitif sınıf için kesinlik 1.0, duyarlılık 0.85 ve F1 skoru 0.92 elde edilerek önceki durumlara göre artış gözlenmiştir. Modelin sınıflar arasındaki ayırım yeteneğini ifade eden AUC değeri ise 0.983 olarak hesaplanmıştır. Şekil 4.12’de test verisindeki 111 örnek üzerinden tahmin sonuçlarını gösteren hata matrisi verilmiştir. Model, Normal tahminlerinin tümünde başarılı olmuştur ancak TB sınıfı için 7 tane hatalı tahmin yapmıştır. Bu sonuçlarla hibrit evrişim katmanının doğruluk ve ayırımı performansına sınıf ayırdımı bakımından bir katkı yaptığı gözlemlenmiştir.



Şekil 4.12: Veri Artırımı ve Hibrit Evrişim Katmanı Sonrası MC Veri Setiyle Test Seti için Hata Matrisi


Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Eklenecek Elde Edilen Sonuçlar

Hibrit evrişim katmanı eklenerek geliştirilen DenseNet201 modeli, veri artırımı sonucunda elde edilen 738 görüntüye CLAHE normalizasyonu uygulanarak eğitilmiştir. Modelin Tüberküloz (TB) ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performansı Şekil 4.13’de verilmiştir. Eğitim ve doğrulama doğruluklarının benzer yükseliş trendine sahip olması modelin eğitim setinde öğrendiği hipotezleri doğrulama setinde başarılı bir şekilde kullanabildiğini gösterir. Kayıp grafiği incelendiğinde başlangıçta doğrulama kaybındaki artışın ortalama ilk 5 eğitim turundan sonra minimize olduğu görülmektedir. Bu sonuçlar, modelin doğrulama setine daha hızlı adapte olabildiğini ve hataları daha erken optimize ettiği için genel performansı da daha fazla artırdığı anlaşılmıştır.



Şekil 4.13: Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Sonrası MC Verisi Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri

Pozitif sınıf için kesinlik metriği 1.0 olarak ölçülmüştür. Hibrit evrişim katmanı ve CLAHE metodunun birlikte uygulanması sonucunda duyarlılık %7’lik bir artışla 0.92’ye yükselmiştir. Bu iyileştirme modelin pozitif sınıfı tanıma kabiliyetinde anlamlı bir gelişme sağladığını göstermektedir. Ayrıca F1 skoru 0.96’ya ulaşırken, test doğruluk değeri en yüksek seviyeye çıkarak 0.96 olarak elde edilmiştir. Modelin sınıflar arasındaki ayırt etme yeteneğini ifade eden AUC değeri ise neredeyse mükemmel bir performansı temsil eden 0.999 olarak hesaplanmıştır. Şekil 4.14’de test verisindeki 111 örnek üzerinden tahmin sonuçlarını gösteren hata matrisi verilmiştir. Model, Normal tahminlerinin tümünde başarılı olmuştur ancak TB sınıfı için 4 tane hatalı tahmin yapmıştır. Bu sonuçlar hibrit evrişim katmanı ve CLAHE yönteminin model performansı üzerinde hem duyarlılık hem de genel doğruluk açısından kayda değer bir iyileştirme sağladığını ve modelin yüksek güvenilirlikte sınıflandırma yapabildiğini göstermektedir.



Şekil 4.14: Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Sonrası MC Veri Setiyle Test Seti için Hata Matrisi

Tablo 4.3’de Montgomery County veri seti ile uygulanan yaklaşımların sonuçları özetlenmiştir.

Tablo 4.3: Montgomery County Veri Seti Sonuçları

Uygulanan Teknikler	Kesinlik	Duyarlılık	F1 Skor	Doğruluk	AUC
Ön İşlemsiz	%100	%75	%86	%90	%85,6
Veri Artırma	%100	%85	%92	%93	%97,6
Veri Artırma + CLAHE	%97	%83	%89	%92	%98,1
Veri Artırma + Hibrit Evrişim Katmanı	%100	%85	%92	%94	%98,3
Veri Artırma + CLAHE + Hibrit Evrişim Katmanı	%100	%92	%96	%96	%99,9
Veri Artırma + CLAHE + Hibrit Evrişim Katmanı + 5 Katlı Çapraz Doğrulama	%94	%94	%94	%96	%99,4


Şekil 4.15’de, yapılan işlemlerin modelin tahmin başarısındaki gelişimini gösteren birleştirilmiş hata matrisi verilmiştir. Uygulanan yaklaşımların model performansı üzerindeki etkilerine bakıldığında Montgomery County verisi için en iyi sonuçlar hibrit evrişim katmanı ile geliştirilmiş DenseNet201 modelinin veri artırımı sonrası CLAHE normalizasyonu uygulanan görüntülerle eğitilmesiyle elde edilmiştir (1,2,3.durum).

1.durum : Veri artırımı uygulanarak elde edilen sonuçları,

1,2.durum : Veri artırımı ve CLAHE uygulanarak elde edilen sonuçları,


1,3.durum : Veri artırımı ve DenseNet201 modeline hibrit evrişim katmanı eklenerek elde edilen sonuçları,

1,2,3.durum : Veri artırımı, CLAHE ve DenseNet201 modeline hibrit evrişim katmanı eklenerek elde edilen sonuçları göstermektedir.



Şekil 4.15: Birleştirilmiş Hata Matrisi

Şekil 4.16’da Montgomery County veri seti için elde edilen ROC eğrileri verilmiştir. ROC eğrileri incelendiğinde, ham veri seti ile model ($AUC = 0.86$) en düşük performansı göstermiştir. Veri artırımı uygulandığında AUC değeri 0.98’e çıkarak modelin performansında belirgin bir iyileşme sağlanmıştır. CLAHE ile kontrast iyileştirmesi ve hibrit evrişimsel katman eklemeleri AUC’yi tek başına artırmamış, ancak veri artırımı, CLAHE ve hibrit evrişimsel katman birlikte kullanıldığında AUC 0.99’a ulaşarak en yüksek performans elde edilmiştir. Bu durum, ön işleme tekniklerinin kombinasyonunun modelin genelleştirme yeteneğini maksimize ettiğini göstermektedir.



Şekil 4.16: Tüm Durumlar İçin ROC Eğrileri

4.3. SHENZHEN VERİ SETİ SONUÇLARI


Shenzhen veri seti 326'sı Normal, 336'sı TB olmak üzere toplam 662 örnek içermektedir. Veri seti ile önerilen yaklaşımlar test edilmiş ve performansları değerlendirilmiştir. Altı farklı durum için elde edilen bulgular sırasıyla tartışılacaktır.

Veri Arttırımı Uygulanmadan Önce Elde Edilen Sonuçlar - Ön İşlemsiz


DenseNet201 modeli, 662 örnek içeren Shenzhen veri seti ile eğitilmiştir. Modelin Tüberküloz (TB) ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performansı Şekil 4.17'de verilmiştir. Eğitim sürecinde modelin eğitim doğruluğu artarken doğrulama doğruluğu yaklaşık ilk 10 eğitim turundan sonra sabit kalmıştır. Bu sabitlik modelin tahmin hatalarını güncelleyemediğini gösterir. Doğrulama kaybı eğrisinde ortalama 50. eğitim turundan sonraki hafif yükseliş modelin veri setine adapte olamadığını ve rastgele tahminler yapabilme potansiyeli olduğunu göstermiştir.

Tablo 4.4'de özetlenen verilere göre pozitif sınıf için kesinlik metriği 0.75, duyarlılık 0.89 ve F1 skoru 0.81 olarak hesaplanmıştır. Test verisinde model doğruluğu 0.82 olarak elde edilmiş sınıf ayırma performansını gösteren AUC değeri ise 0.929'dur. Şekil 4.18'de test verisindeki 100 örnek üzerinden tahmin sonuçlarını gösteren hata matrisi verilmiştir. Model, Normal sınıfında 13 ve TB sınıfında 5 hatalı tahmin gerçekleştirmiştir. Bu sonuçlar modelin doğruluk

ve sınıf ayırma performansının özellikle Normal sınıfındaki tahmin hataları nedeniyle daha ileri optimizasyon ayarlarına ihtiyaç duyduğunu göstermektedir.




Şekil 4.17: Ham Shenzhen Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri



Şekil 4.18: Ham Shenzhen Veri Setiyle Test Seti için Hata Matrisi


Veri Artırımı Uygulandıktan Sonra Elde Edilen Sonuçlar

DenseNet201 modeli, 662 veriye sahip Shenzhen veri setine veri artırımı uygulanmasının ardından eğitilmiştir. Veri artırımı sonrası toplam veri sayısı 1262'ye yükselmiştir. Modelin Tüberküloz (TB) ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performansı Şekil 4.19'da verilmiştir. Veri artırımı sonrası modelin hem doğrulama hem de eğitim setindeki doğruluk eğrilerine bakıldığında eğrilerdeki aşırı dalgalanma ile modelin her iki set için de yeteri kadar stabilize olamadığı görülmüştür. Kayıp eğrilerindeki fark incelendiğinde hataların geriye yayılım işleminde gradyanların güncellenemediği ve kayıp fonksiyonunun minimuma ulaşamadığı anlaşılmıştır.



Şekil 4.19: Veri Artırımı Sonrası Shenzhen Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri


Veri artırımı sonrasında pozitif sınıf için kesinlik metriği %12'lik artışla 0.87 olarak, duyarlılık %4'lük düşüşle 0.85, F1 skoru ise %5'lik artışla 0.86 olarak hesaplanmıştır. Test verisindeki doğruluk değeri 0.86'ya yükselmiştir. Modelin sınıfları ayırt etme becerisini ifade eden AUC değeri ise 0.95 olarak ölçülmüştür. Bu yaklaşımda elde edilen sonuçlar Tablo 4.4'te karşılaştırmalı olarak sunulmuştur. Şekil 4.20'de test verisindeki 190 örnek üzerinden tahmin sonuçlarını gösteren hata matrisi verilmiştir. Model, TB tahminlerinin 14'ünde, Normal sınıf örneklerinin 12'sinde hatalı tahmin yapmıştır. Bu sonuçlar, veri artırımı yönteminin modelin öğrenme kapasitesini artırdığını, negatif ve pozitif sınıf performansını belirli bir düzeyde iyileştirdiğini göstermektedir.



Şekil 4.20: Veri Artırımı Sonrası Shenzhen Veri Setiyle Test Seti için Hata Matrisi


Veri Artırımı ve CLAHE Uygulanarak Elde Edilen Sonuçlar

Veri artırımı ile birlikte görüntülere CLAHE metodu uygulandıktan sonra mevcut DenseNet201 modeli eğitilmiştir. Modelin Tüberküloz (TB) ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performansı Şekil 4.21’de verilmiştir. CLAHE normalizasyonundan sonra eğitim sürecinde görüntülerden yüksek seviye özelliklerin elde edilebildiği fakat bu özellikleri doğrulama seti gibi farklı örnekler için genellenemediği görülmüştür. Kayıp eğrilerindeki geniş makas aralığı aşırı uyumun teknik bir göstergesidir.



Şekil 4.21: Veri Artırımı ve CLAHE Sonrası Shenzhen Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri


Pozitif sınıf için kesinlik metriği 0.85 olarak ölçülmüştür. Bununla birlikte duyarlılık %8’lik azalarak 0.77 seviyesine gerilemiştir. Benzer şekilde F1 skoru da doğruluk metriğiyle paralel bir şekilde %5’lik düşüş göstererek 0.81 olarak hesaplanmıştır. Modelin sınıfları ayırt etme becerisini temsil eden AUC değeri ise belirgin bir azalışla 0.868 olarak kaydedilmiştir. Şekil 4.22’de test verisindeki 190 örnek üzerinden tahmin sonuçlarını gösteren hata matrisi verilmiştir. Model, TB tahminlerinin 23’ünde başarısız olurken, Normal sınıf için 13 tane hatalı tahmin yapmıştır. Bu sonuçlar CLAHE yönteminin belirli veri koşullarında sınıf ayırma performansını olumsuz etkileyebileceğini ve modelin pozitif sınıfları tanıma yeteneğinde bir gerilemeye yol açabileceğini göstermektedir. Sonuçların CLAHE yönteminin model performansı üzerindeki etkilerinin daha kapsamlı analiz edilmesi gerektiğine işaret ettiği söylenebilir.



Şekil 4.22: Veri Artırımı ve CLAHE Sonrası Shenzhen Veri Setiyle Test Seti için Hata Matrisi


Veri Artırımı ve Hibrit Evrişim Katmanı Eklenerek Elde Edilen Sonuçlar

Veri artırma işleminden sonra mevcut DenseNet201 modeline hibrit evrişim katmanı eklenerek model eğitilmiştir. Modelin Tüberküloz (TB) ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performansı Şekil 4.23’de verilmiştir. Hibrit evrişim katmanı sonrası modelin eğitim setindeki başarısı devam ederken doğrulama başarısı ortalama ilk 10 eğitim turundan sonra sabit kalmıştır. Model anlamlı özellikleri çıkarırken iyi bir performans göstermiş fakat bu özelliklere fazla uyum sağlamıştır. Kayıp eğrilerindeki mesafe bahsedilen aşırı uyumu desteklemiştir.



Şekil 4.23: Veri Artırımı ve Hibrit Evrişim Katmanı Sonrası Shenzhen Verisi Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri


Test verisinde doğruluk 0.83’dür. Ancak yalnızca veri artırma uygulanarak elde edilen sonuçlarla kıyaslandığında pozitif sınıf için kesinlik, duyarlılık ve F1 skorlarında belirgin bir iyileşme gözlenmemiştir. Bununla birlikte, veri artırma ve CLAHE yöntemlerinin birlikte kullanıldığı senaryoya göre daha iyi bir performans sergilediği görülmüştür. Modelin sınıflar arasındaki ayırım yeteneğini ifade eden AUC değeri ise 0.90 olarak hesaplanmıştır. Tablo 4.4’de elde edilen sonuçlar karşılaştırılmıştır. Şekil 4.24’de test verisindeki 190 örnek üzerinden tahmin sonuçlarını gösteren hata matrisi verilmiştir. Model, TB tahminlerinin 20’sinde başarısız olurken Normal sınıf için 13 tane hatalı tahmin yapmıştır. Bu durum modelin özellikle TB sınıfını tanımlamada sınırlı bir hassasiyete sahip olabileceğini göstermektedir.



Şekil 4.24: Veri Artırımı ve Hibrit Evrişim Katmanı Sonrası Shenzhen Veri Setiyle Test Seti için Hata Matrisi


Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Eklenecek Elde Edilen Sonuçlar

Hibrit evrişim katmanı eklenerek geliştirilen DenseNet201 modeli, veri artırımı ve CLAHE normalizasyonu uygulanan Shenzhen veri setiyle eğitilmiştir. Modelin Tüberküloz (TB) ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performansı Şekil 4.25’de verilmiştir. Kayıp eğrileri incelendiğinde doğrulama kaybı ile eğitim kaybı arasındaki fark minimize edilmiştir. Doğrulama eğrisindeki dengesizlik modelin eğitim sürecinde katmanların iyi eğitildiğini fakat bazı katmanların aşırı öğrenmesinden kaynaklanan uyum sorunları olduğu görülmüştür. Doğrulama setindeki sabitlik aynı zamanda düşük bir kayıp oranına sahip olduğu için elde edilen çıktıların hata fonksiyonuna olan katksının eğitim boyunca azaldığı görülmüştür.



Şekil 4.25: Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Sonrası Shenzhen Verisi Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri

Pozitif sınıf için kesinlik, duyarlılık ve F1 skor değerleri belirgin bir yükselişle 0.89 olarak elde edilmiştir. Test verisindeki doğruluk oranı 0.90 ile en yüksek seviyeye ulaşırken AUC değeri 0.948 olarak ölçülmüştür. Şekil 4.26'da test verisindeki 190 örnek üzerinden tahmin sonuçlarını veren hata matrisi gösterilmektedir. Model, TB tahminlerinin 10'unda başarısız olurken Normal sınıf için 10 tane hatalı tahmin yapmıştır. Bu sonuçlar modelin özellikle pozitif sınıfları tanımlamada belirli bir başarı sergilediğini ancak sınırlı sayıda hata yapmaya devam ettiğini göstermektedir.



Şekil 4.26: Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Sonrası Shenzhen Veri Setiyle Test Seti için Hata Matrisi

Tablo 4.4'de Shenzhen veri seti ile uygulanan yaklaşımların sonuçları özetlenmiştir.

Tablo 4.4: Shenzhen Veri Seti Sonuçları

Uygulanan Teknikler	Kesinlik	Duyarlılık	F1 Skor	Doğruluk	AUC
Ön İşlemsiz	%75	%89	%81	%82	%92,9
Veri Artırma	%87	%85	%86	%86	%95
Veri Artırma + CLAHE	%85	%77	%81	%81	%86,8
Veri Artırma + Hibrit Evrişim Katmanı	%86	%80	%83	%83	%90
Veri Artırma + CLAHE + Hibrit Evrişim Katmanı	%89	%89	%89	%90	%94,8
Veri Artırma + CLAHE + Hibrit Evrişim Katmanı + 5 Kath Çapraz Doğrulama	%84	%95	%89	%89	%97


Şekil 4.27’de yapılan işlemlerin modelin tahmin başarısındaki gelişimini gösteren birleştirilmiş hata matrisi verilmiştir. Uygulanan yaklaşımların model performansı üzerindeki etkilerine bakıldığında Shenzhen verisi için en iyi sonuçlar hibrit evrişim katmanı ile geliştirilmiş DenseNet201 modelinin veri artırımı sonrası CLAHE uygulanan görüntülerle eğitilmesiyle elde edilmiştir (1,2,3.durum).

1.durum : Veri artırımı uygulanarak elde edilen sonuçları,


1,2.durum : Veri artırımı ve CLAHE uygulanarak elde edilen sonuçları,

1,3.durum : Veri artırımı ve DenseNet201 modeline hibrit evrişim katmanı eklenerek elde edilen sonuçları,

1,2,3.durum : Veri artırımı, CLAHE ve DenseNet201 modeline hibrit evrişim katmanı eklenerek elde edilen sonuçları göstermektedir.

**Şekil 4.27:** Birleştirilmiş Hata Matrisi

Şekil 4.28’de Shenzhen veri seti için elde edilen ROC eğrileri verilmiştir. Bu ROC eğrilerine göre ham veri seti ile model, $AUC = 0.93$ değeri ile iyi bir performans göstermektedir. Veri artırımı uygulandığında AUC değeri 0.95 ’e çıkarak doğrulukta iyileşme sağlanmıştır. CLAHE ile kontrast iyileştirmesi ($AUC = 0.87$) ve hibrit evrimsel katman ($AUC = 0.90$) eklemeleri performansı tek başlarına yükseltmemiştir. Shenzhen verisi için en iyi sınıflandırma başarısı veri artırımı ve CLAHE uygulanan görüntülerle optimize DenseNet201 modelinin eğitilmesi ile elde edilmiştir ($AUC = 0.95$). 5 katlı çapraz doğrulama sonucunda modelin AUC değerinde iyileşme gözlenirse de diğer metrikler göz önüne alındığında en iyi sonucu CLAHE ve hibrit yaklaşımın birlikte kullanıldığı durumda vermiştir.




Şekil 4.28: Tüm Veri Setleri İçin ROC Eğrileri

4.4. MONTGOMERY+SHENZHEN VERİ SETİ

Montgomery ve Shenzhen veri setlerinin birleştirilmesi ile toplamda 800 örnek içeren bir veri seti oluşturulmuştur. Veri seti ile önerilen yaklaşımlar test edilmiş ve performanslar değerlendirilmiştir. Altı farklı durum için elde edilen bulgular sırasıyla tartışılacaktır.

Veri Artırımı Uygulanmadan Önce Elde Edilen Sonuçlar - Ön İşlemsiz


DenseNet201 modeli, 800 örnek içeren Montgomery+Shenzhen veri seti ile eğitilmiştir. Modelin Tüberküloz (TB) ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performansı Şekil 4.29'da verilmiştir. Doğruluk eğrileri incelendiğinde eğitim setinde doğruluğun küçük adımlarla ilerlediği, doğrulama setinde ise ortalama 20 eğitim turundan sonra sabit kaldığı görülmüştür. Bu durum veri setinin model parametrelerini eğitmek için sınırlı bir kapasitesi olduğunu göstermektedir. Kayıp eğrilerindeki fark modelin eğitim setini temsil eden özellikleri ezberlediğini dolayısıyla genelleme kapasitesinin gelişmediğini ortaya koymuştur.



Şekil 4.29: Ham Montgomery+Shenzhen Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri

Pozitif sınıf için kesinlik 0.87, duyarlılık 0.82 ve F1 skoru 0.84 olarak hesaplanmıştır. Test verisindeki doğruluk oranı 0.86, AUC değeri ise 0.918 olarak belirlenmiştir. Metrik sonuçları Tablo 4.5'de özetlenmiştir. Şekil 4.30'da test verisindeki 120 örnek üzerinden tahmin sonuçlarını gösteren hata matrisi verilmiştir. Model, Normal sınıfının tahmininde 7 hatalı sonuç, TB sınıfın tahmininde ise 10 hatalı sonuç üretmiştir. Bu sonuçlar modelin genel performansının oldukça yüksek olduğunu ancak aşırı öğrenmeden dolayı sınıf dengesizliklerinden veya sınıflar arasındaki daha karmaşık örneklerden kaynaklanan zorluklarla karşılaşıldığı anlaşılmıştır. Özellikle test verisinde elde edilen doğruluk oranı ve


AUC değeri, modelin genel sınıflandırma başarısını yansıtsa da, sınıf bazındaki hataların sayısı modelin iyileştirilmesi gereken alanlara işaret etmektedir.



Şekil 4.30: Ham Montgomery+Shenzhen Veri Setiyle Test Seti için Hata Matrisi


Veri Artırımı Uygulandıktan Sonra Elde Edilen Sonuçlar

DenseNet201 modeli, 800 veriye sahip Montgomery+Shenzhen veri setine veri artırımı uygulanmasının ardından 1400 örnek ile eğitilmiştir. Veri artırımı uygulandıktan sonra Tüberküloz (TB) ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performans Şekil 4.31’de verilmiştir. Modelin parametreleri veri artırımı sonrası örneklerin farklı varyasyonlarıyla eğitildikten sonra performansta iyileşme görülmüştür. Doğrulama setinde başlangıçta eğitim seti ile benzer bir trend yakalanmıştır. Ancak modelin bazı katmanları aşırı uyum göstermiş ve ortalama 30 eğitim turundan sonra model, veri seti üzerindeki genelleme başarısını yitirmiştir. Bu sonuçlar modelin çoğu örnek için benzer hataları yaptığını ve artık bu yüzden hata fonksiyonunu güncelleyemediğini göstermiştir.



Şekil 4.31: Veri Artırımı Sonrası Montgomery+Shenzhen Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri


Tablo 4.5’de özetlenen metrikler incelendiğinde bu yaklaşım için pozitif sınıftaki kesinlik 0.87, duyarlılık 0.83 ve F1 skoru 0.85 olarak hesaplanmıştır. Test verisi üzerindeki genel doğruluk oranı 0.87, sınıflar arasındaki ayırım yeteneğini temsil eden AUC değeri ise 0.919 olarak elde edilmiştir. Şekil 4.32’de test verisindeki 210 örnek üzerinden tahmin sonuçlarını gösteren hata matrisi verilmiştir. Model, TB tahminlerinde toplam 16 hata yapmış ve Normal sınıf için 11 hatalı tahmin gerçekleştirmiştir. Tahmin sonuçları modelin genel performansını ve pozitif sınıf tespitindeki sınırlı eksikliklerini göstermektedir.



Şekil 4.32: Veri Artırımı Sonrası Montgomery+Shenzhen Veri Setiyle Test Seti için Hata Matrisi


Veri Artırımı ve CLAHE Uygulanarak Elde Edilen Sonuçlar

Veri artırımı ile birlikte görüntülere CLAHE normalizasyonu uygulandıktan sonra mevcut DenseNet201 modeli eğitilmiştir. Modelin Tüberküloz (TB) ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performansı Şekil 4.33’de verilmiştir. CLAHE sonrası verilerin kontrastı gelişmiş ve bu durum model tarafından görüntülerdeki gereksiz detayların ve/veya gürültülerin de öğrenilmesine yol açmıştır. Grafikler incelendiğinde kayıp eğrileri arasındaki fark modelin doğrulama setinde ortalama 30 eğitim turundan sonra rastgele sonuçlar ürettiğini göstermiştir.



Şekil 4.33: Veri Artırımı ve CLAHE Sonrası Montgomery+Shenzhen Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri

Pozitif sınıf için performans metrikleri incelendiğinde kesinlik değeri, yalnızca veri artırımı uygulanarak elde edilen sonuçtan %7’lik düşük bir değerle 0.80 olarak hesaplanmıştır. Bununla birlikte duyarlılık metriği yaklaşık %7’lik bir artışla 0.90 seviyesine yükselmiştir. F1 skoru değişmeden kalırken, test verisindeki doğruluk oranı 0.85 olarak elde edilmiştir. Modelin sınıflar arasındaki ayırım yeteneğini ifade eden AUC değeri ise 0.936 olarak ölçülmüştür. Tablo 4.5’te metrikler karşılaştırmalı olarak sunulmuştur. Şekil 4.34’te test verisindeki 210 örnek üzerinden tahmin sonuçlarını gösteren hata matrisi verilmiştir. Model, TB tahminlerinde toplam 10 hata yapmış ve Normal sınıfta da 22 hatalı tahmin yapmıştır. Bu sonuçlar modelin eğitim verisi üzerinde yüksek performans göstermesine rağmen doğrulama ve test verilerindeki daha düşük performansı ile aşırı uyum belirtileri taşıdığını göstermektedir. Özellikle doğruluk ve kesinlik metriklerindeki düşüş modelin test verisindeki genellenebilirlik kapasitesinin sınırlı olduğunu ortaya koymaktadır.




Şekil 4.34: Veri Artırımı ve CLAHE Sonrası Montgomery+Shenzhen Veri Setiyle Test Seti için Hata Matrisi

Veri Artırımı ve Hibrit Evrişim Katmanı Eklenecek Elde Edilen Sonuçlar


Veri artırma işleminden sonra mevcut DenseNet201 modeline hibrit evrişim katmanı eklenerek model eğitilmiştir. Modelin Tüberküloz (TB) ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performansı Şekil 4.35’de verilmiştir. Hibrit evrişim katmanı sonrası modelin parametre sayısı arttığından dolayı model veri setine yaklaşık 18. eğitim turunda adapte olmuştur. Ancak eğitim setindeki özelliklerin doğrulama setine uyarlanamaması kayıp fonksiyonunu minimuma ulaştıramamış ve dolayısıyla türetilen hataların değerini düşürememiştir. Bu durum önem derecesi yüksek sınıf temsillerini çıkartmak için ağır gerektiği gibi eğitilemediğini göstermiştir.

Pozitif sınıf için kesinlik metriği önceki yöntemlere kıyasla artış göstererek 0.89’a yükselmiştir. Bununla birlikte duyarlılık metriği diğer durumlara göre en düşük seviyede kalarak 0.78 olarak hesaplanmıştır. F1 skoru 0.83, test verisindeki genel doğruluk oranı ise 0.85 olarak elde edilmiştir. Modelin sınıflar arası ayırt etme yeteneğini ifade eden AUC değeri belirgin bir artış göstermemiş ve 0.935 olarak kaydedilmiştir. Şekil 4.36’da test verisindeki 210 örnek üzerinden tahmin sonuçlarını gösteren hata matrisi verilmiştir. Model, TB sınıfında 22 ve Normal sınıfta 10 yanlış tahmin gerçekleştirmiştir. Bu sonuçlar hibrit evrişim katmanının model performansına negatif sınıf için kesinlik açısından katkı sağladığını ancak duyarlılıkta düşüşe neden olduğunu göstermektedir. Bu durum modelin

negatif sınıfı belirlerken hataları minimize etmeye odaklandığını ancak pozitif sınıfların doğru tespit oranında sınırlamalar yaşadığını ortaya koymaktadır.




Şekil 4.35: Veri Artırımı ve Hibrit Evrişim Katmanı Sonrası Montgomery+Shenzhen Verisi Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri



Şekil 4.36: Veri Artırımı ve Hibrit Evrişim Katmanı Sonrası Montgomery+Shenzhen Veri Setiyle Test Seti için Hata Matrisi


Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Eklenerek Elde Edilen Sonuçlar

DenseNet201 modeline hibrit evrişim katmanı eklendikten sonra veri artırımı ve CLAHE uygulanan Montgomery+Shenzhen veri setiyle eğitilmiştir. Modelin Tüberküloz (TB) ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performansı Şekil 4.37’de verilmiştir. CLAHE sonrası görüntülerdeki ayrıntılar ortaya çıkarılmış ve hibrit evrişim katmanı ile bu ayrıntılar yakalanarak ağırlıklandırılmıştır. Bu yoruma göre grafikler incelendiğinde özellikle kayıp grafiğindeki mesafenin minimize edildiği ve doğruluk eğrilerinin benzer şekilde yükseldiği görülmüştür. Doğrulama eğrilerindeki bu paralellik model parametrelerinin CLAHE sonrası görüntülerle eğitilmesinin öznetelik matrislerini etkili bir şekilde oluşturmada doğrudan etkili olduğunu göstermiştir.



Şekil 4.37: Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Sonrası Shenzhen Verisi Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri

Pozitif sınıf için kesinlik, duyarlılık, F1 skoru ve test verisindeki doğruluk oranı 0.92 olarak elde edilmiştir. Bu sonuçlarla birlikte, tüm yaklaşımlar arasında en yüksek AUC değeri 0.958 olarak hesaplanmıştır. Şekil 4.38’de test verisindeki 210 örnek üzerinden tahmin sonuçlarını gösteren hata matrisi verilmiştir. Model, TB sınıfında 8 ve Normal sınıfta 9 hatalı tahmin yapmıştır. Bu hatalar modelin sınıflar arasındaki ayırmada hala bazı zorluklar yaşadığını ancak genel olarak iyileştirilmiş bir performans sergilediğini göstermektedir.



Şekil 4.38: Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Sonrası Shenzhen Veri Setiyle Test Seti için Hata Matrisi

Tablo 4.5’de Montgomery+Shenzhen veri seti ile uygulanan yaklaşımların sonuçları özetlenmiştir.

Tablo 4.5: Montgomery+Shenzhen Veri Seti Sonuçları

Uygulanan Teknikler	Kesinlik	Duyarlılık	F1 Skor	Doğruluk	AUC
Ön İşlemsiz	%87	%82	%84	%86	%91,8
Veri Artırma	%87	%83	%85	%87	%91,9
Veri Artırma + CLAHE	%80	%90	%85	%85	%93,6
Veri Artırma + Hibrit Evrişim Katmanı	%89	%78	%83	%85	%93,5
Veri Artırma + CLAHE + Hibrit Evrişim Katmanı	%92	%92	%92	%92	%95,8
Veri Artırma + CLAHE + Hibrit Evrişim Katmanı + 5 Katlı Çapraz Doğrulama	%89	%88	%89	%90	%95,6


Şekil 4.39’da yapılan işlemlerin modelin tahmin başarısındaki gelişimini gösteren birleştirilmiş hata matrisi verilmiştir. Uygulanan yaklaşımların model performansı üzerindeki etkilerine bakıldığında Montgomery+Shenzhen verisi için en iyi sonuçlar hibrit evrişim katmanı ile geliştirilmiş DenseNet201 modelinin veri artırımı sonrası CLAHE uygulanan görüntülerle eğitilmesiyle elde edilmiştir (1,2,3.durum).

1.durum : Veri artırımı uygulanarak elde edilen sonuçları,

1,2.durum : Veri artırımı ve CLAHE uygulanarak elde edilen sonuçları,


1,3.durum : Veri artırımı ve DenseNet201 modeline hibrit evrişim katmanı eklenerek elde edilen sonuçları,

1,2,3.durum : Veri artırımı, CLAHE ve DenseNet201 modeline hibrit evrişim katmanı eklenerek elde edilen sonuçları göstermektedir.



Şekil 4.39: Birleştirilmiş Hata Matrisi

Şekil 4.40’da Montgomery+Shenzhen veri seti için elde edilen ROC eğrileri verilmiştir. Bu ROC eğrileri incelendiğinde ham veri setiyle model başlangıçta iyi bir performans göstererek AUC değerini 0.92 olarak elde etmiştir. Veri artırımı uygulaması ile modelin performansı değişmeden yaklaşık 0.92 olarak kalmıştır. Ancak CLAHE ile kontrast iyileştirme kullanıldığında AUC yaklaşık 0.94’e yükselerek performans artışı gözlenmiştir. Aynı şekilde hibrit evrişimsel katman kullanımıyla da AUC 0.94 seviyesine ulaşmıştır. Montgomery+Shenzhen veri seti için en iyi sonuçlar, veri artırımı sonrası görüntülere CLAHE tekniği uygulandıktan sonra hibrit evrişim katmanı eklenerek geliştirilmiş DenseNet201 modelinin eğitildiği durumda elde edilmiştir (AUC yaklaşık 0.96). Bu kombinasyon modelin öğrenme sürecinde özelliklerin daha verimli bir şekilde çıkarılmasına olanak tanıyarak diğer yaklaşımlara kıyasla sınıflandırma doğruluğunu artırmış ve pozitif sınıf için kesinlik, duyarlılık, F1 skoru ve AUC değerlerinde belirgin iyileşmeler sağlamıştır.



Şekil 4.40: Tüm Veri Setleri İçin ROC Eğrileri


4.5. TÜBERKÜLOZ (TB) GÖĞÜS RÖNTGENİ VERİ TABANI VERİ SETİ

Tüberküloz (TB) Göğüs Röntgeni Veri Tabanı'ndan alınan veri seti, 394 adet TB vakalı ve 406 adet Normal olmak üzere 800 görüntü ile oluşturulmuştur. İlerleyen bölümlerde altı farklı durum için elde edilen sonuçlar tartışılacaktır.


Veri Arttırımı Uygulanmadan Önce Elde Edilen Sonuçlar - Ön İşlemsiz

DenseNet201 modeli 800 veriye sahip TB Göğüs Röntgeni veri seti ile eğitilmiştir. Modelin Tüberküloz (TB) ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performansı Şekil 4.41'de verilmiştir. Model veri setindeki temsilleri hızlı bir şekilde öğrenmiş ve bunları doğrulama setinde etkili bir şekilde kullanmıştır. Eğitim ve doğrulama eğrilerindeki yakınlık modelin genelleme yeteneğinin oldukça iyi olduğunu göstermiştir.

Pozitif sınıf için kesinlik 0.98, duyarlılık 0.95 ve F1 skoru 0.97 olarak hesaplanmıştır. Test verisindeki doğruluk oranı 0.97, AUC değeri ise 0.983 olarak belirlenmiştir. Metriklerin karşılaştırması Tablo 4.6'da özetlenmiştir. Şekil 4.42'de test verisindeki 120 örnek üzerinden tahmin sonuçlarını gösteren hata matrisi verilmiştir. Model, TB sınıfının tahmininde 3 hatalı sonuç, Normal sınıfın tahmininde ise 1 hatalı sonuç üretmiştir. Bu sonuçlar modelin genel performansının oldukça yüksek olduğunu ancak sınıf bazındaki hatalara bakıldığında TB sınıflandırması için geliştirilebileceğini göstermektedir.




Şekil 4.41: Ham TB Göğüs Röntgeni Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri



Şekil 4.42: Ham TB Göğüs Röntgeni Veri Setiyle Test Seti için Hata Matrisi


Veri Artırımı Uygulandıktan Sonra Elde Edilen Sonuçlar

DenseNet201 modeli 800 veriye sahip TB Göğüs Röntgeni veri setine veri artırımı uygulanmasının ardından 1400 örnek ile eğitilmiştir. Modelin Tüberküloz (TB) ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performansı Şekil 4.43’de verilmiştir. Kayıp eğrileri incelendiğinde başlangıçtaki yüksek doğruluk kaybı modelin doğrulama setine hemen adapte olamadığını göstermiştir. Ancak yaklaşık 5 eğitim turu sonra yüksek seviyeli sınıf temsilleri sayesinde doğru tahmin olasılıklarının arttığı ve hata fonksiyonunun küçüldüğü görülmüştür. Bu durum doğrulama ve kayıp grafiklerinde eğriler arasındaki mesafeyi minimize etmiş ve model başarılı sonuçlar vermiştir.



Şekil 4.43: Veri Artırımı Sonrası TB Göğüs Röntgeni Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri


Tablo 4.6’da özetlendiği gibi pozitif sınıf için kesinlik metriği 1.0 olarak ölçülmüştür. Duyarlılık 0.94 olarak hesaplanırken F1 skoru ve test verisi doğruluk oranı 0.97 olarak elde edilmiştir. AUC değeri 0.996’dır. Şekil 4.44’de test verisindeki 210 örnek üzerinden tahmin sonuçlarını gösteren hata matrisi verilmiştir. Model, Normal sınıfındaki tahminlerinin tümünde başarılı olurken TB sınıfı için 6 tane hatalı tahmin yapmıştır. Bu sonuçlar sınıf bazlı hata sayılarını azaltmak için farklı optimizasyon yöntemlerine işaret etmektedir.



Şekil 4.44: Veri Artırımı Sonrası TB Göğüs Röntgeni Veri Setiyle Test Seti için Hata Matrisi


Veri Artırımı ve CLAHE Uygulanarak Elde Edilen Sonuçlar

Veri artırımı ile birlikte görüntülere CLAHE metodu uygulandıktan sonra mevcut DenseNet201 modeli eğitilmiştir. Modelin Tüberküloz (TB) ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performansı Şekil 4.45'te verilmiştir. CLAHE sonrası görüntülerin kalitesindeki iyileşme önem derecesi yüksek özellikleri ön plana çıkarırken bazı gürültülerin de sınıf temsili olarak değerlendirilmesine neden olmuştur. Bu durum doğrulama kaybı da incelendiğinde modelin daha fazla ağırlık güncelleyeceği ve veri setine daha yavaş adapte olacağı sonucunu vermiştir. Grafiklere göre eğitim setinden elde edilen özellik vektörleri doğrulama setinde başarıyla genelleştirilmiştir.



Şekil 4.45: Veri Artırımı ve CLAHE Sonrası TB Göğüs Röntgeni Veri Setiyle Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri

Veri artırımı ile birlikte görüntülere CLAHE tekniği uygulandıktan sonra yalnızca veri artırımına kıyasla, pozitif sınıf için kesinlik metriği %4'lük azalışla 0.96 olarak hesaplanmıştır. Öte yandan duyarlılık %2'lik artışla 0.96'ya yükselmiş, F1 skoru ise 0.96 olarak elde edilmiştir. Test verisi için doğruluk oranı 0.96'dır. AUC değeri CLAHE sonrası 0.993 olarak hesaplanmıştır. Tablo 4.6'da metriklerin sonuçları özetlenmiştir. Şekil 4.46'da test verisindeki 210 örnek üzerinden tahmin sonuçları verilmiştir. Model, TB sınıfı için 5 hatalı tahmin yaparken Normal sınıf için 4 tane hatalı tahmin yapmıştır. TB ve normal sınıflar için yapılan hatalar modelin sınıf dengesizliklerine veya bu sınıflardaki daha karmaşık örneklerle karşı duyarlılığının optimize edilmesi gerektiğine işaret etmektedir.




Şekil 4.46: Veri Artırımı ve CLAHE Sonrası TB Göğüs Röntgeni Veri Setiyle Test Seti için Hata Matrisi

Veri Artırımı ve Hibrit Evrişim Katmanı Eklenecek Elde Edilen Sonuçlar


Veri artırma işleminden sonra mevcut DenseNet201 modeline hibrit evrişim katmanı eklenerek model eğitilmiştir. Modelin Tüberküloz (TB) ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performansı Şekil 4.47’de verilmiştir. Doğrulama doğruluğu ilk 5 eğitim turu için incelendiğinde hibrit evrişim katmanı sonrası parametre sayısındaki artış modelin istikrarını dalgalandırmıştır. Hibrit evrişim katmanı ile elde edilen özellik uzayının genişlemesi, modelin ağırlıklarını yaklaşık ilk 10 eğitim turundan sonra optimum seviyede güncelleyebilmesini sağlamıştır. Sonuçlar, modelin hata fonksiyonunun en düşük seviyeye ulaşarak sınıf temsillerini doğrulama setine başarılı bir şekilde uyarlayabildiğini göstermiştir.

Pozitif sınıf için kesinlik metriği 0.98, duyarlılık 0.97 ve F1 skoru ise 0.98 olarak hesaplanmıştır. Test verisindeki doğruluk oranı 0.98’e ulaşırken, AUC değeri 0.998 olarak elde edilmiştir. Metriklerin özeti tablo 4.6’da verilmiştir. Şekil 4.48’de test verisindeki 210 örnek üzerinden tahmin sonuçlarını gösteren hata matrisi verilmiştir. Model TB sınıflandırmasında 3 hatalı tahmin yaparken, Normal sınıf için 2 hatalı tahmin üretmiştir. Bu sonuçlar hibrit evrişim katmanının modelin doğruluk oranı, duyarlılık ve AUC gibi metriklerde bir iyileşme sağladığını göstermektedir. Ayrıca modelin sınıf ayrımındaki başarısının yüksek olmasına rağmen bazı karmaşık örneklerde daha fazla optimizasyona

ihtiyaç duyulmaktadır.




Şekil 4.47: Veri Artırımı ve Hibrit Evrişim Katmanı Sonrası TB Göğüs Röntgeni Verisi Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri



Şekil 4.48: Veri Artırımı ve Hibrit Evrişim Katmanı Sonrası TB Göğüs Röntgeni Veri Setiyle Test Seti için Hata Matrisi


Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Eklenecek Elde Edilen Sonuçlar

DenseNet201 modeline hibrit evrişim katmanı eklendikten sonra veri artırımı ve CLAHE uygulanan Tüberküloz Göğüs Röntgeni VT ile eğitilmiştir. Modelin TB ve Normal görüntüleri sınıflandırmadaki eğitim ve doğrulama süreçlerine ilişkin performansı Şekil 4.49'da verilmiştir. Model CLAHE sonrası görüntülerle eğitim setinde başarılı olmuştur ancak doğrulama setindeki örnekleri sınıflandırırken sınıf temsillerini ifade eden özellikleri doğru bir şekilde ağırlıklandıramamıştır. Ancak ortalama 15 eğitim turu sonra model en iyi parametreleri elde etmiş ve doğrulama setinde en iyi sonuca ulaşmıştır. Kayıp eğrilerinin ilk 15 turdan sonra paralelleşerek 0'a yakınsaması baştaki istikrarsızlığa rağmen modelin tahmin sonuçlarının güvenilirliğini en üst seviyeye taşımıştır.



Şekil 4.49: Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Sonrası TB Göğüs Röntgeni Verisi Eğitim/Doğrulama Setleri için Doğruluk ve Kayıp Grafikleri

Pozitif sınıf için kesinlik, duyarlılık ve F1 skoru 0.99 olarak elde edilmiştir. Test veri setinde doğruluk oranı 0.999, AUC değeri ise 1.0 olarak belirlenmiştir. Şekil 4.50'de test verisindeki 210 örnek üzerinden tahmin sonuçlarını gösteren hata matrisi verilmiştir. Model Normal sınıfındaki tüm tahminlerinde doğru sonuçlar üretirken, TB sınıf için yalnızca 1 hatalı tahmin yapmıştır. Pozitif sınıf için elde edilen yüksek kesinlik (0.99), modelin yanlış pozitif oranını minimumda tutarak doğru sınıflandırma yaparken yüksek duyarlılık ve F1 skoru (0.99), modelin sınıflar arasındaki dengeyi başarılı bir şekilde sağladığını göstermektedir. Bu sonuçlar modelin genel doğruluğunun yanı sıra sınıf dengesizliklerine karşı yüksek performans sunduğunu ve test verisi üzerinde çok düşük hata oranıyla çalıştığını doğrulamaktadır.



Şekil 4.50: Veri Artırımı, CLAHE ve Hibrit Evrişim Katmanı Sonrası TB Göğüs Röntgeni Veri Setiyle Test Seti için Hata Matrisi

Tablo 4.6’da Tüberküloz Göğüs Röntgeni VT ile elde edilen sonuçlar özetlenmiştir.

Tablo 4.6: Tüberküloz Göğüs Röntgeni Veri tabanı Veri Seti Sonuçları

Uygulanan Teknikler	Kesinlik	Duyarlılık	F1 Skor	Doğruluk	AUC
Ön İşlemsiz	%98	%95	%97	%97	%98,3
Veri Artırma	%100	%94	%97	%97	%99,6
Veri Artırma + CLAHE	%96	%96	%96	%96	%99,3
Veri Artırma + Hibrit Evrişim Katmanı	%98	%97	%98	%98	%99,8
Veri Artırma + CLAHE + Hibrit Evrişim Katmanı	%96	%99	%98	%99	%99,6
Veri Artırma + CLAHE + Hibrit Evrişim Katmanı + 5 Katlı Çapraz Doğrulama	%99	%99	%99	%99,9	%100


Şekil 4.51’de yapılan işlemlerin modelin tahmin başarısındaki gelişimini gösteren birleştirilmiş hata matrisi verilmiştir. Uygulanan yaklaşımların model performansı üzerindeki etkilerine bakıldığında Tüberküloz Göğüs Röntgeni VT veri seti için en iyi sonuçlar hibrit evrişim katmanı ile geliştirilmiş DenseNet201 modelinin veri artırımı sonrası CLAHE uygulanan görüntülerle eğitilmesiyle elde edilmiştir (1,2,3.durum).

1.durum : Veri artırımı uygulanarak elde edilen sonuçları,


1,2.durum : Veri artırımı ve CLAHE uygulanarak elde edilen sonuçları,

1,3.durum : Veri artırımı ve DenseNet201 modeline hibrit evrişim katmanı eklenerek elde edilen sonuçları,

1,2,3.durum : Veri artırımı, CLAHE ve DenseNet201 modeline hibrit evrişim katmanı eklenerek elde edilen sonuçları göstermektedir.



Şekil 4.51: Birleştirilmiş Hata Matrisi



Şekil 4.52: Tüm Veri Setleri İçin ROC Eğrileri


Şekil 4.52’de TB Göğüs Röntgeni verisi için elde edilen ROC eğrileri verilmiştir. Grafiğe göre başlangıçta model, ham veri setinde AUC 0.98 değeri ile iyi bir performans göstermiştir. Veri artırımı sonucunda AUC yaklaşık 1.0 olarak ölçülmüştür. CLAHE ve hibrit evrişim katmanı için AUC değerleri sırasıyla 0.99 ve 1.0’dır. İki durumda da modelin test verisindeki

başarısı oldukça yüksektir. Ancak CLAHE ve hibrit evrişim katmanının birlikte kullanıldığı durumda AUC, veri artırımı ve veri artırımı+hibrit evrişim katmanı ile aynı olarak AUC 1.0 elde edilmiştir. Diğer metriklerle değerlendirildiğinde en iyi sınıflandırma başarısı, veri artırımı ve CLAHE uygulanan görüntülerle optimize edilmiş DenseNet201 modelinin eğitilmesi ile elde edilmiştir.

4.6. 5 KATLI ÇAPRAZ DOĞRULAMA SONUÇLARI

Bu bölümde 4 veri seti için CLAHE ve hibrit evrişim katmanının birlikte kullanıldığı durumda elde edilen en iyi sonuçlar 5 katlı çapraz doğrulama yöntemi ile yeniden değerlendirilmiş ve veri setlerinin performansları karşılaştırılmıştır. Şekil 4.53 ve Şekil 4.54’de, 4 veri seti için eğitim veri setlerinden elde edilen doğruluk ve kayıp grafikleri verilmiştir. Veri setlerinin aynı yaklaşımlarla farklı performans göstermesi veri örneklerinin kalitesi ve hastalığın derecesi gibi çeşitli etmenlere bağlıdır. Farklı veri setlerinde benzer başarılar yakalamak kullanılan modelin genelleme yeteneğinin gelişkin olduğunu gösterir. Şekil 4.55 ve Şekil 4.56 ise doğrulama setlerindeki sürece ilişkin doğruluk ve kayıp grafiklerini ifade etmektedir.


Şekil 4.53’e göre, 4 veri seti için en iyi performans TB Göğüs Röntgeni VT ile elde edilmiştir. 4 veri setinin ortalama doğruluk değeri 0.90 ile 1.0 arasındadır. 100 eğitim turu sonunda doğruluk en az 0.98 en yüksek 1.0 olarak elde edilmiştir.



Şekil 4.53: Tüm Veri Setleri İçin Eğitim Doğrulukları


Şekil 4.54’de, 4 veri seti için kayıp fonksiyonlarının sonuçları verilmiştir. Analizlere göre, eğitim kaybı 4 veri seti için de 100 eğitim turu sonunda 0 ile 0.005 arasında minimize

olmaktadır. Sonuçlar, önerilen yaklaşımlarla farklı veri setlerinin küçük bir aralıkta eşit performans gösterebildiğini ortaya koymaktadır.




Şekil 4.54: Tüm Veri Setleri İçin Eğitim Kayıpları

Şekil 4.55, 4 veri setinin doğrulama verisindeki doğruluk performansını ifade etmektedir. En iyi sonuç TB Göğüs Röntgeni VT ile elde edilmiştir ve Montgomery, Shenzhen, Montgomery+Shenzhen veri setleri için en yüksek başarı 0.96 ile 0.98 arasında elde edilmiştir.




Şekil 4.55: Tüm Veri Setleri İçin Doğrulama Doğrulukları

Şekil 4.56’da doğrulama veri setleri için 4 veri setinden elde edilen kayıp grafiği verilmiştir. Grafiğe göre en yüksek kayıp değeri Montgomery County veri setinde ölçülmüştür. Diğer 3 veri seti için kayıp değerleri 0 ile 0.15 aralığında en düşük seviyeye ulaşmıştır.



Şekil 4.56: Tüm Veri Setleri İçin Doğrulama Kayıpları

Şekil 4.57, tüm veri setleri için 5 katlı çapraz doğrulama ROC eğrileri verilmiştir. Montgomery+Shenzhen veri seti, iki setin bireysel başarısına kıyasla daha düşük bir performans göstermiştir. Bu durum, veri setlerinin birleşiminde sınıf örnekleri arasında aşırı örtüşen verilerin varlığına işaret etmiştir. Örtüşen veriler modelin genelleme yeteneğini olumsuz etkiler. Ayrıca iki veri setinin çözünürlük farkı da performansı doğrudan etkileyen etmenlerden biridir. Mükemmel sınıflandırma başarısı 1.0 AUC değeri ile TB Göğüs Röntgeni VT veri setinden elde edilmiştir.



Şekil 4.57: Tüm Veri Setleri İçin ROC Eğrileri

5. TARTIŞMA VE SONUÇ

Bu tez çalışmasında, DenseNet201 modeli ile akciğerlere ait X-ışını görüntülerinin sınıflandırma performansını ölçmek için kullanılan farklı yaklaşımlar ele alınmıştır. İlk olarak ikili çapraz entropi ve odak kayıp fonksiyonu sonuçları elde edilmiştir. Bulgular mevcut çalışma için odak kayıp fonksiyonunun daha avantajlı olduğunu göstermektedir. Ardından CLAHE normalizasyonu ve hibrit evrişim katmanı ile deneyler yapılmıştır. Önerilen yaklaşımlar 4 farklı veri setinde test edilmiş ve sonuçlar karşılaştırılmıştır.

Kayıp fonksiyonu modelin gerçek değerler ve tahmin değerleri arasındaki farkı hesaplayan ve modelin başarımlarını ölçen en önemli parametrelerden biridir. Bu tez çalışması kapsamında ikili sınıflandırma problemlerinde yaygın olarak kullanılan ikili çapraz entropi kaybı ile birlikte sınıf dengesizliği veya çözünürlük farkları sebebiyle yaşanan performans kayıplarını minimize etmeye odaklanan odak kayıp fonksiyonu sonuçları karşılaştırılmıştır. Başlangıçta ikili çapraz entropi fonksiyonu ile tatmin edici sonuçlar elde edilse de, model metrikleri karşılaştırıldığında özellikle doğruluk değerleri için Montgomery+Shenzhen veri setinde belirgin bir artış elde edilmiştir. Tüm veri setleri için eğitim ve doğruluk performansları göz önüne alındığında odak kayıp fonksiyonu ile model başarısının daha istikrarlı ve genelleme bakımından daha güvenilir sonuçlar verdiği görülmüştür.

Çalışmada yer alan 4 veri setindeki tüm örneklerle hem veri artırma işlemleri hem de CLAHE normalizasyonu uygulanmıştır. Veri artırma teknikleri ile elde edilen sonuçların, görüntülere CLAHE yöntemi uygulanarak geliştirilmesi amaçlanmıştır. Elde edilen bulgular CLAHE normalizasyonunun uygulanmasıyla model kapasitesi ile veri setlerinin karmaşıklığı arasındaki ilişkinin daha dengeli hale geldiği gözlemlenmiş ancak bu etkinin model performansı üzerinde belirgin bir iyileştirme veya olumsuz bir etki yaratmadığı tespit edilmiştir.

Mevcut DenseNet201 modeli, hibrit bir evrişim katmanı eklenerek geliştirilmiştir. Bu katman 32 adet (3x3) ve 64 adet (5x5) boyutlarında evrişim filtresine sahip iki ayrı evrişim katmanını birleştirerek farklı ölçeklerdeki özelliklerin eşzamanlı olarak öğrenilmesini sağlamaktadır. Bu yaklaşım modele ek bir derinlik kazandırırken derinliğin beraberinde getirebileceği

hesaplama maliyeti ve gradyan sönümlenmesi gibi olumsuz etkileri hibrit yapının sağladığı çeşitlendirilmiş filtre boyutlarıyla minimize etmiştir. Hibrit katmanın hem düşük hem de yüksek çözünürlükteki özellikleri etkili bir şekilde yakalayarak modelin daha zengin bir temsil öğrenmesini sağladığı gözlemlenmiştir. Bu yöntem veri setlerindeki karmaşık örüntüleri daha iyi öğrenmek ve farklı çözünürlükteki görüntülerin kayıp fonksiyonuna etkisini normalize etmek amacıyla uygulanmıştır. Elde edilen sonuçlar CLAHE tekniğinde olduğu gibi model performansı üzerinde belirgin bir artış sağlamamakla birlikte, herhangi bir olumsuz etki de gözlenmemiştir.

Veri artırma teknikleriyle birlikte görüntülere CLAHE normalizasyonu uygulanmış ve bu ön işleme adımının ardından hibrit evrişim katmanı ile geliştirilmiş DenseNet201 modeli bu verilerle eğitilmiştir. Sonuçlar, CLAHE normalizasyonu ve hibrit katmanın bireysel etkilerinden farklı olarak iki yaklaşımın bir arada kullanıldığında model performansının maksimize edildiğini göstermektedir. CLAHE yöntemi görüntülerde kontrast iyileştirmesi sağlayarak ayırt edici özelliklerin daha belirgin hale gelmesine katkıda bulunmuştur. Hibrit evrişim katmanı ise bu özelliklerin daha etkili bir şekilde öğrenilmesini sağlayarak modelin karmaşık örüntüleri yakalama kapasitesini artırmış ve güçlü bir modelleme yaklaşımı sunmuştur. Dört veri seti için de en iyi sonuçlar bu kombine yaklaşımla elde edilmiştir. Son aşamada elde edilen sonuçların kesinliği 5 katlı çapraz doğrulama ile değerlendirilmiş ve sonuçların güvenilirliği yüksek başarı oranlarıyla test edilmiştir.

Tablo 5.1’de dört veri seti için veri artırımı sonrası görüntülere CLAHE uygulandıktan sonra hibrit evrişim katmanı ile optimize edilmiş DenseNet201 modelinin eğitilmesi ile elde edilmiş olan en iyi sonuçlar özetlenmiştir. Model, Tüberküloz Göğüs Röntgeni VT için mükemmel sonuçlar elde ederken dört veri seti arasında en düşük performans %89 doğruluk ile Shenzhen setinden elde edilmiştir. Veri setlerindeki performans farkı X-ışını görüntülerinin ne zaman, hangi ülkede ve hangi cihazlarla elde edildiğine bağlı olmakla birlikte hastalık evrelerinin neden olduğu farklılıklardan da kaynaklandığı düşünülmektedir. Tez çalışması kapsamında herhangi bir sınıflandırma problemi için veri örneklerinin normalize edilerek bu farklılıkların etkisinin azaltılabileceği ve genelleme açısından gerçek dünya sonuçlarına uygun tahminler üretilebileceği görülmüştür.

Çalışmalardan elde edilen sonuçların literatür ile karşılaştırılması amacıyla Bölüm 2.8’de verilen literatür çalışmalarının özeti Tablo 5.2’de verilmiştir.

Tablo 5.1: Tüm Veri Setleri İçin Elde Edilen En İyi Bulgular

Veri Seti	Kesinlik	Duyarlılık	F1 Skor	Doğruluk	AUC
Montgomery County	%100	%92	%96	%96	%99,9
Shenzhen	%84	%95	%89	%89	%97
Montgomery+Shenzhen	%92	%92	%92	%92	%95,8
Tüberküloz Göğüs Röntgeni VT	%99	%99	%99	%99	%100

Montgomery County ve Shenzhen veri setlerinin bireysel sınıflandırma başarıları çeşitli sınıflandırma yöntemleri kullanılarak [69], [63] ve [71] çalışmalarında incelenmiştir. [69] çalışmasında doğruluk Montgomery County veri seti için %97,5 ve Shenzhen veri setinde %97,6 doğruluk elde ederken [63] çalışmasında Montgomery County için doğruluk %89,9 Shenzhen seti için ise %93,7 olmuştur. [71] çalışmasında Shenzhen veri setinin sınıflandırma doğruluğu %99,2'dir. Bu tez çalışması kapsamında Montgomery County veri setinde en yüksek doğruluk %96 iken Shenzhen setinde bu oran %89 olarak hesaplanmıştır. Literatürdeki sonuçların önceden eğitilmiş ESA modelleriyle elde edildiği göz önüne alındığında bu tez çalışmasındaki sıfırdan eğitilen ESA modeli, etkili geliştirmelerle rekabetçi sınıflandırma sonuçları elde etmiştir.

Montgomery+Shenzhen veri setinin literatürdeki [63], [67] ve [65] çalışmalarında doğruluk oranları sırasıyla %98,7, %87 ve %96'dır. Tez çalışmasında Montgomery+Shenzhen veri seti için doğruluk en yüksek %92'dir ve literatürdeki önceden eğitilen ESA modelleriyle yapılan diğer bazı çalışmalara göre sonuçlar umut vaad etmektedir.

Tüberküloz Göğüs Röntgeni Veri tabanı verilerini kullanarak elde edilen doğruluk [71] çalışmasında %98,8 ve [64]'de %98,6'dır. Bu veri setiyle tez çalışmasında en yüksek doğruluk %99 olarak elde edilmiştir ve literatürdeki diğer çalışmalara göre en iyi sonuç olduğu görülmektedir.

Tez kapsamındaki bulgular değerlendirildiğinde çalışmada kullanılan optimizasyon ve normalizasyon işlemlerinin literatürdeki farklı yaklaşımlar ile yapılan sınıflandırma metotlarına göre daha yüksek ve/veya rekabetçi sonuçlar verdiği görülmektedir. Yüksek parametre sayıları ve karmaşık toplu modellere kıyasla uygun yaklaşımlarla seçilen optimizasyon ve normalizasyon işlemlerinin model performansını en üst seviyeye taşıyabileceği görülmüştür.

Bu tez kapsamında, yukarıda bahsedilen efektif yaklaşımların sınıflandırma problemlerine uygulanması incelenmiştir. Elde edilen bulgular CLAHE normalizasyonu ve hibrit evrişim katmanı optimizasyonlarının dört farklı X-ışını akciğer görüntüsü veri seti için sınıflandırma performansının en yüksek seviyeye ulaştığını ortaya koymuştur. Bu durum geliştirilen yöntemlerin yalnızca akciğer görüntüleri için değil farklı türdeki görüntü verilerinde de gelişme sağlayacak yaklaşımlar olarak umut vaad etmektedir. Bu bağlamda, hibrit evrişim katmanı ile optimize edilen DenseNet201 modeli yüksek enerji fiziğinde karmaşık verilerden özellikler çıkarmak, sonraki makine öğrenimi algoritmaları için özellik setleri oluşturmak, deneylerden elde edilen görüntülerin segmentasyonunu yapmak ve toplanan büyük veri setlerini analiz etmek için kullanılabilir. Bu tez çalışmasında, veri seti ile model optimizasyonu arasında kurulan doğru ilişkinin gerçek dünyaya uyarlanabilir derecede iyi sonuçlar verebileceği görülmüştür.

Tablo 5.2: Literatür Sonuçları

Referans	Yıl	Veri Seti	Method	Doğruluk
Taşcı ve diğerleri [69]	2021	Montgomery, Shenzhen	Görüntülere CLAHE uygulandı ve Bayes tabanlı ESA modelleri önerildi	%97,5, %97,699
Rahman ve diğerleri [64]	2020	Montgomery, Shenzhen, TB Göğüz Röntgeni VT	DenseNet201 segmentasyon yöntemi ile TB sınıflandırması için kullanıldı	%98,6
Fati Sm ve diğerleri [71]	2022	Tüberküloz Göğüs Röntgeni VT, Shenzhen	TB tespiti için normalizasyon yöntemleri ile Resnet50 ve GoogleNet modelleri kullandılar	%99,8 ve %99,2
Nafisah ve diğerleri [63]	2022	Montgomery, Shenzhen	Görüntülere veri artırımı ve segmentasyon uygulandı. Veri setleri bireysel ve kombine olarak değerlendirildi	%89,9(mont.), %93,7(shenzhen), %98,7(kombine)
Showkatian ve diğerleri [67]	2022	Montgomery, Shenzhen	Montgomery ve Shenzhen veri setlerini önerdikleri ConvNet modelini sıfırdan eğitmek için kullandılar	%87
Tummalapalli ve diğerleri [65]	2023	Montgomery, Shenzhen	Tüberkülozun otomatik teşhisi için DenseNet201 modelini kullandılar	%96
Chutia ve diğerleri [66]	2024	NIH veri seti	DenseNet201 modeline hibrit havuzlama katmanı eklendi ve X-ışını görüntülerine CLAHE uygulandı	%95,34
Bu tez çalışmasında	2025	Montgomery, Shenzhen, Mont.+Shenzhen, TB Göğüs Röntgeni VT	DenseNet201 modeline hibrit evrişim katmanı eklendi ve X-ışını görüntülerine CLAHE uygulandı	%96, %89, %92, %99

KAYNAKLAR

- [1]. Carl S. Young. Chapter 4 - electromagnetic waves. In Carl S. Young, editor, *Information Security Science*, pages 77–102. Syngress, 2016.
- [2]. Joanne Zwinkels. Light, electromagnetic spectrum. *Encyclopedia of Color Science and Technology*, 8071:1–8, 2015.
- [3]. Bunun Ben Bugün Öğrendim. X işini tüpü. <https://bunubenbugunogrendim.wordpress.com/tag/x-isini-tup/> t.y. Erişim tarihi: 28 Aralık 2024.
- [4]. Raziye Kübra Kumrular and Adem Polat. Klinik uygulamalarda ileri biyomedikal görüntüleme teknolojileri. *Avrupa Bilim ve Teknoloji Dergisi*, (23):207–221, 2021.
- [5]. Zeynep Yüksel. Manyetik rezonans görüntüleme fizik temelleri ve sistem bileşenleri. *Black Sea Journal of Engineering and Science*, 2(2):57–65, 2019.
- [6]. Özlem Tülek and İhsan Hakan Selvi. Derin q ağları tabanlı parçacık sürü optimizasyonu. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 35(2):855–863, 2023.
- [7]. Analytics Vidhya. How does the gradient descent algorithm work in machine learning? *Analytics Vidhya*, 2020. Accessed: 2024-12-31.
- [8]. İlayda Akbulut and Burcu Özcan. Hava kirliliği tahmini: yapay sinir ağları ve regresyon yöntemleriyle bir karşılaştırma. *Kocaeli Üniversitesi Fen Bilimleri Dergisi*, 3(1):12–22, 2020.
- [9]. Leonid Datta. A survey on activation functions and their relation with xavier and he normal initialization. *arXiv preprint arXiv:2004.06632*, 2020.
- [10]. Sagar Sharma, Simone Sharma, and Anidhya Athaiya. Activation functions in neural networks. *Towards Data Sci*, 6(12):310–316, 2017.
- [11]. Aayush Jaiswal, Neha Gianchandani, Dilbag Singh, Vijay Kumar, and Manjit Kaur. Classification of the covid-19 infected patients using densenet201 based deep transfer learning. *Journal of Biomolecular Structure and Dynamics*, 39(15):5682–5689, 2021.
- [12]. Samuel Van Stroud, Philippa Duckett, Max Hart, Nikita Pond, Sébastien Rettie, Gabriel Facini, and Tim Scanlon. Transformers for charged particle track reconstruction in high energy physics. *arXiv preprint arXiv:2411.07149*, 2024.
- [13]. Laura Fattaruso. Leaders in artificial neural network development share 2024 nobel prize in physics. 2024.
- [14]. Venkitesh Ayyar, Wahid Bhimji, Lisa Gerhardt, Sally Robertson, and Zahra Ronaghi. The use of convolutional neural networks for signal-background classification in particle physics experiments. In *EPJ Web of Conferences*, volume 245, page 06003. EDP Sciences, 2020.

- [15]. World Health Organization. Global tuberculosis report 2022. <https://iris.who.int/bitstream/handle/10665/363752/9789240061729-eng.pdf>, 2022.
- [16]. Lei Cai, Jingyang Gao, and Di Zhao. A review of the application of deep learning in medical image classification and segmentation. *Annals of translational medicine*, 8(11), 2020.
- [17]. M Romer and I Bernard Cohen. Roemer and the first determination of the velocity of light (1676). *Isis*, 31(2):327–379, 1940.
- [18]. James Clerk Maxwell. Viii. a dynamical theory of the electromagnetic field. *Philosophical transactions of the Royal Society of London*, (155):459–512, 1865.
- [19]. Daniel Fleisch. *A student's guide to Maxwell's equations*. Cambridge University Press, 2008.
- [20]. Paul G Huray. *Maxwell's equations*. John Wiley & Sons, 2009.
- [21]. Theodore Frankel. Maxwell's equations. *The American Mathematical Monthly*, 81(4):343–349, 1974.
- [22]. Davis Baird, Richard I Hughes, and Alfred Nordmann. *Heinrich Hertz: classical physicist, modern philosopher*, volume 198. Springer Science & Business Media, 1998.
- [23]. Richard Steiner. History and progress on accurate measurements of the planck constant. *Reports on Progress in Physics*, 76(1):016101, 2012.
- [24]. Otto Glasser. Wc roentgen and the discovery of the roentgen rays. *AJR. American journal of roentgenology*, 165(5):1033–1040, 1995.
- [25]. William H Brock. *William Crookes (1832–1919) and the commercialization of science*. Routledge, 2016.
- [26]. Mikhail Arnoldovich Blokhin. *The Physics of X-rays*, volume 4502. United States Atomic Energy Commission, Office of Technical Information, 1961.
- [27]. Siang Yong Tan and Patricia Sims Poole. Allan macleod cormack (1924–1998): Discoverer of computerised axial tomography. *Singapore medical journal*, 61(1):4, 2020.
- [28]. Mark Nicholls. Sir godfrey newbold hounsfield and allan m. cormack. *European Heart Journal*, 40(26):2101–2103, 07 2019.
- [29]. Catherine Westbrook and John Talbot. *MRI in Practice*. John Wiley & Sons, 2018.
- [30]. Stephen Muggleton. Alan turing and the development of artificial intelligence. *AI communications*, 27(1):3–10, 2014.
- [31]. Zhi-Hua Zhou. *Machine learning*. Springer nature, 2021.
- [32]. Rich Caruana and Alexandru Niculescu-Mizil. An empirical comparison of supervised learning algorithms. In *Proceedings of the 23rd international conference on Machine learning*, pages 161–168, 2006.
- [33]. Horace B Barlow. Unsupervised learning. *Neural computation*, 1(3):295–311, 1989.

- [34]. Richard S Sutton and Andrew G Barto. *Reinforcement learning: An introduction*. MIT press, 2018.
- [35]. Dastan Maulud and Adnan M Abdulazeez. A review on linear regression comprehensive in machine learning. *Journal of applied science and technology trends*, 1(2):140–147, 2020.
- [36]. Ronald A Fisher. The goodness of fit of regression formulae, and the distribution of regression coefficients. *Journal of the Royal Statistical Society*, 85(4):597–612, 1922.
- [37]. Timothy O Hodson. Root mean square error (rmse) or mean absolute error (mae): When to use them or not. *Geoscientific Model Development Discussions*, 2022:1–10, 2022.
- [38]. Rui Xu and Donald Wunsch. Survey of clustering algorithms. *IEEE Transactions on neural networks*, 16(3):645–678, 2005.
- [39]. Vaishali Ganganwar. An overview of classification algorithms for imbalanced datasets. *International Journal of Emerging Technology and Advanced Engineering*, 2(4):42–47, 2012.
- [40]. Bayya Yegnanarayana. *Artificial neural networks*. PHI Learning Pvt. Ltd., 2009.
- [41]. Jinming Zou, Yi Han, and Sung-Sau So. Overview of artificial neural networks. *Artificial neural networks: methods and applications*, pages 14–22, 2009.
- [42]. Pierre Baldi. Gradient descent learning algorithm overview: A general dynamical systems perspective. *IEEE Transactions on neural networks*, 6(1):182–195, 1995.
- [43]. AD Dongare, RR Kharde, Amit D Kachare, et al. Introduction to artificial neural network. *International Journal of Engineering and Innovative Technology (IJEIT)*, 2(1):189–194, 2012.
- [44]. Jianxin Wu. Introduction to convolutional neural networks. *National Key Lab for Novel Software Technology. Nanjing University. China*, 5(23):495, 2017.
- [45]. K O’Shea. An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*, 2015.
- [46]. Zewen Li, Fan Liu, Wenjie Yang, Shouheng Peng, and Jun Zhou. A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE transactions on neural networks and learning systems*, 33(12):6999–7019, 2021.
- [47]. Shaoqing Ren, Kaiming He, Ross Girshick, Xiangyu Zhang, and Jian Sun. Object detection networks on convolutional feature maps. *IEEE transactions on pattern analysis and machine intelligence*, 39(7):1476–1481, 2016.
- [48]. Nikhil Ketkar, Jojo Moolayil, Nikhil Ketkar, and Jojo Moolayil. Convolutional neural networks. *Deep learning with Python: learn best practices of deep learning models with PyTorch*, pages 197–242, 2021.
- [49]. Hossein Gholamalinezhad and Hossein Khosravi. Pooling methods in deep neural networks, a review. *arXiv preprint arXiv:2009.07485*, 2020.

- [50]. Yahya Dogan. A new global pooling method for deep neural networks: Global average of top-k max-pooling. *Traitement du Signal*, 40(2):577–587, 2023.
- [51]. VL Helen Josephine, AP Nirmala, and Vijaya Lakshmi Alluri. Impact of hidden dense layers in convolutional neural network to enhance performance of classification model. In *IOP Conference Series: Materials Science and Engineering*, volume 1131, page 012007. IOP Publishing, 2021.
- [52]. Shibani Santurkar, Dimitris Tsipras, Andrew Ilyas, and Aleksander Madry. How does batch normalization help optimization? *Advances in neural information processing systems*, 31, 2018.
- [53]. Johannes Lederer. Activation functions in artificial neural networks: A systematic overview. *arXiv preprint arXiv:2101.09957*, 2021.
- [54]. P Sibi, S Allwyn Jones, and P Siddarth. Analysis of different activation functions using back propagation neural networks. *Journal of theoretical and applied information technology*, 47(3):1264–1268, 2013.
- [55]. Shiv Ram Dubey, Satish Kumar Singh, and Bidyut Baran Chaudhuri. Activation functions in deep learning: A comprehensive survey and benchmark. *Neurocomputing*, 503:92–108, 2022.
- [56]. Chigozie Nwankpa, Winifred Ijomah, Anthony Gachagan, and Stephen Marshall. Activation functions: Comparison of trends in practice and research for deep learning. *arXiv preprint arXiv:1811.03378*, 2018.
- [57]. Gireen Naidu, Tranos Zuva, and Elias Mmbongeni Sibanda. A review of evaluation metrics in machine learning algorithms. In *Computer Science On-line Conference*, pages 15–25. Springer, 2023.
- [58]. Juan M Gorriz, F Segovia, J Ramirez, A Ortiz, and John Suckling. Is k-fold cross validation the best model selection method for machine learning? *arXiv preprint arXiv:2401.16407*, 2024.
- [59]. Hamza Kheddar, Yassine Himeur, Abbes Amira, and Rachik Soualah. Image classification in high-energy physics: A comprehensive survey of applications to jet analysis. *arXiv preprint arXiv:2403.11934*, 2024.
- [60]. Adam Abed Abud, DUNE collaboration, et al. Sparse convolutional neural networks for particle classification in protodune-sp events. In *Journal of Physics: Conference Series*, volume 2438, page 012125. IOP Publishing, 2023.
- [61]. CMS collaboration et al. Identification of hadronic tau lepton decays using a deep neural network. *arXiv preprint arXiv:2201.08458*, 2022.
- [62]. UK Lopes and João Francisco Valiati. Pre-trained convolutional neural networks as feature extractors for tuberculosis detection. *Computers in biology and medicine*, 89:135–143, 2017.

- [63]. Saad I Nafisah and Ghulam Muhammad. Tuberculosis detection in chest radiograph using convolutional neural network architecture and explainable artificial intelligence. *Neural Computing and Applications*, 36(1):111–131, 2024.
- [64]. Tawsifur Rahman, Amith Khandakar, Muhammad Abdul Kadir, Khandaker Rejaul Islam, Khandakar F Islam, Rashid Mazhar, Tahir Hamid, Mohammad Tariqul Islam, Saad Kashem, Zaid Bin Mahbub, et al. Reliable tuberculosis detection using chest x-ray with deep learning, segmentation and visualization. *Ieee Access*, 8:191586–191601, 2020.
- [65]. Geetamma Tummalapalli, Ch Babji Prasad, and Jami Kousik. Analysing the performance of dense net in the context of tuberculosis disease. In *2024 International Conference on Advancements in Power, Communication and Intelligent Systems (APCI)*, pages 1–7. IEEE, 2024.
- [66]. Upasana Chutia, Anand Shanker Tewari, Jyoti Prakash Singh, and Vikash Kumar Raj. Classification of lung diseases using an attention-based modified densenet model. *Journal of Imaging Informatics in Medicine*, pages 1–17, 2024.
- [67]. Eman Showkatian, Mohammad Salehi, Hamed Ghaffari, Reza Reiazi, and Nahid Sadighi. Deep learning-based automatic detection of tuberculosis disease in chest x-ray images. *Polish journal of radiology*, 87:e118, 2022.
- [68]. James Devasia, Hridayanand Goswami, Subitha Lakshminarayanan, Manju Rajaram, and Subathra Adithan. Deep learning classification of active tuberculosis lung zones wise manifestations using chest x-rays: a multi label approach. *Scientific Reports*, 13(1):887, 2023.
- [69]. Erdal Tasci, Caner Uluturk, and Aybars Ugur. A voting-based ensemble deep learning method focusing on image augmentation and preprocessing variations for tuberculosis detection. *Neural Computing and Applications*, 33(22):15541–15555, 2021.
- [70]. Murat Uçar. Deep neural network model with bayesian optimization for tuberculosis detection from x-ray images. *Multimedia Tools and Applications*, 82(24):36951–36972, 2023.
- [71]. Suliman Mohamed Fati, Ebrahim Mohammed Senan, and Narmine ElHakim. Deep and hybrid learning technique for early detection of tuberculosis based on x-ray images using feature fusion. *Applied Sciences*, 12(14):7092, 2022.
- [72]. Sema Candemir, Stefan Jaeger, Kannappan Palaniappan, Jonathan P Musco, Rahul K Singh, Zhiyun Xue, Alexandros Karargyris, Sameer Antani, George Thoma, and Clement J McDonald. Lung segmentation in chest radiographs using anatomical atlases with nonrigid registration. *IEEE transactions on medical imaging*, 33(2):577–590, 2013.
- [73]. Tawsifur Rahman, Amith Khandakar, and Muhammad Enamul Hoque Chowdhury. Tuberculosis (tb) chest x-ray database, 2020.
- [74]. Gao Huang, Shichen Liu, Laurens Van der Maaten, and Kilian Q Weinberger. Condensenet: An efficient densenet using learned group convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 2752–2761, 2018.

- [75]. Yi Zhu and Shawn Newsam. Densenet for dense flow. In *2017 IEEE international conference on image processing (ICIP)*, pages 790–794. IEEE, 2017.
- [76]. Zhiyuan Li and Sanjeev Arora. An exponential learning rate schedule for deep learning. *arXiv preprint arXiv:1910.07454*, 2019.
- [77]. Raniah Zaheer and Humera Shaziya. A study of the optimization algorithms in deep learning. In *2019 third international conference on inventive systems and control (ICISC)*, pages 536–539. IEEE, 2019.
- [78]. Diederik P Kingma. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.
- [79]. Juan Terven, Diana M Cordova-Esparza, Alfonzo Ramirez-Pedraza, and Edgar A Chavez-Urbiola. Loss functions and metrics in deep learning. a review. *arXiv preprint arXiv:2307.02694*, 2023.
- [80]. Mulyanto Mulyanto, Muhamad Faisal, Setya Widyawan Prakosa, and Jenq-Shiou Leu. Effectiveness of focal loss for minority classification in network intrusion detection systems. *Symmetry*, 13(1):4, 2020.



ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	Şafak YASUN
Doğum Yeri	
Doğum Tarihi	
Uyruğu	☒ T.C. ☐ Diğer:
E-Posta Adresi	
Web Adresi	

Eğitim Bilgileri	
Lisans	
Üniversite	İstanbul Üniversitesi
Fakülte	Fen Fakültesi
Bölümü	Fizik
Mezuniyet Yılı	2021

Yüksek Lisans	
Üniversite	İstanbul Üniversitesi
Enstitü Adı	Fen Bilimleri
Anabilim Dalı	Fizik Anabilim Dalı
Programı	Yüksek Enerji ve Plazma Fiziği Programı
Mezuniyet Tarihi	2025

