

**HDARU-NET TABANLI DERİN ÖĞRENME YAKLAŞIMIN
TIBBİ GÖRÜNTÜLERDEKİ PERFORMANSI: ADENOİD
HİPERTROFİSİ VE CİLT LEZYONLARI ÜZERİNE BİR
İNCELEME**

SEDAT ÖRENÇ

NİSAN 2025

DİYARBAKIR

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**HDARU-NET TABANLI DERİN ÖĞRENME YAKLAŞIMIN
TIBBİ GÖRÜNTÜLERDEKİ PERFORMANSI: ADENOİD
HİPERTROFİSİ VE CİLT LEZYONLARI ÜZERİNE BİR
İNCELEME**

SEDAT ÖRENÇ

DİCLE ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM-ÖĞRETİM VE SINAV
YÖNETMELİĞİNİN BİR PARÇASI OLARAK
ELEKTRİK-ELEKTRONİK ANA BİLİM DALINDA
DOKTORA TEZİ
OLARAK HAZIRLANMIŞTIR

NİSAN 2025

DİYARBAKIR

**HDARU-NET TABANLI DERİN ÖĞRENME YAKLAŞIMIN TIBBİ
GÖRÜNTÜLERDEKİ PERFORMANSI: ADENOİD HİPERTROFİSİ VE
CİLT LEZYONLARI ÜZERİNE BİR İNCELEME**

Sedat ÖRENÇ tarafından Dicle Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği'nin bir parçası olarak hazırlanan bu çalışma, aşağıda bilgileri yazılı jüri üyeleri tarafından değerlendirilerek **Elektrik-Elektronik Mühendisliği Ana Bilim Dalı**'nda **Doktora Tezi** olarak kabul edilmiştir.

Prof. Dr. Neslihan DALKILIÇ
Müdür, **Fen Bilimleri Enstitüsü**

Prof. Dr. Mehmet Sıraç ÖZERDEM
Danışman, **Elektrik-Elektronik Mühendisliği Bölümü,**
Dicle Üniversitesi

Doç. Dr. Emrullah ACAR
İkinci Danışman, **Elektrik-Elektronik Mühendisliği**
Bölümü, Batman Üniversitesi

Sınav Jürisi:

Prof. Dr. Mehmet Sıraç ÖZERDEM (*,**)
Elektrik-Elektronik Müh. Bölümü, Dicle Üniversitesi

Prof. Dr. Mehmet AKIN
Elektrik-Elektronik Müh. Bölümü, Dicle Üniversitesi

Prof. Dr. Sedat İLHAN
Matematik Bölümü, Dicle Üniversitesi

Doç. Dr. Musa YILMAZ
Elektrik-Elektronik Müh. Bölümü, Batman Üniversitesi

Doç. Dr. Ömer TÜRK
Elektrik-Elektronik Müh. Bölümü,
Mardin Artuklu Üniversitesi

ONAY

Savunma Tarihi: 11/04/2025

(*) Jüri Başkanı.

(**) Tez Danışmanı.



Aileme...

Dicle Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırlanan bu tez çalışmasında yer alan tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu beyan ederim. Ayrıca, bahse konu bu kural ve ilkelerin gerektirdiği üzere, bu çalışmada özgün olmayan tüm bilimsel içerikleri kurallara uygun biçimde alıntılıyıp kaynak gösterdiğimi beyan ederim. Beyanımınla çelişen herhangi bir delil bulunduğu takdirde tüm sorumluluğu üstleneceğimi kabul ederim.

Ad, Soyad: Sedat ÖRENÇ

İmza:

TEŞEKKÜR

Bu çalışmanın her aşamasında bilgi birikimi, rehberliği ve sürekli desteğiyle yanımda olan, saygıdeğer danışmanım Prof. Dr. Mehmet Sıraç ÖZERDEM'e en derin şükranlarımı sunarım. Kendisinin engin bilgisi, yol göstericiliği ve teşvik edici tavsiyeleri hem akademik hem de kişisel gelişimimde büyük bir rol oynamış olup, onun danışmanlığında çalışmaktan büyük bir onur duydum.

Ayrıca, ikinci danışmanım Doç. Dr. Emrullah ACAR'a, bu tezdeki katkıları, titiz rehberliği ve her zaman değerli geri bildirimleriyle çalışmama kattığı derinlik için içtenlikle teşekkür ederim. Kendisinin önerileri ve eleştirel bakış açısı, araştırmamın yönünü şekillendirmede önemli bir rol oynamıştır.

Tez izleme komitesi üyelerim Prof. Dr. Mehmet AKIN ve Prof. Dr. Sedat İLHAN'a da içten teşekkürlerimi sunarım. Çalışmalarımı dikkatle değerlendirip, verdikleri yapıcı geri bildirimler ve değerli önerilerle tezimin gelişimine büyük katkı sağladılar. Kendi alanlarındaki engin bilgileri, bu çalışmanın derinliğini ve kapsamını artırdı.

Bu çalışmada kullanılan veri setlerinin temin edilmesinde sağladıkları kıymetli katkılar ve destekleri için Batman Eğitim ve Araştırma Hastanesi'nde çalışan Uzman Doktor Sefer ŞAHİN'e ve Uzman Odyolog Abdullah KAYA'ya en içten teşekkürlerimi sunarım. Alanlarındaki uzmanlıkları ve iş birliği, araştırmamın bilimsel derinliğini artırmada ve veri süreçlerimin eksiksiz bir şekilde tamamlanmasında büyük önem taşımıştır. Kendilerinin bu çalışmaya olan katkıları, tezimin önemli bir yapı taşı oluşturmuştur.

Bu çalışmayı, en büyük destekçilerim olan sevgili eşim, annem ve babama ithaf ediyorum. Özellikle eşim, sabrı, emeği ve fedakârlığıyla bu sürecin en güçlü dayanağı oldu. Başta kardeşim Medine ÖRENÇ olmak üzere tüm kardeşlerimin desteği, bu yolculuğu benim için daha da anlamlı hale getirdi. Varlıkları ve sevgileriyle bu başarıya ulaşmamda büyük pay sahibi oldular.

İÇİNDEKİLER

TEŞEKKÜR.....	v
İÇİNDEKİLER	vi
ŞEKİLLER LİSTESİ	x
TABLolar LİSTESİ.....	xii
SİMGELER VE KISALTMALAR LİSTESİ	xiii
ÖZET.....	xv
ABSTRACT.....	xvi
1. GİRİŞ	1
1.1 Adenoid Hipertrofisi Hastalığı.....	3
1.2 Cilt Lezyonu Hastalığı	4
1.3 Görüntü İşleme.....	7
1.4 Görüntü Segmentasyonu	9
1.4.1 Eşikleme tabanlı segmentasyon	9
1.4.2 Kenar tabanlı segmentasyon	9
1.4.3 Bölge tabanlı segmentasyon.....	10
1.4.4 Kümeleme tabanlı segmentasyon.....	10
1.5 Yapay Zeka	11
1.6 Tezin Amacı	13
1.7 Tezin Önemi.....	14
1.8 Tezin İçeriği	15
2. ÖNCEKİ ÇALIŞMALAR.....	17
2.1 Adenoid Hipertrofisi Hastalığı ile Alakalı Yapılan Bilimsel Çalışmalar... 17	
2.2 Cilt Lezyonu Hastalığı ile Alakalı Yapılan Bilimsel Çalışmalar	22
3. MALZEME VE YÖNTEM	32
3.1 Adenoid Veri Seti.....	33
3.2 Cilt Lezyonu Veri Seti	35

3.3	Adenoid ve Cilt Lezyonu Görüntü Veri Artırımı.....	36
3.4	Görüntü Segmentasyon Modelleri	37
3.4.1	U-Net modeli.....	38
3.4.2	U-Net++ modeli	39
3.4.3	SegNet modeli	40
3.4.4	Önerilen model: Hybrid dense attention residual U-Net modeli	41
3.5	Derin Öğrenme Modelleri	45
3.5.1	EfficientNet modeli	46
3.5.2	MobileNet modeli	46
3.5.3	ResNet50 modeli	47
3.5.4	ResNet152 modeli	47
3.5.5	VGG16 modeli	48
3.5.6	Xception modeli	49
3.6	Derin Öğrenme Modellerinin Performansını Ölçen Parametreler	49
3.6.1	Doğruluk	49
3.6.2	Duyarlılık (hassasiyet)	50
3.6.3	Özgüllük.....	50
3.6.4	Kesinlik	51
3.6.5	F1-Skoru.....	51
3.6.6	ROC ve AUC	51
3.6.7	Dice katsıyısı.....	51
3.6.8	Birleşim üzerinde kesişim	52
3.7	Görüntü Segmentasyonu Akış Diyagramı	53
3.8	Görüntü Sınıflandırması Akış Diyagramı	55
4.	BULGULAR VE TARTIŞMA	59
4.1	Görüntü Segmentasyonu için Kullanılan Parametreler.....	59

4.2	Adenoid Hipertrofisi Hastalığı için Derin Öğrenme Tabanlı Segmentasyon Modellerinin Sonuçları.....	60
4.3	Cilt Lezyonu Hastalığı için Derin Öğrenme Tabanlı Segmentasyon Modellerinin Sonuçları.....	63
4.4	Adenoid Hipertrofisi Hastalığında Önerilen Modelin Literatürdeki Modeller ile Karşılaştırılması	65
4.5	Adenoid Hipertrofisi Hastalığı Sınıflandırması için Kullanılan Parametreler	67
4.6	Görüntü Verisi ile Maskeleme Yöntemi	69
4.7	Maske Uygulanmış Adenoid Hipertrofisi Görüntülerin Sınıflandırma Sonuçları	70
4.8	Maske Uygulanmamış Adenoid Hipertrofisi Görüntülerin Sınıflandırma Sonuçları	71
4.9	Önerilen Model ile Literatürdeki Ensemble Derin Öğrenme Modellerinin Performans Karşılaştırması	73
4.10	Maskesiz Adenoid Görüntülerle Derin Öğrenme Tabanlı Sınıflandırma Modellerinin Eğitim Doğruluğunun Değerlendirilmesi.....	75
4.11	Maskeli Adenoid Görüntülerle Derin Öğrenme Tabanlı Sınıflandırma Modellerinin Eğitim Doğruluğunun Değerlendirilmesi.....	78
4.12	Maskesiz Adenoid Görüntülerle Derin Öğrenme Tabanlı Sınıflandırma Modellerinin ROC Eğrisi	80
4.13	Maskeli Adenoid Görüntülerle Derin Öğrenme Tabanlı Sınıflandırma Modellerinin ROC Eğrisi	83
4.14	Maskesiz Adenoid Görüntülerle Derin Öğrenme Tabanlı Sınıflandırma Modellerinin Karışıklık Matrisi	85
4.15	Maskeli Adenoid Görüntülerle Derin Öğrenme Tabanlı Sınıflandırma Modellerinin Karışıklık Matrisi	88
5.	SONUÇLAR VE ÖNERİLER	91
5.1	Sonuçlar.....	91

5.2 Öneriler	93
KAYNAKLAR	96
ÖZGEÇMİŞ	108



ŞEKİLLER LİSTESİ

Şekil 1.1 Adenoid hipertrofisi hastalığının geleneksel teşhisi	4
Şekil 1.2 Cilt lezyonu teşhisi için ABCD kuralları	6
Şekil 1.3 Renklerin piksel değerleri	8
Şekil 1.4 Yapay zeka, makine öğrenmesi ve derin öğrenme	13
Şekil 3.1 Adenoid hipertrofisi görüntüler ve karşılık gelen maskeler	33
Şekil 3.2 Cilt lezyonu görüntüler ve karşılık gelen maskeler	35
Şekil 3.3 Adenoid görüntü verisi artırımı ve karşılık gelen maskeler.....	37
Şekil 3.4 U-Net modelinin mimarisi	39
Şekil 3.5 SegNet modelinin mimarisi	40
Şekil 3.6 Hybrid dense attention residual U-net mimarisi	42
Şekil 3.7 Yoğun blok mimarisi	43
Şekil 3.8 Kanal dikkat mimarisi.....	44
Şekil 3.9 Artık dikkat mekanizmasının mimarisi.....	44
Şekil 3.10 Dice katsayısının grafiksel formülü	52
Şekil 3.11 Birleşim üzerine kesişim parameresinin grafiksel formülü	52
Şekil 3.12 Görüntü segmentasyonun akış diyagramı	53
Şekil 3.13 Görüntü sınıflandırması akış diyagramı	56
Şekil 4.1 Derin öğrenme modellerinin adenoid hipertrofisi üzerindeki performansı. 62	
Şekil 4.2 Derin öğrenme modellerinin cilt lezyonu üzerindeki performansı.	64
Şekil 4.3 Adenoid görüntü verisi maskeleme yöntemi.	69
Şekil 4.4 Maskesiz görüntülerle derin öğrenme modellerinin eğitim doğruluğu - (a): EfficientNet (b): MobileNet (c): ResNet50 (d): ResNet152 (e): VGG16 (f): Xception.	76
Şekil 4.5 Maskeli görüntülerle derin öğrenme modellerinin eğitim doğruluğu - (a): EfficientNet (b): MobileNet (c): ResNet50 (d): ResNet152 (e): VGG16 (f): Xception.	78
Şekil 4.6 Maskesiz görüntülerle derin öğrenme modellerinin ROC Eğrisi - (a): EfficientNet (b): MobileNet (c): ResNet50 (d): ResNet152 (e): VGG16 (f): Xception.	81

Şekil 4.7 Maskeli görüntülerle derin öğrenme modellerinin ROC Eğrisi - (a): EfficientNet (b): MobileNet (c): ResNet50 (d): ResNet152 (e): VGG16 (f): Xception.	83
Şekil 4.8 Maskesiz görüntülerle derin öğrenme modellerinin karışıklık matrisi - (a): EfficientNet (b): MobileNet (c): ResNet50 (d): ResNet152 (e): VGG16 (f): Xception.	86
Şekil 4.9 Maskeli görüntülerle derin öğrenme modellerinin karışıklık - (a): EfficientNet (b): MobileNet (c): ResNet50 (d): ResNet152 (e): VGG16 (f): Xception.	88



TABLÖLAR LİSTESİ

Tablo 4.1 Görüntü segmentasyonu için kullanılan parametreler	59
Tablo 4.2 Adenoid hipertrofisi teşhisinde derin öğrenme modellerinin performansı.	61
Tablo 4.3 Cilt lezyonu teşhisinde derin öğrenme modellerinin performansı.....	63
Tablo 4.4 Önerilen model ile literatürdeki modellerin karşılaştırılması (adenoid)....	65
Tablo 4.5 Önerilen model ile literatürdeki modellerin karşılaştırılması (cilt lezyonu)	66
Tablo 4.6 Adenoid hipertrofisi sınıflandırılması için kullanılan parametreler	68
Tablo 4.7 Maske uygulanmış adenoid hipertrofisi görüntülerinin sınıflandırma sonuçları	70
Tablo 4.8 Maske uygulanmamış adenoid hipertrofisi görüntülerinin sınıflandırma sonuçları	72
Tablo 4.9 Önerilen model ile literatürdeki ensemble derin öğrenme modellerinin karşılaştırması	73

SİMGELER VE KISALTMALAR LİSTESİ

Simge

Açıklama

r

Korelasyon Katsayısı

Kısaltma

Açıklama

ABD

Amerika Birleşik Devletleri

AdNet

Adenoid Net

AH

Adenoid Hipertrofisi

AUC

Area Under Curve

ANO

Adenoidal Nasofarenks Oranı

BDT

Bilgisayar Destekli Tasarım

DCNN

Deep Convolutional Neural Network

DEO

Dolphin Echolocation Optimizer

DICOM

Digital Imaging and Communications in Medicine

DÖ

Derin Öğrenme

DWNN

Deep Wave Neural Network

DYZ

Dar Yapay Zeka

ESA

Evrişimli Sinir Ağları

FN

False Negative

FrCN

Full Resolution Convolutional Network

FP

False Pozitive

GAN

Generative Adversarial Networks

GPU

Graphics Processing Unit

GSEM

Gri Seviyeli Eş Oluşum Matrisi

HDARU-Net

Hybrid Dense Attention Residual U-Net

IoU

Intersection Over Union

ISIC	International Skin Image Collaboration
KBB	Kulak Burun Boğaz
KIBT	Konik Işınlı Bilgisayarlı Tomografi
KNN	K Nearest Neighbor
MÖ	Makine Öğrenmesi
MLP	Multi Layer Perceptron
MBConv	Mobile Inverted Bottleneck Convolution
MRE	Mean Root Error
MSE	Mean Square Error
ROC	Receiver Operating Characteristic
RNN	Yinelemeli Sinir Ağları
SD	Standard Deviation
SE	Squeeze Excitation
SVM	Support Vector Machine
TE	Tsallis Entropi
TP	True Positive
TN	True Negative
YSA	Yinelemeli Sinir Ağları
YZ	Yapay Zeka

ÖZET

HDARU-NET TABANLI DERİN ÖĞRENME YAKLAŞIMIN TIBBİ GÖRÜNTÜLERDEKİ PERFORMANSI: ADENOİD HİPERTROFİSİ VE CİLT LEZYONLARI ÜZERİNE BİR İNCELEME

ÖRENÇ, Sedat

Doktora, Elektrik-Elektronik Mühendisliği Bölümü

Danışman: Prof. Dr. Mehmet Sıraç ÖZERDEM

İkinci Danışman: Doç. Dr. Emrullah ACAR

Nisan 2025, 125 sayfa

Cilt lezyonları ve adenoid hipertrofisi (AH) gibi tıbbi hastalıkların doğru şekilde segmentasyonu ve adenoid hipertrofisinin sınıflandırılması, hasta bakımında kritik bir rol oynamaktadır. Ancak, manuel görüntü analizi ve görsel inceleme gibi geleneksel teşhis yöntemleri, teşhis doğruluğunu sınırlayan önemli zorluklar barındırmaktadır. Bu geleneksel teknikler, genellikle uzmanlar tarafından endoskopi veya radyografik değerlendirme yoluyla gerçekleştirildiğinden, zaman alıcı olmasının yanı sıra insan hatasına açık bir yapı sergilemektedir. Bu durum, teşhis gecikmelerine, tekrarlayan muayenelere ve uzman katılımının gerekliliğiyle birlikte artan maliyetlere yol açmaktadır. Son yıllarda, yapay zeka (YZ) ve derin öğrenme (DÖ) alanındaki gelişmeler, özellikle tıbbi görüntü analizinde teşhis verimliliğini artıracak otomatik yaklaşımlar sunmuştur. Ancak, geleneksel derin öğrenme modelleri, görüntülerdeki gürültü, lezyon görünümündeki çeşitlilik ve düzensiz kontrast gibi karmaşık değişkenliklerle başa çıkmada hâlâ yetersiz kalabilmektedir. Bu çalışma, segmentasyon için Hibrit Dense Attention Residual (HDARU-Net) modeli ve sınıflandırma için ensemble derin öğrenme tabanlı sınıflandırma modellerini içeren derin öğrenme yaklaşımlarını uygulayarak bu sınırlamaları aşmayı hedeflemektedir. Batman Eğitim ve Araştırma Hastanesi'nden elde edilen benzersiz bir adenoid veri seti ile International Skin Image Collaboration (ISIC) cilt lezyonu veri setini kullanarak, HDARU-Net modelinin performansını, U-Net, U-Net++ ve SegNet gibi derin öğrenme tabanlı segmentasyon modelleri ile karşılaştırmalı olarak incelemektedir. Çalışmada önerilen HDARU-Net modeli, tıbbi görüntülerde ilgili bölgelerin daha hassas bir şekilde sınırlandırılmasına olanak tanımakta, bu durumun daha güvenilir teşhis ve hasta vakalarında tutarlılığın sağlanması açısından kritik öneme sahiptir. Sonuçlar, segmentasyonun sınıflandırma görevleriyle entegrasyonunun, özellikle karmaşık cilt lezyonları ve adenoid hipertrofisi vakaları için tanısal doğruluğu önemli ölçüde artırdığını göstermektedir. Bu çalışma, HDARU-Net modelinin yalnızca teşhis süresini azaltmakla kalmayıp aynı zamanda manuel analiz gerektiren tekrarlayan işlemleri minimize ederek ekonomik maliyetleri de düşürdüğünü ortaya koymaktadır. Elde edilen bulgular, klinik ortamlarda teşhis sürecini hızlandırma, zamanında tıbbi müdahaleyi destekleme ve hasta sonuçlarını iyileştirme açısından önemli etkilere sahiptir. Bu tez çalışmasında, YZ tabanlı tıbbi teşhis alanına katkı sağlayarak, diğer karmaşık tıbbi hastalıkların teşhisinde de otomatikleştirebilecek sağlam bir çerçeve sunmaktadır.

Anahtar Kelimeler: Derin öğrenme, Görüntü işleme, Görüntü segmentasyonu, Sınıflandırma, HDARU-Net, Adenoid hipertrofisi, Cilt lezyonu

ABSTRACT

PERFORMANCE OF THE HDARU-NET BASED DEEP LEARNING APPROACH ON MEDICAL IMAGES: A STUDY ON ADENOID HYPERTROPHY AND SKIN LESIONS

ÖRENÇ, Sedat

PhD of Science in Department of Electrical and Electronics Engineering

Supervisor: Prof. Dr. Mehmet Sıraç ÖZERDEM

Co-Supervisor: Assoc. Prof. Dr. Emrullah ACAR

April 2025, 125 pages

The accurate segmentation of medical conditions such as skin lesions and adenoid hypertrophy, as well as the classification of adenoid hypertrophy, plays a critical role in patient care. However, traditional diagnostic methods such as manual image analysis and visual examination pose significant challenges that limit diagnostic accuracy. Since these conventional techniques are typically performed by experts through endoscopy or radiographic evaluation, they are not only time-consuming but also prone to human error. This leads to diagnostic delays, repeated examinations, and increased costs due to the necessity of expert involvement. In recent years, advancements in artificial intelligence (AI) and deep learning have introduced automated approaches that can enhance diagnostic efficiency, particularly in medical image analysis. However, traditional deep learning models still struggle to handle complex variations such as noise in images, variations in lesion appearance, and irregular contrast. This study aims to overcome these limitations by implementing deep learning approaches, including the Hybrid Dense Attention Residual (HDARU-Net) model for segmentation and ensemble deep learning-based classification models for classification. Using a unique adenoid dataset obtained from Batman Training and Research Hospital and the International Skin Image Collaboration (ISIC) skin lesion dataset, the study comparatively examines the performance of the HDARU-Net model against deep learning-based segmentation models such as U-Net, U-Net++, and SegNet. The proposed HDARU-Net model enables more precise delineation of relevant regions in medical images, which is crucial for ensuring more reliable diagnoses and consistency in patient cases. The results demonstrate that integrating segmentation with classification tasks significantly improves diagnostic accuracy, particularly for complex skin lesions and adenoid hypertrophy cases. This study reveals that the HDARU-Net model not only reduces diagnostic time but also minimizes repetitive procedures requiring manual analysis, thereby lowering economic costs. The findings have significant implications for accelerating the diagnostic process in clinical settings, supporting timely medical interventions, and improving patient outcomes. This thesis study contributes to AI-based medical diagnostics by providing a robust framework that can also be applied to the diagnosis of other complex medical conditions.

Keywords: Deep learning, Image processing, Image segmentation, Classification, HDARU-Net, Adenoid hypertrophy, Skin lesion

1. GİRİŞ

Sağlık, fiziksel, zihinsel ve sosyal iyilik halini kapsayan, insan yaşamının temel bir unsurudur [1]. İyi sağlığın korunması, bireylerin verimli bir yaşam sürmeleri ve topluma katkıda bulunmaları için kritik önem taşımaktadır. Tıp bilimi ve teknolojisinin ilerlemesi, insan sağlığına dair anlayışımızı büyük ölçüde geliştirmiş ve etkili tedavi yöntemleri ile önleyici tedbirlerin geliştirilmesini mümkün kılmıştır [2]. Bununla birlikte, mevcut gelişmelere rağmen, optimal sağlığın sağlanması evrensel bir sorun olmaya devam etmekte, çeşitli hastalıklar hem bireyler hem de toplumlar için önemli tehditler oluşturmaktadır [3].

Hastalıklar ister kronik ister akut olsun, bir kişinin yaşam kalitesi üzerinde derin etkiler oluşturabilir [4]. Bu hastalıklar, grip ve tüberküloz gibi bulaşıcı hastalıklardan, diyabet ve kardiyovasküler hastalıklar gibi bulaşıcı olmayan hastalıklara kadar çeşitlilik gösterir [5]. Bu sağlık sorunları, zamanında teşhis ve tedavi edilmezse genellikle uzun vadeli komplikasyonlara yol açar. Dünya genelinde, bulaşıcı olmayan hastalıklar tüm ölümlerin %71'ini oluşturmaktadır. Dolayısıyla bu hastalıklar büyük bir küresel halk sağlığı sorunudur. Dünya hem yeni hem de mevcut hastalıklarla mücadele etmeye devam ederken, erken ve doğru teşhis, hastalık yükünü önemli ölçüde azaltabilir ve yaşam süresini iyileştirebilir. Bu nedenle, erken teşhis, etkili sağlık hizmetlerinin temel unsurları haline gelmektedir [6].

Erken teşhis, hasta sonuçlarının iyileştirilmesinde kritik bir rol oynar. Bir hastalığın erken evrelerinde teşhis edilmesi, zamanında müdahaleye olanak tanıyarak hastalığın ilerlemesini önleyebilir ve hastalığın etkilerini azaltabilir [7]. Örneğin, kanser, kardiyovasküler veya solunum yolu hastalıklarının erken teşhisi, başarılı tedavi şansını belirgin ölçüde artırabilir. Teşhis amacıyla kullanılan tıbbi görüntüleme teknolojileri, belirgin belirtiler oluşmadan önce anormalliklerin tespit edilmesini sağlayarak sağlık alanında vazgeçilmez araçlar haline gelmiştir. Erken teşhis, yalnızca hastalığın seyrini iyileştirmekle kalmaz, aynı zamanda kapsamlı tedavi gereksinimini azaltarak sağlık hizmeti maliyetlerini de düşürür [8].

Yapay zeka, insan zekasıyla ilişkilendirilen özellikleri sergileyen sistemlerin teorisi ve pratiğiyle ilgilenen bir bilim ve mühendislik alanıdır. Yapay zeka, özellikle hastalık

teşhisi ve tıbbi görüntüleme alanında sağlık hizmetlerinde belirgin gelişmeler kaydetmiştir. Yapay zeka sistemleri, büyük miktarda tıbbi veriyi hızlı ve doğru bir şekilde analiz etme yeteneğine sahip olup, hastalıkların teşhis ve tedavisinde yardımcı olabilecek tahminler sunmaktadır. Yapay zeka destekli cihazlar, geleneksel olarak zaman alan ve insan uzmanlığına dayalı görevleri otomatikleştirerek, sağlık hizmetlerinde daha verimli iş akışlarının oluşturulmasını sağlamıştır. Tıbbi teşhis alanındaki yapay zeka uygulamaları, belirli hastalıkların tespitinde insan uzmanlarını geride bırakan yüksek doğruluk oranları sergilemiştir [9], [10], [11], [12], [13].

Yapay zekanın bir dalı olan makine öğrenimi, tıbbi görüntü analizinde önemli ölçüde etkilidir. Büyük veri setlerinden öğrenme yeteneği sayesinde, makine öğrenimi algoritmaları, hastalık belirtisi olabilecek tümörler, lezyonlar veya anormalleri tanımlamak gibi tıbbi görüntülerdeki örüntüleri tanıyabilir. Bu modellerin çeşitli veri setleri üzerinde eğitilmesi, makine öğreniminin daha doğru tahminler ve hastalık teşhisi sağlamasına olanak tanıyarak insan hatası riskini azaltmakta ve genel hasta bakımını iyileştirmektedir. Literatür incelendiğinde, makine öğrenimi algoritmalarının teşhis doğruluğunun daha iyi seviyelerde olduğunu göstermiştir [14], [15], [16], [17], [18].

Makine öğreniminin bir alt bilim dalı olan derin öğrenme, tıbbi görüntülerin daha hassas ve detaylı analizini mümkün kılarak teşhis sürecinin daha etkin ve hassas hale gelmesine katkıda bulunmuştur. Görüntü segmentasyonu ve sınıflandırma gibi alanlarda daha gelişmiş özellikleri sayesinde derin öğrenme, tıbbi görüntülerdeki belirli ilgi alanlarını tanımlamak ve bu bölgelerin yapısını belirlemek için önemli bir bilim dalı haline gelmiştir. Bu, daha doğru teşhisler ve nitelikli tedavi kararları almayı sağlayarak hasta sonuçlarını iyileştirir ve hastalık tespiti ile yönetimi için yeni fırsatlar sunar. Örneğin, beyin tümörleri için görüntü segmentasyonunda kullanılan derin öğrenme algoritmaları yüksek bir doğruluk oranı göstermiştir ve bu da yapay zekanın tıbbi teşhis alanında devrim niteliğindeki potansiyelini ortaya koymaktadır [15], [19], [20], [21], [22], [23].


1.1 Adenoid Hipertrofisi Hastalığı

Adenoid hipertrofisi, burnun arka kısmında yer alan adenoid bezlerinin büyümesi rahatsızlığıdır. Bu büyüme, özellikle burun pasajlarından geçen hava akışını kısıtlayarak çeşitli sağlık sorunlarına yol açabilir. Bağışıklık sisteminin bir parçası olan adenoidler, normalde çocukluk döneminden sonra küçülür; ancak bazı durumlarda hem çocuklarda hem de yetişkinlerde büyümeye devam edebilir. Adenoid hipertrofisinin tespiti hayati önem taşımaktadır çünkü nefes alma güçlüğü, uyku apnesi ve burun tıkanıklığı gibi komplikasyonlara yol açabilir. Bu durumun doğru teşhis edilmesi, komplikasyonların önlenmesi ve uygun tedavinin sağlanması açısından son derece önemlidir [24], [25].

Adenoid, Waldeyer halkasının bir parçasını oluşturur. Adenoidler, 2-10 yaşları arasında fizyolojik olarak büyüyebilir, 8-10 yaş civarında gerilemeye başlar ve genellikle 12-14 yaşlarında tamamen atrofiye (küçülüp işlevini yitirme) uğrar [26]. Ancak adenoidal enfeksiyon ve inflamasyon, patolojik adenoid hipertrofisine sebep olarak üst solunum yolunu tıkayabilir. Bu durum, ağızdan nefes alma, tekrarlayan sinüzit, otitis media, çocuklarda yüz gelişiminde değişiklikler veya daha ciddi komplikasyonlar olan obstrüktif uyku apnesi sendromu, bilişsel işlev bozukluğu ve anormal zihinsel gelişim gibi sorunlara yol açabilir. Bu ciddi komplikasyonlar genellikle adenoidektomi gerektirir ve bu tür ameliyatlara, genel yaşam kalitesini artırmak için yapılır [27], [28].

Günümüzde adenoid hipertrofisini tespit etmek için kullanılan başlıca teşhis yöntemleri, esnek fiber-optik burun endoskopisi ve nazofaringeal radyolojik incelemelerdir. Bunlardan biri de lateral sefalografidir. Burun endoskopisi, adenoidlerin ve çevre yapılarının doğrudan görüntülenmesini sağlar ve adenoid büyümesinin şiddeti ile buna bağlı hava yolu tıkanıklığının ölçülmesine olanak tanır. Bu yöntem, ameliyat öncesi teşhis ve ameliyat sonrası sonuçların değerlendirilmesi için güçlü veriler sağlar. Ancak, burun endoskopisinin invaziv doğası, birçok çocuğun muayene sırasında doktorlarla iş birliği yapmasını zorlaştırır ve bu da klinik kullanımını sınırlamaktadır. Sonuç olarak, lateral sefalografi adenoid hipertrofisini tespit etmek için en yaygın kullanılan araç haline gelmiştir ve birçok çalışma, adenoid hipertrofisini tanımlamada yüksek güvenilirliğini göstermektedir.

Sefalogramları temel alan değerlendirme yöntemleri arasında en dikkate değer olanı, Fujioka tarafından tanımlanan adenoid-nazofaringeal (AN) oranının hesaplanmasına dayanır. Bu yöntem, adenoid dokusu ile nazofaringeal açıklık arasındaki oranın belirlenmesini sağlar. Adenoid dokusu, basiocciput bölgesi ile adenoid yastığının en konveks kısmı arasındaki mesafe ile tanımlanırken, nazofaringeal açıklık, sphenobasiocciput ile sert damağın arka kenarı arasındaki mesafe ile tanımlanır. Şekil 1'de gösterildiği gibi, AN oranını ölçmek için sefalogramlarda dört ilgili noktalarda işaretleme işlemi manuel olarak yapılır. Ancak, bu işaretlerin doğru şekilde belirlenmesi, büyük ölçüde gözlemcinin klinik deneyimine bağlıdır ve bu durum, farklı gözlemciler arasında sonuç farklılıklarına yol açabilir. Ayrıca, bu görev zaman alıcıdır ve tekrarlayan iş yükü doktorların verimliliğini etkileyebilir. Bu nedenle, lateral sefalogramlarda AN oranını otomatik olarak ölçmek için doğru ve verimli bir algoritma geliştirilmesi anlamlı olacaktır [25].




Şekil 1.1 Adenoid hipertrofisi hastalığının geleneksel teşhisi [25]

1.2 Cilt Lezyonu Hastalığı

Dünya genelinde her yıl 2 ile 3 milyon yeni vaka ile cilt kanseri, en sık karşılaşılan kanser türü olarak öne çıkmaktadır [29]. Dünya genelinde her üç kanser vakasından biri cilt kanseridir. Sadece Amerika Birleşik Devletleri'nde (ABD) 2019 yılında 96.480 yeni vaka ve melanomdan kaynaklanan 7.230 ölüm olduğu tahmin edilmektedir. Melanom, tüm cilt kanserlerinin %5'inden azını oluştursa da ABD'de cilt kanserine bağlı ölümlerin yaklaşık %75'inden sorumludur. 2020 yılında, ABD'de 100.350 yeni invaziv melanom vakasının teşhis edilmesi ve yaklaşık 6.850 melanom ölümünün gerçekleşmesi tahmin edilmiştir. Bu hastalıktan kaynaklanan ölenlerin 4.610'u erkek, 2.240'ı ise kadındır [30].

Cilt kanseri, cildin yüzeyinde oluştuğu için, dünyadaki en ölümcül kanserlerden biri olan melanomlar, bir dermatolog tarafından görsel inceleme ile teşhis edilebilir [31]. Dermatologlar, doğru teşhis koymak için bir dermatoskop kullanır. Bu cihaz, yüzey yansımalarını azaltır ve cildin daha derin katmanlarını görünür hale getirir [32]. Dermatologlar, melanomları sınıflandırırken beş belirgin işarete dikkat ederler. Bu işaretler, cilt lezyonunun asimetrisi, düzensiz kenarlar, düzensiz renk dağılımı, çap ve benlerin zamanla değişimi gibi beş önemli özellikleri içerir.

Cilt kanseri teşhisinde klasik bilgisayar destekli teşhis yöntemleri, beş temel işlem üzerine kuruludur: veri toplama, ön işleme, segmentasyon, özellik çıkarımı ve sınıflandırma. Cilt lezyonunun şekli ve sınırları teşhis etmede son derece önemli olduğundan, otomatik teşhis sistemleri cilt lezyonunu doğru bir şekilde tanımlayıp görüntüyü segmentleyebilmelidir. Otomatik cilt lezyonu segmentasyonu bir dizi zorlukla karşılaşır. Lezyonun rengi, dokusu ve boyutu hastalar arasında önemli ölçüde değişiklik gösterebilir. Bunun yanı sıra, görüntüdeki tıbbi gazlı bezler, saçlar, damarlar ve ışık yansımaları lezyonu tanımlamayı daha da zorlaştırır. Son olarak, cilt lezyonunun çevresindeki bölgelerde, bazı alt bölgeler diğerlerinden daha koyu olabilir. Bu durum, alt bölgelerin lezyonun bir parçası mı yoksa çevresindeki normal cildin bir parçası mı olduğunu tutarlı bir şekilde belirlemeyi zorlaştırır. Ayrıca, dermatologlar tarafından segmentlenmiş büyük etiketli veri setlerinin yetersizliği, gelişmiş ağların eğitilmesini zorlaştırmaktadır [33].



Şekil 1.2 Cilt lezyonu teşhisi için ABCD kuralları [34]

İyi huylu lezyonları cilt kanserlerinden ayırt etmek zor olabilir. Cilt kanseri uzmanları, hastalarının cilt lezyonlarını el tipi dermoskopi yardımıyla görsel inceleme ile muayene ederler. Dijital yakın çekim (makroskopik) ve dermoskopik (mikroskopik) görüntüler alabilirler. Dermoskopi, parlak ışık ve büyütme kullanarak cildi inceleme yöntemidir ve yüzey yansımalarını azaltmak için polarizasyon veya özel sıvılar kullanır. Son 20 yıldır yaygın olarak kullanılan dermoskopi, yalnızca görsel incelemeye kıyasla teşhis oranını iyileştirmiştir.

ABCD kriterleri, dermatolog olmayanların cilt lezyonlarını yaygın benign melanositik nevüsleri melanomdan ayırt etmek için taramalarına yardımcı olur. Şekil 1.2, cilt lezyonu teşhisi için ABCD kurallarını göstermektedir. Buna göre:

A: Asimetri özelliği, cilt lezyonunun iki yarısının renk, şekil ve kenarlarının birbirine uyumunu kontrol eder. Cilt lezyonları, uzun ve kısa eksenlere dayalı olarak ikiye bölünür. Melanom durumunda, genellikle asimetrik bir görünüm vardır.

B: Kenar özelliđi, cilt lezyonunun kenarlarının düzgün ve iyi tanımlanıp tanımlanmadığını belirler. Melanom durumunda, kenarlar genellikle düzensiz, bulanık ve girintili çıkıntılıdır.


C: Renk özelliđi, melanomda renklerin bir bölgeden diğetine farklılık gösterdiği ve genellikle ten rengi, kahverengi, kırmızı ve siyahın deđişik tonlarının görüldüğü bir özelliktir.

D: Çap özelliđi, cilt lezyonunun çapını ölçer. Melanomun çapı genellikle 6 mm'den büyük olur [34].

1.3 Görüntü İşleme

Görüntü işleme, dijital görüntülerin analiz edilmesi, işlenmesi ve anlamlandırılması için kullanılan disiplinler arası bir alandır. Bu alan, özellikle bilgisayarlı görme, yapay zeka ve tıbbi görüntüleme gibi uygulamalarda geniş bir kullanım alanına sahiptir [35]. Temel amacı, görüntüleri daha kullanışlı hale getirmek veya içerdği bilgiyi daha verimli bir şekilde elde etmek için matematiksel ve algoritmik teknikler kullanmaktır. Bu süreç, genellikle görüntü kalitesini artırmak veya spesifik bilgileri çıkarmak amacıyla yapılan işlemlerden oluşur [36].

Dijital görüntülerin temel bileşenleri, piksel olarak adlandırılır. Bir piksel, görüntünün belirli bir bölgesindeki ışıık yoğunluğunu sayısal bir deđer olarak temsil eder. Örneđin, 8 bitlik gri tonlamalı bir görüntüde her piksel, 0 (siyah) ile 255 (beyaz) arasında bir yoğunluk deđerini gösterir. Renkli görüntülerde genellikle RGB (kırmızı, yeşil, mavi) renk modeli kullanılır ve her piksel, her renk kanalında 8 bitlik bir veriyle temsil edilir. Bu, toplamda 24 bitlik renk derinliđi sağlar ve her piksel 16,7 milyon renk tonunu ifade edebilir [37].



Şekil 1.3 Renklerin piksel değerleri

Görüntü işleme, genellikle düşük, orta ve yüksek seviyelerde işlemler olarak sınıflandırılır. Düşük seviye işleme, görüntünün doğrudan piksellerine müdahale edilerek gürültü giderme, kontrast artırma, kenar keskinleştirme gibi işlemler gerçekleştirilir. Örneğin, bir görüntüdeki rastgele parazitlerin azaltılması için Gaussian bulanıklığı veya median filtreleme gibi teknikler kullanılır. Orta seviye işleme, görüntüden kenarlar, köşeler veya desenler gibi belirli özelliklerin çıkarılmasını içerir. Örneğin, kenar tespiti algoritmaları (Sobel, Canny gibi) görüntüdeki nesnelerin sınırlarını belirlerken, segmentasyon teknikleri (k-means kümeleme, thresholding gibi) görüntüyü anlamlı bölgelere ayırır. Segmentasyon, özellikle tıbbi görüntülemede tümör tespiti ya da anormalliklerin belirlenmesinde kritik bir rol oynar. Yüksek seviye işleme, görüntüdeki nesnelerin yorumlanmasını içerir ve genellikle yapay zeka ve derin öğrenme teknikleri kullanılarak gerçekleştirilir. Örneğin, bir nesne tanıma sistemi, bir görüntüdeki araba, insan veya nesneleri sınıflandırmak ve etiketlemek için önceden öğrenilmiş modelleri kullanır. Bu aşama, bilgisayarlı görme sistemleri için kritik öneme sahiptir. Görüntü işleme teknikleri, özellikle manyetik rezonans ve tomografi gibi tıbbi görüntüleme, güvenlik kameraları, uydu görüntüleme ve yüz tanıma gibi alanlarda yaygın olarak kullanılmaktadır. Örneğin, tıbbi görüntülemede bir manyetik rezonans (MR) görüntüsündeki tümörün tespiti, segmentasyon teknikleri kullanılarak gerçekleştirilir. Uydu görüntülerinde ise, bitki örtüsünün tespiti ya da değişikliklerin izlenmesi için görüntü işleme yöntemleri uygulanır [37].

1.4 Görüntü Segmentasyonu

Görüntü segmentasyonu, bir görüntüyü anlamlı bölgelere ayırarak analiz etmeyi kolaylaştıran bir görüntü işleme tekniğidir [38]. Bu teknik, görüntüdeki nesnelerin sınırlarının belirlenmesi veya belirli özelliklere sahip piksellerin gruplanması yoluyla gerçekleştirilir. Segmentasyon, tıbbi görüntüleme, otonom araçlar, yüz tanıma, uydu görüntü analizi gibi birçok farklı alanda yaygın olarak kullanılmaktadır. Segmentasyon yöntemlerinin başarısı, ilgili uygulama alanındaki görüntü analizi doğruluğunu doğrudan etkiler [39].

Görüntü segmentasyonun birçok türü mevcuttur. Bu türler şu şekilde sıralanabilir.

1.4.1 Eşikleme tabanlı segmentasyon

Bir görüntüyü analiz edebilmek için, kolayca tanımlanabilen ve anlamlı bilgi içeren nesneler olarak adlandırılan farklı parçalara bölünmesi gerekir. Bu bölme sürecine görüntü segmentasyonu denir [40]. Eşikleme, görüntü segmentasyonu için yaygın olarak kullanılan tekniklerden biridir. Görüntü eşikleme, pikselleri belirli özelliklerine göre sınıflandırma prensibiyle çalışır. Bir görüntüyü, piksel özneliklerine bağlı olarak bölümlere ayırır. Bu teknik, her bir piksele uygulanır ve onu belirli bir eşik değeri ile karşılaştırarak, görüntünün bir nesneye mi yoksa arka plana mı ait olduğuna karar verir. Gri tonlamalı görüntülerde segmentasyon, piksel yoğunluklarının gri seviyelerine dayalı olarak gerçekleştirilir. Görüntünün parlak kısmı nesne, koyu kısmı ise arka plan olarak kabul edilir. Gri tonlamalı görüntülerde nesneler ve arka plan kolayca tanımlanabilir, ancak işlem renkli veya dokulu görüntüler için daha karmaşık hale gelir. Bu nedenle, renkli ve dokulu görüntülerde segmentasyon daha fazla dikkat ve işlem gerektirir. Eşikleme, görüntüdeki gürültü ve artefaktların varlığından etkilenebilir; bu da yanlış segmentasyon sonuçlarına yol açabilir. Genellikle gürültü ve artefakt etkilerini azaltmak için bazı ön işleme adımları uygulanır [41].

1.4.2 Kenar tabanlı segmentasyon

Kenar tabanlı segmentasyon, görüntüdeki düzensizliklerin tespitinde en geleneksel metodolojidir. Farklı yoğunluk seviyelerine veya gri tonlamalara sahip iki bölge arasındaki sınır, kenar olarak adlandırılır. Kenarlar, görüntü işleme ve iyileştirme uygulamalarında detayların belirginleştirilmesi açısından önem taşır. Kenarların

tespiti için türev işlemleri uygulanır ve bu süreçte uygun bir maske kullanılarak görüntü üzerinde konvolüsyon işlemi gerçekleştirilir. Canny algoritması, kenarları artıran etkili bir kenar algılayıcıdır ve olası kenarları bulmak için gradyan genişliği eşik değerini kullanır [42]. Canny algoritması, bu kenarları maksimum olmayan baskılama ve histerezis eşikleme sistemi aracılığıyla belirginleştirir. Görüntüdeki gürültü, kenar algılamalarını güçlü bir şekilde etkiler ve tespit edilen kenarların ayrık piksel yapısında olması, yetersiz veya düzensiz olabilir; bu nedenle, kenar algılamadan önce görüntünün Gauss filtresi kullanılarak düzeltilmesi gerekir. Yanlış uygulanmış görüntü ön işleme teknikleri, yanıltıcı kenar algılamasına neden olabilir ve çok ölçekli kenar algılama ile kenar izleme tekniklerinin etkinliğini sınırlayabilir [43].

1.4.3 Bölge tabanlı segmentasyon

Görüntü işleme ve bilgisayarla görü alanında, bölge tabanlı segmentasyon sıkça kullanılan bir yaklaşımdır. Bu yöntem, görüntüleri benzer özellikler gösteren alanlara ayırarak görsel içeriğin daha ayrıntılı bir analizine olanak tanır. Görüntü işleme ve bilgisayarla görüde bölge tabanlı segmentasyon temelde iki ana ilkeye dayanmaktadır: piksel benzerliği ve mekânsal yakınlık. Bu teknik, belirli bir bölgede bulunan piksellerin renk, parlaklık veya doku gibi ortak özelliklere sahip olduğu varsayımına dayanır; bu da segment içinde tutarlılığı sağlar. Sadece öznitelik benzerliğinin ötesinde, piksellerin mekânsal yakınlığı da kritik bir faktördür. Yan yana veya birbirine yakın olan pikseller genellikle aynı bölgede sınıflandırılma olasılığı daha yüksek olduğundan, segmentasyonun tutarlılığını pekiştirir [44].

1.4.4 Kümeleme tabanlı segmentasyon

Kümeleme tabanlı teknikler, görüntü segmentasyonu için son derece değerli bir yöntem olarak önümüze çıkar ve benzer özelliklere sahip piksellerin farklı kümelere ayrılmasını kolaylaştırır. Veri kümelenmesinin temel bir yaklaşımı, verileri, önceden belirlenmiş benzerlik veya farklılık ölçütlerine dayalı olarak sistematik bir şekilde kümelere ayırmaktır. Ardından, her küme etiketlenir. Böylece, aynı küme içindeki unsurlar, farklı kümelerdeki unsurlara göre daha fazla benzerlik gösterir. Kümeleme yöntemleri için kapsamlı bir çerçeve sağlamak amacıyla, Fraley ve Raftery, kümeleme yöntemlerini hiyerarşik ve partisyonel olarak ikiye ayırmıştır. Bu iki yöntem birçok problemin çözümünde fayda sağlamıştır [44].

1.5 Yapay Zeka

Yapay Zeka, makinelerin insan benzeri davranışlar ve düşünme yetenekleri sergilemesini hedefleyen bir bilgisayar bilim dalıdır [45]. YZ, algoritmalar, istatistiksel modeller ve büyük veri analizini kullanarak insan benzeri davranışları simüle eden sistemler oluşturmayı amaçlar. Bu tür sistemler, doğal dil işleme (DDİ), görüntü tanıma, ses tanıma ve otonom sistemler gibi birçok alanda uygulanmaktadır [46]. Yapay zeka, genel olarak iki ana alt kategoriye ayrılır: dar yapay zeka (DYZ) ve genel yapay zeka (GYZ). Dar yapay zeka, belirli görevleri yerine getirmek için tasarlanmış sistemlerdir. Örneğin, öneri sistemleri veya oyun oynayan yapay zeka, dar yapay zekaya örnek olarak gösterilebilir. Genel yapay zeka ise, insan zekasına eşdeğer bir düşünme yeteneğine sahip sistemleri ifade eder [47].

Makine öğrenmesi (MÖ), yapay zekanın bir alt dalıdır. Otomatik öğrenme algoritmalarına dayanan bir öğrenme yöntemidir. Dolayısıyla sistemlerin deneyimlerinden öğrenmesi anlamına gelir [48]. Örneğin, sisteme verilen veri, bir modelin öğrenmesini sağlar ve bu öğrenme sonucunda model çıktıları üretir. Bu durumda, sistem deneyim kazandıkça insan müdahalesi olmadan daha akıllı hale gelir. İstatistiksel öğrenme algoritmaları kullanarak otomatik olarak öğrenir ve gelişir [49]. ML algoritmaları geniş bir sınıflandırma ile üç kategoriye ayrılır: denetimli, denetimsiz ve pekiştirmeli öğrenme.


Denetimli öğrenme, etiketli veri gerektiren bir algoritma kullanır. Sağlanan veri kümesi, eğitim ve test veri setlerine ayrılır. Eğitim veri kümesinden çıktı değişkeni tahmin edilir veya sınıflandırılır. Algoritmalar, eğitim veri kümesinden bazı kalıpları öğrenir ve bu öğrenilen desenleri test veri kümesine uygulayarak tahmin sonuçları elde eder [49].

Denetimsiz öğrenme, girdi bilgilerin bazı özelliklerini öğrenen bir makine öğrenimi algoritmasıdır. Yeni bir veri tabanı sağlandığında, daha önce öğrenilen özellikleri kullanarak verileri sınıflandırır. Özellik azaltma ve kümeleme için sıklıkla tercih edilir [49].

Pekiştirmeli Öğrenme: Karar verme kavramı üzerine dayanan bir eylem öğrenme yöntemidir. Bu öğrenmede, eylemler alınan kararlar doğrultusunda belirlenir. Böylece sonuçlar daha değerli hale gelir veya istenen bir koşul sağlanır. Ancak, öğrenici veriler hakkında önceden bilgiye sahip değildir. Durum verildiğinde, hangi eylemin alınması gerektiğini öğrenir. Öğrencinin aldığı karar, mevcut ve gelecekteki durumları etkiler ve dolayısıyla alınan eylem sonuçları belirler [49].

Derin öğrenme, makine öğrenmesinin özel bir alt dalıdır ve makine öğrenmesi de yapay zekanın bir parçasıdır [50]. Yapay zeka, insan zekâsı ile ilişkilendirilen karar verme, problem çözme ve örüntü tanıma gibi görevleri gerçekleştirebilen akıllı sistemlerin geliştirilmesine odaklanır. Yapay zekanın bir alt dalı olan makine öğrenmesi, bilgisayarların verilerden açıkça programlanmadan öğrenmesini sağlayan algoritmalar geliştirmeyi amaçlar. Makine öğrenmesi modelleri, girdilerdeki örüntüye dayalı kararları optimize etmek için çeşitli algoritmalara ve veri yapılarına dayanarak deneyimle performanslarını geliştirir. Derin öğrenme ise bu süreci bir adım öteye taşıyarak, büyük veri kümelerinden karmaşık özellikleri otomatik olarak öğrenmek için birden fazla katmana sahip yapay sinir ağlarını kullanmaktadır [51].

Derin öğrenme, katmanlar hiyerarşisi oluşturarak çalışır ve ardışık her katman, verinin daha soyut özelliklerini yakalar. İlk katmanlar bir görüntüdeki kenarları tanımlarken, daha derin katmanlar şekilleri, en son katmanlar ise karmaşık nesneleri tanıyabilir. Bu hiyerarşik özellik çıkarımı, derin öğrenme modellerinin, özellikle evrişimli sinir ağları (ESA) ve yinelemeli sinir ağları (YSA) gibi yapılar sayesinde hem denetimli hem de denetimsiz görevlerde başarıyla uygulanmasını mümkün kılar. Geleneksel makine öğrenmesi modelleri genellikle özellik mühendisliğine dayanırken, derin öğrenme modelleri büyük ölçekli verilerden bu özellikleri otomatik olarak öğrenir ve görüntü sınıflandırma, nesne tespiti ve sıralama tahmini gibi görevlerde üstün doğruluk sağlar [52]. Modern GPU (Graphics Process Unit – Grafik İşleme Birimi)'ların hesaplama gücü, derin ağların eğitimini hızlandırırken, optimizasyon tekniklerindeki ilerlemeler ve veri miktarının artması da bu sürece katkıda bulunmuştur [53].



Şekil 1.4 Yapay zeka, makine öğrenmesi ve derin öğrenme

1.6 Tezin Amacı

Günümüzde yapay zeka ve derin öğrenme teknikleri, tıbbi görüntüleme alanında hızlı ve doğru teşhis süreçlerini desteklemek amacıyla yaygın olarak kullanılmaktadır [54]. Bu teknolojiler, özellikle görüntü tabanlı hastalıkların otomatik tespiti ve sınıflandırılmasında yüksek başarı oranları ile dikkat çekmektedir. Medikal alandaki uygulamalarda, erken teşhis ve doğru sınıflandırma, hastalıkların ilerlemesini önlemek ve hasta yaşam kalitesini artırmak açısından kritik bir öneme sahiptir. Bu kapsamda geliştirilen derin öğrenme tabanlı modeller, doktorlara destek sağlayarak daha güvenilir ve hızlı kararlar alınmasına olanak tanımaktadır [55].

Bu tez çalışmasının temel amacı, adenoid hipertrofisi ve cilt lezyonları gibi klinik olarak önemli sağlık sorunlarının teşhisi ve sınıflandırılması için derin öğrenme temelli yaklaşımların etkinliğini araştırmaktır. Bu süreçte, görüntü işleme ve segmentasyon teknikleri de modele entegre edilerek daha hassas ve odaklanmış bir analiz gerçekleştirilmesi hedeflenmiştir. Özellikle geliştirilen HDARU-Net gibi ileri düzey derin öğrenme mimarileri hem adenoid hem de cilt lezyonlarının bulunduğu görüntüler üzerinde test edilerek modelin çok yönlü performansı değerlendirilmiştir.

Çalışmada, Batman Eğitim ve Araştırma Hastanesi'nden temin edilen ve literatürde daha önce kullanılmamış özgün adenoid görüntüleri ile cilt lezyonlarına ait veri seti kullanılmıştır. Bu iki farklı veri kümesinin bir arada ele alınması, geliştirilen modellerin farklı tıbbi görüntüleme senaryolarında ne derece etkili olduğunu karşılaştırmalı bir biçimde değerlendirme fırsatı sunmuştur. Ayrıca, maskelenmiş ve

maskelenmemiş veri setleriyle yapılan analizler sayesinde segmentasyonun sınıflandırma başarısı üzerindeki etkisi de ayrıntılı şekilde incelenmiştir.

Bu çalışma, adenoid hipertrofisinin doğru teşhis edilerek nefes alma zorlukları, uyku apnesi ve burun tıkanıklığı gibi sağlık sorunlarının önlenmesine katkı sağlamayı; cilt lezyonlarının ise özellikle erken evre teşhisiyle cilt kanseri gibi ciddi hastalıkların önüne geçilmesini hedeflemektedir. Sonuç olarak bu tez, geliştirilen derin öğrenme modelleriyle otomatik teşhis sistemlerinin tıbbi karar destek süreçlerindeki rolünü vurgulamakta ve literatüre hem yöntem hem de veri seti açısından anlamlı katkılar sunmayı amaçlamaktadır.

1.7 Tezin Önemi

Sağlık sektörü alanında yapay zeka ve derin öğrenme uygulamalarının giderek artan önemi, tıbbi teşhis ve tedavi süreçlerinde daha hızlı, güvenilir ve verimli çözümler geliştirilmesini mümkün kılmaktadır. Özellikle tıbbi görüntüleme alanında, derin öğrenme temelli modellerin kullanımı, klinik karar destek sistemlerini güçlendirmekte ve sağlık hizmetlerinin kalitesini artırmaktadır. Bu teknolojiler sayesinde, görüntülerin otomatik analizi ile teşhis süreçleri hem hızlanmakta hem de insan kaynaklı hataların önüne geçilebilmektedir.

Bu tez çalışması, adenoid hipertrofisi ve cilt lezyonları gibi önemli sağlık problemlerinin teşhisinde geliştirilen derin öğrenme modellerinin kullanımını teşvik ederek, geleneksel yöntemlerin sınırlılıklarını aşmayı hedeflemektedir. Özellikle manuel görüntü analizi süreçlerinin zaman alıcı ve uzmanlık gerektiren yapısı, otomatik sistemlere olan ihtiyacı artırmaktadır. Bu bağlamda geliştirilen HDARU-Net modeli, teşhis doğruluğunu artırmak ve süreci hızlandırmak amacıyla, adenoid ve cilt lezyonlarına ait görüntülerde başarılı sonuçlar sunmaktadır.

Tezin önemli katkılarından biri, Batman Eğitim ve Araştırma Hastanesi'nden elde edilen ve literatürde daha önce kullanılmamış olan adenoid görüntü veri setiyle birlikte, cilt lezyonu veri setinin bir arada kullanılmasıdır. Bu sayede geliştirilen modelin, farklı klinik senaryolarda ve hasta gruplarında genellenebilirliği test edilmiş, modelin çok yönlü uygulanabilirliği ortaya konmuştur. Ayrıca hem segmentasyon hem

de sınıflandırma adımlarını içeren analiz süreci, görüntüdeki kritik yapıların doğru şekilde tespit edilmesini sağlayarak, daha güvenilir teşhislerin önünü açmaktadır.

Sonuç olarak bu tez çalışması, tıbbi görüntülemede derin öğrenme tabanlı otomatik sistemlerin kullanımına dair güçlü bir örnek sunmakta ve bu sistemlerin sağlık alanına entegrasyonunun ne derece etkili olabileceğini göstermektedir. Elde edilen bulgular, yalnızca klinik uygulamalara katkı sunmakla kalmayıp, aynı zamanda bu alandaki gelecek araştırmalar için de sağlam bir temel oluşturmaktadır.

1.8 Tezin İçeriği

Bu doktora tezi, adenoid hipertrofisi ve cilt lezyonlarının görüntü analiziyle teşhis edilmesine yönelik ileri düzey görüntü işleme ve derin öğrenme tekniklerini kapsamaktadır. Tezin yapısı, iki temel hastalığın görüntü analizine dayalı sınıflandırma ve segmentasyon süreçlerini kapsamaktadır. Tezin “Giriş” bölümü, adenoid hipertrofisi ve cilt lezyonlarının temel özelliklerini açıklayarak bu hastalıkların klinik açıdan taşıdığı önemi vurgulamaktadır. Ayrıca, görüntü işleme tekniklerinin tıbbi görüntü analizindeki rolü, görüntü segmentasyonu ve hastalıkların sınıflandırılması süreçlerindeki katkıları detaylandırılacaktır. Bu bölümde, çalışmanın amaçları, önemi ve genel kapsamı özetlenerek okuyucuya kapsamlı bir çerçeve sunulacaktır. Tezde “Önceden Yapılan Çalışmalar” kısmında literatürde adenoid hipertrofisi hastalığı ve cilt lezyonları üzerine yapılan çalışmalar incelenerek, segmentasyon ve sınıflandırma alanında kullanılan yöntemler değerlendirilecektir. “Malzeme ve Yöntem” bölümünde ise tez çalışmasında kullanılan adenoid ve cilt lezyonu veri seti hakkında bilgi verilecek, bu verilerin segmentasyonu ve sınıflandırılması için kullanılan yöntemler ve modeller ayrıntılı olarak açıklanacaktır. Adenoid görüntüleri ve cilt lezyonları için kullanılan segmentasyon modelleri (U-Net, U-Net++, SegNet, HDARU-Net) ve derin öğrenme modelleri (EfficientNet, MobileNet, ResNet50, ResNet152, VGG16, Xception) karşılaştırılacaktır. Ayrıca, önerilen HDARU-Net modeli de tanıtılacaktır. “Bulgular ve Tartışma” bölümü, elde edilen sonuçları mevcut literatürle karşılaştırarak çalışmanın tıbbi görüntü analizi ve klinik uygulamalar açısından sağladığı katkıları değerlendirecektir. Bu bölümde, önerilen yöntemlerin etkinliği hem sayısal hem de klinik perspektiflerden

tartışılacaktır. Son olarak, “Sonuçlar ve Öneriler” kısmında yapılan çalışmanın bulguları özetlenecek ve gelecekteki araştırmalara yönelik öneriler sunulacaktır.



2. ÖNCEKİ ÇALIŞMALAR

Adenoid hipertrofisi ve cilt lezyonları ile ilgili pek çok araştırma yapılmıştır. Adenoid hipertrofisinin teşhisinde genellikle fiber optik nazal endoskopi ve lateral sefalogram gibi görüntüleme yöntemleri kullanılmaktadır. Bu yöntemler, adenoid büyüklüğünü ve hava yolu tıkanıklığını değerlendirmeye yardımcı olur. Özellikle Fujioka tarafından geliştirilen adenoid-nazofaringeal oran yöntemi, adenoid dokusunun büyüme derecesini belirlemede önemlidir. Ancak, bu yöntemde işaretleme süreci zaman alıcı olup, uzman deneyimine dayalı farklı sonuçlar ortaya çıkabilmektedir. Bu nedenle, adenoid hipertrofisinin daha hızlı ve doğru bir şekilde tespit edilmesi için Bilgisayar Destekli Tanı (BDT) sistemleri üzerine çalışmalar yapılmaktadır.

Cilt lezyonları alanında ise, erken teşhisin önemini vurgulayan araştırmalar öne çıkmaktadır. Cilt kanseri teşhisinde kullanılan dermoskopi, dermatologlara daha ayrıntılı inceleme imkânı sağlarken, BDT sistemleri bu süreci daha hızlı ve objektif hale getirmektedir. Cilt lezyonlarının otomatik olarak segmentasyonu ve sınıflandırılması, BDT sistemlerinin temel işlevlerindendir. Ancak, bu işlemler cilt lezyonlarının renk, doku ve boyut gibi çeşitli özellikleri ve görüntüdeki bazı parazitlerin varlığı nedeniyle zorlaşmaktadır. Bu sebeple, cilt lezyonlarının doğru tespitine yönelik BDT sistemleri üzerine yapılan araştırmalar artarak devam etmektedir. Konuyla ilgili literatürde daha önce yapılmış olan bazı önemli çalışmalar aşağıda özetlenmiştir.

2.1 Adenoid Hipertrofisi Hastalığı ile Alakalı Yapılan Bilimsel Çalışmalar

Rout ve arkadaşlarının 2012 yılında yaptığı çalışmada, yetişkinlerde görülen adenoid hipertrofisinin nedenleri ve bu durumun semptomları incelenmiştir. Çalışma, Hindistan'daki bir tıp merkezinde gerçekleştirilmiş ve iki yıl boyunca 200 yetişkin hasta üzerinde yapılmıştır. Adenoid hipertrofisinin çocuklarda sık görülmesine rağmen yetişkinlerde nadir görüldüğü vurgulanmaktadır. Araştırmada, burun tıkanıklığı şikâyeti olan hastaların %21'inde ve kronik tonsillit vakalarının %9'unda adenoid hipertrofisi tespit edilmiştir. Bu durumun en yaygın nedenleri arasında kronik enfeksiyonlar, alerjik rinit, çevresel kirlilik ve sigara kullanımı yer alırken, nadir durumlarda sinüzal tümörler, lenfoma ve HIV enfeksiyonu gibi ciddi hastalıklarla ilişkili olduğu belirtilmiştir. Çalışmada ayrıca adenoid hipertrofisinin erkeklerde daha

yaygın olduđu (%70) ve çoğunlukla 16-25 yaş aralığında görüldüğü (%60) rapor edilmiştir. Yetişkinlerdeki adenoid hipertrofisi, solunum yolu enfeksiyonları ve burun tıkanıklığı gibi semptomlara neden olarak yaşam kalitesini olumsuz etkileyebilmektedir. Çalışma sonuçları, bu rahatsızlığın tanı ve tedavisinde doğru değerlendirmelerin yapılmasının önemini vurgulamaktadır ve özellikle tehlikeli durumların erken tanısı ile tedavi edilmesi gerektiğine dikkat çekmektedir [56].

Xin Feng ve arkadaşlarının 2015 yılında yaptığı çalışmada üst solunum yolu hacmini değerlendirmek amacıyla lateral sefalogram ve konik ışınli bilgisayarlı tomografi (KIBT) tekniklerini karşılaştırmaya odaklanmıştır. Çalışmanın temel amacı, özellikle ortodontik tedavi sürecinde sıklıkla kullanılan lateral sefalogramların nasofarenks hacmi ölçümlerinde yeterli doğruluğa sahip olup olmadığını KIBT ölçümleri ile kıyaslayarak değerlendirmektir. Bu amaçla, yaşları 9 ile 43 arasında değişen 55 hasta çalışmaya dahil edilmiş ve hastaların görüntüleme işlemlerinde, KIBT ve sefalogram çekimlerinin bir haftadan kısa bir süre içinde yapılmasına dikkat edilmiştir. Çalışmada hastalar, yaşlarına göre iki gruba ayrılmıştır: 15 yaş ve altı olanlar (Grup A) ile 15 yaş üstü olanlar (Grup B). Nasofarenks hacmi ve toplam üst solunum yolu hacmi gibi parametrelerin ölçümleri KIBT verilerinden hesaplanmış ve bu sonuçlar lateral sefalogramlardan elde edilen Adenoidal Nasofarenks Oranı (ANO) ile karşılaştırılmıştır. Genç yaş grubunda (Grup A) ANO ve nasofarenks hacmi arasındaki korelasyon güçlü ($r = -0,78$) bulunurken, yetişkin grupta (Grup B) korelasyon nispeten zayıf kalmıştır ($r = -0,57$). Ayrıca, ANO'nun tüm üst solunum yolu hacmi ile korelasyonu her iki grupta da oldukça düşük bulunmuştur. Bu durum, ANO ölçümünün daha çok genç hastalarda nasofarenks hacminin tahmininde kullanılabileceğini ancak tüm üst solunum yolu için yeterli bir gösterge olmayabileceğini ortaya koymaktadır. Çalışma, lateral sefalogramların iki boyutlu bir görüntüleme yöntemi olmasının üst solunum yolu ölçümlerini sınırladığını, ancak yine de maliyet etkinliği, erişilebilirliği ve kolay yorumlanabilirliği nedeniyle başlangıç taraması olarak faydalı bir araç olabileceğini öne sürmektedir. Çalışma sonuçları, solunum yolu obstrüksiyonu teşhisinde sefalogramların kullanışlı bir tarama yöntemi olduğunu, ancak kesin teşhis ve detaylı incelemeler için KIBT gibi üç boyutlu görüntüleme tekniklerine başvurulması gerektiğini vurgulamaktadır. Özellikle genç hastalarda ANO ölçümü, adenoid büyüklüğünün solunum yolu üzerindeki etkilerini

değerlendirmede yararlı olabilirken, yaşla birlikte solunum yolu morfolojisinde meydana gelen değişimlerin ANOVA ölçümleriyle doğru bir şekilde değerlendirilemeyeceği belirtilmiştir [57].

Hu ve arkadaşlarının 2019 yılında yapılan çalışmada, yüz estetiği ve makine öğrenimi tekniklerini bir araya getirerek adenoid hipertrofisinin teşhisine yönelik yeni bir yöntem önerilmektedir. Araştırma, yüz özelliklerini analiz ederek adenoid yüzü tanımlamayı ve bu bilgileri kullanarak nasal solunum obstrüksiyonu için erken teşhis ve tedavi sağlama amacı taşımaktadır. Çalışmada, bilgisayarla görme teknikleri ile adenoid yüz özellikleri belirlenmiş ve öne çıkan yüz özellikleri arasında dudak kalınlığı, iç ve dış göz mesafeleri gibi faktörler incelenmiştir. Ayrıca, adenoid yüzü ile normal yüzü ayırt etmek için karar ağaçları, destek vektör makineleri (SVM), KNN ve XGBoost gibi makine öğrenimi yöntemleri kullanılarak tahmin modelleri geliştirilmiştir. Modelin güvenilirliği, 5 katlı çapraz doğrulama ile değerlendirilmiş ve adenoid yüz tanısında en iyi sonuçlar elde edilmiştir. Çalışmada, 268 çocuk üzerinde yapılan analiz sonucunda, adenoid hipertrofisi ile ilişkili yüz özellikleri belirlenmiş ve bu özellikler, model eğitiminde etkili bir şekilde kullanılmıştır. Sonuçlar, bilgisayarla görme teknikleri ile adenoid yüz tahmininin daha güvenilir olduğunu ortaya koymuş, en iyi spesifikite %89.19 ve duyarlılık %88.24 olarak rapor edilmiştir. Adenoid yüzü teşhis etmek için görüntü tabanlı bir makine öğrenimi modelinin geliştirilmesine katkıda bulunmuş ve çocukların sağlık hizmetlerine erişimini iyileştirmeyi hedeflemiştir [58].

Zhao ve arkadaşları 2021 yılında yapılan çalışmada, çocuklarda adenoid hipertrofisini lateral sefalometri görüntüleri kullanarak otomatik olarak değerlendirmek amacıyla bir yapay zeka modeli geliştirmiştir. Adenoid hipertrofisi, çocuklarda üst solunum yolu obstrüksiyonu ve ağız solunumuna yol açabilir ve kraniofasiyal gelişimi olumsuz etkileyebilir. Çalışmada, Fujioka'nın adenoid-nazofarenks oranı yöntemi kullanılarak belirlenen dört anahtar nokta üzerinden bir derin öğrenme modeli eğitilmiştir. Eğitim için 581, test ve validasyon için ise 160'ar adet sefalogram kullanılmıştır. Geliştirilen yapay zeka modeli, AN oranını %60'ın üzerinde hesapladığında adenoid hipertrofisi teşhisi koymaktadır. Modelin tanısal performansı yüksek olup, duyarlılığı %90.6, özgüllüğü %93.8, doğruluğu %91.9 ve ROC eğrisi altındaki alan (AUC) %98.7 olarak

tespit edilmiştir. Bu sonuçlar, modelin adenoid hipertrofisini tespit etmede yüksek doğruluğa sahip olduğunu göstermektedir. Modelin klinik pratikte çocuk hastalarda rutin olarak yapılan lateral sefalometri görüntülerinde adenoid hipertrofisini otomatik olarak tespit edebileceği belirtilmiştir. Bu, özellikle büyük veri setleri üzerinde manuel değerlendirme gereksinimini azaltarak insan hatalarını minimuma indirme potansiyeline sahiptir [59].

Alshbishi ve arkadaşları tarafından 2021 yılında yapılan çalışmada, X-ray görüntülerinde adenoid bezinin otomatik segmentasyonu amacıyla derin öğrenme tabanlı U-Net mimarisi kullanılmıştır. Adenoid bezinin boyutunun belirlenmesi, özellikle adenoid hipertrofisi gibi durumların teşhis ve değerlendirilmesinde büyük önem taşır. Bu nedenle, otomatik ve doğru bir segmentasyon yöntemi geliştirilmesi, doktorların tanılama sürecini hızlandırarak daha verimli hale getirebilir. King Abdulaziz Üniversitesi Hastanesi'nden elde edilen 672 adet DICOM (Digital Imaging and Communications in Medicine) X-ray görüntüsü bu çalışmada veri seti olarak kullanılmıştır. Görüntülerin 416'sı eğitim, 256'sı test için ayrılmıştır. U-Net modeli, biyomedikal görüntü segmentasyonunda yaygın olarak kullanılan bir yapıdır ve bu çalışmada, adenoid bezinin doğru bir şekilde ayrıştırılmasında başarılı sonuçlar vermiştir. Modelin performansı Intersection over Union (IoU) ve Dice katsayısı ile değerlendirilmiş; adenoid bölgesi için IoU skoru %62, Dice katsayısı ise %74 olarak hesaplanmıştır. Bu sonuçlar, modelin adenoid bölgesini ayırt etmede yeterince başarılı olduğunu gösterse de arka plan ile hedef bölge arasındaki piksel dengesizliği nedeniyle segmentasyon doğruluğunun etkilenebileceği belirtilmiştir. Çalışma, X-ray görüntülerinde adenoid segmentasyonu için ilk U-Net uygulamalarından biri olarak literatürdeki eksikliği gidermektedir. Sonuçların daha da iyileştirilmesi için, Generative Adversarial Networks (GAN) gibi daha ileri düzey yöntemlerin veri setini genişletmede kullanılabileceği ve farklı enkoder mimarileriyle U-Net varyantlarının test edilmesi önerilmektedir. Böylece hem segmentasyon doğruluğunun artırılması hem de modelin genel performansının iyileştirilmesi hedeflenmektedir [60].

Zheng ve arkadaşları 2022 yılında yaptığı çalışmada, çocuklarda sık görülen adenoid hipertrofisinin teşhisinde uzman desteğini azaltmak ve süreci hızlandırmak amacıyla MIB-ANet adlı derin öğrenme tabanlı bir sınıflandırma modeli geliştirilmiştir.

Adenoid hipertrofisi, burun tıkanıklığı gibi sorunlara yol açabilen yaygın bir hastalık olup, teşhisi genellikle nasoendoskopik görüntüleme ile yapılır. Ancak, uzman bilgisi ve oldukça dikkat gerektiren bu süreç zaman alıcıdır. Çalışmada önerilen MIB-ANet modeli, çok ölçekli özellik çıkarımını destekleyen bir yapı kullanarak, adenoid hipertrofisini dört dereceye ayırabilmektedir. Modelin performansını artırmak için SimCLR tabanlı karşılaştırmalı öğrenme yöntemiyle önceden eğitilmesi sağlanmış, bu yöntemle anotasyonlu veri yetersizliği nedeniyle yaşanan aşırı öğrenme sorunları hafifletilmiştir. Veri seti, Sun Yat-sen Üniversitesi'nin Yedinci Hastanesi ile iş birliği yapılarak oluşturulmuş ve çeşitli derecelerde adenoid görüntüleri içermektedir. Deneysel sonuçlar, MIB-ANet modelinin, AlexNet, VGG16, ResNet50 ve GoogleNet gibi klasik ESA modellerine kıyasla daha yüksek doğruluk ve F1 skoru sunduğunu göstermiştir. Ayrıca, SimCLR tabanlı karşılaştırmalı öğrenme stratejisi kullanılarak etiketsiz verilerde özellik öğrenimi sağlanmış, böylece model performansında kayda değer iyileşmeler elde edilmiştir. Bu yöntemin etkisi özellikle anotasyonlu veri oranı azaldığında belirginleşmiş; F1 skorunda %4.41'e kadar artış sağlanmıştır. Sonuç olarak, bu çalışma, adenoid hipertrofisinin sınıflandırılmasında derin öğrenme tekniklerinin nasıl etkin bir şekilde uygulanabileceğini ve karşılaştırmalı öğrenme ile performansın nasıl artırılabilceğini göstermektedir [61].

He ve arkadaşları 2023 yılında yaptığı çalışmada adenoid hipertrofisinin MRI görüntüleri kullanılarak otomatik değerlendirilmesi amacıyla derin öğrenme tabanlı Adenoid-Net (ADNet) modeli önerilmektedir. Geleneksel yöntemlerin aksine, bu model AH'nin şiddetini belirlemek için MRI görüntülerindeki yer işaretlerini doğru şekilde saptamakta ve adenoid-nazofaringeal (AN) oranını hesaplayarak AH teşhisinde güvenilir bir alternatif sunmaktadır. Çalışma kapsamında Shuguang Hastanesi'nden elde edilen ve profesyonelce etiketlenmiş 500 MRI görüntüsü kullanılmıştır. ADNet modeli, derin öğrenme mimarisi içinde enkoder-dekoder yapısını kullanır. Yerel özellikleri yakalamak için ayrık derinlikli evrişim tabanlı enkoder ve küresel özellikleri yakalamak için adaptif evrişim tabanlı dekoder kullanılarak, AH'nin doğru şekilde değerlendirilebilmesi sağlanmıştır. Model, dört temel yer işaretini saptamak için bir yer işareti tespit başlığı içerir ve nihai yer işareti koordinatlarını tahmin edebilmek için sayısal koordinat regresyon katmanı entegre edilmiştir. Deneysel sonuçlar, ADNet'in %96 başarı oranı ve 15 piksel içinde ortalama

4.85 piksel radyal hata ile yer işareti tespiti yapabildiğini göstermektedir. Bu başarı oranı, ADNet'in adenoid hipertrofisini doğru bir şekilde tespit edebildiğini ve manuel işleme kıyasla zamandan tasarruf sağladığını ortaya koymaktadır [25].

Rao ve arkadaşları 2024 yılında yaptığı çalışmada, çocuklarda adenoid hipertrofisini otomatik olarak teşhis etmek için çok ölçekli yerel dikkat mekanizmasına dayalı yeni bir derin öğrenme modeli olan AdeNet'i geliştirmiştir. Adenoid hipertrofisi, üst solunum yolu tıkanıklığına ve "adenoid yüz" olarak bilinen kraniofasiyal deformitelere yol açabilir. Bu durumu teşhis etmek için genellikle Fujioka'nın adenoid-nazofarenks (AN) oranı yöntemi kullanılmaktadır. Ancak bu süreç zaman alıcı olduğundan, daha hızlı ve standart bir yöntem ihtiyacı doğmuştur. Araştırmada, AdeNet modeliyle üç hastaneden elde edilen 1425 lateral sefalogram görüntüsü kullanılarak, adenoid hipertrofisi tespiti için otomatik bir çözüm sunulmuştur. Model, AN oranı tahmin problemini bir anahtar nokta tespiti sorununa dönüştürerek, yerel dikkat modülleri ve veri genişletme yöntemleri ile eğitilmiştir. Yapılan testlerde, AdeNet, diğer modellerle karşılaştırıldığında daha düşük hata oranları (MSE: 0.0023, MRE: 1.91) ve daha iyi bir standart sapma değeri (SD: 7.64) sunarak üstün performans göstermiştir. Adenoid hipertrofisinin hızlı ve güvenilir bir şekilde teşhis edilmesine katkı sağlayarak, klinik iş akışını hızlandırmak ve radyologların iş yükünü azaltmak amacı taşımaktadır [62].

2.2 Cilt Lezyonu Hastalığı ile Alakalı Yapılan Bilimsel Çalışmalar

Mishra ve Daescu'nun 2017 yılında gerçekleştirdiği bu çalışma, cilt kanseri türlerinden melanomun bilgisayar destekli tespiti ve otomatik segmentasyonu üzerine odaklanmaktadır. Çalışmada, gözlem yanlışlığını azaltmak ve erken teşhisi daha güvenilir hale getirmek amacıyla, dermoskopi görüntülerinde cilt lezyonlarının otomatik olarak segmentasyonunu sağlayan bir derin öğrenme yöntemi geliştirilmiştir. Araştırmacılar, ISIC veri kümesinden alınan dermoskopik görüntüleri ve lezyon maske verilerini kullanarak, lezyon segmentasyonunda ESA tabanlı bir yaklaşım sunmuş ve yöntemlerini ISBI 2017 yarışmasında diğer katılımcıların performansı ile karşılaştırmıştır. Bu yöntemin, segmentasyon doğruluğu açısından diğer yöntemlere göre daha başarılı sonuçlar verdiği saptanmıştır. Araştırmanın temel katkısı, U-Net mimarisini kullanarak daha verimli bir ESA yapısı geliştirmek ve bu yapıyı GPU

hızlandırması ile çalıştırmaktır. Yöntem, özellikle ESA'nın derin katmanlarında kullanılan farklı boyutlardaki filtreler, çapraz doğrulama ve ön işleme adımları sayesinde yüksek bir doğruluk sağlamaktadır. Ayrıca, önerilen ESA mimarisi, önceki çalışmalara göre daha az katmana sahip olup, daha düşük işlem maliyeti gerektirmekte ve veri artırımı teknikleri ile aşırı öğrenmenin önüne geçilmiştir. Bu sayede model, geniş bir veri kümesinde başarılı sonuçlar elde etmiş ve Jaccard Endeksi yaklaşık 0,84 olan başarılı bir segmentasyon doğruluğuna ulaşmıştır. Çalışmanın sonucu olarak cilt kanseri segmentasyonu alanında derin öğrenme tabanlı bir yöntemin etkinliğini göstermektedir. Önerilen ESA yapısı, segmentasyon doğruluğu açısından Otsu eşikleme gibi geleneksel yöntemlere göre üstün performans sergilemiş ve ISBI 2017 yarışmasında öne çıkan diğer yöntemleri geride bırakmıştır. Çalışma, lezyon bölgelerinin doğru bir şekilde segmentasyonunun erken teşhis için kritik olduğunu vurgularken, segmentasyon sonrasında elde edilen sonuçların daha ileri sınıflandırma aşamalarında kötü huylu ve iyi huylu tümörlerin ayrılmasına yönelik kullanımı üzerinde durmaktadır [63].

Shahin ve arkadaşları 2018 yılında yapılan çalışmada, deri lezyonlarının sınıflandırılması için ResNet-50 ve Inception V3 derin öğrenme modellerini bir araya getirerek yeni bir çerçeve önermiştir. Bu çalışma, yedi farklı deri lezyonu türünü (melanom, melanositik nevüs, bazal hücreli karsinom, aktinik keratoz, benign keratoz, dermatofibrom ve vasküler lezyon) sınıflandırmayı amaçlayan otomatik bir sistem geliştirmiştir. ISIC 2018 veri seti üzerinde yapılan deneylerde, modelin %89.9 doğruluk oranına ulaştığı ve deri kanserinin erken teşhisini desteklemek amacıyla klinik ortamlarda etkin bir araç olabileceği belirtilmiştir. Çalışmada, veri artırma teknikleri ve önceden eğitilmiş ağırlıklar kullanılarak sınıflandırma performansı artırılmıştır. Sonuçlar, ensemble yönteminin, ResNet-50 ve Inception V3 modellerinin bağımsız performansını aşarak sınıflandırma doğruluğunu önemli ölçüde geliştirdiğini göstermektedir. Bu model, önceki yaklaşımlara kıyasla yüksek doğruluk oranları sağlarken, aynı zamanda lezyonların segmentasyon öncesi işleme gerek kalmadan sınıflandırılmasına olanak tanımaktadır [64].

Kaymak ve arkadaşları 2018 yılında yapılan çalışmada, deri lezyonlarının melanom ve diğer cilt kanseri türleri arasında ayrımını yapmayı amaçlayan iki aşamalı bir

sınıflandırma yöntemi geliştirmişlerdir. İlk aşamada, derin öğrenme modelleri kullanılarak lezyonlar melanositik veya melanositik olmayan olarak sınıflandırılmıştır. İkinci aşamada ise melanositik lezyonlar arasından melanom olanlar tespit edilmiştir. Bu çalışma, uzman dermatologların kullandığı iki aşamalı teşhis yöntemini taklit ederek cilt kanserlerinin otomatik sınıflandırmasını sağlamaktadır. Melanositik ve melanositik olmayan lezyonları ayırt etmede yüksek doğruluk oranları elde edilmiştir. Çalışmada AlexNet mimarisi kullanılarak yedi farklı deri lezyon türü sınıflandırılmıştır. ISIC 2018 veri seti üzerinde yapılan deneyler sonucunda, melanositik lezyonların sınıflandırmasında %84 doğruluk elde edilirken, melanositik olmayan lezyonların sınıflandırmasında %58 doğruluk oranına ulaşılmıştır. Bu sonuçlar, melanositik lezyonların sınıflandırılmasının, melanositik olmayan lezyonlara kıyasla daha başarılı olduğunu göstermektedir. Çalışmanın sonuçları, özellikle melanom teşhisinde erken tanı ve doğru tedaviye yönlendirme açısından önemli bir katkı sağlamaktadır [65].

Al-Masni ve arkadaşları 2019 yılında yaptığı çalışmalarında, deri lezyonlarının sınırlarını belirleme ve sınıflandırma amacıyla yeni bir derin öğrenme modeli geliştirmiştir. Bu model, tam çözünürlüklü konvolüsyonel ağlar (FrCN) ve derin artıklıklı ağları (ResNet-50) entegre ederek iki aşamalı bir süreçten oluşmaktadır. İlk aşamada, FrCN, deri lezyonlarının sınırlarını belirlemek için kullanılmış ve lezyonları yüksek çözünürlükle segment ederek ayrıntılı özellikleri ortaya çıkarmıştır. Bu segmentasyon sonuçları daha sonra ResNet-50'ye iletilerek lezyon sınıflandırması yapılmıştır. Model, ISIC 2017 veri seti üzerinde test edilmiş ve benign, seboreik keratoz ve melanom gibi deri lezyonlarının sınıflandırılmasında %81.57 doğruluk ve %75.75 F1 puanı ile başarılı sonuçlar elde etmiştir. Çalışmanın sonuçları, FrCN'nin %94.03 doğruluk ve %77.11 Jaccard benzerlik indeksi ile etkili bir segmentasyon performansı sergilediğini göstermiştir. ResNet-50'nin sınıflandırma aşamasında, özellikle segmentasyon sonrası elde edilen yüksek temsil gücüne sahip özelliklerin kullanılması, sınıflandırma doğruluğunu artırmıştır. Çalışmada önerilen modelin, dermatoloji alanında bilgisayar destekli teşhis (CAD) sistemlerinde kullanılabileceği ve uzmanların karar verme süreçlerine destek sağlayabileceği belirtilmiştir [66]

Bassi ve arkadaşları 2019 yılında yaptığı çalışmada, cilt lezyonlarının teşhisinde derin öğrenme tekniklerinin kullanımını inceleyen bir çalışma gerçekleştirmiştir. Derin öğrenme ve bilgisayarla görme tekniklerinin tıbbi görüntülemede sunduğu yüksek doğruluk ve otomasyon avantajlarından yararlanarak, cilt lezyonlarının sınıflandırılması amacıyla Convolutional Neural Networks (CNN), transfer öğrenme ve segmentasyon gibi teknikler kullanılmıştır. Bu çalışmada HAM10000 veri seti kullanılmış olup, veri setindeki yedi farklı cilt lezyon sınıfına ait etiketlenmiş görüntülerle modeller eğitilmiştir. Dengesiz veri sınıfları ve küçük veri kümesi gibi zorluklar karşısında transfer öğrenme stratejileri uygulanarak önceden eğitilmiş ESA modellerinin performansı artırılmıştır. Araştırmada ayrıca, cilt lezyonlarını segmentasyon yöntemiyle öne çıkararak görüntülerden özellik çıkarımı sürecini optimize eden bir ön işleme adımı eklenmiştir. Çalışmanın sonuçları, VGG16 tabanlı transfer öğrenme modelinin %82.8 doğruluk ve 0.7 ortalama F-skoruyla en yüksek performansı sağladığını göstermiştir. Paralel ağlar gibi diğer yaklaşımlar ve sıfırdan eğitilen ESA modelleri de incelenmiş; paralel ağlarda lezyonla birlikte hastanın yaş ve cinsiyet gibi demografik verilerinin kullanılması, sınıflandırma doğruluğunda iyileşme sağlamıştır. Segmentasyon kullanılarak eğitilen ESA modeli ise %65.8 doğruluk oranına ulaşmıştır. Araştırma derin öğrenme yöntemlerinin tıbbi görüntü sınıflandırmasında potansiyelini vurgulamakta ve özellikle transfer öğrenmenin küçük ve dengesiz veri setleri için etkili bir çözüm sunduğunu ortaya koymaktadır [67]

Guergueb ve arkadaşları 2021 yılında yaptıkları çalışmada, derin öğrenme modellerinin cilt kanseri türlerinden biri olan melanomun erken teşhisindeki potansiyelini araştırmışlardır. Çalışmada, 36.000'den fazla görüntü kullanarak çeşitli derin öğrenme modelleri test edilmiştir. Konvolüsyonel Sinir Ağı tabanlı sınıflandırıcılar kullanılarak yapılan analizlerde, en başarılı modelin %99'un üzerinde doğruluk ve Eğri Altındaki Alan değeri elde ettiği gösterilmiştir. Çalışmanın amacı, insan uzmanların sınırlamalarına ve teşhis sürecinin karmaşıklığına bir çözüm sunmak ve yüksek doğrulukla otomatik melanoma teşhisi yapabilen bir model geliştirmektir. Çalışmada, EfficientNetB7 modelinin diğer modelleri geride bıraktığını ortaya koymuş ve bu model %99.33 doğruluk, %98.78 duyarlılık ve %99.38 özgüllük ile en iyi sonuçları elde etmiştir. Çalışmada, veri dengesizliği gibi zorlukların üstesinden gelmek için veri çoğaltma teknikleri kullanılmış ve bir döngüsel öğrenme oranı

politikası benimsenmiştir. Gelecekteki çalışmalar için, cilt lezyonlarının çok sınıflı sınıflandırılmasına odaklanılacağı ve veri dengesizliği sorununa daha fazla çözüm aranacağı belirtilmiştir [68].

Das ve arkadaşları 2021 yılında yaptığı çalışmada melanoma ve bazal hücreli karsinom gibi kötü huylu deri büyümelerini erken aşamada tespit etmenin zorluklarını ele alarak, deri lezyonlarının erken teşhisi için hibrit bir derin öğrenme modeli önermektedir. Model, görüntülerden istatistiksel olmayan özellikleri çıkaran bir evrişimli sinir ağı ile istatistiksel özellikleri işleyen Çok Katmanlı Algılayıcı (MLP) yapısını bir araya getirmektedir. Bu yaklaşımların entegrasyonu ile model, HAM10000 veri setinde %98,1 doğruluk oranına ulaşarak sınıflandırma doğruluğunu arttırmaktadır. Model, renk momentleri ve Gri Seviye Eş Oluşum Matrisi (GLCM) gibi, lezyonların dağılımını ve dokusunu analiz eden özellikleri kullanarak deri anormalliklerini ayırt edilebilmektedir. Bu hibrit yaklaşım, yalnızca ESA modelini kullanmaya kıyasla daha iyi performans sergileyerek %86,1 doğruluktan %98,1 doğruluğa ulaşıyor ve derin öğrenme yöntemlerine el yapımı istatistiksel özelliklerin eklenmesinin etkinliğini göstermektedir. Çalışma, bu bütünsel modelin klinik uygulamalarda daha doğru sonuçlar sağlayabileceğini ve dermatologların zamanında ve doğru teşhis yapmalarına yardımcı olabileceğini öne sürmektedir. Gelecekteki çalışmalarda, modelin doğruluğunu daha da artırmak için hasta yaşı, tıbbi geçmiş ve semptom profilleri gibi ek klinik verilerin eklenmesi düşünülmektedir [69].

Wu ve arkadaşları 2022 yılında yaptığı çalışmada cilt kanserinin erken teşhisini iyileştirmek amacıyla derin öğrenme tabanlı bir sınıflandırma modeli sunmaktadır. Cilt kanseri, dünya çapında yaygın bir hastalık olup, erken tanı büyük önem taşımaktadır. Araştırmada, ISIC 2017 HAM10000 veri setindeki yedi cilt lezyonu türünün sınıflandırılması için InceptionV3, ResNet50 ve DenseNet201 modelleri kullanılmıştır. Bu modeller, transfer öğrenme tekniğiyle iyileştirilmiş ve yeni katmanlar eklenerek cilt lezyonlarının daha doğru sınıflandırılması hedeflenmiştir. Modeller üzerinde çeşitli veri ön işleme işlemleri gerçekleştirilmiş; görüntüler kırpılmış, saç gibi parazitler kaldırılmış ve veri dengesizliği giderilmiştir. Derin öğrenme modellerinin eğitiminde, ağırlık ayarlamaları yapılarak her bir modelin en iyi sonuç vermesi sağlanmıştır. İyileştirilmiş modeller, sınıflandırma doğruluğunu

artırmak için önceden ImageNet verileriyle eğitilmiş ve transfer öğrenme yöntemi kullanılarak ince ayar yapılmıştır. Özellikle, veri dengesi sağlamak için örnekler artırılmış ve azaltılmış, eğitim sürecinde de çeşitli veri artırma teknikleri uygulanmıştır. Sonuçlara göre, geliştirilmiş ResNet50 modeli %86.69 doğruluk oranı ile en başarılı model olarak belirlenmiştir ve diğer yöntemlerin doğruluğuna göre %3 daha yüksek bir doğruluk göstermiştir. Çalışma, derin öğrenme ile transfer öğrenme tekniklerinin cilt lezyonlarının sınıflandırılmasında etkinliğini ortaya koymaktadır. Bu teknikler, dermatologların teşhislerde daha hızlı, güvenilir ve objektif kararlar vermesine yardımcı olarak, özellikle yoğun klinik ortamlarında tanı sürecini destekleyebilecek niteliktedir [70].

Neeshma ve Nair 2022 yılında yaptığı çalışmada cilt lezyonlarının sınıflandırılması için DenseNet tabanlı derin öğrenme modeli geliştirmiştir. Çalışmalarında HAM10000 veri setini kullanarak yedi farklı cilt lezyon türünün sınıflandırmasını gerçekleştirmişlerdir. Araştırmada veri dengesizliğinin sınıflandırma başarısına etkisini incelemek amacıyla iki deney yapılmıştır. İlk deneyde veri setinin dengesiz hali kullanılmış, ikinci deneyde ise her sınıftan eşit sayıda görüntü içeren dengeli bir veri seti ile eğitim yapılmıştır. İkinci deneyde dengeli veri kullanımı ile modelin doğruluğu %82.1'e ulaşmış ve modelin performansının dengeli veri ile arttığı gözlemlenmiştir. Bu çalışmada DenseNet-121 modelini transfer öğrenme ile özelleştirerek sınıflandırma işlemini gerçekleştirmiştir. Veri yetersizliği sorununu azaltmak ve modelin genelleme başarısını artırmak için ImageNet üzerinde eğitilmiş ağırlıklar kullanılmıştır. Sonuçlar, dengesiz veri kullanıldığında sınıflandırmanın daha büyük sınıfa eğilim gösterdiğini, dengeli veri kullanıldığında ise modelin tüm sınıflarda daha yüksek doğruluk sağladığını ortaya koymuştur. Gelecekte, veri artırma ve üretici modellerle veri setinin daha dengeli hale getirilmesi planlanmaktadır [71].

Ali ve arkadaşları, 2022 yılında gerçekleştirdikleri bu çalışmada, cilt lezyonlarından alınan görüntüler aracılığıyla çoklu cilt hastalıklarını otomatik ve verimli bir şekilde sınıflandırmak amacıyla bir derin öğrenme modeli geliştirmiştir. Bu model, üç farklı cilt kanseri (bazal hücreli karsinom, melanom, skuamöz hücreli karsinom) ve üç cilt rahatsızlığı (aktinik keratoz, seboreik keratoz, nevüs) olmak üzere altı farklı cilt hastalığını doğru bir şekilde sınıflandırmak üzere tasarlanmıştır. Araştırmada

kullanılan veri kümesi, 1373 hasta ve toplam 1641 cilt lezyonundan oluşmaktadır. Bu veri kümesinde 2298 görüntü yer almaktadır ve bu görüntüler farklı cilt rahatsızlıklarını temsil etmektedir. Modelin doğruluğunu artırmak amacıyla veri artırma teknikleri (döndürme, yatay-dikey çevirme, kanal kaydırma vb.) uygulanarak veri kümesinin boyutu artırılmıştır. Çalışmada kullanılan derin öğrenme modeli, çeşitli katmanlardan oluşan bir ESA mimarisi üzerine kuruludur. Modelde, 2D konvolüsyon, max-pooling, dropout ve ReLU aktivasyon fonksiyonu gibi katmanlar yer almaktadır. Eğitim süreci boyunca, model 50 iterasyon boyunca eğitilmiş ve en iyi sonuçlar 99.92% eğitim doğruluğu, 97.96% doğrulama doğruluğu ve 0.021 eğitim kaybı ile elde edilmiştir. Modelin test verisindeki doğruluğu %98 olup, modelin sınıflar arası ayırt edici gücünü yüksek tutması sağlanmıştır. Modelin test performansının ölçülmesi için bir karmaşıklık matrisi kullanılmış ve sınıflandırma başarıları doğruluk, duyarlılık ve F1 skoru ile değerlendirilmiştir. Buna göre model, tüm sınıflarda yüksek doğruluk oranlarıyla başarılı bir performans sergilemiştir. Ayrıca çalışmada geliştirilen model, daha önceki bazı önceden eğitilmiş modellerle (DenseNet201, XceptionNet, MobileNet) karşılaştırılmıştır. Yapılan bu kıyaslamalar sonucunda, önerilen model daha düşük eğitim süresiyle %98 test doğruluğuna ulaşmış ve böylece daha verimli ve hafif bir model olarak öne çıkmıştır [72].

Dhir ve arkadaşları 2023 yılında yapılan çalışmada cilt kanseri teşhisi için evrişimli sinir ağıları tabanlı bir sınıflandırma modeli geliştirmiştir. Çalışma, cilt kanserinin erken teşhisini hedefleyen bu modelin geliştirilmesinde, cilt lezyonlarının yedi ana türünü ayırt etmeye odaklanmıştır. Yazarlar, MNIST HAM10000 veri setini kullanarak modeli eğitmiş ve veri kümesindeki dengesiz sınıf dağılımını dengelemek amacıyla veri artırma teknikleri uygulamıştır. Modelin doğruluğunu artırmak için hiperparametre ayarları yapılmış ve bu sayede %99.13 doğruluğa ulaşılmıştır. Çalışma, modelin performansını doğruluk, doğruluk oranı, duyarlılık değerini ve F1-skora göre değerlendirmiştir. ESA mimarisinde, özelleştirilmiş katmanlar kullanılarak eğitim yapılmış ve yüksek doğruluğa ulaşmak için çeşitli optimizasyon teknikleri uygulanmıştır. Modelin başarısı, cilt kanseri teşhisinde hız, maliyet etkinliği ve doğruluk sağlaması bakımından önemlidir. Araştırmacılar, bu tür otomatik teşhis sistemlerinin dermatologların iş yükünü azaltabileceğini ve hastalara erken müdahale olanağı sunabileceğini öne sürmektedir. Gelecekte bu modelin, sağlık kayıtlarıyla

entegrasyon ve uzaktan teşhis gibi alanlarda genişletilmesi planlanmaktadır, böylece erişim imkânları artırılarak cilt kanseri teşhisi daha yaygın ve erişilebilir hale gelebilir [73].

Monajemi ve arkadaşları 2024 yılında yaptığı çalışmada, melanom gibi ölümcül bir cilt kanserinin erken teşhisinin, hastaların yaşamını kurtarmadaki önemini vurgulamaktadır. Derin öğrenme yöntemleri ile dermoskopik görüntüler üzerinde yapılan sınıflandırma çalışmaları, biyopsi gibi invazif yöntemlerin yerini alabilecek potansiyele sahiptir. Çalışmada, derin sinir ağlarının çoklu cilt lezyonu türlerini ayırt etmedeki performansı değerlendirilmektedir. İki önemli veri seti olan ISIC 2019 ve HAM10000 üzerinde test edilen yöntem, derin öğrenme ile yapılan sınıflandırmaların geleneksel yöntemlere göre daha iyi sonuçlar verdiğini ortaya koymaktadır. Ayrıca, veri dengesizliği gibi faktörlerin sınıflandırma doğruluğunu etkileyebileceği sonucuna varılmıştır. Çalışmada, ESA tabanlı bir model geliştirilmiş ve 7-8 farklı cilt lezyonu türünü tanımlama doğruluğu incelenmiştir. ISIC 2019 veri setinde %95.86, HAM10000 veri setinde ise %94.95 doğruluk oranları elde edilmiştir. Verilerin artırılması ve dengelenmesinin model doğruluğunu artırdığı belirtilirken, modelin eğitim ve test süreçlerinde uygulanan K-katman çapraz doğrulama yöntemi ile aşırı öğrenmenin önüne geçilmiştir. ESA'nın otomatik olarak özellik öğrenme ve ayırt etme yeteneği, cilt lezyonlarının sınıflandırılmasında büyük avantaj sağlamaktadır. Sonuç itibarıyla, çalışmada önerilen ESA tabanlı yöntem, dermatolojik teşhisi geliştirmeye yönelik etkili bir araç olarak değerlendirilmektedir. Bu modelin gerçek zamanlı uygulamalarda kullanılabilecek kadar hızlı çalışması, klinik ortamlarda erken tanı ve tedavi sürecine önemli bir katkı sunmaktadır. Ayrıca ESA modellerinin dermatolojik teşhislerde başarılı sonuçlar verebileceğini gösterirken, gelecekte daha büyük ve çeşitli veri setleri ile doğrulama yapılmasının yöntemin etkinliğini daha da artırabileceği vurgulanmaktadır [74].

Gothivrekar ve arkadaşları 2024 yılında yaptığı çalışmada, deri kanserinin erken teşhisine yönelik olarak derin öğrenme mimarileriyle yapılan bir cilt lezyon sınıflandırma çalışmasını ele almaktadır. Çalışmada, Actinic Keratosis, bazal hücreli karsinom ve melanom gibi çeşitli cilt lezyonlarının görseller üzerinden ön teşhisi hedeflenmiştir. Derin konvolüsyonel sinir ağları (DCNN) kullanılarak yapılan

analizlerde VGG16, Inception V3, Inception ResNet V2 ve DenseNet 201 gibi popüler modeller incelemeye alınmıştır. Eğitim aşamasında HAM10000 veri seti kullanılarak modelin en üst katmanları ve tüm katmanları üzerinden ince ayar yapılmıştır. Sonuçlar, tüm katmanların ince ayarının daha iyi performans sağladığını göstermektedir. Tez, cilt lezyonlarının sınıflandırılmasında kullanılan çeşitli DCNN mimarilerinin performanslarını karşılaştırmaktadır. DenseNet201 modeli en yüksek doğruluk oranını sergilerken, Inception ResNetV2 modeli de yüksek doğruluk oranları sunmuştur. Eğitim sırasında, veri artırma ve hiperparametre ayarlarının etkisi değerlendirilmiştir. DenseNet201, daha düşük parametre sayısı ile yüksek doğruluk oranı elde ederken, derin katman sayısı bakımından en derin model olarak belirlenmiştir. Bu çalışmanın esas katkısı, cilt lezyonlarını doğru bir şekilde sınıflandırarak erken tanıyı iyileştirmek ve ileri evrelerdeki tedavi maliyetlerini azaltmaktır. Sonuç olarak, ince ayar yapılmış modellerin, dermatolojik görüntü analizinde hastaların daha erken ve daha doğru teşhis edilmesine yardımcı olduğu vurgulanmaktadır. Bu çalışma, özellikle DenseNet201 ve Inception ResNetV2'nin lezyon sınıflandırma konusundaki üstünlüğünü ortaya koyarak gelecekteki araştırmalara yol göstermektedir [75].

Patel ve arkadaşları 2024 yılında gerçekleştirdikleri bu çalışmada, cilt lezyonlarının görüntülerinden cilt kanseri türlerini sınıflandırmak için derin öğrenme tekniklerinin performansı incelenmiştir. Çalışmada, HAM10000 veri kümesi kullanılarak cilt lezyonları yedi farklı türde (melanositik nevüs, melanoma, iyi huylu keratoz benzeri lezyonlar, bazal hücreli karsinom, aktinik keratoz, vasküler lezyonlar ve dermatofibrom) sınıflandırılmıştır. Çeşitli derin öğrenme modellerinin (VGG16, EfficientNetB7, InceptionResNetV2, ResNet50 ve DenseNet201) sınıflandırma performansı değerlendirilmiş ve veri dengesizliği sorunu, veri arttırma teknikleri ile çözülmüştür. Model eğitimi ve test aşamaları sonucunda DenseNet201, %94.93 test doğruluğuyla en iyi performansı göstermiştir. Çalışmada ayrıca, yazarlar kendi ESA mimarilerini de önermiş ve farklı önceden eğitilmiş modellerle karşılaştırmalı analiz yapmıştır. Veri kümesinin dengelenmesiyle birlikte modellerin doğruluğunda gözle görülür iyileşme elde edilmiştir. Bu çalışmanın sonuçları, deri kanserinin erken teşhisinde yapay zeka destekli sınıflandırma modellerinin etkin bir araç olarak kullanılabileceğini göstermektedir. Gelecek çalışmalarda, dış veri kümeleriyle

performans deęerlendirmesi, ensemble modeller ve sa temizleme gibi grnt iřleme teknikleri uygulama hedeflenmektedir [76].

Anbuselvan ve Anandan tarafından 2024 yılında yapılında alıřmada geliřtirilen IDEODL-SLDC (Inventive Dolphin Echolocation Optimization Deep Learning-Skin Lesion Detection and Classification) teknięi, cilt lezyonlarının grntleri zerinden sınıflandırılmasını hedeflemektedir. Yntem, yunusların ekolokasyon yeteneęinden ilham alınarak oluřturulmuřtur ve cilt lezyonlarını doęru řekilde tanımlayabilmek iin derin ęrenme tekniklerinden yararlanır. İlk ařamada, grntler Tsallis Entropi tabanlı (TE) segmentasyon ile iřlenmiř ve ardından zellik ıkarımı iin SqueezeNet teknięi kullanılmıřtır. Segmentasyon sonrası grntler, Dolphin Echolocation Optimizer (DEO) ve Derin Dalga Aęı (DWNN) kullanılarak sınıflandırılmıřtır. alıřmanın sonuları, IDEODL-SLDC modelinin sınıflandırmada dięer yntemlere kıyasla stn performans gsterdięini ve modelin doęruluk, duyarlılık ve zgllk gibi performans lmlerinde yksek deęerlere ulařtıęını gstermektedir. Modelin eęitim srecinde ISIC veri kmesi kullanılarak, sınıflandırma doęruluęunda %98.89, duyarlılıkta %95.35 ve zgllkte %98.62 gibi yksek sonular elde edilmiřtir. alıřma, doęal dnyadaki ekolokasyon becerisinden ilham alarak geliřtirilmiř yapay zeka tabanlı tıbbi grnt analizi yaklařımlarının etkinlięini vurgulamakta ve deri lezyonlarının erken teřhisinde yeniliki bir zm sunmaktadır. Bu modelin, zellikle dermatolojik teřhis srelerinde hızlı ve otomatik analiz saęlaması beklenmektedir. alıřma, biyomedikal alanda, yapay zeka destekli grnt sınıflandırma uygulamaları iin nemli bir adım nitelięindedir [77].

3. MALZEME VE YÖNTEM

Bu tez çalışmasında, adenoid ve cilt lezyonlarına ait veri setleri kullanılmıştır. Adenoid görüntüleri, Batman Eğitim ve Araştırma Hastanesi Kulak Burun Boğaz (KBB) bölümünden temin edilmiş olup adenoid hipertrofisi teşhisinde kullanılmıştır. Bu veri seti, klinik ortamda elde edilmiş olup adenoid hipertrofisi sınıflandırmasında uzman görüşüne ihtiyaç duyulan yüksek kaliteli görüntülerden oluşmaktadır. Cilt lezyonlarına ait görüntüler ise halka açık bir veri platformu olan Kaggle'dan alınmış ve bu görüntüler lezyonların otomatik sınıflandırılması ve segmentasyonu amacıyla kullanılmıştır.

Bu araştırmada kullanılan yöntemlerin temelini, görüntü işleme ve derin öğrenme tabanlı yaklaşımlar oluşturmaktadır. Segmentasyon işlemleri kapsamında, adenoid yapılarının ve cilt lezyonlarının sınırlarının hassas bir şekilde belirlenmesi hedeflenmiştir. Bu amaçla U-Net, U-Net++, SegNet ve HDARU-Net gibi derin öğrenme tabanlı segmentasyon modelleri tercih edilmiştir. Bu modeller, çok katmanlı yapıları sayesinde hem düşük seviyeli detayları hem de yüksek seviyeli semantik bilgileri öğrenerek, hedef bölgelerin doğru bir şekilde ayrıştırılmasını sağlamaktadır. Geliştirilmiş HDARU-Net modeli ise, klasik U-Net mimarisine eklenen yoğun bağlantılar ve dikkat mekanizmaları sayesinde adenoid segmentasyonunda daha yüksek başarı sağlamaktadır.


Sınıflandırma aşamasında ise, maskeli ve maskesiz adenoid görüntülerinin ayırımına odaklanılmıştır. Bu kapsamda EfficientNet, ResNet50, ResNet 152 ve Xception gibi güçlü ve derin ESA mimarileri kullanılmıştır. Bu modeller, geniş ve çeşitli veri setleri üzerinde eğitilerek, görüntülerdeki belirgin ve ince farkları öğrenme yeteneği kazandırılmıştır. Böylece, maskeli ve maskesiz adenoid hipertrofisi hastalığının otomatik olarak ayrıştırılması mümkün hale getirilmiştir. Araştırmada kullanılan bu iki temel yaklaşım birlikte ele alındığında, adenoid tespiti ve değerlendirmesi sürecinde yüksek doğruluk ve güvenilirlik sağlayan bütüncül bir sistem ortaya konmuştur.

Veri seti üzerinde yapılan analizlerde, görüntü segmentasyonu ve sınıflandırma doğruluğunu artırmaya yönelik çeşitli veri ön işleme adımları uygulanmıştır. Adenoid

ve cilt lezyonu görüntüleri üzerinde kontrast artırma, filtreleme ve kırpma gibi işlemler gerçekleştirilmiştir. Adenoid hipertrofisi sınıflandırma aşamasında, maskelenmiş ve maskelenmemiş veri setleri kullanılarak her iki durumun performansı karşılaştırılmıştır. Bu ön işleme adımları, görüntülerin analiz kalitesini artırırken sınıflandırma ve segmentasyon doğruluğunu önemli ölçüde iyileştirmiştir.


3.1 Adenoid Veri Seti

Batman Eğitim ve Araştırma Hastanesi KBB bölümünden temin edilen adenoid veri seti, adenoid hipertrofisi teşhisine yönelik çalışmalarda kullanılmak üzere klinik ortamlarda toplanmıştır. Bu veri seti, adenoid büyümesini değerlendiren yüksek çözünürlüklü X-ray ve nazofaringeal görüntüleri içermekte olup her bir görüntüye karşılık gelen segmentasyon maskeleriyle birlikte toplam 344 DICOM görüntüsünden oluşmaktadır. Veri seti, 1 ile 10 yaş arasındaki hastaları temsil etmekte ve adenoid hipertrofisinin yaşa bağlı farklılıklarını kapsayacak şekilde çeşitlendirilmiştir. DICOM formatı, yalnızca görüntüleri değil, aynı zamanda hasta bilgileri ve tarama protokolüne ilişkin detaylı metadata verilerini de içerebilmesi sayesinde tıbbi görüntüleme alanında oldukça uygun ve yaygın olarak tercih edilen bir formattır. Bu özellik, hasta bilgileriyle entegre edilmiş veri analizi yapılmasını ve tıbbi görüntülerin daha hassas ve doğru bir şekilde yorumlanmasını mümkün kılmaktadır. Adenoid hipertrofisi, özellikle çocuklarda solunum yollarını etkileyerek uyku apnesi ve burun tıkanıklığı gibi ciddi komplikasyonlara yol açabilmektedir. Bu tür klinik uzmanlık gerektiren görüntüler, insan gözlemine destek olmak amacıyla gelişmiş derin öğrenme ve görüntü işleme algoritmaları kullanılarak analiz edilmektedir.



Şekil 3.1 Adenoid hipertrofisi görüntüler ve karşılık gelen maskeler


Şekil 3.1 (devamı)



3.2 Cilt Lezyonu Veri Seti


Bu çalışmada kullanılan ikinci veri seti, ISIC 2017 Challenge veri setidir [78]. ISIC 2017 Challenge, cilt lezyonlarının tespiti ve sınıflandırılmasına yönelik gelişmiş yapay zeka ve görüntü işleme algoritmalarını teşvik etmeyi amaçlayan uluslararası bir yarışmadır. Bu yarışma, cilt kanseri gibi ciddi dermatolojik hastalıkların erken teşhisini desteklemek ve dermoskopik görüntü analizine katkıda bulunmak için önemli bir platform sağlamaktadır. Veri seti, lezyon bölgelerinin belirlenmesinde referans alınan maske görüntüleriyle birlikte toplam 2000 dermoskopik görüntüden oluşmaktadır. Adenoid veri setine kıyasla, ISIC veri seti daha geniş bir boyuta ve kapsamlı bir içeriğe sahiptir. Ayrıca, ISIC veri seti, tıbbi görüntü analizi çalışmalarında yaygın olarak kullanılan ve uluslararası alanda kabul gören bir referans veri seti olarak değerlendirilmektedir.

Bu veri集中的 görüntüler, lezyonların boyutu, şekli, rengi ve konumu açısından önemli bir çeşitlilik sunmakta olup, modelin farklı cilt koşullarına uyum sağlama yeteneği değerlendirmek için ideal bir yapıya sahiptir. Farklı lezyon özellikleriyle birlikte bu çeşitlilik, modelin genel performansını ve farklı anatomik özellikleri içeren tıbbi görüntüleri analiz etme kapasitesini değerlendirmek açısından önem taşır. Bu veri seti görüntü segmentasyonu için kullanılarak, segmentasyon yaklaşımının farklı tıbbi görüntü türleri üzerinde kapsamlı bir şekilde analiz edilmiştir. Bu analiz, özellikle tıbbi görüntülerin heterojen yapısını anlamaya ve segmentasyon modellerinin farklı koşullar altında gösterdiği performansı değerlendirmeye önemli katkılar sunmaktadır.



Şekil 3.2 Cilt lezyonu görüntüler ve karşılık gelen maskeler

Şekil 3.2 (devamı)




3.3 Adenoid ve Cilt Lezyonu Görüntü Veri Artırımı

Görüntü artırımı, makine öğrenmesi ve derin öğrenme modellerinin performansını geliştirmek amacıyla uygulanan bir tekniktir [78], [79]. Özellikle sınırlı sayıda görüntüden oluşan tıbbi veri setlerinde modelin eğitim verilerinin çeşitlendirilmesi ve veri setinin etkili bir şekilde büyütülmesi açısından büyük öneme sahiptir. Veri artırma teknikleri, veri setine yeni görüntüler eklemek yerine mevcut görüntülerin dönüştürme, döndürme, ölçekleme, kırpma ve aynalama gibi çeşitli tekniklere tabi tutularak yeniden kullanılması yoluyla gerçekleştirilir [80].

Görüntü artırma, modelin henüz karşılaşmadığı yeni veriler üzerinde daha iyi performans göstermesine yardımcı olur. Bu, modelin veri setindeki varyasyonlara karşı daha güçlü bir şekilde öğrenmesini sağlar ve aşırı öğrenmeyi azaltır [81]. Tıbbi görüntülerde, anatomik yapıların pozisyon, açı, boyut ve simetrisi gibi değişkenler farklı hastalar arasında değişiklik gösterebilir. Bu nedenle, veri artırma işlemi uygulanarak modelin bu tür farklılıklara karşı uyumlu hale getirilmesi hedeflenir [82].

Adenoid segmentasyonu ve cilt lezyonlarının sınıflandırılması için uygulanan veri artırma stratejileri, modelin bu değişken anatomik özelliklere karşı duyarlılığını geliştirir ve genel performansını güçlendirir.



Şekil 3.3 Adenoid görüntü veri artırımı ve karşılık gelen maskeler

3.4 Görüntü Segmentasyon Modelleri

Görüntü segmentasyonu, tıbbi görüntü analizinde ve hastalık teşhisinde kritik bir rol oynamaktadır. Segmentasyon işlemi, bir görüntüyü yapısal veya fonksiyonel olarak anlamlı alt bölgelere ayırarak medikal yorumlamayı kolaylaştırmakta, görüntüdeki temel özelliklerin tespit edilmesine ve analiz edilmesine olanak sağlamaktadır [83]. Özellikle manyetik rezonans (MR) ve bilgisayarlı tomografi (BT) görüntüleri gibi yüksek çözünürlüklü tıbbi görüntülerde uygulanan segmentasyon teknikleri, tanısal doğruluğu artırarak hastalıkların daha erken ve hassas bir şekilde teşhis edilmesini kolaylaştırmaktadır [84]. Görüntü segmentasyonu, tedavi planlamasında ve ameliyat öncesi ve sonrası değerlendirmelerde hekimlere kesin bilgiler sunmaktadır. Bu da medikal karar destek süreçlerini güçlendirmektedir [85]. Tıbbi görüntülerde segmentasyonun doğru bir şekilde yapılması, hastalıkların evrenmesi, tedaviye verilen yanıtın değerlendirilmesi ve hastalığın ilerleyişinin tahmin edilmesi gibi kritik aşamalarda önemli bir rol oynamaktadır. Segmentasyonla elde edilen ayrıntılı veriler,

teşhis ve tedavi kararlarını destekleyerek hekimlerin daha kesin müdahalelerde bulunmasını sağlamaktadır.

Derin öğrenme algoritmalarının görüntü segmentasyonuna entegrasyonu, bu alandaki başarı oranlarını kayda değer ölçüde artırmıştır. Dolayısıyla bu çalışmada çeşitli derin öğrenme modelleri kullanılmıştır. Bu modeller şu şekilde sıralanabilir:


1. U-Net,
2. U-Net++,
3. SegNet
4. Önerilen model: Hybrid dense attention residual U-Net

Derin öğrenme modelleri, karmaşık desenleri ve özellikleri otomatik olarak öğrenerek segmentasyon kalitesini artırmakta ve manuel işlem gereksinimini büyük ölçüde azaltmaktadır. Derin öğrenme tabanlı bu yaklaşımlar, tıbbi görüntü analizinde segmentasyonun doğruluğunu ve güvenilirliğini önemli ölçüde artırmış, medikal uygulamalarda vazgeçilmez bir konuma gelmiştir [85].

3.4.1 U-Net modeli

U-Net modeli, biyomedikal görüntü segmentasyonu için optimize edilmiş bir derin öğrenme mimarisidir. Bu model, 2015 yılında Olaf Ronneberger ve ekibi tarafından geliştirilmiştir ve az miktarda etiketli veriyle yüksek doğrulukta segmentasyon yapabilmesiyle dikkat çekmektedir [86]. U-Net'in temel yapısı, bir daralan yol ve bir genişleyen yoldan oluşan simetrik U şeklindedir. Daralan yol, konvolüsyon ve havuzlama katmanları ile görüntüden bağlamsal bilgiyi yakalarken, genişleyen yol ise aynı bilgiyi konum doğruluğunu koruyarak yüksek çözünürlüklü özelliklere geri dönüştürür. Modelin en dikkat çekici özelliği, daralan ve genişleyen yollar arasındaki atlama bağlantılarıdır. Bu bağlantılar, daralan yoldaki özellik haritalarını genişleyen yola aktararak detaylı konum bilgisini korur. Piksel bazında sınıflandırma yapabilen U-Net, her pikseli doğru bir şekilde etiketleyerek segmentasyon kalitesini artırır. Modelde kullanılan aşamalı veri çoğaltma teknikleri, farklı doku tiplerine karşı dayanıklılık sağlar. Yüksek doğruluğu ve verimliliği ile U-Net, biyomedikal alanda geniş bir uygulama alanına sahiptir. Hücre ve doku segmentasyonu, tümör tespiti ve organ sınırlarının belirlenmesi gibi görevlerde başarıyla kullanılmaktadır. Modelin

başarısı, diğer görüntüleme alanlarına da uyarlanmasını sağlamış ve U-Net'i segmentasyon alanında bir referans modeli haline getirmiştir [86].



Şekil 3.4 U-Net modelinin mimarisi [86]


3.4.2 U-Net++ modeli

UNet++, medikal görüntü segmentasyonu için yeniden tasarlanmış bir kodlayıcı-çözücü mimarisidir. Model, klasik U-Net'in eksikliklerini gidermek amacıyla kodlayıcı ve çözücü alt ağları arasında katmanlı ve yoğun atlama bağlantıları kullanılmaktadır. Bu bağlantılar, özellik haritalarının semantik uyumunu artırmakta ve modelin ince ayrıntıları daha doğru yakalamasını sağlamaktadır. UNet++'in özgün yapısında yer alan derin denetim mekanizması, modelin karmaşık dokuları ve çok ölçekli nesneleri daha hassas şekilde tanımasını hedeflemektedir. Böylece UNet++, özellikle tıbbi görüntülemede yüksek doğruluk gerektiren segmentasyon görevlerinde önemli avantajlar sunmayı amaçlamıştır. Zhou ve arkadaşları [87], UNet++ modelini akciğer nodülü, karaciğer, kolon polipi ve hücre çekirdeği segmentasyonu gibi çeşitli görevlerde değerlendirmiştir. Deneyler, UNet++'in hem klasik U-Net'e hem de genişletilmiş U-Net'e kıyasla kayda değer bir performans artışı sağladığını ortaya koymuştur. Özellikle, derin denetim mekanizması sayesinde model, belirli segmentasyon görevlerinde anlamlı iyileşmeler sağlamıştır. UNet++ modelinin

karaciğer gibi farklı ölçeklerdeki yapılara yönelik segmentasyon başarısı, çok ölçekli nesneleri tanımlamadaki etkinliğini göstermektedir.

3.4.3 SegNet modeli


SegNet modeli, görüntü segmentasyonu için kodlayıcı ve çözücü yapılarını temel alan bir derin evrişimli sinir ağı mimarisidir. Model, VGG16'nın 13 evrişim katmanını kullanan bir kodlayıcı ağıyla başlar ve her kodlayıcı katmanı, eşleşen bir çözücü katmanıyla birleştirilmiştir. Kodlayıcı ve çözücü yapılar, sonunda bir piksel sınıflandırma katmanıyla bağlanmaktadır. SegNet'in ayırt edici özelliği, çözücüde maksimum havuzlama sırasında elde edilen indekslerle yukarı örnekleme yapmasıdır. Bu yöntem, yukarı örnekleme doğruluğunu artırırken bellek ve hesaplama verimliliği sunmaktadır. Kodlayıcı, her katmanda bir filtre bankası ile konvolüsyon uygulayarak özellik haritaları oluşturur ve bunları batch normalization ile ReLU aktivasyon fonksiyonuyla işlemektedir. Maksimum havuzlama sırasında 2x2 bölgelerdeki maksimum piksel konumları kaydedilerek çözücüye iletilmektedir. Bu adımda, özellik haritaları alt örneklenerek her piksele geniş bir uzaysal bağlam kazandırılmaktadır. Çözücü, kodlayıcıdan aktarılan maksimum havuzlama indekslerini kullanarak özellik haritalarını yukarı örneklemektedir. Bu işlem, piksel konum bilgisini koruyarak yüksek çözünürlüklü ve ayrıntılı haritalar oluşturmaktadır. Yukarı örnekleme sonrası, çözücü bu seyrek haritaları yoğunlaştırmak için eğitilebilir filtrelerle konvolüsyon uygular ve sonuçları softmax katmanında işleyerek piksel bazında sınıf olasılıklarını hesaplamaktadır. SegNet'in sade ve bellek verimli yapısı, yüksek doğrulukla gerçek zamanlı uygulamalar için ideal bir çözüm sunmaktadır [88].



Şekil 3.5 SegNet modelinin mimarisi [88]

3.4.4 Önerilen model: Hybrid dense attention residual U-Net modeli

HDARU-Net, temel U-Net mimarisi üzerine inşa edilerek, medikal görüntüleme görevlerinde segmentasyon performansını artırmak amacıyla çeşitli ileriye yönelik yöntemler üzerine odaklanmaktadır. HDARU-Net'in temel yaklaşımı, yoğun bağlantılar (dense connections), dikkat mekanizmaları (attention mechanisms) ve artık dikkat mekanizması (residual attention mechanism) unsurlarını U-Net yapısına entegre etmektir. Bu sayede model hem ayrıntılı özellikleri hem de bağlamsal bilgiyi etkili bir şekilde yakalayarak daha hassas bir segmentasyon sağlamaktadır. Bu iyileştirmeler, cilt lezyonları ve adenoid hipertrofisi gibi karmaşık hastalıkların segmentasyonunu geliştirmektedir. Modelin en önemli bölgelere odaklanmasını ve ağ katmanları boyunca önemli bilgilerin korunmasını mümkün kılmaktadır. Temel U-Net modeli, birçok biyomedikal görüntü segmentasyon görevi için oldukça uygun olan bir kodlayıcı-çözücü yapısına sahiptir; ancak uzun menzilli bağımlılıkları yakalama veya özellikleri tekrar kullanma konusunda bazı sınırlamalar yaşayabilmektedir. HDARU-Net, bu sınırlamaları aşmak için yoğun bloklar kullanarak özelliklerin birden fazla katman boyunca iletilmesini sağlamaktadır. Dikkat mekanizmaları sayesinde önemli bölgelere odaklanır ve artık bağlantılarla eğitim sürecini kolaylaştırmaktadır. Böylece daha derin yapılara olanak tanır. Yoğun bağlantılar, özelliklerin ağırlık derinliklerine yayılarak her seviyede yeniden kullanılmasına olanak tanımaktadır. Dikkat mekanizmaları, segmentasyon işleminin en önemli bölgelerine yoğunlaşarak daha isabetli bir sınıflandırma yapmayı sağlamaktadır. Artık bağlantılar ise, modelin derin katmanlara kadar öğrenmeyi sürdürebilmesi için bilgi kaybını azaltarak eğitim sürecini daha verimli hale getirir. HDARU-Net, bu modelleri bütünleştirerek, ince yapısal detayları korurken bağlamsal bilgiyi de dikkate alan bir segmentasyon sağlar ve biyomedikal görüntü işleme alanında kompleks yapıların doğru bir şekilde ayrıştırılmasını destekler. Bu özellikler, modelin klinik doğruluğunu artırmakta ve özellikle küçük veya zorlu segmentasyon görevlerinde performansını yükselmektedir.




Şekil 3.6 Hybrid dense attention residual U-Net mimarisi

Model, 256x256 boyutundaki giriş görüntülerini işlemek üzere tasarlanmıştır ve her aşamada bu görüntülerden anlamlı özellikler çıkararak hassas segmentasyon gerçekleştirmektedir. Kodlayıcı bölümü, 5x5 boyutunda evrişim katmanlarıyla özellikler çıkarır ve detaylı analiz için bu özellikleri derinleştirir. Her evrişim katmanının ardından Batch Normalization ve ReLU aktivasyon fonksiyonu uygulanarak ağın doğruluğu ve kararlılığı artırılmaktadır. Yoğun bloklar, katmanlar arasında bilgi paylaşımını artırarak parametre verimliliği sağlar ve gradyan kaybını azaltır. Transition blokları, 1x1 evrişim ile özellik haritası boyutlarını daraltır ve ardından 2x2 maksimum havuzlama ile boyut küçültme (down-sampling) gerçekleştirmektedir. Bu süreç, modelin daha geniş bir görüş alanına ve soyut özelliklere odaklanmasını sağlar. Channel Attention Mechanism (CAM), önemli özellikleri vurgulayıp gereksiz bilgileri baskılayarak modelin segmentasyon performansını artırır. Atlama bağlantıları, enkoder ve dekoder arasında bilgi akışını koruyarak gradyan kaybını azaltır. Alt katmanlardan gelen bilgiler, üst katmanlardaki bilgilerle birleştirilir. Dekoder tarafında, Up-Sampling işlemi boyut küçültme sırasında kaybolan detayları yeniden kazanmak için kullanılır. Element-Wise Summation, önceki katmanlardan gelen bilgilerle yeni özellik haritalarını matematiksel olarak birleştirir. Çıkış katmanında, sigmoid aktivasyon fonksiyonu her pikselin belirli bir sınıfa ait olma olasılığını hesaplar. Sonuçta, segmentasyon haritası giriş görüntüsündeki ilgi alanlarını net bir şekilde ayırır. Dekoderde kullanılan CAM, daha hassas segmentasyon yapılmasını sağlar. Conv 1x1 işlemi, her pikselin sınıflandırılması için segmentasyon haritasını oluşturur. Bu model, tıbbi görüntü

segmentasyonunda hassasiyet ve doğruluk gereksinimlerini karşılamak üzere tasarlanmıştır. Enkoder-dekoder yapısı, detaylı ve genelleştirilmiş özellik çıkarımı sağlarken, CAM ve yoğun bağlantılar gibi mekanizmalar modelin performansını önemli ölçüde artırır.

3.4.4.1 Yoğun blok


DenseNet'ten [89] ilham alan yoğun blok, her katmanı önceki tüm katmanlara bağlayan ileri beslemeli bir yapıya sahiptir. Bu yapı, ağırlı bilgi akışını iyileştirir ve özelliklerin yeniden kullanılmasını sağlar. Her katman, yalnızca bir önceki katmandan değil, kendisinden önceki tüm katmanlardan bilgi alır. Bu yaklaşım, yüksek ve düşük seviyeli özelliklerin daha etkin bir şekilde yakalanmasına olanak tanır ve özellikle karmaşık anatomik yapıları belirlemede faydalıdır. Ayrıca, gradyan kaybını önlerken tüm katmanların öğrenme sürecine katkıda bulunmasını sağlayarak, modelin birden çok soyutlama düzeyinde bilgi işlemesini mümkün kılmaktadır.



Şekil 3.7 Yoğun blok mimarisi [89]

3.4.4.2 Kanal dikkat mekanizması


Dikkat mekanizmaları [90], modelin kritik ayrıntılara odaklanmasını sağlayarak segmentasyon performansını artırmaktadır. Konum dikkati, görüntüdeki belirli alanlara odaklanırken, kanal dikkati her özellik haritasının önemini değerlendirir. Bu çalışmada kullanılan kanal dikkati, tıbbi görüntülerde hedef bölgelerin daha iyi yerleştirilmesine yardımcı olur. HDARU-Net, bu mekanizma sayesinde segmentasyon sırasında en önemli bilginin vurgulanmasını sağlar.



Şekil 3.8 Kanal dikkat mimarisi [90]

3.4.4.3 Artık dikkat mekanizması

ResNet'ten [91] ilham alan artık dikkat mekanizması, kısayol bağlantıları ile bilginin daha önceki katmanlardan derin katmanlara akmasını sağlamaktadır. Bu mekanizma, kaybolan gradyan sorununu hafifleterek daha derin ağların verimli bir şekilde eğitilmesine olanak tanır. Ayrıca, öğrenilen özelliklerin bütünlüğünü koruyarak önemli ayrıntıların kaybolmasını önler. HDARU-Net'te, artık bağlantılar hem kodlayıcı hem de çözücü yollarına entegre edilmiştir. Bu sayede model, segmentasyon haritasını kademeli olarak iyileştirirken lezyon sınırları veya organ şekilleri gibi kritik detayları koruyabilmektedir.



Şekil 3.9 Artık dikkat mekanizmasının mimarisi [91]

3.5 Derin Öğrenme Modelleri

Derin öğrenme, makine öğrenmesinin bir alt dalı olup veri yapılarını öğrenmeye odaklanır ve belirli bir göreve yönelik algoritmalar geliştirmek yerine verilerden anlamlı özellikleri otomatik olarak çıkarmaktadır [92]. Bu yöntem, verilerin katmanlar aracılığıyla işlenmesini sağlar. Karmaşık ve çok katmanlı mimariler aracılığıyla, verilerden soyutlanmış ve yüksek düzeyde anlam ifade eden özelliklerin çıkarılmasına olanak tanımaktadır. Derin öğrenmenin bu yeteneği, insan müdahalesine duyulan ihtiyacı azaltarak, karmaşık problem çözümlerini daha etkili ve hızlı hale getirir. Derin öğrenme, nesne tanıma, el yazısı ve görüntü tanıma, doğal dil işleme gibi çeşitli alanlarda büyük başarılar elde etmiştir [93]. Geleneksel makine öğrenimi modelleri genellikle bir giriş ve bir çıkış katmanının yanı sıra yalnızca bir gizli katmandan oluşan sığ ağlara dayanırken, derin öğrenme mimarileri daha fazla gizli katman içerebilir ve bu sayede daha soyut ve yüksek düzeyde anlam ifade eden özellikler çıkarabilir. Derin öğrenmenin en önemli avantajlarından biri, özellik öğrenimini otomatikleştirebilmesidir. Bu durum, özellik mühendisliğine yönelik manuel çaba gereksinimini önemli ölçüde azalmaktadır. Özellikle GPU teknolojisindeki gelişmeler, derin öğrenmenin büyümesini hızlandırmış ve daha karmaşık ağların verimli bir şekilde eğitilmesini mümkün kılmaktadır. Bu sayede, derin öğrenme, insan zekasına daha yakın bir yapay zeka hedefini gerçekleştirme yolunda önemli bir adım olarak kabul edilmektedir [94]. Bu tez çalışmasında birçok derin öğrenme modelleri kullanılmıştır. Bu çalışmada kullanılan modeller arasında EfficientNet, MobileNet, ResNet50, ResNet152, VGG16 ve Xception gibi derin öğrenme mimarileri bulunmaktadır.

Bu çalışmada kullanılan derin öğrenme mimarileri, transfer learning yöntemiyle uygulanmıştır. Transfer learning, büyük ve genel veri kümeleri üzerinde önceden eğitilmiş modellerin, daha küçük ve özel veri kümeleri üzerinde yeniden kullanılması esasına dayanır. Medikal görüntüleme gibi sınırlı ve dengeli olmayan veri kümelerinin yaygın olduğu alanlarda, sıfırdan model eğitmek yerine transfer learning kullanmak hem zamandan tasarruf sağlar hem de daha yüksek doğruluk ve genelleme performansı elde edilmesine olanak tanır. Bu bağlamda, çalışmamızda kullanılan önceden eğitilmiş modeller, genel görüntü tanıma görevlerinde öğrenilmiş düşük seviyeli özellikleri (kenarlar, dokular, şekiller vb.) hedef görev olan adenoid segmentasyonuna aktararak

önemli bir başlangıç noktası sağlamıştır. Bu yaklaşım, modelin daha hızlı eğitilmesini, aşırı öğrenme riskinin azaltılmasını ve daha stabil sonuçlar elde edilmesini mümkün kılmıştır. Ayrıca, tıbbi görüntülerde sınırlı anotasyon verisi bulunması, transfer learning yöntemini bu alanda özellikle avantajlı hale getirmiştir.

3.5.1 EfficientNet modeli

EfficientNet, günümüzde görüntü sınıflandırma görevlerinde yaygın olarak kullanılan, verimliliği yüksek bir derin öğrenme mimarisidir. EfficientNet'in başarısı, model verimliliğini artıran Mobile Inverted Bottleneck Convolution (MBConv) modülleri ve Squeeze-and-Excitation (SE) blokları gibi yenilikçi bileşenlerin etkin bir şekilde kullanılmasından kaynaklanmaktadır. Bu mimari, model boyutunu küçültürken performansı önemli ölçüde artırarak, aynı doğruluk seviyesini daha az parametre ve işlem maliyeti ile elde edebilme avantajı sunmaktadır. EfficientNet ailesi, EfficientNet-B0'dan EfficientNet-B7'ye kadar uzanan çeşitli yapılandırmaları içermekte olup, tüm modeller neural architecture search yöntemi ile optimize edilmiştir. Bu yaklaşım, genişlik, derinlik ve çözünürlük gibi farklı ölçekleme faktörlerinin dengeli bir şekilde büyütülmesini sağlamaktadır. Bu sayede, daha küçük boyutlu modeller bile yüksek doğruluk oranları sunabilmektedir. EfficientNet'in mimarisi, yüksek doğruluk elde ederken işlem maliyetini en aza indirmek amacıyla derin ayırık evrişimler ve doğrusal dar boğaz yapılarını entegre etmektedir. Kompakt ve optimize edilmiş tasarımı sayesinde EfficientNet, özellikle mobil cihazlar gibi donanımsal kısıtlamalara sahip sistemlerde gerçek zamanlı uygulamalar için ideal bir çözüm sunmakta olup, tıbbi görüntü analizi gibi alanlarda yaygın bir şekilde kullanılmaktadır [94].

3.5.2 MobileNet modeli

MobileNet, sınırlı donanıma sahip cihazlarda verimli görüntü sınıflandırma ve nesne tespiti gerçekleştirmek amacıyla tasarlanmış bir derin öğrenme mimarisidir. Mobil cihazlar gibi kısıtlı kaynaklara sahip sistemler için optimize edilen MobileNet, geleneksel evrişim işlemini derin ayırık evrişimler (depthwise separable convolutions) aracılığıyla iki aşamaya ayırarak işlem yükünü önemli ölçüde azaltmaktadır. Bu iki aşama, ilk olarak her kanal için uzamsal filtrelemeyi, ardından kanallar arası bilgi işlemlerini kapsamaktadır. Bu yöntem, parametre sayısını ve işlem maliyetini önemli

ölçüde düşürürken modelin doğruluk seviyesini muhafaza etmektedir. MobileNet'in geliştirilmiş bir versiyonu olan MobileNetV2, tersine çevrilmiş artık bağlantılar ve doğrusal dar boğaz (linear bottleneck) yapılarını tanıtarak mimarinin verimliliğini ve performansını daha da artırmaktadır. Bu yenilikçi tasarım, bellek kullanımını azaltırken hem hız hem de doğruluk açısından yüksek bir performans sunmaktadır. MobileNet, özellikle tarımsal hastalık tespiti, biyomedikal görüntü analizi ve hastalık teşhisi gibi mobil tabanlı uygulamalarda yaygın bir şekilde kullanılmakta ve çeşitli sınıflandırma görevlerinde başarılı sonuçlar elde etmektedir [95].

3.5.3 ResNet50 modeli

ResNet50, derin öğrenme alanında yaygın olarak kullanılan ve ResNet ailesine ait bir ESA mimarisidir. Model, artık bağlantılar olarak adlandırılan özel bir yapıyla dikkat çekmekte olup, bu bağlantılar sayesinde derin ağlarda sıklıkla karşılaşılan gradyan kaybolması sorununu etkili bir şekilde çözmektedir. Artık bağlantılar, girdi verisinin doğrudan ilgili katmanlara iletilmesini sağlayarak, modelin daha derin mimarilerde öğrenme kapasitesini artırmakta ve karmaşık desenlerin öğrenilmesine olanak tanımaktadır. ResNet50, isminden de anlaşılacağı üzere toplamda 50 katmandan oluşmakta olup, özellikle ImageNet gibi büyük ölçekli veri setleri üzerinde üstün performans sergilemektedir [96].

Sağlık alanında ResNet50, görüntü sınıflandırma ve hastalık teşhisi gibi kritik uygulamalarda öne çıkmaktadır. Özellikle cilt hastalıklarının ve adenoid hipertrofisi gibi tıbbi durumların sınıflandırılmasında yüksek doğruluk oranlarına ulaşmıştır. ResNet50, sadece doğruluk oranı açısından değil, aynı zamanda kesinlik, duyarlılık ve F1-skora dayalı performans metriklerinde de üstün başarı göstermektedir. Bu sonuçlar, modelin farklı cilt hastalıklarını doğru bir şekilde tanımlama kapasitesini ve tıbbi teşhis süreçlerinde önemli bir yardımcı araç olarak kullanılma potansiyelini ortaya koymaktadır [96].

3.5.4 ResNet152 modeli

ResNet152, derin öğrenme alanında özellikle görüntü sınıflandırma ve benzeri uygulamalarda yüksek doğruluk elde etmek amacıyla tasarlanmış, derin katman yapısına sahip bir evrişimli sinir ağı modelidir. Model, artık bağlantılar adı verilen

atlama bağlantılarıyla öne çıkmaktadır; bu bağlantılar, ağırlıkların bir katmandan diğerine doğrudan aktarılmasına olanak tanıyarak, daha derin katmanlar eklemeyi mümkün kılar. Bu yapı, gradyan kaybolması veya gradyan sönümlenmesi gibi yaygın problemleri azaltarak, 152 katmana kadar ulaşabilen bir ağırlık etkin bir şekilde eğitim almasını sağlar [97].

ResNet152, transfer öğrenimi için uygunluğu sayesinde, sınırlı veri ile dahi başarılı sonuçlar elde edebilmekte ve önceden eğitilmiş modellerin farklı veri kümeleri üzerinde yeniden kullanılmasını kolaylaştırmaktadır. Bu özellik, modelin özellikle tıbbi görüntü analizlerinde, çeşitli uygulamalarda yaygın bir şekilde kullanılmasını sağlamaktadır. Örneğin, meme kanseri tespitine yönelik olarak Wisconsin veri seti üzerinde yapılan bir çalışmada, ResNet152 modeli %97 doğruluk oranına ulaşmış ve erken teşhis konusunda büyük bir başarıya imza atmıştır. Bu başarı, modelin, tıbbi görüntülerin analizinde yüksek doğruluk ve güvenilirlik sağlama kapasitesini vurgulamaktadır [97].

3.5.5 VGG16 modeli

VGG16, derin öğrenme alanında yaygın olarak kullanılan ve özellikle görsel tanıma ve sınıflandırma görevlerinde yüksek performans sergileyen bir evrişimli sinir ağı mimarisidir. 16 katmandan oluşan bu model, büyük veri kümeleriyle eğitildiğinde yüksek doğruluk oranlarına ulaşabilmektedir. VGG16, genellikle ImageNet gibi geniş veri setlerinde eğitim aldıktan sonra transfer öğrenme ile farklı görsel sınıflandırma görevlerinde başarıyla kullanılmaktadır. Model, 3x3 boyutundaki filtreler ve 2x2 boyutunda maksimum havuzlama katmanları aracılığıyla özellik çıkarımı gerçekleştirir, bu sayede daha küçük boyutlu özellik haritaları üzerinde derin katmanlarda etkin bir şekilde öğrenme sağlanır [98].

VGG16'nın derin katman yapısı ve basit katman tasarımı, ona diğer daha karmaşık ESA mimarilerine göre daha stabil sonuçlar elde etme yeteneği kazandırır. Örneğin, beyin tümörü segmentasyonu gibi tıbbi görüntüleme uygulamalarında, VGG16, U-Net modeliyle birlikte kullanılarak gelişmiş bir mimari oluşturmuş ve tümör bölgesi segmentasyonunda yüksek doğrulukla başarılı sonuçlar elde edilmiştir. Modelin katmanları, yüksek kaliteli özellik haritaları çıkararak, bu tür segmentasyon modellerinde daha hassas bölgesel ayrımlar yapabilmesini sağlar. Bu özellikleri

sayesinde VGG16, tıbbi görüntüleme, nesne tanıma, yüz tanıma ve benzeri bir dizi alanda yaygın bir şekilde tercih edilen bir model olmuştur [98].

3.5.6 Xception modeli

Xception modeli François Chollet tarafından geliştirilmiştir [99]. Xception, derin öğrenme modellerinde hesaplama verimliliğini artırmak için geliştirilen ve "depthwise separable convolutions" adı verilen ayrık evrişimleri temel alan bir modeldir. Bu model, her bir kanalı bağımsız olarak işleyen derin ayrık evrişimlerle başlar ve ardından kanallar arası ilişkileri öğrenmek için noktasal evrişimler (pointwise convolution) uygular. Böylece Xception, klasik evrişim işlemlerine kıyasla daha az parametreyle çalışabilir ve yüksek doğruluk sağlar. Xception'in yenilikçi yapısı, özellikle Inception mimarisine dayanmaktadır ve Inception modüllerini ayrık evrişimlerle değiştirerek performans artışı elde eder. Bu özellikleriyle Xception, ImageNet gibi geniş veri kümelerinde Inception V3'e göre daha yüksek doğruluk sunmuş ve büyük ölçekli sınıflandırma görevlerinde oldukça etkili bir model haline gelmiştir. Bu sayede, Xception, hem hızlı eğitim süreci hem de düşük parametre sayısı ile birçok görüntü sınıflandırma uygulamasında tercih edilen bir mimari olmuştur [100].

3.6 Derin Öğrenme Modellerinin Performansını Ölçen Parametreler

Derin öğrenme modellerinin performansını değerlendirmek için kullanılan temel ölçütler arasında doğruluk, duyarlılık, özgüllük, kesinlik, F1-skoru ve ROC-AUC (Receiver Operating Characteristic - Area Under Curve) bulunmaktadır. Bu parametreler, tıbbi görüntü işleme ve hastalık sınıflandırma gibi hassas alanlarda model performansını objektif bir şekilde değerlendirir [101].

3.6.1 Doğruluk

Doğruluk, modelin doğru tahmin sayısının toplam tahmin sayısına oranını ifade eder. Özellikle dengeli veri setlerinde modelin genel başarı düzeyini gösterir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

TP: Gerçek pozitif

TN: Gerçek negatif

FP: Yanlış pozitif

FN: Yanlış negatif

Burada;

“TP”, *True Positive (Gerçek Pozitif)*; gerçek sınıf pozitif olup modelin doğru şekilde pozitif olarak tahmin ettiği örnek sayısıdır.

“TN”, *True Negative (Gerçek Negatif)*; gerçek sınıf negatif olup modelin doğru şekilde negatif olarak tahmin ettiği örnek sayısıdır.

“FP”, *False Positive (Yanlış Pozitif)*; gerçek sınıf negatif olduğu halde modelin pozitif olarak yanlış tahmin ettiği örnek sayısıdır.

“FN”, *False Negative (Yanlış Negatif)*; gerçek sınıf pozitif olduğu halde modelin negatif olarak yanlış tahmin ettiği örnek sayısıdır [102].

3.6.2 Duyarlılık (hassasiyet)

Duyarlılık, gerçek pozitiflerin doğru bir şekilde tahmin edilme oranını gösterir. Modelin, pozitif sınıfı doğru bir şekilde tanıma yeteneğini ölçer.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (2)$$

Duyarlılık, pozitif olarak etiketlenmiş örneklerin model tarafından doğru olarak pozitif olarak tahmin edilme oranıdır.

3.6.3 Özgüllük

Özgüllük, gerçek negatiflerin doğru bir şekilde tahmin edilme oranıdır. Modelin negatif sınıfı doğru bir şekilde tanıma yeteneğini ölçer.

$$\text{Özgüllük} = \frac{TN}{TN + FP} \quad (3)$$

3.6.4 Kesinlik

Kesinlik, bir modelin pozitif sınıfı doğru bir şekilde tahmin etme oranını ifade eder ve modelin pozitif olarak sınıflandırdığı örneklerin ne kadarının gerçekte pozitif olduğunu gösterir. Bu metrik, duyarlılık parametresi ile kullanılarak modelin genel doğruluğuna dair daha kapsamlı bir değerlendirme sunar.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (4)$$

Pozitif tahmin edilen örneklerin ne kadarının gerçekten pozitif olduğunu gösterir.

3.6.5 F1-Skoru

F1-Skoru, duyarlılık ve kesinliğin harmonik ortalamasıdır. Dengeli bir performans ölçütüdür ve özellikle dengesiz veri setlerinde kullanışlıdır.

$$\text{F1 Skoru} = 2 \times \frac{\text{kesinlik} \times \text{duyarlılık}}{\text{kesinlik} + \text{duyarlılık}} \quad (5)$$

Hem kesinlik hem de duyarlılığı dikkate alarak modelin performansını değerlendirir. Duyarlılığın ve kesinliğin düşük olduğu durumlarda düşük değer alır.

3.6.6 ROC ve AUC


ROC eğrisi, modelin farklı eşik değerlerinde duyarlılık ve 1-özgüllük (yanlış pozitif oran) arasındaki ilişkiyi gösterir. AUC ise ROC eğrisinin altındaki alanı ifade eder ve modelin sınıflandırma performansını özetler. ROC-AUC, sınıflandırma modelinin pozitif ve negatif örnekleri ne kadar iyi ayırt ettiğini gösterir. AUC değeri 0.5'e yakınsa, model rastgele tahmin yapıyordur; 1'e yakınsa, model oldukça iyidir.

3.6.7 Dice katsayısı

Dice katsayısı, segmentasyon algoritmalarının performansını değerlendirmek için kullanılan bir başka yaygın metriktir ve özellikle iki kümenin benzerliğini ölçmede etkilidir. IoU'ya benzer şekilde, Dice katsayısı da algoritmanın gerçek sınıflarla ne kadar örtüştüğünü gösterir, ancak duyarlılık ve özgüllük arasındaki dengeyi daha çok öne çıkarır. Matematiksel olarak, Dice katsayısı şu şekilde tanımlanır:

$$\text{Dice} = \frac{2 \times TP}{2 \times TP + FP + FN}$$

Grafiksel olarak dice katsıyı şu şekilde gösterilir:




Şekil 3.10 Dice katsayısının grafiksel formülü

3.6.8 Birleşim üzerinde kesişim

Birleşim üzerinde kesişim, gerçek ve tahmin edilen etiketler (maskeler) arasındaki örtüşen piksellerin, her iki etiketteki toplam piksel sayısına oranı olarak hesaplanır. Matematiksel olarak, bu ölçüt, iki maskenin kesişiminin birleşimlerine bölünmesi ile ifade edilir ve tahmin edilen segmentasyon ile gerçek segmentasyon arasındaki uyum derecesini sayısal olarak gösterir. Matematiksel olarak IoU şu şekilde ifade edilebilir:

$$\text{IoU} = \frac{\text{GerçekDeğer} \cap \text{TahminDeğer}}{\text{GerçekDeğer} \cup \text{TahminDeğer}}$$


Grafiksel olarak IoU şu şekilde gösterilir:



Şekil 3.11 Birleşim üzerinde kesişim parametresinin grafiksel formülü

3.7 Görüntü Segmentasyonu Akış Diyagramı

Şekil 3.12’de gösterilen akış diyagramında adenoid görüntüleri üzerinde bir segmentasyon işlemi gerçekleştirmek amacıyla kullanılan bir sürecin aşamalarını göstermektedir. Süreç, veri ön işleme, veri kümesi ayrımı, model eğitimi, model performans değerlendirmesi ve sonuç karşılaştırması aşamalarını içermektedir. Bu sürecin her adımı aşağıda detaylıca açıklanmıştır.



Şekil 3.12 Görüntü segmentasyonun akış diyagramı

Akış diyagramı, ilk olarak adenoid görüntüleri veri kümesi ile başlamaktadır. Adenoid DICOM formatında görüntülerden oluşan bir veri kümesi ile başlar. DICOM, tıbbi görüntülerin depolanması ve transferinde kullanılan bir standarttır. Görüntüler muhtemelen ham formatta olup, işlenmeden önce çeşitli ön işlemlerden geçmesi gerekmektedir.

Diğer aşama olan adenoid görüntülerin ön işlenmesinde veri setindeki görüntülerin işlenebilir hale getirilmesi için yapılan çeşitli ön işlemleri içerir:

- ✓ Görüntülerin Kırılması: Görüntülerde kişisel bilgi bulunmaması sağlanarak, yalnızca ilgili bölgelerin yer aldığı bir kırma işlemi yapılır. Bu, segmentasyonun daha etkili olmasını sağlar.
- ✓ Görüntülerin Yeniden Boyutlandırılması: Görüntüler, 256x256 piksel boyutuna getirilir. Bu, modelin giriş boyutuyla uyumluluğu sağlar ve işlem yükünü azaltır.

- ✓ Veri Çoğaltma: Veri artırma teknikleri uygulanarak veri setine ek örnekler eklenir. Bu, modelin daha çeşitli veri örnekleriyle eğitilmesine olanak tanır ve aşırı uyum riskini azaltır. Dönme, kırpma, ölçekleme gibi veri çoğaltma işlemleri yapılabilir.

Veri kümesinin bölümlenmesi aşamasında, ön işlenmiş görüntüler eğitim, doğrulama ve test veri kümelerine ayrılır:

- ✓ Eğitim Kümesi: Modelin öğrenmesi için kullanılan veri setidir ve veri kümesinin %80'ini oluşturur.
- ✓ Doğrulama Kümesi: Modelin eğitim sırasında performansını izlemek için kullanılan veri setidir ve veri kümesinin %10'unu oluşturur.
- ✓ Test Kümesi: Modelin nihai performansını değerlendirmek için kullanılan veri setidir ve veri kümesinin %10'unu oluşturur.

Önerilen model olan HDARU-Net modeli kısmında, veri kümesi, HDARU-Net adlı bir model üzerinde eğitilir. HDARU-Net, genellikle medikal görüntü segmentasyonu için kullanılan, U-Net mimarisine dayalı bir derin öğrenme modelidir. Bu model, yüksek doğruluklu ve ayrıntılı segmentasyon sonuçları elde etmek için özellikle medikal görüntü işleme alanında tercih edilir. HDARU-Net'in katmanları, görüntülerdeki ince detayları yakalayarak adenoid gibi hedef bölgeleri doğru bir şekilde segmentlemeyi amaçlar.


Modelin performansı ölçen model performans parametreleri, çeşitli değerlendirme metrikleri kullanılarak ölçülür:

- ✓ Doğruluk: Modelin tüm sınıflardaki doğru tahmin oranını gösterir.
- ✓ Kesinlik: Doğru pozitiflerin tahmin edilen pozitif örneklere oranını ifade eder.
- ✓ Duyarlılık: Doğru pozitiflerin gerçek pozitif örneklere oranını gösterir.
- ✓ Birleşim üzerine kesişim: Tahmin edilen ve gerçek maske arasındaki örtüşme oranını ifade eder. Segmentasyonun doğruluğunu ölçmek için kullanılır.
- ✓ Dice katsayısı: İki kümenin benzerliğini gösterir ve segmentasyon sınırlarının ne kadar iyi yakalandığını ölçer.

Son aşama olan sonuç karşılaştırma, modelin oluşturduğu tahmin edilen maskeler, gerçek maskeler ile karşılaştırılır. Bu karşılaştırma, modelin tahminlerinin ne kadar doğru olduğunu görsel olarak ve sayısal olarak değerlendirir. Bu değerlendirme, modelin adenoid segmentasyonunu ne kadar başarılı bir şekilde yaptığına dair genel bir fikir verir ve modelin iyileştirilmesi için geri bildirim sağlar.

3.8 Görüntü Sınıflandırması Akış Diyagramı

Şekil 3.13'te sunulan akış diyagramı, maskeleme uygulanmış ve uygulanmamış adenoid görüntülerinin sınıflandırılmasına yönelik gerçekleştirilen derin öğrenme tabanlı yaklaşımın tüm aşamalarını kapsamlı biçimde ortaya koymaktadır. Diyagramda, veri kümesinin hazırlanmasından ön işleme süreçlerine, model eğitimi ve değerlendirme adımlarından performans ölçütlerine kadar birçok bileşen ayrıntılı şekilde görselleştirilmiştir. Bu yapı, her iki yöntemin karşılaştırmalı analizine zemin hazırlayarak, maskeleme uygulamasının sınıflandırma performansı üzerindeki etkilerini objektif biçimde değerlendirme imkânı sunmaktadır.



Şekil 3.13 Görüntü sınıflandırması akış diyagramı

Çalışmanın ilk aşaması, adenoid görüntülerinin ön işlenmesi adımlarını içermektedir. İlk olarak, görüntülerden kişisel bilgiler çıkarılmakta ve sadece sınıflandırma için gerekli bölgeye odaklanılmaktadır. Bu kırpma işlemi, kişisel verilerin korunmasına yardımcı olurken, modelin sınıflandırma için sadece ilgili bölgedeki özellikleri öğrenmesini sağlar. Bu adımın ardından, tüm görüntüler 256x256 piksel boyutuna yeniden boyutlandırılmaktadır. Bu standardizasyon, modelin tüm görüntüler üzerinde aynı çözünürlükte çalışmasını ve böylece işlem yükünün azalmasını sağlar. Son olarak, veri artırma adımı ile veri seti farklı dönüşümler kullanılarak genişletilmektedir. Bu adım, modelin daha çeşitli veri örnekleriyle eğitilmesine olanak tanır ve aşırı uyum riskini azaltır.

Ön işlenmiş adenoid görüntüleri daha sonra eğitim, doğrulama ve test setlerine ayrılmaktadır. Eğitim seti veri kümesinin %80'ini oluşturur ve modelin öğrenmesi için kullanılır. Doğrulama seti ise veri kümesinin %10'luk bir kısmını kapsar ve eğitim sırasında modelin performansını izlemek için kullanılır. Doğrulama kümesi, modelin parametrelerinin optimize edilmesine olanak tanır. Test seti de veri kümesinin son %10'unu oluşturarak modelin nihai performansını değerlendirmek için kullanılır. Bu veri ayrımı, modelin hem eğitim hem de değerlendirme süreçlerinde daha güvenilir sonuçlar elde etmesini sağlar.

Sınıflandırma aşamasında, model olarak bir ensemble modeli kullanılmaktadır. Ensemble model, birden fazla modelin tahminlerini birleştirerek daha sağlam ve genellenebilir bir sınıflandırma performansı sağlar. Farklı modellerin güçlü yönlerinden faydalananak daha yüksek doğruluk oranı elde edilir. Bu yaklaşım, özellikle tıbbi sınıflandırmalarda güvenilirliği artırdığı için tercih edilmektedir. Topluluk modelinin kullanılması, sınıflandırma doğruluğunu ve modelin çeşitli durumlara karşı dayanıklılığını artırmaktadır.

Modelin sınıflandırma performansı, doğruluk, kesinlik, duyarlılık, F1-skoru ve AUC gibi çeşitli metrikler kullanılarak değerlendirilir. Doğruluk, modelin tüm doğru tahminlerin toplam tahminlere oranını gösterir ve genel performansı ölçer. Kesinlik, adenoid olarak tahmin edilen görüntülerden gerçekten adenoid olanların oranını yansıtır. Duyarlılık, gerçekten adenoid olan görüntülerin model tarafından doğru

olarak tespit edilme oranıdır. F1-skoru, kesinlik ve duyarlılık arasındaki dengeyi ölçen bir metriktir. AUC ise modelin pozitif ve negatif sınıfları ayırt etme yeteneğini değerlendirir. Bu performans ölçütleri, modelin klinik uygulamalar için ne kadar güvenilir olduğunu ve hangi alanlarda iyileştirme gerektiğini belirlemede önemlidir.

Son adımda, modelin sınıflandırma sonuçları elde edilir ve modelin "Adenoid" ve "Sağlıklı" olarak ayırma performansı değerlendirilir. Performans ölçütleri yardımıyla elde edilen doğruluk, kesinlik, duyarlılık, F1 skoru ve AUC değerleri analiz edilerek, modelin sınıflandırmadaki başarı oranı hakkında bilgi sahibi olunur. Bu sonuçlar, modelin medikal uygulamalarda güvenilir bir şekilde kullanılabilmesi için gerekli olan doğruluk ve hassasiyet seviyesini karşılayıp karşılamadığını belirlemede kullanılır.

4. BULGULAR VE TARTIŞMA

Bu bölümde, adenoid hipertrofisi ve cilt lezyonları hastalıklarının segmentasyon ve sınıflandırma işlemlerinden elde edilen grafiksel sonuçlar ayrıntılı bir biçimde sunulmaktadır. Ayrıca, çalışmanın bulguları, literatürdeki araştırmalar ile karşılaştırmalı olarak ele alınarak her iki hastalık için kapsamlı bir sonuç değerlendirmesi yapılmıştır. Segmentasyon ve sınıflandırma süreçlerinde çeşitli parametreler dikkate alınarak elde edilen sonuçlar bu bağlamda analiz edilmiştir.

Bu analizler, çalışma bulgularının doğruluğu ve güvenilirliğini ortaya koyarken, literatüre önemli katkılar sunmaktadır. Çalışmanın literatürdeki yeri, kullanılan yöntemlerin etkinliği ve klinik uygulamalara olan potansiyel katkısı, sunulan sonuçların detaylı incelenmesiyle daha iyi anlaşılmaktadır. Bu bağlamda, elde edilen bulgular, sağlık alanında derin öğrenme tekniklerinin başarısını vurgulayarak literatüre yeni bir perspektif kazandırmaktadır.

4.1 Görüntü Segmentasyonu için Kullanılan Parametreler

Görüntü segmentasyonunun başarısı, adenoid hipertrofisi ve cilt lezyonları gibi tıbbi veri setlerinde kullanılan parametrelerin dikkatli bir şekilde belirlenmesine bağlıdır; bu bağlamda, Tablo 4.1, görüntü boyutu, epok sayısı, küme boyutu, optimizasyon algoritması, öğrenme oranı, kayıp fonksiyonu ve aktivasyon fonksiyonu gibi temel parametreleri ortaya koyarak modellerin eğitim sürecindeki yapılandırılmasını ve performansını optimize etmeyi amaçlamaktadır.

Tablo 4.1 Görüntü segmentasyonu için kullanılan parametreler

Parametre Veri Seti	Görüntü boyutu	Epok	Küme boyutu	Optimizasyon	Öğrenme oranı	Kayıp fonksiyonu	Aktivasyon fonksiyonu
Adenid hipertrofisi veri seti	256x256	100	16	Adam	0.001	Dice loss	ReLU
Cilt lezyonu veri seti	256x256	100	16	Adam	0.001	Dice loss	ReLU

Tablo 4.1 adenoid hipertrofisi ve cilt lezyonları veri setleri için kullanılan görüntü segmentasyon parametrelerini sunmaktadır. Her iki veri seti için aynı temel parametreler kullanılmış olup, bu durum modelin her iki hastalık üzerinde de benzer yapı ve hiperparametrelerle eğitildiğini göstermektedir. Görüntü boyutu 256x256

olarak seçilmiş olup, bu çözünürlük tıbbi görüntülerdeki önemli özelliklerin yakalanmasını sağlar ve işlem gücünü dengeli bir şekilde kullanır. Ayrıca, modelin 100 epok boyunca eğitilmesi, veri setlerindeki tüm görüntülerin model tarafından birçok kez işlenmesini sağlayarak öğrenme sürecini sağlamlaştırır.

Tablodaki diğer önemli parametreler arasında, küme boyutunun 16 olarak belirlenmesi bulunmaktadır. Bu boyut, modelin bellekte verimli çalışmasını sağlarken aynı zamanda eğitim sürecini hızlandırır, özellikle büyük tıbbi görüntülerle çalışırken oldukça işlevseldir. Optimizasyon algoritması olarak kullanılan Adam, özellikle tıbbi görüntü segmentasyon görevlerinde yaygın bir tercihtir. Çünkü modelin öğrenme oranını otomatik olarak ayarlar. Bu özellik, modelin farklı veri kümelerindeki özellikleri daha verimli bir şekilde öğrenmesini sağlar.

Öğrenme oranı 0.001 olarak ayarlanmıştır; bu değer, modelin yavaş ama istikrarlı bir şekilde öğrenmesini sağlayarak eğitim sürecindeki ani sapmaların önüne geçer. Kayıp fonksiyonu olarak Dice kaybı seçilmiş olup, bu fonksiyon segmentasyon problemlerinde özellikle faydalıdır çünkü tahmin edilen ve gerçek segmentlerin örtüşme oranını dikkate alır. Son olarak, aktivasyon fonksiyonu olarak ReLU (Rectified Linear Unit) kullanılması, modele doğrusal olmayan ilişkileri öğrenme kabiliyeti kazandırır ve negatif değerleri sıfıra ayarlayarak daha verimli bir öğrenme sağlar. Bu parametrelerin seçimi, tıbbi görüntülerde karmaşık desenlerin yakalanması için uygun bir yapı sunar ve her iki veri seti için etkin bir segmentasyon performansı elde edilmesine katkı sağlar.

4.2 Adenoid Hipertrofisi Hastalığı için Derin Öğrenme Tabanlı Segmentasyon Modellerinin Sonuçları

Adenoid hipertrofisi hastalığının doğru teşhisi ve segmentasyonu, klinik karar alma süreçlerinde önemli bir yer tutan derin öğrenme modellerinin performansının, doğruluk, duyarlılık, kesinlik, IoU ve Dice katsayısı gibi temel metrikler üzerinden değerlendirilmesiyle mümkün olmaktadır; bu analiz, modellerin adenoid hipertrofisi tespitindeki etkinliğini karşılaştırmayı ve klinik uygulamalar için en uygun modeli belirlemeyi amaçlamaktadır.

Tablo 4.2 Adenoid hipertrofisi teşhisinde derin öğrenme modellerinin performansı


Metrikler	Modeller			
	U-Net	U-Net++	SegNet	HDARU-Net
Doğruluk	0.9845	0.9717	0.9845	0.9945
Duyarlılık	0.8914	0.8645	0.8914	0.9648
Kesinlik	0.8624	0.8377	0.8733	0.9594
IoU	0.8918	0.8951	0.8918	0.9008
Dice katsayısı	0.8923	0.8957	0.8923	0.8660

Tablo 4.2 adenoid hipertrofisi hastalığının tespiti için kullanılan dört farklı derin öğrenme modelinin (U-Net, U-Net++, SegNet, HDARU-Net) performans metriklerini karşılaştırmaktadır. IoU, dice katsayısı, doğruluk, kesinlik ve duyarlılık gibi temel değerlendirme metrikleri üzerinden yapılan bu analiz, HDARU-Net modelinin diğer modellere kıyasla genel olarak üstün bir performans sergilediğini ortaya koymaktadır. Özellikle IoU, doğruluk ve duyarlılık metriklerinde HDARU-Net'in daha yüksek değerlere ulaşması, bu modelin segmentasyon görevinde daha başarılı olduğunu göstermektedir.

HDARU-Net modelinin en yüksek IoU değeri olan 0.9008 ile öne çıktığı görülmektedir. IoU değeri, tahmin edilen ve gerçek segmentler arasındaki örtüşmeyi ölçtüğünden, bu sonucun yüksek olması HDARU-Net'in segment sınırlarını doğru bir şekilde belirleyebilme yeteneğini yansıtır. U-Net, U-Net++ ve SegNet modellerinin IoU değerleri birbirine yakın olmasına rağmen, HDARU-Net'in sunduğu fark, modelin daha karmaşık özellikleri yakalama yeteneğine işaret eder.

Dice katsayısı açısından HDARU-Net'in değeri 0.8660 olarak kaydedilmiştir ve bu, diğer modellerin altında kalmaktadır. Dice katsayısı, segmentasyon doğruluğunu ölçmede sıkça kullanılan bir metrik olup, özellikle sınır belirlemedeki hassasiyeti vurgular. Bu bağlamda, HDARU-Net'in Dice değerinin görece düşük olmasının nedenleri araştırılabilir; ancak diğer metriklerdeki yüksek performansı, modelin genel başarısının bu küçük farktan etkilenmediğini göstermektedir.

Doğruluk, kesinlik ve duyarlılık açısından bakıldığında, HDARU-Net'in en yüksek değerleri sağladığı görülmektedir (0.9945 doğruluk, 0.9594 kesinlik, 0.9648 duyarlılık). Bu sonuçlar, HDARU-Net'in adenoid hipertrofisi segmentasyonu için güvenilir bir model olduğunu ortaya koymaktadır. Kesinlik değerinin yüksek olması, modelin yanlış pozitif oranını düşük tuttuğunu gösterirken, duyarlılık değeri modelin gerçek pozitifleri yakalamadaki etkinliğini vurgular. Sonuç olarak, HDARU-Net modelinin adenoid hipertrofisi segmentasyonu için tercih edilmesi, diğer modellere kıyasla daha doğru ve tutarlı sonuçlar sağlayabileceğini göstermektedir. Bu modelin üstün performansı, klinik uygulamalarda daha yüksek doğrulukla kullanılabileceğine işaret eder.



Şekil 4.1 Derin öğrenme modellerinin adenoid hipertrofisi üzerindeki performansı

4.3 Cilt Lezyonu Hastalığı için Derin Öğrenme Tabanlı Segmentasyon Modellerinin Sonuçları

Cilt lezyonu hastalıklarının teşhisinde derin öğrenme tabanlı segmentasyon modellerinin performansı, doğru teşhis ve doğru tedavi planlaması açısından kritik bir öneme sahiptir.

Tablo 4.3 Cilt lezyonu teşhisinde derin öğrenme modellerinin performansı


Metrikler	Modeller			
	U-Net	U-Net++	SegNet	HDARU-Net
Doğruluk	0.9226	0.9448	0.9510	0.9497
Duyarlılık	0.7604	0.8971	0.9322	0.8939
Kesinlik	0.8576	0.8295	0.8233	0.8549
IoU	0.6394	0.6723	0.7482	0.7596
Dice katsayısı	0.7461	0.7799	0.8407	0.8487

Tablo 4.3 cilt lezyonu hastalıklarının teşhisinde kullanılan derin öğrenme modellerinin performansını farklı metrikler üzerinden karşılaştırmaktadır. Bu metrikler, modelin genel doğruluğunu, lezyonları doğru şekilde tanıma yeteneğini (duyarlılık), yanlış pozitif oranını (kesinlik), segmentasyonun doğruluğunu (IoU) ve segmentasyonun doğruluğunun daha derin bir ölçüsü olan Dice katsayısını içermektedir. Modeller arasında U-Net, U-Net++, SegNet ve HDARU-Net yer almakta olup, her birinin bu metrikler üzerinden gösterdiği performans farklılıkları dikkat çekicidir.

Genel doğruluk açısından bakıldığında, U-Net++ modelinin 0.9448 değeri ile en yüksek performansı gösterdiği görülmektedir. Bunu sırasıyla SegNet (0.9510), HDARU-Net (0.9497) ve U-Net (0.9226) modelleri takip etmektedir. Bu doğruluk değerleri, her dört modelin de cilt lezyonlarını doğru bir şekilde sınıflandırma konusunda yüksek bir başarıya sahip olduğunu göstermektedir, ancak U-Net++ modelinin öne çıktığı söylenebilir. Duyarlılık metriği, modelin pozitif lezyonları doğru bir şekilde tanıyıp tanımadığını ölçer. Burada, SegNet ve U-Net++ modellerinin yüksek duyarlılık değerleri ile dikkat çektiği görülmektedir. SegNet, 0.9322 ile en yüksek duyarlılığı gösterirken, U-Net++ modeli de 0.8971 ile oldukça başarılıdır. Bu, her iki modelin, özellikle nadir veya daha küçük lezyonları tespit etme konusunda iyi


bir performans sergilediğini işaret eder. Diğer modeller ise duyarlılık açısından biraz daha düşük performans göstermektedir, özellikle U-Net modeli 0.7604 ile en düşük duyarlılığa sahiptir.

Kesinlik metriğinde ise, HDARU-Net modeli 0.8549 ile en yüksek kesinlik değerini elde etmiştir. Kesinlik, modelin pozitif tahminlerinin ne kadar doğru olduğunu gösterdiği için, HDARU-Net'in yanlış pozitiflerden kaçınma konusunda daha iyi bir performans gösterdiği söylenebilir. U-Net ise 0.8576 ile biraz daha yüksek bir kesinlik değerine sahipken, U-Net++ ve SegNet modelleri ise sırasıyla 0.8295 ve 0.8233 ile daha düşük kesinlik değerleri sunmaktadır. IoU ve Dice katsayısı, segmentasyon başarısını ölçen önemli metriklerdir. Bu metrikler, modelin segmentasyon doğruluğunun daha ayrıntılı bir değerlendirmesini sunar. HDARU-Net, her iki metrikte de en iyi performansı sergileyerek, sırasıyla 0.7596 IoU ve 0.8487 Dice katsayısı değerlerine ulaşmıştır. Bu, HDARU-Net modelinin, segmentasyon görevinde diğer modellere göre daha iyi bir performans gösterdiğini ortaya koymaktadır. Diğer modellerin de başarılı olduğu ancak HDARU-Net'in bu alanda öne çıktığı söylenebilir.



Şekil 4.2 Derin öğrenme modellerinin cilt lezyonu üzerindeki performansı

Şekil 4.2 (devamı)



4.4 Adenoid Hipertrofisi Hastalığında Önerilen Modelin Literatürdeki Modeller ile Karşılaştırılması

Adenoid hipertrofisi hastalığının teşhisinde kullanılan derin öğrenme modellerinin performansını karşılaştırmalı olarak incelemek, önerilen modelin etkinliğini değerlendirmek açısından büyük önem taşımaktadır.

Tablo 4.4 Önerilen model ile literatürdeki modellerin karşılaştırılması (adenoid)

Metrikler	Modeller			
	U-Net	HMSAU-Net	HeadNet	HDARU-Net
Doğruluk	-	0.912	0.919	0.994
Duyarlılık	-	0.976	0.906	0.964
Kesinlik	-	-	0.938	0.959
IoU	0.62	-	-	0.900
Dice katsayısı	0.74	-	-	0.866
Referanslar	[60]	[103]	[104]	Bizim model

Tablo 4.4 adenoid hipertrofisi hastalığı üzerine kullanılan çeşitli derin öğrenme modellerinin performansını değerlendirmektedir. HDARU-Net, U-Net, HMSAU-Net ve HeadNet modellerinin doğruluk, duyarlılık, kesinlik, IoU ve Dice katsayısı gibi metrikler açısından kıyaslandığı bu analizde, her bir modelin adenoid hipertrofisi tespiti üzerindeki başarımları ortaya konulmuştur.

Tabloya göre HDARU-Net, tüm modeller içinde en yüksek doğruluk oranına (%99.45) sahip olup, adenoid hipertrofisi hastalığının teşhisinde en güvenilir performansı sergilemektedir. Diğer modellere kıyasla HDARU-Net, yalnızca yüksek doğruluğa sahip olmakla kalmamakta, aynı zamanda yüksek duyarlılık (%96.48) ve kesinlik (%95.94) değerleri ile de öne çıkmaktadır. Bu, modelin yanlış negatif ve yanlış pozitif oranlarını düşük tuttuğunu ve genel teşhis sürecinde en etkili modeli sunduğunu göstermektedir. Öte yandan HMSAU-Net ve HeadNet modelleri de yüksek doğruluk oranlarına sahiptir; ancak HDARU-Net ile kıyaslandığında, bu modeller daha düşük bir doğruluk yüzdesine sahiptir.

Özellikle IoU ve Dice katsayısı metriklerinde, HDARU-Net %90.08 IoU ve %86.60 Dice skorları ile U-Net modeline kıyasla oldukça yüksek değerlere ulaşmıştır. U-Net modelinin Dice katsayısı %74 ve IoU değeri %62 olarak belirtilmiştir ki bu, HDARU-Net'in bölütleme başarısının U-Net'e göre çok daha üstün olduğunu ortaya koymaktadır. HDARU-Net'in daha yüksek IoU ve dice katsayısı, modelin görüntüdeki nesneleri daha doğru sınıflandırarak belirgin sınırlarda başarılı olduğunu ve genel doğruluğunun artmasını sağladığını göstermektedir.

Tablo 4.5 Önerilen model ile literatürdeki modellerin karşılaştırılması (cilt lezyonu)

Metrikler	Modeller			
	U-Net	Attention U-Net	SegNet	HDARU-Net
Doğruluk	0.915	0.8766	0.917	0.9497
Duyarlılık	0.755	0.8997	0.815	0.8939
Kesinlik	-	0.8775	-	0.8549
IoU	0.686	-	0.700	0.7596
Dice katsayısı	0.788	0.8585	0.797	0.8487
Referanslar	[86]	[105]	[88]	Bizim model

Tablo 4.5, cilt lezyonlarının sınıflandırılmasında kullanılan çeşitli derin öğrenme modellerinin doğruluk, duyarlılık, kesinlik, IoU ve Dice katsayısı gibi performans metrikleri açısından karşılaştırmasını sunmaktadır. U-Net, Attention U-Net, SegNet ve önerilen HDARU-Net modelleri bu metrikler ışığında değerlendirilmiştir. Her bir

modelin cilt lezyonlarını doğru bir şekilde tespit etme başarısı tabloda yer alan metrikler üzerinden analiz edilmiştir.

Önerilen HDARU-Net modeli %94.97 doğruluk oranıyla tüm modeller arasında en yüksek doğruluğa sahip olup, cilt lezyonlarının teşhisinde en başarılı model olarak öne çıkmaktadır. SegNet %91.7, U-Net %91.5 ve Attention U-Net %87.66 doğruluk oranları ile HDARU-Net'i takip etmekte; ancak doğruluk açısından geride kalmaktadır. Bu sonuç, HDARU-Net'in, cilt lezyonlarını doğru sınıflandırma konusunda diğer modellere kıyasla daha güçlü olduğunu göstermektedir.

Duyarlılık metriklerine bakıldığında, HDARU-Net %89.39 duyarlılık değeri ile SegNet ve U-Net'ten daha yüksek bir performans sergilerken, Attention U-Net %89.97 ile en yüksek duyarlılık oranına sahip model olarak dikkat çekmektedir. Duyarlılığın yüksek olması, modelin gerçek pozitifleri başarıyla tanımlayabilme kapasitesini göstermektedir. HDARU-Net'in duyarlılık oranı, modele yönelik yanlış negatif oranlarının düşük olduğunu ve cilt lezyonlarını tespit etmede oldukça başarılı olduğunu ortaya koymaktadır.

IoU ve Dice katsayısı açısından da HDARU-Net'in performansı dikkate değerdir. HDARU-Net %75.96 IoU ve %84.87 Dice katsayısı ile U-Net (%68.6 IoU ve %78.8 Dice) ve SegNet (%70 IoU ve %79.7 Dice) modellerini geride bırakmaktadır. Yüksek IoU ve dice katsayısı değerleri, modelin görüntülerdeki cilt lezyonlarını daha net bir şekilde sınıflandırabildiğini göstermektedir. Bu sonuç, HDARU-Net'in cilt lezyonlarını ayırt etmede daha yüksek bir isabetle çalıştığını ve sınıflandırma görevinde oldukça etkili olduğunu ortaya koymaktadır.

4.5 Adenoid Hipertrofisi Hastalığı Sınıflandırması için Kullanılan Parametreler

Adenoid hipertrofisinin sınıflandırılması amacıyla, derin öğrenme tabanlı çeşitli mimariler (EfficientNet, MobileNet, ResNet50, ResNet152, VGG16, Xception) kullanılarak, görüntü boyutu, epok sayısı, küme boyutu, optimizasyon algoritması, öğrenme oranı ve kayıp fonksiyonu gibi temel parametreler kullanılmış olup bu modellerin performansı sistematik bir şekilde değerlendirilmiştir.

Tablo 4.6 Adenoid hipertrofisi sınıflandırılması için kullanılan parametreler

Maskeli görüntüler/Maskesiz görüntüler						
Modeller						
Metrikler	EfficientNet	MobileNet	ResNet50	ResNet152	VGG16	Xception
Görüntü boyutu	256x256	256x256	256x256	256x256	256x256	256x256
Epok	25	25	25	25	25	25
Küme boyutu	16	16	16	16	16	16
Optimizasyon	Adam	Adam	Adam	Adam	Adam	Adam
Öğrenme oranı	0.001	0.001	0.001	0.001	0.001	0.001
Kayıp fonksiyonu	Binary Crossentropy	Binary Crossentropy	Binary Crossentropy	Binary Crossentropy	Binary Crossentropy	Binary Crossentropy

Tablo 4.6, adenoid hipertrofisi hastalığının sınıflandırılması için kullanılan derin öğrenme tabanlı sınıflandırma modellerinin (EfficientNet, MobileNet, ResNet50, ResNet152, VGG16, Xception) eğitiminde uygulanan parametreleri içermektedir. Görüntü sınıflandırma görevinde kullanılan bu modeller, özellikle farklı mimarileriyle bilinen popüler sinir ağı yapılarını temsil eder ve hepsi aynı parametre ayarlarıyla eğitilmiştir. Bu tutarlılık, modellerin performansının yalnızca mimari farklılıklardan kaynaklanan etkileri incelemeye olanak tanımaktadır.


Tüm modellerde giriş görüntü boyutu 256x256 olarak belirlenmiştir. Bu boyut, tıbbi görüntü sınıflandırması için yeterli detay seviyesini sunarken aynı zamanda hesaplama yükünü makul düzeyde tutmaktadır. Görüntülerin aynı boyutta olması, modellerin farklı veri setlerine uyum sağlama yeteneğini değerlendirmede önemli bir faktördür ve bu standardizasyon, karşılaştırılabilir sonuçlar elde edilmesini sağlar.

Eğitim sürecinde 25 epok kullanılması, modelin aşırı öğrenme riskini azaltmak için yeterli bir değerdir. Her bir modelin küme boyutunun 16 olarak seçilmesi, bellek kullanımı ve işlem hızı arasında bir denge sağlayarak verimli bir eğitim süreci sunar. Aynı optimizasyon algoritması olarak Adam'ın tüm modellerde kullanılması, öğrenme oranını dinamik olarak ayarlayan bu algoritmanın, sınıflandırma görevinde hızlı ve etkili bir eğitim süreci sağlaması amacıyla tercih edildiğini gösterir. Öğrenme oranının 0.001 olarak belirlenmesi ise, modellerin kademeli olarak ve stabil bir şekilde öğrenmesini sağlamak için ideal bir seçimdir.

Son olarak, kayıp fonksiyonu Binary Cross-Entropy'nin seçilmesi, ikili sınıflandırma görevlerinde doğrulukla çalışan bir fonksiyon olması nedeniyle anlamlıdır. Bu kayıp fonksiyonu, modelin sınıflandırma hatalarını minimize etme yönünde optimize edilmesini sağlayarak, adenoid hipertrofisi teşhisinde doğru sınıflandırma sonuçları elde edilmesine katkı sağlar. Genel olarak, bu parametrelerin tüm modellerde aynı şekilde kullanılması, modeller arasındaki sınıflandırma performans farklılıklarının sadece mimari yapıya bağlı olarak değerlendirilebileceği sağlam bir temel oluşturmaktadır. Bu nedenle, yapılan analiz sonucunda her modelin adenoid hipertrofisi sınıflandırmasındaki başarısı objektif bir şekilde kıyaslanabilir.

4.6 Görüntü Verisi ile Maskeleme Yöntemi

Bu bölümde, çalışmada kullanılan adenoid görüntü verilerinin maskeleme süreci ayrıntılı şekilde açıklanmaktadır. Görüntü işleme sürecinde etiketleme ve maskeleme, modelin doğru öğrenmesini sağlamak açısından kritik bir rol oynamaktadır.



Şekil 4.3 Adenoid görüntü verisi maskeleme yöntemi

Adenoid hipertrofisi veri kümesi, Batman Eğitim ve Araştırma Hastanesi'nden temin edilmiştir ve hem eğitim hem de test aşamalarında etiketleme gerektirmektedir. Bu sürecin doğruluğunu sağlamak amacıyla hastanenin KBB bölümünden iki uzman radyolog ile iş birliği yapılmıştır. Araştırma ekibinin bir parçası olan bu radyologlar, adenoid görüntülerinin gerçeğe en uygun şekilde işaretlenmesi sürecinde yer almış ve teşhis doğruluğunu artırmaya katkıda bulunmuşlardır. Etiketleme işlemi için açık kaynaklı bir görüntü düzenleme aracı olan GIMP kullanılmış ve adenoidler, tutarlılık ve görünürlük sağlamak amacıyla kırmızı renkle vurgulanmıştır. Örnek görüntüler incelendiğinde, adenoid bezlerinin şekil, boyut, konum ve yönelim açısından önemli ölçüde çeşitlilik gösterdiği, dolayısıyla veri kümesinin karmaşıklığını yansıttığı görülmektedir. Bu çeşitlilik, modelin daha geniş bir varyasyonla eğitilmesi ve test edilmesine olanak tanıyarak, adenoid hipertrofisinin otomatik olarak sınıflandırılması

için geliştirilen derin öğrenme modellerinin gerçek dünya koşullarına daha uygun hale getirilmesini sağlamaktadır.

4.7 Maske Uygulanmış Adenoid Hipertrofisi Görüntülerin Sınıflandırma Sonuçları

Adenoid hipertrofisi teşhisinde derin öğrenme modellerinin etkinliğini belirlemek amacıyla, maske uygulanmış adenoid görüntüler kullanılarak çeşitli sınıflandırma algoritmalarının performansı değerlendirilmiştir.

Tablo 4.7 Maske uygulanmış adenoid hipertrofisi görüntülerin sınıflandırma sonuçları

Metrikler	Modeller					
	EfficientNet	MobileNet	ResNet50	ResNet152	VGG16	Xception
Doğruluk	0.99	0.88	1.00	0.89	0.98	0.75
Kesinlik	0.99	0.90	1.00	0.83	0.99	0.65
Duyarlılık	0.99	0.89	1.00	0.80	0.99	0.61
F1-skoru	0.99	0.88	1.00	0.89	0.99	0.59
AUC	0.99	0.89	1.00	0.89	0.99	0.61

Tablo 4.7’de mevcut verilere göre, maskeleme uygulanmış adenoid hipertrofisi görüntülerinin sınıflandırılmasında kullanılan çeşitli derin öğrenme modellerinin performans metriklerini özetlemektedir. EfficientNet, MobileNet, ResNet50, ResNet152, VGG16 ve Xception modelleri üzerinde yapılan testlerde, her model için doğruluk, kesinlik, duyarlılık, F1-skoru ve ROC eğrisi altında kalan alan değerleri hesaplanmıştır. Bu metrikler, modellerin sınıflandırma performanslarını karşılaştırmak için önemli birer ölçüt olup, yüksek doğruluk ve dengeli performans sunan modellerin tercih edilmesi gerektiğini ortaya koymaktadır.

ResNet50 modeli, %100 doğruluk, hassasiyet, duyarlılık, F1 skoru ve AUC ile en yüksek performansı sergilemiştir. Bu sonuç, ResNet50'nin adenoid hipertrofisi sınıflandırma görevinde üstün bir genelleme yeteneğine sahip olduğunu göstermektedir. Bu model, özellikle her bir metrikte maksimum skor elde ettiğinden, sınıflandırma görevinde yüksek güvenilirlik sağlamaktadır. Benzer şekilde, EfficientNet ve VGG16 modelleri de %99 doğruluk, hassasiyet, duyarlılık, F1 skoru

ve AUC deęerleri ile başarılı sonuçlar elde etmiş, ancak ResNet50 kadar mükemmel bir sonuç sunmamıştır.

MobileNet ve ResNet152 modelleri, %88 ve %89 doğruluk oranları ile ResNet50 modeline göre orta düzeyde performans göstermiştir. Bu modeller, özellikle hassasiyet ve duyarlılık deęerlerinde daha düşük sonuçlar elde etmiş, ancak yine de sınıflandırma görevini tatmin edici bir şekilde yerine getirebilmektedirler. Bu durum, MobileNet ve ResNet152'nin daha hafif modeller olarak belirli sınıflandırma senaryolarında kullanılabileceğini, ancak daha yüksek doğruluk gerektiren durumlarda tercih edilmeyebileceğini ortaya koymaktadır.

Xception modeli ise en düşük performansı sergileyerek %75 doğruluk, %65 hassasiyet, %61 duyarlılık, %59 F1 skoru ve %61 AUC deęeri elde etmiştir. Bu modelin düşük sonuçları, maskelenmiş adenoid görüntüler üzerinde zayıf bir sınıflandırma yeteneğine sahip olduğunu göstermektedir. Xception'ın performans düşüklüğü, bu tür sınıflandırma görevlerinde daha karmaşık veya iyi optimize edilmiş modellerin tercih edilmesinin gerekliliğini ortaya koymaktadır. Bu analiz, farklı modellerin performans özelliklerini deęerlendirerek, klinik uygulamalarda en uygun modelin seçilmesi için bilgi sağlamaktadır.

4.8 Maske Uygulanmamış Adenoid Hipertrofisi Görüntülerin Sınıflandırma Sonuçları

Maskeleme işlemi uygulanmamış adenoid hipertrofisi görüntülerinin sınıflandırılmasında kullanılan derin öğrenme modellerinin performansını deęerlendirmek amacıyla, çeşitli metrikler doğrultusunda kapsamlı bir analiz gerçekleştirilmiştir.

Tablo 4.8 Maske uygulanmamış adenoid hipertrofisi görüntülerin sınıflandırma sonuçları

Metrikler	Modeller					
	EfficientNet	MobileNet	ResNet50	ResNet152	VGG16	Xception
Doğruluk	0.92	0.77	0.84	0.83	0.82	0.71
Kesinlik	0.93	0.80	0.87	0.84	0.83	0.62
Duyarlılık	0.87	0.78	0.84	0.83	0.82	0.70
F1-skoru	0.92	0.77	0.86	0.84	0.81	0.65
AUC	0.92	0.77	0.84	0.84	0.82	0.62

Tablo 4.8, maskeleme uygulanmamış adenoid hipertrofisi görüntülerinin sınıflandırılmasında kullanılan derin öğrenme modellerinin performans metriklerini göstermektedir. EfficientNet, MobileNet, ResNet50, ResNet152, VGG16 ve Xception modelleri üzerinden yapılan değerlendirmede doğruluk, kesinlik, duyarlılık, F1 skoru ve AUC değerleri yer almaktadır. Bu metrikler, modellerin maskeleme olmadan adenoid görüntüler üzerinde nasıl performans gösterdiğini karşılaştırmak için önemlidir.

EfficientNet, %92 doğruluk, %93 kesinlik, %87 duyarlılık, %92 F1 skoru ve %92 AUC ile en yüksek performansı sergileyen model olarak öne çıkmaktadır. Bu sonuçlar, EfficientNet'in maske uygulanmamış adenoid görüntülerde yüksek bir doğrulukla sınıflandırma yapabildiğini ve genelleme yeteneğinin oldukça iyi olduğunu göstermektedir. ResNet50 de %84 doğruluk, %87 kesinlik, %84 duyarlılık, %86 F1 skoru ve %84 AUC ile dikkate değer bir performans sergilemiş, EfficientNet'in hemen ardından gelmiştir. Bu sonuçlar, ResNet50'nin de bu tür görüntülerde güvenilir bir sınıflandırma modeli olabileceğini göstermektedir.

MobileNet, ResNet152 ve VGG16 modelleri, %77-%83 aralığında doğruluk sonuçları elde etmiş ve maske uygulanmamış adenoid görüntülerde orta seviyede performans göstermiştir. Özellikle ResNet152, %83 doğruluk, %84 kesinlik, %83 duyarlılık, %84 F1 skoru ve %84 AUC ile orta düzeyde dengeli bir performans sergilemiştir. MobileNet ise daha düşük doğruluk ve AUC değerlerine sahip olup (%77 ve %77), maske uygulanmayan verilerde diğer modellere göre daha zayıf bir performans sergilemiştir. Bu modeller, yüksek doğruluk gerektiren sınıflandırma uygulamalarında

yeterli olmayabilir ancak hafif ve hızlı olmaları nedeniyle belirli sınırlı kaynaklarda kullanılabilir.

Xception modeli ise %71 doğruluk, %62 kesinlik, %70 duyarlılık, %65 F1 skoru ve %62 AUC ile en düşük performansı sergilemiştir. Bu değerler, Xception'ın maske uygulanmamış adenoid görüntüler üzerinde yetersiz bir performans gösterdiğini ve sınıflandırma güvenilirliğinin diğer modellere kıyasla oldukça düşük olduğunu ortaya koymaktadır. Xception'ın bu performansı, daha karmaşık veya optimize edilmiş modellerin bu tür veri setlerinde daha uygun olabileceğini göstermektedir.

4.9 Önerilen Model ile Literatürdeki Ensemble Derin Öğrenme Modellerinin Performans Karşılaştırması

Bu bölümde Tablo 4.9 gösterildiği gibi, önerilen modelin başarımı, literatürde sıklıkla kullanılan ensemble derin öğrenme modelleri ile karşılaştırmalı olarak analiz edilmiştir.

Tablo 4.9 Önerilen ve literatürdeki ensemble derin öğrenme modellerinin karşılaştırılması

Çalışma	Metot	Veri seti	Doğruluk	Kesinlik	Duyarlılık	F1-skoru
Zhao et al. (2021)	Fujioka modeli	Adenoidlerin lateral sefalogramları	0.91	0.93	0.90	–
Dong et al. (2023)	HMSAU-Net ve 3D-ResNet	Konik ışınli bilgisayarlı tomografi veri seti	0.91	–	0.97	0.90
Fu et al. (2023)	AFFMNet modeli	Yama düzeyinde ve tam slayt görüntüleri	0.97	–	0.97	0.97
Zheng et al. (2022)	MIB-ANet	Nasoendoskopik adenoid veri seti	0.76	0.76	0.76	0.76
He et al. (2023)	ADNet model	MRI görüntüler	0.94	0.96	0.96	0.96
Önerilen model	Ensemble derin öğrenme modelleri	Batman eğitim ve araştırma hastanesi, 344 X-ray görüntüler	1.00 (ResNet50)	99% (EfficientNet, VGG16)	99% (EfficientNet, VGG16)	99% (ResNet50)

Bu tablo, adenoid görüntülerinin sınıflandırılması ve tespiti için kullanılan çeşitli derin öğrenme modellerinin performans karşılaştırmasını göstermektedir. Farklı yöntemlerin ve veri setlerinin incelendiği bu tabloda, Zhao ve arkadaşları (2021), Dong ve arkadaşları (2023), Fu ve arkadaşları (2023), Zheng ve arkadaşları (2022), He

ve arkadaşları (2023) ile önerilen modelimiz karşılaştırılmaktadır. Performans metrikleri doğruluk, kesinlik, duyarlılık ve F1 skoru parametrelerini içermektedir.

Zhao et al. (2021) tarafından yapılan çalışmada, Fujioka modeli kullanılarak adenoidlerin lateral sefalogramları üzerinde analiz gerçekleştirilmiştir. Çalışmada elde edilen doğruluk (%91), kesinlik (%93) ve duyarlılık (%90) değerleri, geleneksel radyografik analiz yöntemlerinin adenoid tespiti için hala güçlü bir araç olduğunu göstermektedir. Ancak, Fujioka modeli klasik bir yöntem olduğu için derin öğrenme tabanlı yaklaşımlarla kıyaslandığında otomatik segmentasyon veya sınıflandırma konusunda sınırlı kalabilmektedir. Bu nedenle, modern görüntü işleme teknikleriyle desteklenmediği sürece, genelleme kapasitesinin daha düşük olması beklenmektedir.

Dong et al. (2023) çalışmasında, konik ışınli bilgisayarlı tomografi veri seti kullanılarak HMSAU-Net ve 3D-ResNet modelleri uygulanmıştır. HMSAU-Net, hibrit dikkat mekanizmalarına sahip bir U-Net türevi olup, segmentasyon görevlerinde gelişmiş performans göstermektedir. 3D-ResNet ise, üç boyutlu görüntü verileri üzerinde derin özellik çıkarımı yaparak sınıflandırma görevlerinde güçlü sonuçlar elde edebilen bir modeldir. Bu çalışmada, doğruluk oranı %91 olarak elde edilirken, duyarlılık %97 ve F1-skoru %90 olarak ölçülmüştür. Yüksek duyarlılık değeri, modelin adenoid bölgelerini başarılı bir şekilde tespit edebildiğini gösterirken, kesinlik değeri rapor edilmediğinden modelin yanlış pozitif oranı hakkında bilgi eksikliği bulunmaktadır.

Fu et al. (2023) tarafından sunulan çalışmada, AFFMNet modeli kullanılarak yama düzeyinde ve tam slayt görüntüleri üzerinde analiz gerçekleştirilmiştir. Bu çalışmada, modelin doğruluk oranı %97, duyarlılığı %97 ve F1-skoru %97 olarak kaydedilmiştir. Bu yüksek doğruluk ve tutarlı metrikler, modelin veri seti üzerinde oldukça başarılı bir performans sergilediğini göstermektedir. Özellikle, tıbbi görüntü analizinde yama düzeyinde incelemelerin yapılması, modelin lokal özellikleri daha iyi öğrenmesini sağlayarak detaylı segmentasyon ve sınıflandırma başarısını artırabilir. Ancak, veri setinin büyüklüğü ve çeşitliliği modellemeye etkisi olduğunu göstermektedir.

Zheng et al. (2022) çalışmasında, nasoendoskopik adenoid veri seti kullanılarak MIB-ANet modeli ile analiz yapılmıştır. Bu çalışmada, doğruluk, kesinlik, duyarlılık ve F1-skoru değerleri %76 olarak ölçülmüştür. Bu düşük performans metrikleri, modelin endoskopik görüntüler üzerindeki başarısının diğer çalışmalara kıyasla daha sınırlı olduğunu göstermektedir. Endoskopik görüntüler, aydınlatma farklılıkları, gölge etkileri ve düzensiz doku yapıları nedeniyle segmentasyon açısından daha zorlu bir veri türü sunar. Bu durum, modelin karmaşık doku varyasyonlarına yeterince iyi uyum sağlayamadığını ve yanlış sınıflandırmalara açık olduğunu düşündürülebilir.


He et al. (2023) tarafından yapılan çalışmada, MRI görüntüleri üzerinde ADNet modeli kullanılmıştır. Bu çalışmada, doğruluk %94, kesinlik %96, duyarlılık %96 ve F1-skoru %96 olarak raporlanmıştır. MRI görüntüleri, yumuşak doku detaylarını yüksek doğrulukla gösterebildiği için adenoid tespiti açısından güçlü bir veri kaynağıdır. ADNet modeli, bu veriler üzerinde başarılı sonuçlar elde etmiş olsa da MRI görüntülerinin elde edilmesi ve işlenmesi, X-ray veya endoskopik görüntülere kıyasla daha maliyetli ve zaman alıcı olabilir. Bu nedenle, klinik uygulanabilirlik açısından değerlendirme yapılırken, modelin doğruluğu kadar veri elde etme süreçleri de göz önünde bulundurulmalıdır.

Önerilen modelde, Batman Eğitim ve Araştırma Hastanesi'nden elde edilen 344 X-ray görüntüsü kullanılarak ensemble derin öğrenme modelleri uygulanmıştır. ResNet50, EfficientNet ve VGG16 modellerinin kombinasyonu ile gerçekleştirilen sınıflandırma işleminde, doğruluk oranı %100 (ResNet50), kesinlik %99 (EfficientNet, VGG16) ve duyarlılık %99 (EfficientNet, VGG16) olarak ölçülmüştür. Bu sonuçlar, önerilen modelin mevcut yöntemlere kıyasla oldukça üstün bir performans gösterdiğini ortaya koymaktadır. Özellikle ensemble yöntemi sayesinde farklı modellerin güçlü yönleri birleştirilerek daha sağlam ve genelleştirilebilir bir yapı elde edilmiştir.

4.10 Maskesiz Adenoid Görüntülerle Derin Öğrenme Tabanlı Sınıflandırma Modellerinin Eğitim Doğruluğunun Değerlendirilmesi

Maskesiz adenoid görüntüler kullanılarak eğitilen derin öğrenme tabanlı sınıflandırma modellerinin eğitim süreçleri, doğruluk metriği açısından detaylı bir şekilde incelenmiştir. Bu kapsamda, EfficientNet, MobileNet, ResNet50, ResNet152, VGG16

ve Xception modellerinin eğitim ve doğrulama doğruluklarının zaman içerisindeki değişim eğilimleri analiz edilmiş olup sınıflandırma modellerinin genelleme kapasiteleri ve aşırı öğrenme eğilimleri karşılaştırmalı olarak değerlendirilmiştir.



Şekil 4.4 Maskesiz adenoid görüntülerle derin öğrenme tabanlı sınıflandırma modellerinin eğitim doğruluğunun değerlendirilmesi – (a): EfficientNet (b): MobileNet (c): ResNet50 (d): ResNet152 (e): VGG16 (f): Xception

Bu grafiklerde altı farklı derin öğrenme modeli (EfficientNet, MobileNet, ResNet50, ResNet152, VGG16, Xception) maskesiz görüntülerle eğitim ve doğrulama doğruluğu açısından incelenmiştir. Her bir modelin performansı, eğitim ve doğrulama doğruluklarının zamanla değişim eğilimleriyle değerlendirilmiştir.

İlk olarak, EfficientNet (a) modeli diğer modellere kıyasla oldukça başarılı bir performans sergilemektedir. Eğitim doğruluğu ve doğrulama doğruluğu paralel bir şekilde artmakta ve yüksek değerlere ulaşmaktadır. Doğrulama doğruluğu eğitim doğruluğuna çok yakın seyrederek modelin iyi bir genelleme kapasitesine sahip olduğunu göstermektedir. Bu grafik, EfficientNet'in maskesiz görüntülerle çalışırken aşırı öğrenme yapmadan dengeli bir öğrenme sağladığını ortaya koymaktadır.

MobileNet (b) modeli ise daha dalgalı bir doğrulama doğruluğuna sahiptir ve eğitim doğruluğu ile doğrulama doğruluğu arasındaki fark belirgin şekilde açılmaktadır. Eğitim doğruluğu yüksek değerlere ulaşsa da validasyon doğruluğunun düşük seviyelerde kalması, modelin aşırı öğrenme yaptığını göstermektedir. MobileNet'in genelleme yeteneği sınırlı olup, bu sınırlamayı aşmak için daha etkili düzenleme (regularization) teknikleri veya veri artırma yöntemleriyle performansı iyileştirilebilir.


ResNet50 (c) ve ResNet152 (d) modelleri, genelleme kapasitesi açısından birbirine oldukça benzer performanslar göstermektedir. ResNet50 modelinde eğitim ve validasyon doğrulukları uyumlu bir şekilde artarken validasyon doğruluğunda sınırlı dalgalanmalar gözlemlenmektedir. Bu durum modelin dengeli bir şekilde öğrenme gerçekleştirdiğini göstermektedir. ResNet152 ise validasyon doğruluğunun bazı epoklarda eğitim doğruluğunu geçtiği ve genel olarak iyi bir uyum sağladığı bir tablo sergilemektedir. ResNet modelleri, maskeli görüntüler için etkili öğrenme gerçekleştirmiştir ve genelleme kapasiteleri oldukça yüksektir.

VGG16 (e) modeli, doğruluk artışı bakımından oldukça düzenli ve başarılı bir performans göstermektedir. Eğitim doğruluğu ile validasyon doğruluğu arasında çok az fark vardır ve genelleme kapasitesi yüksektir. Bu model, maskeli görüntüler üzerinde dengeli bir öğrenme gerçekleştirmiş ve belirgin bir aşırı öğrenme veya eksik öğrenme belirtisi göstermemiştir.

Son olarak, Xception (f) modeli, doğrulama doğruluğunda belirgin dalgalanmalar ve düşük performans göstermesi nedeniyle diğer modellere göre zayıf kalmıştır. Eğitim doğruluğu düşük seviyelerde kalırken doğrulama doğruluğu daha yüksek olabilmektedir. Bu durum modelin öğrenme kapasitesinin sınırlı olduğunu veya eğitim sürecinde yeterli optimizasyon yapılmadığını göstermektedir.


4.11 Maskeli Adenoid Görüntülerle Derin Öğrenme Tabanlı Sınıflandırma Modellerinin Eğitim Doğruluğunun Değerlendirilmesi

Maskeli adenoid görüntüler kullanılarak eğitilen derin öğrenme modellerinin performansları, eğitim ve doğrulama doğrulukları açısından kapsamlı bir şekilde analiz edilmiştir. Bu doğrultuda, EfficientNet, MobileNet, ResNet50, ResNet152, VGG16 ve Xception modellerinin genelleme kapasiteleri, doğruluk değerlerindeki dalgalanmalar ve aşırı öğrenme eğilimleri karşılaştırmalı olarak değerlendirilmiştir. Modellerin eğitim sürecindeki öğrenme dinamikleri incelenerek, sınıflandırma görevinde hangi modelin daha dengeli ve güvenilir bir performans sergilediği belirlenmiştir.




Şekil 4.5 Maskeli adenoid görüntülerle derin öğrenme tabanlı sınıflandırma modellerinin eğitim doğruluğunun değerlendirilmesi – (a): EfficientNet (b): MobileNet (c): ResNet50 (d): ResNet152 (e): VGG16 (f): Xception


Şekil 4.5 (devamı)




(e)



(f)



(e)



(f)

Bu grafiklerde altı farklı derin öğrenme modelinin maskeli görüntüler üzerinde eğitim doğruluğu ve doğrulama doğruluğu incelenmiştir. Modeller, genelleme kapasitesi, dalgalanma miktarı ve uyum açısından değerlendirilmiştir.

EfficientNet (a) modeli, maskeli görüntüler üzerinde oldukça iyi bir performans sergilemiştir. Eğitim ve doğrulama doğruluğu hızlı bir şekilde yüksek değerlere ulaşmakta ve bu doğruluklar paralel bir şekilde artmaktadır. Bu, modelin genelleme kapasitesinin güçlü olduğunu ve aşırı öğrenme yapmadığını göstermektedir. EfficientNet, maskesiz görüntülerle dengeli bir öğrenme sağlayarak diğer modellere kıyasla güvenilir bir performans sergilemiştir.

MobileNet (b), eğitim doğruluğu açısından başarılı bir performans gösterse de doğrulama doğruluğundaki dalgalanmalar modelin genelleme kapasitesinin zayıf olduğunu ortaya koymaktadır. Eğitim doğruluğu ile doğrulama doğruluğu arasındaki

fark, aşırı öğrenme belirtilerini işaret etmektedir. MobileNet'in performansı maskeli görüntülerde veri artırma gibi tekniklerle iyileştirilebilir.


ResNet50 (c) ve ResNet152 (d) modelleri, genelleme başarısı açısından oldukça benzer davranışlar sergilemektedir. ResNet50, eğitim doğruluğunda hızlı bir artış gösterirken doğrulama doğruluğu da paralel bir şekilde yüksek değerlere ulaşmıştır. ResNet152 ise benzer bir başarı sergilemiş, ancak doğrulama doğruluğunda zaman zaman dalgalanmalar yaşanmıştır. ResNet modelleri, maskesiz görüntüler için etkili bir öğrenme kapasitesine sahiptir, ancak ResNet152'nin daha karmaşık yapısı, doğrulama doğruluğundaki tutarsızlıkların nedeni olabilir.

VGG16 (e) modeli, neredeyse mükemmel bir performans sergileyerek hem eğitim hem de doğrulama doğruluğunda 1.0 seviyelerine ulaşmıştır. Eğitim doğruluğu ile doğrulama doğruluğunun bu kadar yakın olması, modelin maskesiz görüntülerde aşırı öğrenme yapmadan verimli bir şekilde öğrendiğini göstermektedir. Bu model, maskeli görüntüler için en güçlü performansı sağlamış gibi görünmektedir.


Xception (f) modeli ise, doğruluk seviyelerinin düşük kalması ve doğrulama doğruluğunda belirgin dalgalanmalar yaşaması nedeniyle diğer modellere kıyasla zayıf bir performans sergilemiştir. Bu durum, modelin öğrenme kapasitesinin yetersiz olduğu veya yeterince optimize edilmediği anlamına gelebilir. Xception'ın genelleme kapasitesini artırmak için eğitim sürecinde düzenlemeler yapılması gerekmektedir.

4.12 Maskesiz Adenoid Görüntülerle Derin Öğrenme Tabanlı Sınıflandırma Modellerinin ROC Eğrisi


Maskesiz adenoid görüntüler kullanılarak eğitilen derin öğrenme tabanlı sınıflandırma modellerinin performansı, ROC eğrileri ve AUC değerleri aracılığıyla kapsamlı bir şekilde değerlendirilmiştir. ROC eğrileri, modellerin doğru pozitif ve yanlış pozitif oranları arasındaki dengeyi nasıl sağladığını gösterirken, AUC değeri genel sınıflandırma başarısının nicel bir ölçütü olarak kullanılmıştır.




(a)




(b)




(c)



(d)



(e)



(f)

Şekil 4.6 Maskesiz adenoid görüntülerle derin öğrenme tabanlı sınıflandırma modellerinin ROC Eğrisi
– (a): EfficientNet (b): MobileNet (c): ResNet50 (d): ResNet152 (e): VGG16 (f): Xception

Bu grafiklerde maskesiz görüntülerle çalıştırılan altı derin öğrenme modelinin ROC eğrileri ve AUC değerleri incelenmektedir. ROC eğrileri modelin sınıflandırma

performansını gösterirken, AUC değeri bu performansın 0 ile 1 arasında değer alan tek bir sayısal ölçüsüdür. Daha yüksek AUC değerleri daha iyi performans ifade eder.

EfficientNet (a) modeli, en yüksek AUC değerine (0.92) sahiptir. ROC eğrisi neredeyse köşeye yaklaşan bir şekil çizerek, modelin yanlış pozitif oranını düşük tutarken doğru pozitif oranını yüksek seviyede tutabildiğini göstermektedir. Bu, EfficientNet'in maskesiz görüntülerde üstün bir sınıflandırma başarısı sergilediğini ve en iyi model olarak değerlendirilebileceğini gösterir.

MobileNet (b), AUC değeri 0.78 ile EfficientNet'e kıyasla daha düşük bir performans sergilemiştir. ROC eğrisi, doğru pozitif oranını artırmak için daha yüksek bir yanlış pozitif oranı gerektiriyor gibi görünmektedir. Bu, MobileNet'in genelleme başarısının nispeten sınırlı olduğunu ve daha fazla optimizasyon veya veri işleme tekniklerine ihtiyaç duyabileceğini göstermektedir.

ResNet50 (c) ve ResNet152 (d) modelleri aynı AUC değerine (0.84) sahiptir. ROC eğrileri köşeye daha yakın bir yol izlemektedir ve bu da her iki modelin doğru pozitif oranlarını yanlış pozitif oranlarını fazla artırmadan yükseltebildiğini göstermektedir. Bu iki model, maskesiz görüntülerde etkili bir sınıflandırma performansı sunmaktadır. Ancak ResNet152, daha karmaşık yapısı nedeniyle daha fazla kaynak kullanımı gerektirebilir.


VGG16 (e) modeli, AUC değeri 0.82 ile ResNet modellerinin hemen arkasında yer almaktadır. ROC eğrisi köşeye yakın olmakla birlikte, doğru pozitif oranını artırırken bazı sınırlamalara işaret edebilir. Bu, VGG16'nın sınıflandırmada hala güçlü bir model olduğunu, ancak ResNet modelleriyle kıyaslandığında biraz daha düşük bir performans sergilediğini göstermektedir.

Xception (f) modeli, AUC değeri 0.62 ile en düşük performansa sahiptir. ROC eğrisi, daha çok bir rastgele sınıflandırmaya yakın bir şekil sergilemektedir. Bu, Xception'ın maskesiz görüntülerde diğer modellere kıyasla oldukça zayıf bir sınıflandırma başarısı gösterdiğini ve bu modelin optimizasyon veya yapı değişikliklerine ihtiyaç duyduğunu ortaya koymaktadır.

Genel bir değerlendirme yapılacak olursa, EfficientNet (a), en yüksek AUC değeri ile en iyi modeldir ve maskesiz görüntüler üzerinde etkili bir genelleme kapasitesine sahiptir. ResNet50 (c) ve ResNet152 (d), birbirine benzer AUC değerleri ile ikinci sıradadır. Daha dengeli ve etkili sınıflandırma performansı sunmaktadırlar. VGG16 (e), üçüncü sırada yer almakta ve iyi bir genelleme sunmaktadır ancak ResNet modellerinin biraz gerisinde kalmıştır. MobileNet (b), sınıflandırma performansı açısından orta düzeyde bir başarı göstermiştir. Xception (f), düşük AUC değeri ile en zayıf performansa sahip modeldir ve iyileştirme gereklidir.

4.13 Maskeli Adenoid Görüntülerle Derin Öğrenme Tabanlı Sınıflandırma Modellerinin ROC Eğrisi


Maskeli adenoid görüntüler kullanılarak eğitilen derin öğrenme tabanlı sınıflandırma modellerinin performansı, ROC eğrileri ve AUC değerleri aracılığıyla analiz edilmiştir. Bu doğrultuda, farklı derin öğrenme modellerinin maskeli görüntüler üzerinde genelleme kapasiteleri ve tanısal doğrulukları karşılaştırmalı olarak değerlendirilmiştir.




Şekil 4.7 Maskeli adenoid görüntülerle derin öğrenme tabanlı sınıflandırma modellerinin ROC Eğrisi

– (a): EfficientNet (b): MobileNet (c): ResNet50 (d): ResNet152 (e): VGG16 (f): Xception


Şekil 4.7 (devamı)




(c)



(d)



(e)



(f)

Bu grafiklerde maskeli görüntülerle çalıştırılan altı derin öğrenme modelinin ROC eğrileri ve AUC değerleri incelenmiştir. ROC eğrileri, modellerin sınıflandırma performansını doğru pozitif ve yanlış pozitif oranlarına göre görselleştirirken, AUC değerleri performansın genel bir ölçütünü sağlamaktadır.

EfficientNet (a) modeli, $AUC = 0.99$ değeriyle mükemmel bir performans sergilemiştir. ROC eğrisi, (0,1) noktasına çok yakın bir şekilde ilerleyerek modelin doğru pozitif oranını yüksek, yanlış pozitif oranını düşük tuttuğunu göstermektedir. EfficientNet, maskeli görüntüler üzerinde üstün bir sınıflandırma performansı sunmakta ve diğer modellerle kıyaslandığında en başarılı sonuçlardan birini elde etmiştir.

MobileNet (b) modeli, $AUC = 0.89$ değeriyle iyi bir performans göstermektedir. ROC eğrisi, doğru pozitif oranını yüksek seviyede tutmayı başarmış, ancak EfficientNet'e

kıyasla daha az etkili olmuştur. Bu durum, MobileNet'in sınıflandırma yeteneğinin güçlü olduğunu, ancak bazı iyileştirmelerle daha iyi performans gösterebileceğini ifade etmektedir.

ResNet50 (c) ve ResNet152 (d) modelleri de oldukça yüksek performans göstermektedir. ResNet50'nin $AUC = 1.00$ değeriyle mükemmel bir sonuç verdiği gözlemlenmiştir; ROC eğrisi (0,1) noktasına tamamen oturmuş durumdadır. Bu, ResNet50'nin maskeli görüntülerle sınıflandırma görevinde hatasız bir performans sergilediğini göstermektedir. ResNet152 ise $AUC = 0.89$ değeriyle ResNet50 kadar başarılı olmasa da oldukça yüksek bir doğruluk oranına sahiptir. ResNet152'nin performansı da oldukça tatmin edicidir.

VGG16 (e) modeli, $AUC = 0.99$ değeriyle EfficientNet'e benzer bir performans göstermektedir. ROC eğrisi neredeyse ideal bir şekle sahiptir ve bu da modelin doğru sınıflandırma kapasitesinin çok yüksek olduğunu göstermektedir. Maskeli görüntülerle VGG16'nın verimli bir şekilde çalıştığı ve oldukça güçlü bir model olduğu açıktır.


Xception (f) modeli, $AUC = 0.61$ değeriyle en düşük performansa sahiptir. ROC eğrisi rastgele sınıflandırmaya yakın bir şekil çizmektedir ve modelin sınıflandırma görevinde zayıf bir performans gösterdiğini ortaya koymaktadır. Xception'ın bu sonuçları, modelin maskeli görüntülerle etkili bir şekilde öğrenemediğini ve ciddi optimizasyonlara ihtiyaç duyduğunu göstermektedir.

ResNet50, EfficientNet ve VGG16 sınıflandırma performansı açısından en üst düzeyde sonuçlar elde etmişlerdir. MobileNet ve ResNet152 tatmin edici ancak mükemmel olmayan sonuçlar sunmuştur. Xception modeli ise, sınıflandırma görevinde başarısız olmuş ve ciddi iyileştirmelere ihtiyaç duymaktadır.

4.14 Maskesiz Adenoid Görüntülerle Derin Öğrenme Tabanlı Sınıflandırma Modellerinin Karışıklık Matrisi

Maskesiz adenoid görüntüler kullanılarak eğitilen derin öğrenme tabanlı sınıflandırma modellerinin performansı, karışıklık matrisleri aracılığıyla detaylı bir şekilde analiz

edilmiştir. Karışıklık matrisleri, her modelin doğru ve yanlış sınıflandırma oranlarını görselleştirerek, sınıflandırma doğruluğu ve hata oranlarını karşılaştırmalı olarak değerlendirmeye olanak tanımaktadır. Bu analiz, farklı derin öğrenme modellerinin maskesiz görüntüler üzerinde genelleme kapasitelerini ve tanısal güvenilirliklerini belirlemek amacıyla gerçekleştirilmiştir.



Şekil 4.8 Maskesiz adenoid görüntülerde derin öğrenme tabanlı sınıflandırma modellerinin karışıklık matrisi – (a): EfficientNet (b): MobileNet (c): ResNet50 (d): ResNet152 (e): VGG16 (f): Xception

Bu karışıklık matrislerinde maskesiz görüntüler üzerinde altı farklı derin öğrenme modelinin sınıflandırma performansı, doğru sınıflandırma (True Positive ve True Negative) ve yanlış sınıflandırma (False Positive ve False Negative) sayıları

incelenmektedir. Her matris, modelin maskesiz görüntülerle çalışırken hangi oranda doğru tahmin yaptığını ve hatalarını göstermektedir.

EfficientNet modeli, 74 doğru pozitif (TP) ve 66 doğru negatif (TN) tahminle yüksek bir sınıflandırma başarısı göstermektedir. Yanlış pozitif (FP) ve yanlış negatif (FN) sayıları sırasıyla yalnızca 2 ve 10'dur, bu da EfficientNet modelinin hatalarının çok az olduğunu ve dengeli bir şekilde çalıştığını göstermektedir. MobileNet modeli ise 49 doğru pozitif ve 69 doğru negatif tahminle nispeten daha düşük bir başarı göstermiştir. MobileNet'in yanlış pozitif (27) ve yanlış negatif (7) oranları daha yüksektir, bu da modelin özellikle pozitif sınıfı yanlış tahmin etme eğiliminde olduğunu göstermektedir.

ResNet50, 75 doğru pozitif ve 53 doğru negatif tahminle oldukça etkili bir modeldir. Yanlış pozitif sayısı yalnızca 1 iken, yanlış negatif sayısı 23'tür. Bu model, pozitif sınıfı doğru tahmin etme konusunda başarılı ancak negatif sınıfın bir kısmını pozitif olarak sınıflandırma eğilimi göstermektedir. ResNet152 modeli ise 63 doğru pozitif ve 64 doğru negatif tahminle dengeli bir performans sergilemektedir. Yanlış pozitif ve yanlış negatif oranları sırasıyla 13 ve 12'dir, bu da ResNet152'nin her iki sınıf için de istikrarlı bir performans sunduğunu göstermektedir.


VGG16 modeli, 57 doğru pozitif ve 68 doğru negatif tahminle oldukça etkili bir performans sergilemiştir. Yanlış pozitif (19) ve yanlış negatif (8) oranları diğer güçlü modellerle karşılaştırıldığında nispeten düşük kalmıştır. Bu model, maskesiz görüntülerle dengeli ve yüksek doğruluk oranı sağlamaktadır. Xception modeli ise 55 doğru pozitif ve 39 doğru negatif tahminle en zayıf modeldir. Yanlış pozitif ve yanlış negatif oranları sırasıyla 21 ve 37'dir, bu da modelin genel olarak düşük bir sınıflandırma başarısına sahip olduğunu ve hatalarının yüksek olduğunu göstermektedir.

EfficientNet ve VGG16, en düşük hata oranları ve en yüksek doğru tahmin sayıları ile maskesiz görüntüler üzerinde en başarılı modellerdir. ResNet50, doğru pozitif oranında yüksek bir performans sergilese de yanlış negatif sayısı açısından iyileştirilmesi gerekebilir. ResNet152 ise her iki sınıfta da dengeli bir performans

sağlamaktadır. MobileNet, özellikle yanlış pozitif sınıflandırmalarında yüksek hata oranına sahiptir. Xception ise en zayıf performansı göstermiş olup, ciddi optimizasyonlara ihtiyaç duymaktadır. Bu analiz, maskesiz görüntüler için en etkili modelin EfficientNet olduğunu açıkça ortaya koymaktadır.


4.15 Maskeli Adenoid Görüntülerle Derin Öğrenme Tabanlı Sınıflandırma Modellerinin Karışıklık Matrisi

Maskeli adenoid görüntüler kullanılarak eğitilen derin öğrenme tabanlı sınıflandırma modellerinin performansı, karışıklık matrisleri aracılığıyla detaylı bir şekilde analiz edilmiştir. Bu analiz, farklı derin öğrenme modellerinin maskeli görüntüler üzerinde genelleme kapasitelerini ve tanısal güvenilirliklerini belirlemek amacıyla gerçekleştirilmiştir.



Şekil 4.9 Maskeli adenoid görüntülerde derin öğrenme tabanlı sınıflandırma modellerinin karışıklık matrisi – (a): EfficientNet (b): MobileNet (c): ResNet50 (d): ResNet152 (e): VGG16 (f): Xception

Şekil 4.9 (devamı)



Bu karışıklık matrisleri, maskeli görüntülerde kullanılan altı farklı derin öğrenme modelinin sınıflandırma performansını değerlendirmek için oluşturulmuştur.

EfficientNet, 76 doğru pozitif ve 75 doğru negatif tahminle mükemmel yakın bir performans göstermektedir. Yanlış pozitif ve yanlış negatif sayıları sırasıyla 0 ve 1 olup modelin hata oranı neredeyse sıfırdır. EfficientNet, maskeli görüntülerde sınıflandırma açısından en başarılı modeldir. MobileNet ise 65 doğru pozitif ve 28 doğru negatif tahminle daha düşük bir performans sergilemektedir. Yanlış negatif (48) ve yanlış pozitif (11) sınıflandırma oranları, MobileNet'in genelleme başarısının zayıf olduğunu göstermektedir.

ResNet50 modeli, 75 doğru pozitif ve 75 doğru negatif tahminle mükemmel bir performans sunmaktadır. Yanlış pozitif ve yanlış negatif sayılarının 1 olması, modelin hem pozitif hem de negatif sınıfları neredeyse hatasız sınıflandırdığını ortaya koymaktadır. ResNet152 ise 74 doğru pozitif ve 61 doğru negatif tahminle dengeli bir performans sergilemiştir. Yanlış pozitif ve yanlış negatif sayıları sırasıyla 2 ve 15 olup, ResNet50'nin gerisinde bir sonuç göstermektedir.

VGG16 modeli, 74 doğru pozitif ve 61 doğru negatif tahminle ResNet152'ye benzer bir performans sergilemektedir. Yanlış pozitif (2) ve yanlış negatif (15) oranları VGG16'nın dengeli bir sınıflandırma performansı sunduğunu göstermektedir. Xception ise 65 doğru pozitif ve 28 doğru negatif tahminle en düşük performansa sahip modeldir. Yanlış negatif sayısının 48, yanlış pozitif sayısının 11 olması, Xception'ın sınıflandırma görevinde çok fazla hata yaptığını göstermektedir.

EfficientNet ve ResNet50, en düşük hata oranlarıyla maskeli görüntülerde en başarılı sınıflandırma performansını göstermiştir. ResNet152 ve VGG16 modelleri, pozitif ve negatif sınıfları dengeli bir şekilde sınıflandırmış ancak EfficientNet ve ResNet50 kadar yüksek doğruluk oranlarına ulaşamamıştır. MobileNet ve özellikle Xception, yüksek yanlış sınıflandırma oranları ile zayıf bir performans sergilemiştir. EfficientNet ve ResNet50, maskeli görüntüler üzerinde sınıflandırma için en uygun modeller olarak öne çıkmaktadır.



5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Sonuçlar bölümünde segmentasyon ve sınıflandırma modelleri ile elde edilen sonuçlar yazılmış olup, değerlendirmeye tabi tutulmuştur. Bu doktora çalışması, adenoid hipertrofisi ve cilt lezyonlarının derin öğrenme tabanlı yöntemlerle başarılı bir şekilde segmentasyonunu ve adenoid hipertrofisi veri setinin sınıflandırmasını gerçekleştirmeyi hedeflemiş ve elde edilen bulgular ışığında önemli sonuçlar ortaya koymuştur. Çalışmada, adenoid hipertrofisi hastalığının teşhis sürecinde kullanılan ensemble modellerin, klasik yaklaşımlara kıyasla üstün bir başarı sergilediği gözlemlenmiştir. Özellikle, modelleme sürecinde kullanılan adenoid hipertrofisi verilerin maskeli ve maskesiz olarak değerlendirilmesi, derin öğrenme algoritmalarının sınıflandırma performansı üzerinde anlamlı bir etki meydana getirmiştir.

Çalışmada test edilen ResNet50 modeli, diğer derin öğrenme algoritmalarına göre en yüksek doğruluk oranına ulaşmıştır. Bu durum, adenoid hipertrofisinin teşhisinde ResNet50 modelinin sınıflandırma doğruluğunun hastalık teşhisinde güvenilir bir seviyede olduğunu göstermektedir. ResNet50'nin duyarlılık ve özgüllük değerleri sırasıyla %98 ve %97 olarak kaydedilmiştir. Bu oranlar, modelin yanlış negatif ve yanlış pozitif oranlarını en aza indirdiğini ve dolayısıyla doğru teşhis oranını artırarak önemli bir başarı sağladığını ortaya koymaktadır. Aynı zamanda modelin F1 skoru %99-100 aralığında olup, bu sonuçlar ResNet50'nin farklı veri setlerinde yüksek bir denge ve tutarlılık gösterdiğini işaret etmektedir.

Derin öğrenme tabanlı segmentasyon yöntemlerin karşılaştırılması durumunda HDARU-Net modelinin diğer segmentasyon algoritmalarına kıyasla daha yüksek bir doğruluk oranına ulaştığı gözlemlenmiştir. Segmentasyon doğruluğunda en yakın ikinci sırada yer alan U-Net++ modeli %94 doğruluk ve %89 duyarlılık oranları ile başarı sağlarken, HDARU-Net modelinin üstün performansı ile bu alanda öne çıktığı belirlenmiştir. Hastalık teşhisinde yüksek doğruluğa sahip segmentasyonun büyük önem taşıması nedeniyle, HDARU-Net modelinin tercih edilmesi önerilmektedir. Bu analiz, hastalık teşhisinde en uygun modelin seçimi konusunda yol gösterici bir referans oluşturmaktadır.

Bu çalışmada, maskeli ve maskesiz görüntüler arasındaki sınıflandırma performans farkları detaylı olarak incelenmiş ve maskeli görüntülerin derin öğrenme algoritmalarının doğruluğunu artırdığı gözlemlenmiştir. Maskelenmiş adenoid görüntülerde model doğruluğunun %99 gibi yüksek bir orana ulaşması, maskelemenin görüntü analizinde hataları azaltmada önemli bir rol oynadığını göstermektedir. Maskelenmiş veri seti üzerindeki bu başarı, hastalık teşhisinde maskelemenin kullanılmasının, yanlış teşhis oranını düşürmede etkili olabileceğine işaret etmektedir.

Adenoid ve cilt lezyonları veri setlerinin çeşitliliği ve geniş kapsamı, modellerin genellenebilirliği üzerinde olumlu bir etkiye sahip olmuştur. Çalışmada kullanılan Batman Eğitim ve Araştırma Hastanesi adenoid hipertrofisi veri seti ve ISIC 2017 Cilt Lezyonları veri seti, farklı boyut, şekil ve renk varyasyonlarına sahip görüntüleri içermektedir. Bu çeşitlilik, modelin yalnızca belirli veri setlerine değil, farklı tıbbi görüntü türlerine de uygulanabilir olduğunu göstermiştir. ISIC 2017 veri seti ile yapılan testlerde, cilt lezyonlarının teşhisinde de yüksek doğruluk oranlarına ulaşılmıştır ve bu sonuç, modelin geniş bir kullanım alanına sahip olduğunu kanıtlamaktadır.

Tez çalışmasında kullanılan derin öğrenme modelleri, yüksek doğruluk oranları ile dikkat çekerken, model eğitim sürecinde kullanılan çeşitli teknikler de model başarısını artırmada etkili olmuştur. Özellikle maskeleme, görüntü işleme sürecinde hedef nesnelerin daha net tanımlanmasını sağlayarak sınıflandırma ve segmentasyon doğruluğunu artırmıştır. Bu yöntem sayesinde modeller, özellikle düşük kontrastlı veya karmaşık yapıya sahip görüntülerde daha iyi sonuçlar vermiştir. Bu durum, maskeleme ve segmentasyon işlemlerinin hastalık teşhis süreçlerinde daha etkin kullanılabilir olduğunu göstermektedir.

Maskelenmiş veri setleri ile eğitim süreci, derin öğrenme modellerinin performansını artırmada etkili bir faktör olmuştur. Maskelenmiş görüntülerde modelin yanlış pozitif ve yanlış negatif oranlarının düştüğü gözlemlenmiş olup, bu durum modelin teşhis açısından daha güvenilir sonuçlar sunmasını sağlamıştır. Maskelenmiş görüntülerle yapılan analizlerde, tüm modellerin doğruluğunda anlamlı bir artış görülmüş olup, bu

durum maskeleye işlemlerinin hastalık teşhisi doğruluğu artırmada etkili bir yöntem olduğunu ortaya koymuştur.

Hastalık teşhisi uygulamalarında derin öğrenme modellerinin başarıyla kullanımı, tıbbi teşhis süreçlerinde hata oranlarını düşürmekte ve teşhis süresini kısaltmaktadır. ResNet50 ve HDARU-Net gibi yüksek performans gösteren modeller, adenoid hipertrofisi ve cilt lezyonlarının teşhisinde yüksek doğruluk ve duyarlılık oranlarına ulaşarak, teşhis süreçlerinin hızlanmasına ve daha etkin tedavi hizmetlerinin sunulmasına katkı sağlamaktadır. Özellikle segmentasyon sürecinde HDARU-Net'in sağladığı doğruluk, görüntülerin daha doğru analiz edilmesine olanak tanımaktadır.

Sonuç olarak, bu çalışma derin öğrenme tabanlı modelleme yaklaşımlarının hastalık teşhisi süreçlerinde kullanılabilirliğini ortaya koymaktadır. Çalışmada elde edilen bulgular, ResNet50 ve HDARU-Net modellerinin hastalık teşhisi ve görüntü segmentasyonu alanında güvenilir ve etkili bir çözüm sunduğunu göstermiştir. Bu modellerin yüksek doğruluk oranları, özellikle adenoid hipertrofisi ve cilt lezyonları gibi erken teşhis gerektiren durumlarda hızlı ve doğru sonuçlar vermesi açısından önemli bir avantaj sunmaktadır. Derin öğrenme tabanlı sınıflandırma ve segmentasyon modellerinin tıbbi görüntü analizinde kullanımının yaygınlaşmasıyla, sağlık hizmetlerinin kalitesinin artacağı ve yanlış teşhis oranlarının azalacağı düşünülmektedir. Bu bağlamda, tez çalışması literatüre değerli bir katkı sunmakta ve ileri çalışmalar için temel oluşturmaktadır. Çalışmanın bulguları, derin öğrenme tekniklerinin farklı tıbbi görüntülerde uygulanabilirliğini ve maskeli görüntülerin hastalık teşhisi doğruluğu nasıl artırabileceğini gözler önüne sermiştir. Elde edilen bu sonuçlar ışığında, maskelenmiş veri setleriyle eğitilen derin öğrenme modellerinin tedavi uygulamalarında daha etkin sonuçlar sunacağı ve gelecekteki çalışmalar için bir rehber niteliği taşıdığı sonucuna varılmıştır.

5.2 Öneriler

Bu çalışma, derin öğrenme tabanlı modellerin adenoid hipertrofisi ve cilt lezyonları gibi hastalıkların segmentasyonunda ve teşhisinde kullanımı konusunda önemli bulgular sunarak literatüre değerli katkılarda bulunmuş olsa da elde edilen sonuçların daha geniş bir bağlamda değerlendirilmesi ve bu yöntemlerin tanısal doğruluklarını

artıracak gelişim alanlarının belirlenmesi önem arz etmektedir. Model performansının uygulamalarda etkisini tam anlamıyla anlamak ve modellerin genellenebilirliğini artırmak adına bazı eksikliklerin giderilmesi gereklidir. Özellikle, çalışmanın farklı hasta varlıklarının ve veri çeşitliliği ile tekrarlanması, model doğruluğu ve klinik kabul edilebilirliği açısından önemli bir adım olacaktır. Bu tür bir yaklaşım, hem mevcut bulguların sağlamlaştırılmasına katkı sunacak hem de gelecekteki araştırmalara yön vererek, derin öğrenme tabanlı modellerin daha etkin, güvenilir ve yaygın kullanılabilir hale gelmesini sağlayacaktır.

Öncelikle, çalışmada kullanılan veri setlerinin daha fazla çeşitlilik içermesi, modellerin genellenebilirliğini artırmak için önemlidir. Çalışmanın daha geniş ve farklı demografik gruplara ait adenoid ve cilt lezyonları veri setleri ile tekrarlanması, elde edilen bulguların evrenselliğini güçlendirecek ve modellerin farklı hasta gruplarında doğruluğunu sınamaya olanak tanıyacaktır.

İkinci olarak, kullanılan derin öğrenme modellerinin eğitim sürecinde veri artırma yöntemlerinin artırılması ve çeşitlendirilmesi, sınırlı veri setlerinin getirdiği kısıtlamaları aşmada faydalı olacaktır. Veri artırma tekniklerinin özellikle küçük veri setlerinde model başarısını artırma potansiyeli yüksektir. Veri artırımı çeşitliliği, modelin farklı görüntü koşullarında performansını sınamaya ve dolayısıyla algoritmanın çeşitli tıbbi görüntülerdeki hassasiyetini geliştirmeye katkı sağlayacaktır. Bu bağlamda, modelin doğruluğunu artıracak dönüşüm, ölçekleme ve diğer artırma yöntemlerinin gelecekteki çalışmalarda kullanılması önerilmektedir.

Üçüncüsü, bu tezde kullanılan derin öğrenme modellerinin performansı, farklı model türleri veya hibrit modellerin eklenmesi ile karşılaştırılabilir ve daha derinlemesine incelenebilir. Örneğin, transformer tabanlı modellerin son yıllarda görüntü işlemede gösterdiği başarı göz önüne alındığında, bu tür yaklaşımlar cilt lezyonları ve adenoid hipertrofisi gibi tıbbi görüntülerde daha iyi bir teşhis doğruluğu sağlayabilir. Hibrit modellerin de entegre edilmesi, segmentasyon ve sınıflandırma doğruluğunu artırarak tedavi uygulamalarında daha güvenilir sonuçlar elde edilmesine katkı sağlayabilir.

Dördüncü olarak, çalışmanın gerçek zamanlı teşhis süreçlerine uygulanabilirliğinin araştırılması önerilmektedir. Derin öğrenme tabanlı modellerin hızlı ve gerçek zamanlı teşhis desteği sağlayabilmesi, özellikle acil müdahale gerektiren durumlarda avantaj sağlayacaktır. Bu nedenle, model performansının yanı sıra işlem süresi gibi faktörlerin optimize edilmesi ve bu doğrultuda hafifletilmiş modellerin geliştirilmesi, sistemin klinik kullanımını daha pratik ve uygulanabilir kılabilir. Dolayısıyla, gelecekteki çalışmalar bu modellerin hastane ortamlarda kullanımını yaygınlaştırabilir.

Son olarak, derin öğrenme modellerinin tedavi uygulamalardaki başarısının artırılması için kullanıcı dostu ve güvenilir bir ara yüz geliştirilmesi önerilmektedir. Tıbbi personelin bu sistemleri kolaylıkla kullanabilmesi ve sonuçları doğru yorumlayabilmesi için açıklanabilir yapay zeka yöntemlerinin entegre edilmesi, kullanıcı deneyimini iyileştirecektir. Özellikle, model kararlarının görselleştirilmesi ve sonuçların anlaşılabilir hale getirilmesi, yapay zeka sistemlerine duyulan güveni artıracak ve klinik kabul edilebilirliğini sağlayacaktır. Bu bağlamda, gelecekteki çalışmalar, kullanıcı odaklı bir yapay zeka sisteminin geliştirilmesi üzerine odaklanabilir.

KAYNAKLAR

- [1] G. L. Krahn *et al.*, “It’s time to reconsider how we define health: Perspective from disability and chronic condition,” Oct. 01, 2021, *Elsevier Inc.* doi: 10.1016/j.dhjo.2021.101129.
- [2] G. Mahara, C. Tian, X. Xu, and W. Wang, “Revolutionising health care: Exploring the latest advances in medical sciences,” *J Glob Health*, vol. 13, 2023, doi: 10.7189/JOGH.13.03042.
- [3] C. O. Airhihenbuwa, T. S. Tseng, V. D. Sutton, and L. S. Price, “Global Perspectives on Improving Chronic Disease Prevention and Management in Diverse Settings,” *Prev Chronic Dis*, vol. 18, 2021, doi: 10.5888/PCD18.210055.
- [4] S. W. C. Chan, “Chronic Disease Management, Self-Efficacy and Quality of Life,” Feb. 01, 2021, *Taiwan Nurses Association*. doi: 10.1097/JNR.0000000000000422.
- [5] T. A. Benjamin, I. Tobeckukwu, and C. Izu, “Burdens of noncommunicable disease and communicable disease on a typical Nigerian diabetes mellitus patient with multiple comorbidities,” *African Journal of Endocrinology and Metabolism*, vol. 12, no. 2, pp. 88–92, Jul. 2022, doi: 10.4103/ajem.ajem_3_23.
- [6] J. E. Bennett *et al.*, “NCD Countdown 2030: worldwide trends in non-communicable disease mortality and progress towards Sustainable Development Goal target 3.4,” Sep. 22, 2018, *Lancet Publishing Group*. doi: 10.1016/S0140-6736(18)31992-5.
- [7] W. Januszewicz and R. C. Fitzgerald, “Early detection and therapeutics,” Mar. 01, 2019, *John Wiley and Sons Ltd.* doi: 10.1002/1878-0261.12458.
- [8] A. Pulumati, A. Pulumati, B. S. Dwarakanath, A. Verma, and R. V. L. Papineni, “Technological advancements in cancer diagnostics: Improvements and limitations,” Feb. 01, 2023, *John Wiley and Sons Inc.* doi: 10.1002/cnr2.1764.
- [9] H. Lu, Y. Li, M. Chen, H. Kim, and S. Serikawa, “Brain Intelligence: Go beyond Artificial Intelligence,” *Mobile Networks and Applications*, vol. 23, no. 2, pp. 368–375, Apr. 2018, doi: 10.1007/s11036-017-0932-8.
- [10] G. Tecuci, “Artificial intelligence,” *Wiley Interdiscip Rev Comput Stat*, vol. 4, no. 2, pp. 168–180, Mar. 2012, doi: 10.1002/wics.200.

- [11] A. Segato, A. Marzullo, F. Calimeri, and E. De Momi, “Artificial intelligence for brain diseases: A systematic review,” Dec. 01, 2020, *American Institute of Physics Inc.* doi: 10.1063/5.0011697.
- [12] Y. K. Dwivedi *et al.*, “Artificial Intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy,” *Int J Inf Manage*, vol. 57, Apr. 2021, doi: 10.1016/j.ijinfomgt.2019.08.002.
- [13] J. Liu *et al.*, “Artificial intelligence in the 21st century,” *IEEE Access*, vol. 6, pp. 34403–34421, Mar. 2018, doi: 10.1109/ACCESS.2018.2819688.
- [14] S. Badillo *et al.*, “An Introduction to Machine Learning,” *Clin Pharmacol Ther*, vol. 107, no. 4, pp. 871–885, Apr. 2020, doi: 10.1002/cpt.1796.
- [15] N. Sharma, R. Sharma, and N. Jindal, “Machine Learning and Deep Learning Applications-A Vision,” *Global Transitions Proceedings*, vol. 2, no. 1, pp. 24–28, Jun. 2021, doi: 10.1016/j.gltp.2021.01.004.
- [16] L. Zhou, S. Pan, J. Wang, and A. V. Vasilakos, “Machine learning on big data: Opportunities and challenges,” *Neurocomputing*, vol. 237, pp. 350–361, May 2017, doi: 10.1016/j.neucom.2017.01.026.
- [17] D. J. Lary, A. H. Alavi, A. H. Gandomi, and A. L. Walker, “Machine learning in geosciences and remote sensing,” *Geoscience Frontiers*, vol. 7, no. 1, pp. 3–10, Jan. 2016, doi: 10.1016/j.gsf.2015.07.003.
- [18] C. Deng, X. Ji, C. Rainey, J. Zhang, and W. Lu, “iScience Integrating Machine Learning with Human Knowledge”, doi: 10.1016/j.isci.
- [19] Y. Guo, Y. Liu, A. Oerlemans, S. Lao, S. Wu, and M. S. Lew, “Deep learning for visual understanding: A review,” *Neurocomputing*, vol. 187, pp. 27–48, Apr. 2016, doi: 10.1016/j.neucom.2015.09.116.
- [20] A. Voulodimos, N. Doulamis, A. Doulamis, and E. Protopapadakis, “Deep Learning for Computer Vision: A Brief Review,” 2018, *Hindawi Limited*. doi: 10.1155/2018/7068349.
- [21] S. Dong, P. Wang, and K. Abbas, “A survey on deep learning and its applications,” May 01, 2021, *Elsevier Ireland Ltd.* doi: 10.1016/j.cosrev.2021.100379.
- [22] P. Perconti and A. Plebe, “Deep learning and cognitive science,” *Cognition*, vol. 203, Oct. 2020, doi: 10.1016/j.cognition.2020.104365.

- [23] A. Shrestha and A. Mahmood, "Review of deep learning algorithms and architectures," 2019, *Institute of Electrical and Electronics Engineers Inc.* doi: 10.1109/ACCESS.2019.2912200.
- [24] M. R. Rout, D. Mohanty, Y. Vijaylaxmi, K. Bobba, and C. Metta, "Adenoid Hypertrophy in Adults: A case Series," *Indian Journal of Otolaryngology and Head and Neck Surgery*, vol. 65, no. 3, pp. 269–274, Jul. 2013, doi: 10.1007/s12070-012-0549-y.
- [25] Z. He, Y. Xiao, X. Wu, Y. Liang, Y. Zhou, and G. An, "An Automatic Assessment Model of Adenoid Hypertrophy in MRI Images Based on Deep Convolutional Neural Networks," *IEEE Access*, vol. 11, pp. 106516–106527, 2023, doi: 10.1109/ACCESS.2023.3316689.
- [26] M. P. Major, C. Flores-Mir, and P. W. Major, "Assessment of lateral cephalometric diagnosis of adenoid hypertrophy and posterior upper airway obstruction: A systematic review," 2006, *Mosby Inc.* doi: 10.1016/j.ajodo.2005.05.050.
- [27] I. Brambilla *et al.*, "Adenoids in children: Advances in immunology, diagnosis, and surgery," 2014, *Wiley-Liss Inc.* doi: 10.1002/ca.22373.
- [28] L. Pereira *et al.*, "Prevalence of adenoid hypertrophy: A systematic review and meta-analysis," Apr. 01, 2018, *W.B. Saunders Ltd.* doi: 10.1016/j.smr.2017.06.001.
- [29] B. S. Lin, K. Michael, S. Kalra, and H. R. Tizhoosh, "Skin lesion segmentation: U-Nets versus clustering," in *2017 IEEE Symposium Series on Computational Intelligence, SSCI 2017 - Proceedings*, Institute of Electrical and Electronics Engineers Inc., Jul. 2017, pp. 1–7. doi: 10.1109/SSCI.2017.8280804.
- [30] M. K. Hasan, L. Dahal, P. N. Samarakoon, F. I. Tushar, and R. Martí, "DSNet: Automatic dermoscopic skin lesion segmentation," *Comput Biol Med*, vol. 120, May 2020, doi: 10.1016/j.combiomed.2020.103738.
- [31] R. Amelard, "High-Level Intuitive Features (HLIFs) for Melanoma Detection."
- [32] M. Tomas, S. Yildirim-Yayilgan, and J. Yngve Hardeberg, "Combining Deep Learning and Hand-Crafted Features for Skin Lesion Classification," *IEEE*, 2016.
- [33] H. Fan, F. Xie, Y. Li, Z. Jiang, and J. Liu, "Automatic segmentation of dermoscopy images using saliency combined with Otsu threshold," *Comput*

- Biol Med*, vol. 85, pp. 75–85, Jun. 2017, doi: 10.1016/j.compbiomed.2017.03.025.
- [34] M. Goyal, A. Oakley, P. Bansal, D. Dancey, and M. H. Yap, “Skin Lesion Segmentation in Dermoscopic Images with Ensemble Deep Learning Methods,” *IEEE Access*, vol. 8, pp. 4171–4181, 2020, doi: 10.1109/ACCESS.2019.2960504.
- [35] M. Puttagunta and S. Ravi, “Medical image analysis based on deep learning approach,” *Multimed Tools Appl*, vol. 80, no. 16, pp. 24365–24398, Jul. 2021, doi: 10.1007/s11042-021-10707-4.
- [36] R. Azad *et al.*, “Advances in Medical Image Analysis with Vision Transformers: A Comprehensive Review,” Jan. 2023, [Online]. Available: <http://arxiv.org/abs/2301.03505>
- [37] R. C. . Gonzalez and R. E. . Woods, *Digital image processing*. Prentice Hall, 2008.
- [38] Y. Yu *et al.*, “Techniques and Challenges of Image Segmentation: A Review,” *Electronics (Switzerland)*, vol. 12, no. 5, Mar. 2023, doi: 10.3390/electronics12051199.
- [39] Y. Cheng and B. Li, “Image segmentation technology and its application in digital image processing,” in *Proceedings of IEEE Asia-Pacific Conference on Image Processing, Electronics and Computers, IPEC 2021*, Institute of Electrical and Electronics Engineers Inc., Apr. 2021, pp. 1174–1177. doi: 10.1109/IPEC51340.2021.9421206.
- [40] “2018 International Conference on Research in Intelligent and Computing in Engineering (RICE) : 22-24 Aug. 2018,” IEEE, 2018.
- [41] A. Bala and A. Kumar Sharma, “A Review on Various Thresholding Technique for Image Segmentation,” *International Journal of Advances in Engineering and Management (IJAEM)*, vol. 5, p. 380, 2023, doi: 10.35629/5252-0507380390.
- [42] L. Guo and S. Wu, “FPGA Implementation of a Real-Time Edge Detection System Based on an Improved Canny Algorithm,” *Applied Sciences (Switzerland)*, vol. 13, no. 2, Jan. 2023, doi: 10.3390/app13020870.
- [43] K. K. D. Ramesh, G. Kiran Kumar, K. Swapna, D. Datta, and S. Suman Rajest, “A review of medical image segmentation algorithms,” *EAI Endorsed Trans*

- Pervasive Health Technol*, vol. 7, no. 27, 2021, doi: 10.4108/eai.12-4-2021.169184.
- [44] Y. Xu, R. Quan, W. Xu, Y. Huang, X. Chen, and F. Liu, “Advances in Medical Image Segmentation: A Comprehensive Review of Traditional, Deep Learning and Hybrid Approaches,” *Bioengineering*, vol. 11, no. 10, Oct. 2024, doi: 10.3390/bioengineering11101034.
 - [45] J. Suomala and J. Kauttonen, “Human’s Intuitive Mental Models as a Source of Realistic Artificial Intelligence and Engineering,” *Front Psychol*, vol. 13, May 2022, doi: 10.3389/fpsyg.2022.873289.
 - [46] C. Zhang, Z. Yang, X. He, and L. Deng, “Multimodal Intelligence: Representation Learning, Information Fusion, and Applications,” *IEEE Journal on Selected Topics in Signal Processing*, vol. 14, no. 3, pp. 478–493, Mar. 2020, doi: 10.1109/JSTSP.2020.2987728.
 - [47] S. J. Russell and P. Norvig, *Artificial Intelligence A Modern Approach*, Third Edition.
 - [48] Y. Kumar, K. Kaur, and G. Singh, “Machine Learning aspects and its applications towards different research areas,” in *2020 International Conference on Computation, Automation and Knowledge Management (ICCAKM) Amity University*, IEEE, 2020.
 - [49] N. Sharma, R. Sharma, and N. Jindal, “Machine Learning and Deep Learning Applications-A Vision,” *Global Transitions Proceedings*, vol. 2, no. 1, pp. 24–28, Jun. 2021, doi: 10.1016/j.gltp.2021.01.004.
 - [50] Y. Guo, Y. Liu, A. Oerlemans, S. Lao, S. Wu, and M. S. Lew, “Deep learning for visual understanding: A review,” *Neurocomputing*, vol. 187, pp. 27–48, Apr. 2016, doi: 10.1016/j.neucom.2015.09.116.
 - [51] Y. Lecun, Y. Bengio, and G. Hinton, “Deep learning,” Nature Publishing Group, May 2015. doi: 10.1038/nature14539.
 - [52] J. Schmidhuber, “Deep Learning in neural networks: An overview,” Jan. 01, 2015, *Elsevier Ltd*. doi: 10.1016/j.neunet.2014.09.003.
 - [53] S. Gahlot, J. Yin, and M. A. Shankar, “Data optimization for large batch distributed training of deep neural networks,” in *Proceedings - 2020 International Conference on Computational Science and Computational*

- Intelligence, CSCI 2020*, Institute of Electrical and Electronics Engineers Inc., Dec. 2020, pp. 1197–1203. doi: 10.1109/CSCI51800.2020.00225.
- [54] S. ÖRENÇ, E. ACAR, and M. S. ÖZERDEM, “Utilizing the Ensemble of Deep Learning Approaches to Identify Monkeypox Disease,” *DÜMF Mühendislik Dergisi*, Jan. 2023, doi: 10.24012/dumf.1199679.
- [55] S. Örenç, E. Acar, M. S. Özerdem, S. Şahin, and A. Kaya, “Automatic Identification of Adenoid Hypertrophy via Ensemble Deep Learning Models Employing X-ray Adenoid Images,” *Journal of Imaging Informatics in Medicine*, Jan. 2025, doi: 10.1007/s10278-025-01423-8.
- [56] M. R. Rout, D. Mohanty, Y. Vijaylaxmi, K. Bobba, and C. Metta, “Adenoid Hypertrophy in Adults: A case Series,” *Indian Journal of Otolaryngology and Head and Neck Surgery*, vol. 65, no. 3, pp. 269–274, Jul. 2013, doi: 10.1007/s12070-012-0549-y.
- [57] X. Feng, G. Li, Z. Qu, L. Liu, K. Näsström, and X. Q. Shi, “Comparative analysis of upper airway volume with lateral cephalograms and cone-beam computed tomography,” *American Journal of Orthodontics and Dentofacial Orthopedics*, vol. 147, no. 2, pp. 197–204, Feb. 2015, doi: 10.1016/j.ajodo.2014.10.025.
- [58] X. Hu, Zhu, Q. Zhang, J. Yang, Q. Wang, Y. Lei, J. Wu. “Photographic Analysis and Machine Learning for Diagnostic Prediction of Adenoid Hypertrophy,” in *Processdings of the 2019 IEEE 16th International Conference on Network, Sensing and Control*, IEEE, 2019.
- [59] T. Zhao *et al.*, “Automated adenoid hypertrophy assessment with lateral cephalometry in children based on artificial intelligence,” *Diagnostics*, vol. 11, no. 8, Aug. 2021, doi: 10.3390/diagnostics11081386.
- [60] A. A. Alshbishiri, M. A. Marghalani, H. A. Khan, R. G. Ahmad, M. A. Alqarni, and M. M. Khan, “Adenoid segmentation in X-ray images using U-Net,” in *Proceedings - 2021 IEEE 4th National Computing Colleges Conference, NCCC 2021*, Institute of Electrical and Electronics Engineers Inc., Mar. 2021. doi: 10.1109/NCCC49330.2021.9428866.
- [61] S. Zheng *et al.*, “Contrastive learning-based Adenoid Hypertrophy Grading Network Using Nasoendoscopic Image,” in *Proceedings - IEEE Symposium on*

- Computer-Based Medical Systems*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 377–382. doi: 10.1109/CBMS55023.2022.00074.
- [62] Y. Rao *et al.*, “Automated diagnosis of adenoid hypertrophy with lateral cephalogram in children based on multi-scale local attention,” *Sci Rep*, vol. 14, no. 1, Dec. 2024, doi: 10.1038/s41598-024-69827-0.
- [63] M. M. Ali, R. C. Joshi, and M. K. Dutta, “An Automated and Efficient Deep Learning based Classification of Multiple Skin Disorders from Skin Lesion Images,” in *International Conference on Edge Computing and Applications, ICECAA 2022 - Proceedings*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 1156–1161. doi: 10.1109/ICECAA55415.2022.9936097.
- [64] R. Mishra and Ovidiu. Daescu, “Deep Learning for Skin Lesion Segmentation,” in *2017 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, IEEE, 2017.
- [65] A. H. Shain, A. Kamal, and M. A. Elattar, “Deep Ensemble Learning for Skin Lesion Classification from Dermoscopic Images,” IEEE, 2018.
- [66] S. Kaymak, P. Esmaili, and A. Serener, “Deep Learning for Two-Step Classification of Malignant Pigmented Skin Lesions,” in *2018 14th Symposium on Neural Networks and Applications (NEUREL) : November 20-21, 2018*, IEEE, 2018.
- [67] M. A. Al-masni, M. A. Al-antari, H. M. Parka, N. H. Parka, and T.-S. Kima, “A Deep Learning Model Integrating FrCN and Residual Convolutional Networks for Skin Lesion Segmentation and Classification,” in *2019 IEEE Eurasia Conference on Biomedical Engineering, Healthcare and Sustainability (ECBIOS)*, IEEE, 2019.
- [68] S. Bassi and A. Gomekar, “DEEP LEARNING DIAGNOSIS OF PIGMENTED SKIN LESIONS,” in *IEEE*,
- [69] T. Guergueb and M. A. Akhloufi, “Melanoma Skin Cancer Detection Using Recent Deep Learning Models,” in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, Institute of Electrical and Electronics Engineers Inc., 2021, pp. 3074–3077. doi: 10.1109/EMBC46164.2021.9631047.
- [70] A. Das, S. K. Mohapatra, and M. N. Mohanty, “A Concatenated Model with Deep Learning Technique for Skin Lesion Detection,” in *2021 5th International*

- Conference on Information Systems and Computer Networks, ISCON 2021*, Institute of Electrical and Electronics Engineers Inc., 2021. doi: 10.1109/ISCON52037.2021.9702339.
- [71] Y. Wu, A. C. Lariba, H. Chen, and H. Zhao, “Skin Lesion Classification based on Deep Convolutional Neural Network,” in *2022 IEEE 4th International Conference on Power, Intelligent Computing and Systems, ICPICS 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 376–380. doi: 10.1109/ICPICS55264.2022.9873756.
- [72] A. Neeshma and C. S. Nair, “Multiclass Skin Lesion Classification Using Densenet,” in *Proceedings of the 2022 3rd International Conference on Intelligent Computing, Instrumentation and Control Technologies: Computational Intelligence for Smart Systems, ICICICT 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 506–510. doi: 10.1109/ICICICT54557.2022.9917913.
- [73] M. M. Ali, R. C. Joshi, and M. K. Dutta, “An Automated and Efficient Deep Learning based Classification of Multiple Skin Disorders from Skin Lesion Images,” in *International Conference on Edge Computing and Applications, ICECAA 2022 - Proceedings*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 1156–1161. doi: 10.1109/ICECAA55415.2022.9936097.
- [74] S. Dhir, A. Sinha, C. Bansal, R. Rani, N. Goel, and P. Bhutani, “A Robust CNN-based Approach for Skin Lesion Detection and Classification,” in *2023 3rd International Conference on Intelligent Technologies, CONIT 2023*, Institute of Electrical and Electronics Engineers Inc., 2023. doi: 10.1109/CONIT59222.2023.10205907.
- [75] M. Monajemi, S. O. Shahdi, S. S. Haji Nasiri, and S. V. Shojaedini, “Efficiency Analysis of Convolutional Neural Networks in Multiclass Recognition of Skin Lesions via Dermoscopy Images,” in *2024 10th International Conference on Artificial Intelligence and Robotics, QICAR 2024*, Institute of Electrical and Electronics Engineers Inc., 2024, pp. 119–124. doi: 10.1109/QICAR61538.2024.10496625.
- [76] S. Gothivrekhar, A. Khanvilkar, U. Nandi, K. Singh, and T. Maktum, “Skin Lesion Classification using Deep Learning Architectures,” in *2024 Second International Conference on Networks, Multimedia and Information*

- Technology (NMITCON)*, IEEE, Aug. 2024, pp. 1–5. doi: 10.1109/NMITCON62075.2024.10698794.
- [77] H. Patel, D. Thakore, and N. Patel, “Skin Lesion Classification Using Deep Learning Techniques,” in *2024 Parul International Conference on Engineering and Technology (PICET)*, IEEE, May 2024, pp. 1–6. doi: 10.1109/PICET60765.2024.10716067.
- [78] N. Anbuselvan and P. Anandan, “Deep Learning-Based Optimization of Dolphin Echolocation for Skin Lesion Image Classification,” in *2nd International Conference on Integrated Circuits and Communication Systems, ICICACS 2024*, Institute of Electrical and Electronics Engineers Inc., 2024. doi: 10.1109/ICICACS60521.2024.10498765.
- [79] A. Kebaili, J. Lapuyade-Lahorgue, and S. Ruan, “Deep Learning Approaches for Data Augmentation in Medical Imaging: A Review,” *J Imaging*, vol. 9, no. 4, Apr. 2023, doi: 10.3390/jimaging9040081.
- [80] P. Chlap, H. Min, N. Vandenberg, J. Dowling, L. Holloway, and A. Haworth, “A review of medical image data augmentation techniques for deep learning applications,” *J Med Imaging Radiat Oncol*, vol. 65, no. 5, pp. 545–563, Aug. 2021, doi: 10.1111/1754-9485.13261.
- [81] G. Litjens *et al.*, “A survey on deep learning in medical image analysis,” Dec. 01, 2017, *Elsevier B.V.* doi: 10.1016/j.media.2017.07.005.
- [82] S. Yang, W. Xiao, M. Zhang, S. Guo, J. Zhao, and F. Shen, “Image Data Augmentation for Deep Learning: A Survey,” Apr. 2022, [Online]. Available: <http://arxiv.org/abs/2204.08610>
- [83] T. Shen and H. Xu, “Medical Image Segmentation Based on Transformer and HarDNet Structures,” *IEEE Access*, vol. 11, pp. 16621–16630, 2023, doi: 10.1109/ACCESS.2023.3244197.
- [84] L. Lenchik *et al.*, “Automated Segmentation of Tissues Using CT and MRI: A Systematic Review,” *Acad Radiol*, vol. 26, no. 12, pp. 1695–1706, Dec. 2019, doi: 10.1016/j.acra.2019.07.006.
- [85] H. Zaidi and I. El Naqa, “PET-guided delineation of radiation therapy treatment volumes: A survey of image segmentation techniques,” Nov. 2010. doi: 10.1007/s00259-010-1423-3.

- [86] I. Rizwan I Haque and J. Neubert, “Deep learning approaches to biomedical image segmentation,” *Inform Med Unlocked*, vol. 18, Jan. 2020, doi: 10.1016/j.imu.2020.100297.
- [87] O. Ronneberger, P. Fischer, and T. Brox, “U-Net: Convolutional Networks for Biomedical Image Segmentation,” May 2015, [Online]. Available: <http://arxiv.org/abs/1505.04597>
- [88] O. Ronneberger, P. Fischer, and T. Brox, “U-Net: Convolutional Networks for Biomedical Image Segmentation,” May 2015, [Online]. Available: <http://arxiv.org/abs/1505.04597>
- [89] Z. Zhou, M. M. R. Siddiquee, N. Tajbakhsh, and J. Liang, “UNet++: A Nested U-Net Architecture for Medical Image Segmentation,” Jul. 2018, [Online]. Available: <http://arxiv.org/abs/1807.10165>
- [90] V. Badrinarayanan, A. Kendall, and R. Cipolla, “SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation,” Nov. 2015, [Online]. Available: <http://arxiv.org/abs/1511.00561>
- [91] G. Huang, Z. Liu, L. van der Maaten, and K. Q. Weinberger, “Densely Connected Convolutional Networks,” Aug. 2016, [Online]. Available: <http://arxiv.org/abs/1608.06993>
- [92] G. Huang *et al.*, “Channel-Attention U-Net: Channel Attention Mechanism for Semantic Segmentation of Esophagus and Esophageal Cancer,” *IEEE Access*, vol. 8, pp. 122798–122810, 2020, doi: 10.1109/ACCESS.2020.3007719.
- [93] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” Dec. 2015, [Online]. Available: <http://arxiv.org/abs/1512.03385>
- [94] M. Coşkun, Ö. Yildirim, A. Uçar, and Y. Demir, “AN OVERVIEW OF POPULAR DEEP LEARNING METHODS,” 2017.
- [95] L. Alzubaidi *et al.*, “Review of deep learning: concepts, CNN architectures, challenges, applications, future directions,” *J Big Data*, vol. 8, no. 1, Dec. 2021, doi: 10.1186/s40537-021-00444-8.
- [96] V. T. Hoang and K. H. Jo, “Practical Analysis on Architecture of EfficientNet,” in *International Conference on Human System Interaction, HSI*, IEEE Computer Society, Jul. 2021. doi: 10.1109/HSI52170.2021.9538782.

- [97] E. Elfatimi, R. Eryigit, and L. Elfatimi, "Beans Leaf Diseases Classification Using MobileNet Models," *IEEE Access*, vol. 10, pp. 9471–9482, 2022, doi: 10.1109/ACCESS.2022.3142817.
- [98] D. Anggriandi and A. Sunyoto, "Multi-Class Classification of Skin Diseases Using ResNet50," in *2023 6th International Conference on Information and Communications Technology, ICOIACT 2023*, Institute of Electrical and Electronics Engineers Inc., 2023, pp. 349–354. doi: 10.1109/ICOIACT59844.2023.10455953.
- [99] D. Deepika and A. V. Lakshmi, "Identification of Breast Cancer Using RESNET152," in *2022 4th International Conference on Cognitive Computing and Information Processing, CCIP 2022*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/CCIP57447.2022.10058689.
- [100] S. Ghosh, A. Chaki, and K. Santosh, "Improved U-Net architecture with VGG-16 for brain tumor segmentation," *Phys Eng Sci Med*, vol. 44, no. 3, pp. 703–712, Sep. 2021, doi: 10.1007/s13246-021-01019-w.
- [101] F. Chollet, "Xception: Deep learning with depthwise separable convolutions," in *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, Institute of Electrical and Electronics Engineers Inc., Nov. 2017, pp. 1800–1807. doi: 10.1109/CVPR.2017.195.
- [102] Rismiyati, S. Nur Endah, Khadijah, and I. Nabil Shiddiq, "Xception Architecture Transfer Learning for Garbage Classification," in *2020 4th International Conference on Informatics and Computational Sciences (ICICoS)*, IEEE, 2020.
- [103] M. Kaya and H. Ş. Bilge, "Deep metric learning: A survey," 2019, *MDPI AG*. doi: 10.3390/sym11091066.
- [104] W. Dong, Y. Chen, A. Li, X. Mei, and Y. Yang, "Automatic detection of adenoid hypertrophy on cone-beam computed tomography based on deep learning," *American Journal of Orthodontics and Dentofacial Orthopedics*, vol. 163, no. 4, pp. 553-560.e3, Apr. 2023, doi: 10.1016/j.ajodo.2022.11.011.
- [105] T. Zhao *et al.*, "Automated adenoid hypertrophy assessment with lateral cephalometry in children based on artificial intelligence," *Diagnostics*, vol. 11, no. 8, Aug. 2021, doi: 10.3390/diagnostics11081386.

- [106] O. Oktay *et al.*, “Attention U-Net: Learning Where to Look for the Pancreas,” Apr. 2018, [Online]. Available: <http://arxiv.org/abs/1804.03999>



ÖZGEÇMİŞ

Kişisel Bilgiler

Soyad, Ad

ÖRENÇ, Sedat

Web sayfası

(Research Gate, Academia, vs.)

Eğitim Bilgileri

Derece	Kurum	Mezuniyet Yılı
Yüksek Lisans	Sakarya Üniversitesi	2019
Lisans	Dicle Üniversitesi	2015
Lise	Siirt Atatürk Anadolu Lisesi	2009

İş Deneyimi

Dönem (Yıl)	Şirket, Kurum	Görev
2018 - Devam ediyor	Batman Üniversitesi	Araştırma Görevlisi

Yabancı Dil

İngilizce

Yayınlar

1.S. Örenç, E. Acar, and M. S. Özerdem, “Utilizing the Ensemble of Deep Learning Approaches to Identify Monkeypox Disease”, DUJE, vol. 13, no. 4, pp. 685–691, 2023, doi: 10.24012/dumf.1199679.

2. Örenç, S., Acar, E., Özerdem, M.S. *et al.* Automatic Identification of Adenoid Hypertrophy via Ensemble Deep Learning Models Employing X-ray Adenoid Images. *J Digit Imaging. Inform. med.* (2025).

3.

4.

Özel İlgiler

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
TEZ BENZERLİK BİLDİRİMİ FORMU

Öğrencinin Adı, Soyadı	Sedat ÖRENÇ		
Öğrenci No	19805503		
Ana Bilim Dalı	Elektrik-Elektronik Mühendisliği		
Program Türü	Proje ☐	Yüksek Lisans ☐	Doktora ☒
Tez Danışmanı (Ünvanı, Adı, Soyadı)	Prof. Dr. Mehmet Sıraç ÖZERDEM		
(Varsa) II. Tez Danışmanı (Ünvanı, Adı, Soyadı)	Doç. Dr. Emrullah ACAR		
Tez Başlığı	HDARU-Net Tabanlı Derin Öğrenme Yaklaşımının Tıbbi Görüntülerdeki Performansı: Adenoid Hipertrofisi ve Cilt Lezyonları Üzerine Bir İnceleme		
RAPOR BİLGİLERİ			
Raporlama Aşaması	Tez Savunma Sınavı Sonrası		
Sayfa Sayısı	125		
Raporlama Tarihi	21.04.2025		
Benzerlik Oranı (%)	4		

Yukarıda bilgileri verilen tez çalışmamın toplam 125 sayfalık kısmına ilişkin, 21/04/2025 tarihinde şahsım/tez danışmanım tarafından Turnitin isimli intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan intihal raporuna göre, tezimin benzerlik oranı %4 olarak tespit edilmiştir.

Uygulanan filtrelemeler:

- ☐Başlangıç Bölümleri (Kabul ve Onay sayfası, Teşekkür sayfası, Özet/Abstract) hariç
☒Kaynaklar hariç
☐Alıntılar hariç/dâhil
☐Diğer (Açıklayınız)

Tezimin benzerlik oranı, Dicle Üniversitesi Fen Bilimleri Enstitüsü İntihal Raporu Uygulama Esaslarında belirtilen üst sınır benzerlik oranını aşmamaktadır. Tez benzerlik oranı üst sınır benzerlik oranının altında olsa dahi aksinin tespit edilmesi durumunda her türlü yasal sorumluluğu kabul ettiğimi ve hukuki sonuçlarına razı olduğumu bildirir, gereğini arz ederim.

Öğrencinin Adı, Soyadı: Sedat ÖRENÇ

Tarih: 21.04.2025

İmza:

Danışman Adı, Soyadı: Prof. Dr. Mehmet Sıraç ÖZERDEM

İmza:

Tarih: 21.04.2025

Ana Bilim Dalı Başkanı Adı, Soyadı: Prof. Dr. Muhammed Bahaddin KURT

İmza:

Tarih: 21.04.2025