

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**AĞIZ BÖLGESİ İLE İLGİLİ HASTALIK VE ANATOMİK
YAPILARIN YAPAY ZEKÂ TABANLI TESPİT EDİLMESİ**

Meryem DURMUŞ

Doktora Tezi

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

OCAK 2025

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Doktora Tezi

AĞIZ BÖLGESİ İLE İLGİLİ HASTALIK VE ANATOMİK YAPILARIN
YAPAY ZEKÂ TABANLI TESPİT EDİLMESİ

Tez Yazarı
Meryem DURMUŞ

Danışman
Prof. Dr. Burhan ERGEN

OCAK 2025
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Doktora Tezi

Başlığı:	Ağız Bölgesi ile İlgili Hastalık ve Anatomi Yapıların Yapay Zekâ Tabanlı Tespit Edilmesi
Yazarı:	Meryem DURMUŞ
İlk Teslim Tarihi:	09.01.2025
Savunma Tarihi:	29.01.2025

TEZ ONAYI

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

Danışman:	Prof. Dr. Burhan ERGEN Fırat Üniversitesi, Mühendislik Fakültesi	İmza Onayladım
Başkan:	Prof. Dr. İbrahim TÜRKOĞLU Fırat Üniversitesi, Teknoloji Fakültesi	Onayladım
Üye:	Prof. Dr. Ahmet Bedri ÖZER Fırat Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Doç. Dr. Abidin ÇALIŞKAN Batman Üniversitesi, Mühendislik Mimarlık Fakültesi	Onayladım
Üye:	Doç. Dr. Harun BİNGÖL Malatya Turgut Özal Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi	Onayladım

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

İmza

Prof. Dr. Burhan ERGEN
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Ağız Bölgesi ile İlgili Hastalık ve Anatomik Yapıların Yapay Zekâ Tabanlı Tespit Edilmesi” Başlıklı Doktora Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

29.01.2025

Meryem DURMUŞ



ÖNSÖZ

Bu tez çalışması, ağız bölgesi ile ilgili hastalıkların ve anatomik yapıların yapay zekâ tabanlı tespiti üzerine odaklanmaktadır. Diş hekimliği alanında dijital görüntüleme teknolojileri, hastalıkların erken teşhisi ve tedavi planlamasında giderek daha kritik bir rol üstlenmektedir. Yapay zekâ tabanlı analiz yöntemleri, bu süreçlerde daha hızlı ve hassas kararlar alınmasını sağlayarak tanı ve teşhis süreçlerini yüksek bir seviyeye taşımaktadır. Çalışma kapsamında, gömülü dişlerin, çürük dişlerin ve diş enfeksiyonlarının yapay zekâ ile tespitine yönelik farklı derin öğrenme tabanlı yöntemler uygulanmıştır. Her bir yöntem, alanında özgün veri kümeleri kullanılarak geliştirilmiş ve kapsamlı bir biçimde değerlendirilmiştir.

Tezimin her aşamasında bilgi ve tecrübeleriyle beni yönlendiren, rehberliği ve desteğiyle bu süreci daha verimli geçirmemi sağlayan değerli danışman hocam Prof. Dr. Burhan ERGEN'e en derin saygı ve teşekkürlerimi sunarım.

Doktora eğitim sürecim boyunca beni her zaman destekleyen, sabır ve anlayışıyla yanımda olan eşim Arş. Gör. Ömer DURMUŞ'a ve her adımda desteğini hissettiğim kıymetli aileme minnettarım.

Bu çalışma, Mersin Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu'nun 06/03/2024 tarihli ve 2024/247 sayılı kurul kararı izni ile gerçekleştirilmiş olup, özgün veri kümesi oluşturularak yapılmıştır. Bu tez sürecinde emeği geçen herkese sonsuz teşekkürlerimi sunarım.

Meryem DURMUŞ

ELAZIĞ, 2025

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vii
ABSTRACT	viii
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	xi
EKLER LİSTESİ	xii
SİMGELER VE KISALTMALAR	xiii
1. GİRİŞ	1
1.1. Literatür İncelemesi	3
1.1.1. Sağlık Alanında Yapay Zekâ Çalışmaları	3
1.1.2. Diş Hekimliği Alanında Yapay Zekâ Çalışmaları	5
1.1.3. Derin Öğrenme Yöntemlerinin Tıbbi Görüntüleme Alanındaki Kullanımı	7
1.1.4. Diş Hastalıklarının Yapay Zekâ Tabanlı Tespiti Çalışmaları	9
1.1.5. Gömülü Diş Tespiti Üzerine Yapılan Çalışmalar	11
1.1.6. Enfeksiyon Tespiti Üzerine Yapılan Çalışmalar	12
1.1.7. Çürük Tespiti Üzerine Yapılan Çalışmalar	13
1.2. Önerilen Sistemin Genel Çerçevesi	14
1.2.1. Tezin Amacı	15
1.2.2. Tezin Çıktıları ve Yenilikçi Yönleri	15
1.2.3. Tezin Organizasyonu	15
2. MATERYAL VE METOT	17
2.1. Diş Görüntüleme Teknikleri	17
2.1.1. Bitewing Radyografi	17
2.1.2. Periapikal Radyografi	18
2.1.3. Konik Işınlı Bilgisayarlı Tomografi (KIBT)	19
2.1.4. Panoramik Radyografi	20
2.2. Diş Anatomisi	21
2.2.1. Diş Çürükleri	21
2.2.2. Diş Enfeksiyonları	22
2.2.3. Gömülü Dişler	23
2.3. Görüntü Segmentasyon Teknikleri	23
2.3.1. Bölge Tabanlı Segmentasyon Yöntemleri	24
2.3.2. Piksel Tabanlı Segmentasyon Yöntemleri	26
2.3.3. Omurga Modelleri	34
2.4. Performans Metrikleri	37
3. DIŞ HASTALIKLARI VERİ KÜMESİNİN HAZIRLANMASI	40
3.1. Literatürde Yer Alan Veri Kümeleri	40
3.1.1. Gömülü Diş Veri Kümesi	40
3.2. Toplanan Veri Kümelerinin Diş Hastalıklarına Göre Listelenmesi	41
3.2.1. Enfeksiyon Veri Kümesi	42
3.2.2. Çürük Diş Veri Kümesi	43

4. PANORAMİK DİŞ RÖNTGENLERİNDE GÖMÜLÜ DİŞ TESPİTİ	45
4.1. Veri Kümesi.....	45
4.2. Önerilen Yöntem	45
4.3. Deneysel Çalışmalar ve Sonuçları	47
5. PANORAMİK DİŞ RÖNTGENLERİNDE ENFEKSİYON TESPİTİ.....	59
5.1. Veri Kümesi.....	59
5.2. Önerilen Yöntem	60
5.3. Deneysel Çalışmalar ve Sonuçları	62
6. PANORAMİK DİŞ RÖNTGENLERİNDE ÇÜRÜK TESPİTİ	67
6.1. Veri Kümesi.....	67
6.2. Önerilen Yöntem	68
6.3. Deneysel Çalışmalar ve Sonuçları	71
7. SONUÇLAR.....	76
KAYNAKLAR.....	77
EKLER	84
ÖZGEÇMİŞ	

ÖZET

Ağız Bölgesi ile İlgili Hastalık ve Anatomik Yapıların Yapay Zekâ Tabanlı Tespit Edilmesi

Meryem DURMUŞ

Doktora Tezi

FIRAT ÜNİVERSİTESİ

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Ocak 2025, Sayfa: xiv + 83

Son zamanlarda bilgisayar yazılım ve donanım teknolojisindeki hızlı gelişmeler, yapay zekâ ve derin öğrenme yöntemlerinin farklı alanlarda yaygın şekilde uygulanmasına olanak tanımıştır. Bu gelişmeler, özellikle görüntü işleme, nesne tespiti ve segmentasyon gibi alanlarda dikkat çekici ilerlemelere yol açmıştır. Bu tez çalışması, ağız bölgesi ile ilgili hastalıkların ve anatomik yapıların yapay zekâ destekli piksel tabanlı segmentasyonu üzerine odaklanmaktadır. Günümüzde diş sağlığı, insan sağlığının önemli bir bileşeni olarak kabul edilmekte ve panoramik radyografi görüntüleri, diş hekimliği pratiğinde yaygın bir şekilde kullanılmaktadır.

Literatürdeki çalışmalar genellikle diş hastalıklarını ve yapılarını tespit etmek için görüntüleri kırma yöntemi ile analiz ederken, bu çalışmada panoramik röntgen görüntüleri üzerinde herhangi bir ön işleme yapılmadan tüm ağız bölgesi üzerinde segmentasyon işlemleri gerçekleştirilmiştir. Çalışma kapsamında, gömülü dişlerin, çürük dişlerin ve diş enfeksiyonlarının tespitine yönelik yapay zekâ tabanlı farklı yöntemler uygulanmıştır. Ayrıca Literatürde panoramik radyografi ile segmentasyon uygulamak için veri kümesi ihtiyacı olduğu görüldüğünden uzman diş hekimleri ile birlikte yeni bir veri kümesi oluşturulmuş ve etiketlenmiştir.

Bu tez çalışması, literatürdeki eksiklikleri gidermeyi amaçlamakta ve panoramik radyografi görüntülerinde yapay zekâ tabanlı segmentasyonu için yeni bir veri kümesi ve en ideal segmentasyon yöntemlerini sunmaktadır. Uygulanan yöntemlerin doğruluğu ve etkinliği, diğer güncel modeller ile karşılaştırılarak analiz edilmiştir. Elde edilen sonuçlar, uygulanan yöntemlerin başarılı olduğunu göstermiştir ve diş hekimliği alanında tanı ve tedavi süreçlerine katkı sağlayacak potansiyele sahip olduğunu ortaya koymuştur.

Anahtar Kelimeler: Derin öğrenme, Panoramik diş radyografileri, Yapay zekâ, Anatomik yapı ve hastalık tespiti

ABSTRACT

Artificial Intelligence Based Detection of Diseases and Anatomical Structures Related to The Oral Region

Meryem DURMUŞ

Ph.D. Thesis

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

January 2025, Pages: xiv + 83

Recent advancements in the fields of computer software and hardware technology have paved the way for the widespread integration of artificial intelligence and deep learning methodologies across diverse disciplines. These developments have resulted in significant advancements, particularly in domains such as image processing, object detection and segmentation. The present thesis focuses on the utilization of artificial intelligence to facilitate the segmentation of diseases and anatomical structures related to the oral region. In the contemporary context, dental health is acknowledged as a pivotal component of human health, with panoramic radiography images being extensively utilized within the domain of dental practice.

However the majority of studies in the literature analyze images by cropping method to detect dental diseases and structures, in this study, segmentation operations were performed on the whole mouth region without any preprocessing on panoramic X-ray images. In the course of the study, ranges of artificial intelligence-based methodologies were employed for the identification of impacted teeth, decayed teeth and dental infections. In addition, as there is a need for a dataset to apply segmentation using panoramic radiography in the literature, a new dataset was created and annotated with expert dentists.

This thesis aims to fill the gaps in the literature and presents a new dataset and optimal segmentation methods for artificial intelligence-based segmentation of panoramic radiography images. The accuracy and efficiency of the applied methods were analyzed in comparison with other current models. The results obtained have shown that the applied methods are successful and have the potential to contribute to diagnostic and treatment processes in the field of dentistry.

Keywords: Deep learning, Panoramic dental radiographs, Artificial intelligence, Anatomical structure and disease detection

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1. Bitewing röntgen görüntüsü [59].....	17
Şekil 2.2. Periapikal röntgen görüntüsü [63]	18
Şekil 2.3. Konik Işınlı Bilgisayarlı Tomografi röntgen görüntüleri. (A) aksiyal (B) koronal (C) sagittal (D) ortogonal görünüm [66]	19
Şekil 2.4. Panoramik röntgen görüntüsü	21
Şekil 2.5. UNet ağ mimarisi [90].....	27
Şekil 2.6. Attention Unet model mimarisi [93]	27
Şekil 2.7. R2U-Net model mimarisi [94]	28
Şekil 2.8. U2-Net model mimarisi [95]	29
Şekil 2.9. Unet 3+ model mimarisi [96]	30
Şekil 2.10. PSPNet model mimarisi [98].....	31
Şekil 2.11. FPN model mimarisi [100].....	32
Şekil 2.12. LinkNet model mimarisi [104].....	33
Şekil 2.13. Swin Transformer mimarisi [116]	37
Şekil 3.1. Birleştirilmiş veri kümesinden örnek görüntüler (gömülü dış)	41
Şekil 3.2. Özgün veri kümesinden örnek görüntüler (enfeksiyon)	42
Şekil 3.3. Özgün veri kümesinden örnek görüntüler (çürük dış)	43
Şekil 4.1. Veri kümesine ait örnek görüntüler	45
Şekil 4.2. Mevcut çalışmaya genel bakış.....	46
Şekil 4.3. Uygulanan Segmentasyon modelleri (a) UNet, (b) LinkNet, (c) PSPNet, (d) FPN	46
Şekil 4.4. UNet tabanlı görsel sonuçlar	49
Şekil 4.5. PSPNet tabanlı görsel sonuçlar	51
Şekil 4.6. FPN tabanlı görsel sonuçlar	52
Şekil 4.7. LinkNet tabanlı görsel sonuçlar	54
Şekil 4.8. UNet+EfficientNetB7 tabanlı segmentasyon modelinin eğitim/doğrulama grafikleri	56
Şekil 4.9. Segmentasyon modellerinin başarısız tespitine örnekler.....	57
Şekil 5.1. Veri kümesinden örnek panoramik dış görüntüleri ve maskeleri	60
Şekil 5.2. EfficientNetB4 tabanlı Swin UNet mimarisi.....	61
Şekil 5.3. EfficientNetB4 tabanlı Swin Transformer UNet için performans parametrelerine ait görsel grafik	64
Şekil 5.4. Önerilen mimarinin görsel sonuçları	65
Şekil 6.1. Veri kümesine ait örnek görüntüler	68

Şekil 6.2. Eff-UNet 3+ mimarisinin yapısı	69
Şekil 6.3. Segmentasyon modellerine ait görsel sonuçlar	73
Şekil 6.4. UNet3+ için performans parametrelerine ait görsel grafik	74
Şekil 6.5. UNet3+ modeline ait doğruluk grafiği	75



TABLÖLAR LİSTESİ

	Sayfa
Tablo 2.1. Karmaşıklık Matrisi	38
Tablo 3.1. Literatürde yer alan veri kümelerinden oluşturulan yeni veri kümesi detayları.....	40
Tablo 3.2. Toplanan özgün veri kümeleri detayları	42
Tablo 4.1. Omurga ağı mimarilerinin özellikleri	47
Tablo 4.2. Deneysel çalışmalarda kullanılan görüntü segmentasyon model hiper parametreleri	48
Tablo 4.3. UNet tabanlı performans sonuçları (%)	49
Tablo 4.4. PSPNet tabanlı performans sonuçları (%)	50
Tablo 4.5. FPN tabanlı performans sonuçları (%)	52
Tablo 4.6. LinkNet tabanlı performans sonuçları (%).....	53
Tablo 4.7. Tüm modellerin performans karşılaştırması (%)	55
Tablo 4.8. Segmentasyon modellerinin performans karşılaştırması (%).....	56
Tablo 5.1. Önerilen model mimarisine ait hiper parametreler	62
Tablo 5.2. Segmentasyon modellerinin performans karşılaştırması	63
Tablo 6.1. Deneysel çalışmalarda kullanılan görüntü segmentasyon model hiper parametreleri	70
Tablo 6.2. Segmentasyon modellerinin performans karşılaştırması	72

EKLER LİSTESİ

Sayfa

Ek- 1:	Etik Kurul Raporu.....	84
--------	------------------------	----



SİMGELER VE KISALTMALAR

Simgeler

$(/2)$	: Alt örnekleme
$(*2)$	: Üst örnekleme
C	: Toplam sınıf sayısı
C_i	: Girdi görüntü derinliği
C_s	: Evrişim işleminde kullanılan filtre sayısı
d_k	: Dikkat vektör boyutu
F_{in}	: Girişten gelen özellik haritası
F_{out}	: İşlem sonrası üretilen yeni özellik haritası
H_i	: Özellik çıkarım sürecinde girdi görüntü yüksekliği
$H(x)$	: Artık blok çıktısı
K	: Anahtar
K_i	: Öğrenilmiş matrisler
M_i	: Önceden eğitilmiş özellik haritaları
N_i	: Normalleştirme haritaları
Q	: Sorgu
V	: Değer
W_i	: Özellik çıkarım sürecinde girdi görüntü genişliği

Kısaltmalar

2B	: 2 boyutlu
3B	: 3 boyutlu
ADNN	: Adaptif sinir ağı
AG	: Dikkat geçidi
AP	: Ortalama hassasiyet
AUC	: ROC eğrisi altındaki alan
BDT	: Bilgisayar destekli tasarım
B-ESA	: Bölge tabanlı evrişimsel sinir ağları
BORNN	: Bakteriyel optimizasyon tekrarlayan sinir ağı
BP	: Geri yayılım algoritması
BT	: Bilgisayarlı tomografi
CGM	: Sınıflandırma tabanlı modül
CORS	: Kronik dış kaynaklı burun ve sinüs iltihabı"
CPS	: Siber fiziksel sistem
DANN	: Derin öğrenme sinir ağı
DESA	: Derin evrişimsel sinir ağı

DHB-ESA	: Daha hızlı bölgesel evrişimsel sinir ağıları
DN	: Doğru negatif
DP	: Doğru pozitif
DVM	: Destek vektör makineleri
ESA	: Evrişimsel sinir ağı
FCN	: Tam evrişimli ağ
FPN	: Özellik piramidi ağı
GONN	: Genetik optimizasyon sinir ağı
GPU	: Grafik işlemci birimi
HB-ESA	: Hızlı bölgesel evrişimsel sinir ağıları
IoT	: Nesnelerin interneti
IoU	: Birleşim üzerindeki kesişme oranı
KIBT	: Koni ışınli bilgisayarlı tomografi
mAP	: Genel ortalama kesinlik
Maskeli B-ESA	: Maskeli bölgesel evrişimsel sinir ağıları
MRG	: Manyetik rezonans görüntüleme
MRI	: Manyetik rezonans görüntüleme
MSR	: Çok ölçekli bölütlenmiş bölge
ODSI-DB	: Ağız ve diş spektral görüntü veritabanı
PSPNet	: Piramit sahne ayrıştırma ağı
RAM	: Rastgele erişimli bellek
ReLU	: Doğrultulmuş lineer birim
ROC	: Alıcı işletim karakteristiği
RoI	: İlgi bölgesi
RPN	: Bölge öneri ağı
RSU	: Artık u- blokları
SE	: Squeeze-and-excitation
TME	: Temporomandibular eklem
VGG	: Görsel geometri grubu
VRF	: Dikey kök kırıkları
YN	: Yanlış negatif
YOLO	: You only look once
YP	: Yanlış pozitif

1. GİRİŞ

Ağız hastalıkları ve anatomik yapılar yalnızca fiziksel sağlığı değil, aynı zamanda yaşamın psikolojik ve sosyal yönlerini de etkilemektedir. Bireylerin yaşam kalitesini önemli ölçüde etkilemekte ve etkili tedavi için doğru ve zamanında teşhis gerektirmektedir. Diş çürükleri, diş eti hastalıkları ve anatomik yapılar gibi ağız boşluğunu etkileyen hastalıklar önemli rahatsızlıklara, fonksiyonel bozukluklara ve yaşam kalitesinin düşmesine neden olabilmektedir. Bu durumların erken tespiti ve doğru teşhisi, etkili tedavi stratejilerinin uygulanması ve daha ileri komplikasyonların önlenmesi için önem arz etmektedir. Geleneksel teşhis yöntemleri genellikle tıbbi görüntülerin manuel olarak yorumlanmasına dayanmaktadır. Bu durum zaman alıcı olabilmekte ve farklı hekimler arasında farklı yorumlamalara sebep olabilmektedir [1, 2].

Yapay zekânın bir alt kümesi olan derin öğrenme, verilerdeki karmaşık desenleri işlemek için insan beyni işlevlerini taklit eden sinir ağlarını içermektedir. Derin öğrenme, büyük hacimli verileri işleyebilen, karmaşık örüntüleri tanımlayabilen ve dikkate değer bir hassasiyetle tahmine dayalı bilgi çıkarımları üretebilen karmaşık sinir ağı mimarilerinden yararlanır. Derin öğrenmenin diş hekimliği alanında kullanımı, yüksek hacimli görüntüleme verileri ve hassas analiz gerekliliği nedeniyle avantaj sağlamaktadır. Diş kliniklerinde üretilen görüntüleme verilerinin hacminin artmasıyla birlikte, geleneksel manuel yorumlama yöntemleri artan hassasiyet ve verimlilik taleplerini karşılamakta yetersiz kalmaya başlamıştır. Bu zorluk, teşhis sürecini otomatikleştirmek ve geliştirmek için yapay zekâ teknolojilerinin, özellikle de derin öğrenmenin benimsenmesinin yolunu açmıştır [3].

Derin öğrenme algoritmaları, özellikle de Evrimsel Sinir Ağları (ESA), görüntü sınıflandırma, nesne algılama ve segmentasyon süreçlerinde çeşitli diş anormalliklerini ve hastalıklarını tanımlamak için uygulanmıştır. Ağız boşluğu, diş çürükleri, diş eti hastalıkları ve anatomik yapılar gibi çok çeşitli hastalıklara ve anatomik anormalliklere sıklıkla maruz kalabilmektedir. Doğru ve zamanında müdahaleler olumsuz sağlık sonuçlarının önlenmesinde hayati bir rol oynadığından, kesin tanı yöntemlerinin geliştirilmesi büyük önem taşımaktadır. Geleneksel teşhis yaklaşımları genellikle tedavinin doğruluğunu ve zamanında yapılmasını tehlikeye atabilecek öznel yorumlara dayanmaktadır [4].

Diş hekimliğinde diş çürükleri, gömülü dişler ve diş enfeksiyonları gibi durumların teşhisi için yaygın olarak kullanılan panoramik diş radyografi, diş ve iskelet yapılarının kapsamlı bir görüntüsünü sağlamaktadır. Panoramik radyografilerin yorumlanması genellikle uzman bilgisi gerektirir ve bu durum süreci insan hatasına eğilimli hale getirebilmektedir. Bu noktada, derin öğrenme modelleri, teşhis hassasiyetini artırarak ve yanlış teşhis olasılığını azaltarak dönüştürücü bir avantaj sunmaktadır [5].

Çürük lezyonlarının erken tespiti, önleyici ve minimal girişimsel müdahalelerin uygulanmasına olanak sağlayarak diş yapısının korunmasına ve kapsamlı onarıcı işlemler gerektiren daha şiddetli aşamalara ilerlemesinin önlenmesine olanak tanınması açısından önem arz etmektedir. Görsel ve dokusal muayene ve radyografik değerlendirme gibi geleneksel çürük tespit yöntemleri, erken mine lezyonlarını tutarlı bir şekilde tespit edemeyebilir ve bu durum teşhis ve tedavinin gecikmesine neden olabilmektedir. Diş radyografilerinin analizinde derin öğrenme algoritmalarının uygulanması, çürük tespitinin duyarlılığını ve özgüllüğünü artırarak zamanında ve doğru teşhisi kolaylaştırabilmektedir [4].

Gömülü dişler, özellikle de üçüncü azı dişleri, diş hekimliğinde sık karşılaşılan bir durum olmaktadır. Gömülü dişler dişlerin etrafındaki yumuşak dokuların iltihaplanması, komşu dişlerin erimesi (diş dokularının kaybı) ve kist veya tümör gelişimi gibi çeşitli istenmeyen durumlara yol açabilmektedir. Gömülü dişlerin doğru tespiti ve değerlendirilmesi, tedavi planlaması ve olası komplikasyonların önlenmesi için önem arz etmektedir. Panoramik radyografi görüntüleri, gömülü dişlerin değerlendirilmesinde standart bir görüntüleme yöntemi olarak hizmet vermektedir; ancak yorumlanması önemli ölçüde uzmanlık gerektirmektedir. Derin öğrenme modelleri, panoramik radyografilerde gömülü dişlerin tespit edilmesine ve sınıflandırılmasına yardımcı olmak, teşhis doğruluğunu artırmak ve klinik karar vermeye yardımcı olabilmektedir [6].

Diş kökü çevresi ve diş eti iltihaplanmaları da dâhil olmak üzere diş kaynaklı enfeksiyonlar, teşhis edilip tedavi edilmezse önemli sağlık risklerini oluşturabilmektedir. Bu enfeksiyonlar ağrıya, diş kaybına yol açabilir ve patojenlerin ağız boşluğunun ötesine yayılması durumunda sistemik rahatsızlıklara bile neden olabilir. Derin öğrenme yaklaşımları, diş radyografilerinde bu tür enfeksiyonların tespitini daha hızlı ve daha yüksek doğrulukla sağlamak için uygulanmış olup, geleneksel teşhis yöntemlerine katkı sağlamakta ve zamanında müdahale yoluyla hasta ve hastalık olasılıklarını azaltmayı hedeflemektedir [2].

Radyografi görüntülerin otomatik analizi, hekim yorgunluğunu ve önyargısını azaltabilmektedir. Ayrıca büyük hacimli verileri verimli bir şekilde işleyerek tutarlı yorumlar sağlayabilmekte ve böylece teşhis süreçlerini standartlaştırabilmektedir. Yapay zekânın entegrasyonu diş hekimliği uygulamalarında iş akışını kolaylaştırabilmekte ve klinik çalışanlarının yoğun zaman alan görüntü analizi yerine hasta bakımına daha fazla odaklanmalarını sağlayabilmektedir. Bu teknolojilerin benimsenmesi, eğitim algoritmaları için büyük, etiketli veri kümelerine duyulan ihtiyaç, veri gizliliğine ilişkin endişeler ve yapay zekâ araçlarının mevcut klinik sistemlere sorunsuz bir şekilde entegre edilmesi gerekliliği gibi zorlukları da beraberinde getirebilmektedir. Bu zorlukların üstesinden gelmek, yapay zekâ uygulamalarının faydalarını en üst düzeye çıkarırken potansiyel risklerini en aza indirecek şekilde geliştirilmesini ve hayata geçirilmesini sağlamak için gerekli olmaktadır [7].

1.1. Literatür İncelemesi

1.1.1. Sağlık Alanında Yapay Zekâ Çalışmaları

Yapay zekâ, sağlık hizmetlerinin kalitesini artırma, hastalıkların erken teşhisi ve tedavi süreçlerinin iyileştirilmesi gibi alanlarda büyük bir potansiyele sahip olmaktadır. Ayrıca büyük veri analitiği ve makine öğrenimi kullanılarak hasta verilerinin analiz edilmesi ve anlamlı sonuçların çıkarılması yetenekleri de bulunmaktadır. Bu durum, klinik uygulamalarda daha doğru tanı ve tedavi yöntemlerinin geliştirilmesine olanak tanımaktadır. Bunun yanı sıra, yapay zekâ destekli sağlık hizmetleri, pandemi gibi acil durumlarda hızlı yanıt verme kapasitesini artırarak, sağlık sistemlerinin dayanıklılığını güçlendirmeyi amaçlamaktadır. Pandemi dönemlerinde, sağlık sistemlerinin karşılaştığı zorluklar daha belirgin hale gelmektedir. Bazel ve arkadaşları tarafından gerçekleştirilen bir çalışmada, COVID-19 pandemisinin sağlık sistemleri üzerindeki etkileri incelenmiş ve yapay zekâ, nesnelerin interneti (IoT), blok zinciri ve büyük veri teknolojilerinin sağlık hizmetlerinde nasıl kullanılabileceği ele alınmıştır. Bu teknolojilerin, hastalıkların tespiti, izlenmesi ve tanı konulması gibi kritik alanlarda sağladığı avantajlar, sağlık sistemlerinin acil durumlara karşı daha dayanıklı hale gelmesine katkıda bulunmaktadır [8].

Zhang ve arkadaşları tarafından önerilen Sağlık-CPS (Siber-Fiziksel Sistem), bulut ve büyük veri analitiği teknolojileri ile desteklenen hasta merkezli sağlık uygulamaları sunmaktadır. Bu sistem, sağlık verilerinin toplanması, yönetimi ve hizmet sunumu süreçlerini birleştirerek, sağlık hizmetlerinin etkinliğini artırmayı hedeflemektedir. Böylece, acil durumlarda sağlık hizmetlerine erişim hızlanmakta ve sağlık sistemlerinin dayanıklılığı artırılabilir [9].

Yapay zekâ ile tanısal görüntüleme analizinin, hasta sonuçlarının öngörülmesi ve yaşamsal bulguların izlenmesi gibi konularda önemli bir potansiyele sahip olduğu görülmektedir. Kunt ve arkadaşları tarafından sunulan bir çalışmada, yapay zekânın acil tıptaki potansiyeli vurgulanmakta ve bu teknolojinin çeşitli uygulamaları ele alınmaktadır. Yapay zekâ sistemleri, görüntüleme teknikleri ile elde edilen verileri analiz ederek hastalıkların erken teşhisinde ve doğru tanı koyma süreçlerinde kritik bir rol oynamaktadır. Ayrıca, hasta verilerini inceleyerek sağlık durumlarını ve olası komplikasyonları tahmin etmekte, böylece sağlık hizmetlerinin etkinliğini artırmakta ve acil durumlarda hızlı müdahale imkânı sunmaktadır. Bu tür uygulamalar, sağlık hizmetlerinin etkinliğini artırarak acil durumlarda hızlı müdahale imkânı sunmaktadır [10].

Öncel ve Aslan tarafından gerçekleştirilen çalışmada, yapay zekânın kalp damar hastalığının tıptaki potansiyelini kapsamlı bir şekilde ele almakta ve karşılaşılan zorlukları detaylı bir biçimde açıklamaktadır. Bu durum, yapay zekânın sağlık alanındaki uygulamalarının daha ileriye taşınabilmesi için veri çeşitliliğinin artırılması gerektiğini ortaya koymaktadır. Ayrıca, sağlık verilerinin kalitesi ve güvenilirliği, bu algoritmaların etkinliğini doğrudan etkileyen unsurlar

arasında bulunmaktadır. Dolayısıyla, daha çeşitli ve kapsamlı veri kümeleri sağlamak, bu algoritmaların doğruluk oranını artırabilir ve kalp damar hastalıklarının daha hızlı ve doğru bir şekilde teşhis edilmesine olanak tanıyabilir [11].

Yapay zekâ destekli sistemler, tıbbi görüntüleme verilerinden elde edilen bilgileri analiz ederek, hastalıkların erken teşhisini mümkün kılmakta ve bu sayede hasta bakımını önemli ölçüde iyileştirmektedir. Şimşek ve Uğraş'a göre, genel muayenelerinde bu teknolojiler, sağlık profesyonellerinin iş yükünü azaltmakta ve klinik karar verme süreçlerini daha etkili hale getirmektedir. Bu bağlamda, bu sistemlerin kullanımının, hata oranlarını düşürmesi ve hasta güvenliğini artırması gibi önemli avantajları da bulunmaktadır [12].

Rehman ve arkadaşlarının gerçekleştirdiği bir incelemede, büyük veri analitiğinin klinik karar verme süreçlerinde nasıl kullanılabileceği ve bu süreçlerin iyileştirilmesi için hangi stratejilerin benimsenmesi gerektiği üzerinde durulmaktadır. Çalışma, sağlık hizmetlerinde büyük veri analitiğinin uygulanmasının getirdiği fırsatları ve zorlukları detaylandırarak, sağlık sistemlerinin bu zorlukları aşmak için hangi stratejileri benimsemesi gerektiğine dair öneriler sunmaktadır. Özellikle, büyük veri analitiği, hasta verilerinin toplanması, analizi ve yorumlanması süreçlerini optimize ederek, klinik karar verme süreçlerinin daha hızlı ve etkili bir şekilde gerçekleştirilmesine olanak tanımaktadır. Bu bağlamda, bahsedilen çalışmada araştırmacılar, veri entegrasyonu, makine öğrenimi teknikleri ve gerçek zamanlı veri analizi gibi yenilikçi stratejilerin önemini vurgulamaktadır. Ayrıca, sağlıkçıların bu yeni teknolojileri benimseme konusundaki direncinin, bu süreçlerin etkin bir şekilde uygulanmasında önemli bir engel teşkil ettiğini belirtmektedirler [13].

Yapay zekâ, bireylerin genetik ve tıbbi geçmişlerine dayalı olarak özelleştirilmiş tedavi planları geliştirme kapasitesine sahiptir. Böylece hastaların kişisel verilerini toplayarak sağlık önerileri sunmakta ve sağlık profesyonellerinin klinik karar verme süreçlerine katkıda bulunmaktadır. Parekh ve arkadaşları çalışmalarında bireylerin sağlık durumlarını daha iyi anlamalarına ve tedavi süreçlerini optimize etmelerine olanak tanıma üzerine odaklanmışlardır. Kişiselleştirilmiş tıp, bireylerin tedaviye verdikleri yanıtları izleyerek, tedavi planlarını gerçek zamanlı olarak güncelleme imkânı sunmaktadır. Bu süreç, hasta memnuniyetini artırmakta ve sağlık hizmetlerinin etkinliğini yükseltmektedir [14].

Manias ve arkadaşları, yeni teknolojilerin bireylerin sağlık verilerini analiz ederek, kişiye özel sağlık izleme ve karar destek sistemleri geliştirdiğini belirtmektedir. Bu tür sistemler, bireylerin sağlık durumlarını daha iyi anlamalarına ve sağlık hizmetlerine erişimlerini artırmalarına yardımcı olmaktadır. Özellikle, bu teknolojilerin veri analizi yetenekleri, hastaların bireysel sağlık geçmişlerini ve genetik bilgilerini dikkate alarak, hedeflenmiş tedavi önerileri sunma imkânı vermektedir. Ayrıca, bu teknolojilerin sağlık hizmetlerine entegrasyonu, sağlıkçıların karar verme süreçlerini iyileştirerek, daha hızlı ve doğru müdahaleler gerçekleştirmelerine olanak tanımaktadır. Bu durum, yalnızca bireylerin sağlık sonuçlarını iyileştirmekle kalmayıp, aynı zamanda sağlık

sisteminin genel verimliliğini ve etkililiğini artırmaktadır. Kişiselleştirilmiş sağlık yaklaşımları, özellikle kronik hastalıkların yönetiminde, hastaların tedaviye uyumunu artırmakta ve sonuçların iyileşmesine katkı sağlamaktadır [15].

Çelik ve Kaya çalışmalarında yapay zekânın sağlık hizmetlerinde yaygınlaşması, etik tartışmaları ve kaygıları gündeme getirdiğinden bahsetmektedir. Tartışmalar, bu uygulamaların sağlık hizmetleri üzerindeki artan etkisi ile birlikte daha da belirgin hale gelmektedir. Özellikle, yapay zekâ teknolojilerinin hastaların kişisel verilerini nasıl işlediği ve bu verilerin gizliliği üzerine ciddi endişeler bulunmaktadır. Bu uygulamaların artan etkisi, sağlık alanında etik sorunların daha yakından incelenmesini gerektirmektedir. Bu bağlamda, karar verme süreçlerinde şeffaflık ve veri güvenliği gibi konuların ele alınması önem arz etmektedir. Ayrıca, hekimlerin bu sistemlerin kararlarına ne ölçüde güvenebileceği ve bu sistemlerin hasta bakımını nasıl etkilediği gibi sorular da kritik bir öneme sahip olmaktadır. Bu nedenle, araştırmacılar çalışmalarında sağlık alanındaki uygulamaların etik çerçeveler içinde değerlendirilmesi, yalnızca teknolojinin geliştirilmesi açısından değil, aynı zamanda hasta güvenliği ve sağlık hizmetlerinin kalitesi açısından da hayati bir gereklilik olduğunu vurgulamışlardır [16].

Mehta ve arkadaşları tarafından gerçekleştirilen haritalama çalışmasında, sağlık alanında büyük veri analitiği ve yapay zekâ teknolojilerinin mevcut durumu kapsamlı bir şekilde değerlendirilmiştir. Çalışma, sağlık sistemlerinde yapay zekâ ve büyük veri kullanımına yönelik karşılaşılan zorlukları detaylı bir şekilde inceleyerek, bu zorlukların aşılması için gerekli olan araştırma alanlarını belirlemekte ve bu alanlarda daha fazla çalışma yapılmasının önemini vurgulamaktadır. Özellikle, sağlık hizmetlerinin etkinliğini artırmak ve hasta bakımını iyileştirmek amacıyla bu alanda potansiyel uygulamaları daha iyi anlamak, sağlık çalışanlarının ve araştırmacıların önünde duran kritik bir ihtiyaç olarak öne çıkmaktadır [17].

1.1.2. Diş Hekimliği Alanında Yapay Zekâ Çalışmaları

Yapay zekâ, diş hekimlerine tanı koyma, tedavi planlama ve hasta yönetimi gibi süreçlerde yardımcı olabilmektedir. Bu uygulamalar, diş hekimlerinin klinik karar verme süreçlerini hızlandırmakta ve daha doğru sonuçlar elde etmelerine olanak tanımaktadır. Bonny ve arkadaşları tarafından sunulan bir çalışmada, yapay zekânın diş hekimliğinde tanı ve tedavi önerileri sağlamak için kullanıldığı belirtilmektedir. Çalışma, bu yöntemlerin diş hekimliği uygulamalarında nasıl bir rol oynadığını ve bu teknolojinin klinik karar verme süreçlerine katkısını vurgulamaktadır. Ayrıca, bu yöntemlerin hastaların bireysel özelliklerine ve geçmiş tıbbi bilgilerine dayalı olarak özelleştirilmiş tedavi planları oluşturma yeteneği, diş hekimliği alanında daha etkili ve kişiselleştirilmiş bir yaklaşım sunmaktadır. Yapay zekâ algoritmaları, görüntü işleme teknikleri ile birleştirildiğinde, diş hekimlerinin radyografik verileri daha hızlı ve doğru bir şekilde analiz

etmelerini sağlamakta ve bu durum erken teşhis ve tedavi sürecini önemli ölçüde iyileştirmektedir [18].

Mallineni ve arkadaşları tarafından yapılan bir çalışmada, son teknolojik yöntemlerin diş hekimliğinde, özellikle görüntü tanıma sistemlerinde, önemli bir rol oynadığı ifade edilmektedir. Çeşitli diş problemlerinin daha erken aşamalarda tespit edilmesine olanak tanıyarak, hastaların tedavi süreçlerini hızlandırmakta ve sonuçları iyileştirmektedir. Bu uygulamaları, elde edilen verilerin derinlemesine analizini gerçekleştirebildiği için, diş hekimleri, hastalarının bireysel ihtiyaçlarına göre özelleştirilmiş tedavi planları geliştirebilmektedir. Bu durum, diş hekimlerinin daha doğru tanımlar koymasına ve tedavi süreçlerini daha etkili bir şekilde yönetmesine olanak tanıyabilmektedir [19].

Dhopte ve Bagde tarafından gerçekleştirilen bir çalışmada, derin öğrenme yöntemlerinin otomatik tanı ve tedavi planlama sistemlerinde etkin bir şekilde kullanıldığı ve bu uygulamanın hasta sonuçlarını iyileştirdiği vurgulanmaktadır. Derin öğrenme yöntemleri, hastaların tıbbi geçmişi, anatomik varyasyonları ve tedavi başarı oranları gibi çok çeşitli faktörleri analiz ederek, diş hekimlerine daha bilinçli ve etkili kararlar verme imkânı sunmaktadır. Bu tür sistemler, diş hekimlerinin daha kişiselleştirilmiş ve etkili tedavi yaklaşımları geliştirmelerine olanak tanıırken, aynı zamanda tedavi süreçlerinde hız ve doğruluk sağlama potansiyeli taşımaktadır. Böylece bu yöntemler ile hastaların bireysel ihtiyaçlarına göre özelleştirilmiş tedavi planlarını oluşturabilir, bu durum hem hasta memnuniyetini artırmakta hem de tedavi sürelerini kısaltmaktadır [20].

Karaoglanoglu ve arkadaşları tarafından yapılan bir çalışmada, diş çekimi öncesi kaygı düzeylerinin değerlendirildiği ve bu kaygının azaltılması için yapay zekâ tabanlı yöntemlerin uygulanmasının önemine vurgu yapılmaktadır. Çalışma, hasta kaygısının diş hekimliği uygulamalarında karşılaşılan yaygın bir sorun olduğunu göstermekte ve bu teknolojilerin bu sorunun üstesinden gelmedeki rolünü detaylandırmaktadır. Bu uygulamalarla hastanın dikkatini dağıtıp kaygı seviyelerini düşürerek hastaların tedavi süreçlerinde daha rahat hissetmelerine yardımcı olarak kaygı seviyelerini düşürebileceği düşünülmektedir [21].

Bacanli ve arkadaşları gerçekleştirdiği bir çalışmada, derin öğrenme yöntemlerinin periapikal radyografilerde dental dolguların otomatik olarak tespit edilmesi için kullanıldığı belirtilmektedir. Çalışma, bu teknolojilerin diş hekimliğinde nasıl bir karar destek aracı olarak işlev görebileceğini göstermektedir [22].

Siddiqui ve arkadaşları tarafından yapılan bir çalışmada, restoratif diş hekimliği, oral patoloji ve ortodonti gibi çeşitli alanlarda tanı koyma, tedavi ihtiyaçlarının değerlendirilmesi ve tedavi planlaması gibi işlevlerden bahsedilmiştir. Bu inceleme, bu yöntemlerin görüntü analizi ve veri madenciliği gibi teknolojik araçlar kullanarak, diş hekimlerine karmaşık klinik durumları daha etkili bir şekilde yönetme ve hızlı karar verme süreçlerinde önemli avantajlar sağladığını ortaya koymaktadır. Ayrıca, yapay zekâ sistemlerinin, hasta verilerini analiz ederek bireyselleştirilmiş

tedavi önerileri sunma potansiyeli, diş hekimliğinde hasta sonuçlarını iyileştirme açısından büyük bir fırsat sunmaktadır [23].

Khanagar ve arkadaşları tarafından gerçekleştirilen bir çalışmada, yapay zekâ yöntemleri ile diş hekimlerinin hastalarının bireysel ihtiyaçlarına uygun, daha etkili tedavi planları oluşturmalarına olanak tanıdığını vurgulanmıştır. Bu yöntemlerin analitik yetenekleri, hastaların geçmiş tıbbi verilerini ve klinik bulgularını analiz ederek, daha doğru teşhisler koyulmasına ve tedavi süreçlerinin optimize edilmesine katkıda bulunmaktadır. Bu durum, yalnızca diş hekimlerinin hastalarına daha iyi hizmet sunmalarını sağlamakla kalmayıp, aynı zamanda klinik karar verme süreçlerini destekleyerek sağlık hizmetlerinin genel kalitesini artırmaktadır [24].

Batra ve arkadaşları tarafından yapılan bir çalışmada, uzaktan tanı, kayıt tutma ve hasta izleme süreçleri ele alınmıştır. Bu uygulamalar, diş hekimlerinin daha geniş bir hasta grubuna ulaşmalarını sağlamakta ve tedavi süreçlerini daha verimli hale getirmektedir [25].

Mörch ve Ducret tarafından gerçekleştirilen bir incelemede, diş hekimliğindeki yapay zekâ uygulamalarının birçok etik sorunla karşılaşılabilceği vurgulanmıştır. Bu bağlamda, veri gizliliği, model önyargısı ve hasta güvenliği gibi konular, klinik uygulamalarda benimsenmesi açısından kritik engeller olarak belirlenmiştir. Örneğin, hasta verilerinin gizliliği, bu yöntemlerin etkinliği açısından hayati öneme sahipken, bu sistemlerin kullanımı sırasında bu verilerin korunması gerektiği hususu, etik bir sorumluluk olarak değerlendirilmektedir. Ayrıca, model önyargısı, bu algoritmalarının eğitim süreçlerinde kullanılan verilerin çeşitliliği ile doğrudan ilişkilidir. Eğer bu veriler temsili bir şekilde seçilmezse, sonuçlar yanıltıcı olabilir ve belirli hasta gruplarına karşı ayrımcı sonuçlar doğurabilir. Bu nedenle, bu uygulamaların etik çerçeveler içinde geliştirilmesi ve uygulanması gerektiği, sadece teknolojinin güvenli ve etkili bir şekilde kullanılmasını sağlamakla kalmayıp, aynı zamanda hasta haklarının korunması açısından da son derece önemli olmaktadır [26].

1.1.3. Derin Öğrenme Yöntemlerinin Tıbbi Görüntüleme Alanındaki Kullanımı

Tıbbi görüntüleme, hastalıkların tanısı, izlenmesi ve tedavi süreçlerinde kritik bir rol oynamaktadır. Geleneksel makine öğrenimi yöntemleri, görüntü analizi için belirli özelliklerin manuel olarak çıkarılmasını gerektirirken, derin öğrenme, ham verilerden otomatik olarak özellikler öğrenme yeteneği sunmaktadır. Ayrıca, derin öğrenme algoritmaları, büyük veri kümeleri ile desteklendiğinde, yüksek doğruluk oranları ile sınıflandırma ve segmentasyon işlemlerini gerçekleştirebilmektedir. Özellikle, kanser taraması, radyolojik teşhis ve cerrahi planlama gibi kritik alanlarda bu teknolojilerin kullanımı, hem klinik uygulamalarda hem de araştırma aşamalarında önemli ilerlemeler sağlamakla ve bu sayede sağlık hizmetlerinin etkinliğini artırmaktadır. ESA'lar, görüntü sınıflandırma, segmentasyon ve nesne tespiti gibi görevlerde yüksek performans sergilemektedir. Bu tür ağlar, katmanlar arasındaki derin yapıları sayesinde,

karmaşık görüntü verilerini etkili bir şekilde işleyebilmekte ve yüksek doğruluk oranları elde edebilmektedir. Bu yöntemlerin görüntü verilerini doğrudan öğrenme yeteneği sayesinde, geleneksel makine öğrenimi yöntemlerinden önemli ölçüde farklılaştığı görülmektedir. ESA'ların bu alandaki başarısı, özellikle büyük veri kümeleriyle çalışabilme kabiliyetlerinden ve çeşitli görüntüleme tekniklerine (örneğin, MRI, BT ve ultrason) entegrasyon yeteneklerinden kaynaklanmaktadır. Ayrıca, bu yöntemlerin, tıbbi teşhis süreçlerinde zaman ve kaynak tasarrufu sağladığı, hastalıkların erken teşhisi için önemli bir avantaj sunduğu bilinmektedir [27].

Tıbbi görüntüleme alanında derin öğrenmenin sağladığı avantajlar arasında, görüntülerin otomatik olarak analiz edilmesi ve yorumlanması yer almaktadır. Puttagunta ve Ravi, bu yöntemlerin, X-ray, bilgisayarlı tomografi (BT), mamografi ve dijital histopatoloji görüntüleri gibi çeşitli tıbbi görüntüleme türlerinde hastalıkların tespiti için yaygın olarak kullanıldığını vurgulamaktadır. Bu teknolojiler, görüntülerin daha hızlı bir şekilde değerlendirilmesini sağlarken, aynı zamanda insan hatası olasılığını da azaltarak sonuçların güvenilirliğini artırmaktadır. Bu yöntemler, büyük veri kümeleri üzerinde eğitim alarak, karmaşık görüntü örüntülerini tanıma yetenekleri geliştirmekte ve bu sayede, erken teşhis ve müdahale olanaklarını genişletmektedir. Özellikle kanser gibi ilerleyici hastalıkların tespitinde, bu teknolojilerin sağladığı hassasiyet ve hız, klinik uygulamalarda olumlu değişikliklere yol açmaktadır. Örneğin, birçok çalışma, derin öğrenme tabanlı sistemlerin, geleneksel yöntemlere kıyasla daha yüksek doğru teşhis oranları sağladığını göstermiştir. Bu durum, tıbbi görüntüleme süreçlerinin hızlanmasına ve doğruluğunun artmasına katkıda bulunarak, sağlık hizmetlerinin kalitesini önemli ölçüde iyileştirmektedir. Ayrıca, bu teknolojilerin entegrasyonu, sağlık profesyonellerinin karar verme süreçlerini destekleyerek, hastaların tedavi süreçlerinde daha kişiselleştirilmiş yaklaşımlara olanak tanımaktadır [28].

Guo ve arkadaşları, çok modlu görüntü analizi üzerine önerdikleri mimarinin, özellik öğrenme, sınıflandırıcı ve karar verme seviyelerinde çapraz modül entegrasyonu sağladığını ifade etmektedir. Bu tür bir entegrasyon, farklı görüntüleme modalitelerinden elde edilen verilerin daha etkili bir şekilde analiz edilmesine olanak tanımaktadır. Özellikle, çok modlu verilerin bir araya getirilmesi, her bir modalitenin güçlü yönlerinden yararlanarak, daha kapsamlı ve doğru analiz sonuçları elde edilmesini sağlamaktadır. Örneğin, manyetik rezonans görüntüleme (MRG) ve BT gibi farklı modaliteler, birlikte kullanıldığında, hastaların durumunu daha ayrıntılı bir biçimde değerlendirme imkânı sunmaktadır. Derin öğrenme algoritmaları, bu verilerin birleşimini optimize etmek için çeşitli yöntemler ve teknikler kullanmakta, böylece görüntüleme süreçlerinde daha yüksek doğruluk ve güvenilirlik sağlanmaktadır. Ayrıca, bu tür entegrasyon, klinik uygulamalarda tanı süreçlerini hızlandırma ve hastalıkların daha erken aşamalarda tespit edilme potansiyelini artırma konusunda önemli avantajlar sunmaktadır. Bunun sonucunda, sağlık alanında daha etkili karar verme mekanizmaları ve bireyselleştirilmiş tedavi yaklaşımları geliştirilebilmektedir [29].

Bu teknolojiler, sađlık alanında çok daha geniş bir yelpazede çözümler sunma kapasitesine sahiptir. Kim ve arkadaşları, bu yöntemlerin, bilgisayarla destekli tanı, hastalık tahmini, görüntü segmentasyonu ve görüntü üretimi gibi çeşitli sađlık sorunlarına yönelik çözümler sunduđunu belirtmektedir. Özellikle, bu yöntemler, karmaşık verilerin işlenmesi ve analizinde sağladığı avantajlarla dikkat çekmektedir. Derin öğrenme algoritmaları, büyük veri kümelerinin işlenmesi sırasında, geleneksel yöntemlere kıyasla daha yüksek doğruluk oranları ile çalışabilmektedir. Örneđin, bu algoritmalar, görüntülerin analiz edilmesi ve anormal bulguların tespit edilmesinde insan performansını aşabilmektedir. Bu durum, hem zaman hem de maliyet açısından önem arz etmekte ve hekimlerin daha verimli bir şekilde çalışmasına olanak tanımaktadır [30].

Ahmad ve arkadaşları, derin öğrenme tabanlı tıbbi görüntü analizinin sınırlı veri kümeleri gibi zorluklar içerdiğini vurgulamışlardır. Özellikle, tıbbi verilerin genellikle etiketlenmiş kısıtlı örneklerle sınırlı olması, modelin genel performansını ve güvenilirliğini olumsuz etkilemektedir. Ek olarak, derin öğrenme algoritmalarının karmaşıklığı ve hesaplama gereksinimleri, bu teknolojilerin yaygın bir şekilde uygulanmasını zorlaştıran diğer önemli engeller arasında yer almaktadır. Araştırmacılar, bu zorlukları aşabilmek amacıyla veri artırma yöntemleri, transfer öğrenme teknikleri gibi yöntemler üzerine yoğunlaşmışlardır [31].

1.1.4. Diş Hastalıklarının Yapay Zekâ Tabanlı Tespiti Çalışmaları

Diş hastalıklarının tespiti, sađlık alanında önemli bir yer tutmaktadır. Son yıllarda, yapay zekâ ve makine öğrenimi gibi teknolojilerin gelişimi, diş hekimliğinde hastalıkların daha hızlı ve doğru bir şekilde teşhis edilmesine olanak sağlamaktadır. Diş hastalıklarının erken teşhisi hasta sađlığı ve yaşam kalitesi için önem arz etmektedir. Kim ve arkadaşları çalışmalarında, koronal çürük, proksimal çürük, servikal çürük, periapikal radyolusensi ve kalan kökler olmak üzere beş yaygın hastalığı kapsayan 10.000 panoramik diş görüntülerine HB-ESA, ResNet ve Inception modellerini uygulamışlardır. Bahsedilen hastalıkların teşhisinde uygulanan bu modeller %90 üzerinde doğruluk vermiştir. Tespit hassasiyetini artırmak için her hastalık ayrı ayrı modellenmiş ve sonuçlar yapay zekânın diş hekimlerine yardımcı olma, tedavi planlama süresini azaltma ve yanlış teşhisleri en aza indirmedeki önemli rolünü vurgulamıştır [32].

Kheraif ve arkadaşları çalışmalarında, radyografik 2B (2 boyutlu) diş görüntülerini işlemek için hibrit grafik kesim segmentasyonunun yanı sıra evrişimsel sinir ağıları kullanmışlardır. Ön işleme aşamasında, kontrastı artırmak ve parlaklığı eşitlemek için histogram tabanlı bir yaklaşım kullanılmış, böylece diş ve kemik bölgelerinin ayırt edilmesi kolaylaştırılmıştır. Bu yöntem %97,07'lik bir segmentasyon doğruluđu elde etmiştir [33].

Murata ve arkadaşları, maksiller sinüs tespiti için 400 sađlıklı ve 400 iltihaplı, panoramik görüntülerin yer aldığı bir veri kümesi üzerinde çalışmışlardır. Kategoriler 6000 örneđe çıkarılarak veri artırma işlemi uygulanmıştır. AlexNet derin mimarisi uygulanarak 60 sađlıklı ve 60 iltihaplı

sinüs üzerinde yapılan testlerde %87,5 doğruluk, %86,7 hassasiyet, %88,3 özgüllük ve 0,875 AUC (ROC eğrisinin altındaki alan) elde edilmiştir [34].

Bulut tabanlı evrişimsel sinir ağları dental görüntülemelerde önemli gelişmeler sunmaktadır. Elbarga ve arkadaşları tarafından gerçekleştirilen bir çalışmada, konik ışınlı bilgisayarlı tomografi (KIBT) görüntülerde dental implantların ve protez kron segmentasyonu için bir ESA modeli eğitilmiştir. Model, 280 KIBT taramasından oluşan bir veri kümesi kullanarak, implantlar için $0,92 \pm 0,02$ ve restorasyonlu implantlar için $0,91 \pm 0,03$ Dice benzerlik katsayısı ile yüksek segmentasyon doğruluğu elde etmiştir. Ayrıca, segmentasyonu yarı otomatik yaklaşımlardan 60 kat daha hızlı (<30 saniye) tamamlayarak üstün başarı göstermiştir [35].

Kohlakala ve arkadaşları çalışmalarında, çeşitli açılardan 2B projeksiyonlar oluşturarak 3B (3 boyutlu) BDT (Bilgisayar Destekli Tespit) yüzey modellerinden yapay eğitim örnekleri üreten bir algoritma önermişlerdir. Bu örnekleri, X-ışını görüntülerinde dental implant bağlantı türlerini tanımlamak için tam evrişimli bir ağı (FCN) eğitmek için kullanmışlardır. Çalışmada hem yarı otomatik hem de tam otomatik sistemler önerilmiş ve tam otomatik sistemde %94,0 segmentasyon doğruluğu ve %71,7 tanıma doğruluğu elde edilmiştir [36].

Kim ve arkadaşları, 2.430 normal ve maksiller sinüs vakasından oluşan 4.860 hastanın X-ray görüntülerini kullanarak maksiller sinüs sınıflandırması üzerine bir çalışma yürütmüştür. Veri kümesi eğitim (%70), doğrulama (%15) ve test (%15) alt kümelerine ayrılmıştır. Çalışmada üç derin öğrenme modeli-VGG-16, VGG-19 ve ResNet-101 kullanılmış ve bunların sınıflandırma sonuçları çoğunluk karar algoritması kullanılarak birleştirilmiştir. Önerdikleri yöntem %94,1'lik bir doğruluk sonucu göstermiş, lezyon bölgesinin segmentasyonu için çoğunluk karar algoritması kullanılmıştır [37].

Muresan ve arkadaşları tarafından yapılan bir çalışmada, panoramik röntgen görüntülerinin analizi ile dişlerin otomatik tespiti ve dental problem sınıflandırması üzerine bir yaklaşım önerilmiştir. Bu çalışma, diş hekimlerine doğru tanı koyma süreçlerinde yardımcı olmayı amaçlamaktadır. Üç diş kliniğinden alınan panoramik X-ray görüntüleri kullanıldığı bu çalışmada 0,89 doğruluk, 0,98 kesinlik, 0,91 hassasiyet ve 0,93 F1 skoru elde edilmiştir [38].

Mertoğlu ve arkadaşları, panoramik diş röntgen görüntülerin tespiti ve numaralandırılması üzerine yaptıkları çalışmada, derin öğrenme kullanılarak 200 anonim panoramik görüntü üzerinde testler gerçekleştirmişlerdir. Bu çalışmada, DESA (Derin Evrişimsel Sinir Ağı) modeli, dişlerin tespitinde ve numaralandırılmasında yüksek başarı oranları elde etmiştir. Elde edilen doğruluk, hassasiyet ve F1 skoru sırasıyla %99.6, %98.0 ve %98.8 olarak bulunmuştur [39].

Fukuda ve arkadaşları çalışmalarında 300 görüntüden oluşan bir veri kümesinden 330 dikey kök kırıklarını (VRF) kullanarak panoramik radyografilerde dikey kök kırıklarını tespit etmek için bir ESA modeli değerlendirmişlerdir. DetectNet ve DIGITS sürüm 5.0 ile geliştirilen model, güvenilirliği sağlamak için beş kat çapraz doğrulamaya tabi tutulmuştur. Sistem 0,75 hassasiyet,

0,93 hassasiyet ve 0,83 F ölçüsü elde ederek 267 kırığı doğru bir şekilde tanımlarken 20 kırık olmayan dişi yanlış tespit etmiştir [40].

Hossam ve arkadaşları, derin öğrenme yöntemlerinin diş hastalıklarının teşhisindeki kullanımı üzerine çalışmışlardır. Çalışmada, 17 ağız hastalığını teşhis etmek için uzmanlar tarafından etiketlenmiş diş görüntülerinden oluşan ODSI-DB veri kümesi kullanılmıştır. Araştırmada CenterNet ResNet, EfficientNet ve MobileNet modelleri test edilmiş ve MobileNet'in daha yüksek performans göstermiştir. Sınıflandırmada %95,2, lokalizasyonda %90,7 ve regülasyonda %91 doğruluk elde edilmiştir [41].

1.1.5. Gömülü Diş Tespiti Üzerine Yapılan Çalışmalar

Ariji ve arkadaşları, iki farklı hastaneden toplanan 3200 panoramik görüntü üzerinde segmentasyon teknikleri ile bir transfer öğrenme yaklaşımı kullanarak mandibular kanalın gömülü üçüncü molar dişe yakınlığı üzerine çalışmışlardır. Çalışmada, A Hastanesinden alınan verilerle bir kaynak model geliştirilmiş ve bu model daha sonra hedef modeller oluşturmak için B Hastanesinden alınan daha küçük veri kümeleri ile birleştirilmiştir. Elde ettikleri 0,831 Dice katsayısı ile çalışma, transfer öğrenmenin sınırlı verilerle bile yüksek performans elde edebileceğini göstermiştir [42].

Jeon ve arkadaşları yaptıkları çalışmada, süt ve karma diş yapısına sahip pediatrik hastaların periapikal görüntülerinde gömülü meziodensleri tespit etmek için YOLOv3, RetinaNet ve EfficientDet-D3 algoritmalarını kullanarak derin öğrenme modelleri geliştirmişlerdir. Çalışmada yaşları 3 ile 13 arasında değişen 600 pediatrik hastanın periapikal radyografilerinden oluşan bir veri kümesi kullanılmıştır. Veri kümesi eğitim (540 görüntü) ve doğrulama (60 görüntü) olarak bölünürken, test için 120 görüntü (60 meziodensli ve 60 meziodenssiz) kullanılmıştır. Her model 300 iterasyon üzerinden eğitilmiş ve performansları doğruluk, hassasiyet ve özgüllük açısından değerlendirilmiştir. EfficientNet-D3 %99,2 ile en yüksek doğruluğu, RetinaNet %98,3 ve YOLOv3 %97,5 oranında değer elde etmiştir [43].

Faure ve arkadaşları 530 panoramik radyografiden oluşan bir veri kümesinden gömülü dişleri tespit etmek için DHB-ESA (Daha Hızlı Bölgesel Evrişimsel Sinir Ağları) ve ResNet modellerini kullanmış ve %51,7 ile %88,9 arasında değişen tespit doğrulukları elde etmiştir. Toplamda 450 etiketli gömülü dişin bulunduğu veri kümesi, bir veya daha fazla gömülü diş içeren 178 radyografiden oluşmaktadır. Model eğitimi için omurga olarak ResNet101 ile Detectron2'yi kullanılmıştır. COCO veri kümesi üzerinde X101-FPN modeli için %43,0'lük kıyaslama AP'sini aşarak %50,58'lik bir ortalama hassasiyet (AP) elde etmiştir [6].

Zhang ve arkadaşları, gömülü mandibular üçüncü molar dişlerin çekilmesinin ardından postoperatif yüz şişliğinin belirlenmesinde yapay sinir ağlarının tahmin doğruluğunu değerlendirmek için bir çalışma gerçekleştirmişlerdir. Çalışmada, sinir ağının eğitim hızını artırırken yerel minimum riskini en aza indiren BP algoritması ile birlikte geliştirilmiş bir eşlenik gradyan geri yayılım (BP)

algoritması kullanmışlardır. Model, 300 eğitim ve kalan 100 test olmak üzere 400 hastadan alınan veriler kullanılarak eğitilmiş ve test edilmiştir. Hasta demografisi, üçüncü molar dişlerin anatomik özellikleri ve cerrahi prosedür detayları gibi faktörleri bir araya getiren sinir ağı, ameliyat sonrası şişlik ile işlevsel bir tahmin ilişkisi kurmuştur. Genellemeyi iyileştirmek için 5 kat çapraz doğrulama ve erken durdurma teknikleri kullanan modelde, %98,00 oranında doğruluk elde edilmiştir [44].

Imak ve arkadaşları, panoramik diş röntgeni görüntülerinde gömülü dişlerin segmentasyonu için ters çevrilmiş bir artık blok ve çift yönlü ConvLSTM katmanlarını içeren yeni bir kodlayıcı-kod çözücü ağ mimarisi olan ResMIBCU-Net üzerinde çalışmışlardır. Geliştirilmiş UNet mimarisi, gömülü dişlerin tespitinde %99,82 gibi yüksek bir doğruluk oranına ulaşarak derin öğrenme tabanlı yaklaşımların oral radyolojide tanı araçlarının geliştirilmesindeki potansiyelini vurgulamışlardır [45].

1.1.6. Enfeksiyon Tespiti Üzerine Yapılan Çalışmalar

Prajapati ve arkadaşları, evrişimsel sinir ağları ve transfer öğrenme yaklaşımı ile 80 adet diş çürüğü, 110 adet periapikal enfeksiyon ve 61 adet periodontitis olmak üzere 251 etiketli görüntüden oluşan RVG X-ray görüntüleri üzerinde üç farklı diş hastalığının sınıflandırılmasına dayalı bir çalışma yürütmüşlerdir. Araştırmacılar, küçük veri kümeleriyle ilişkili zorlukların üstesinden gelmek için önceden eğitilmiş bir VGG16 modeli kullanarak bir transfer öğrenme yaklaşımı uygulamışlardır. Sınıflandırma sonuçları diş çürüğü için %87,5, periapikal enfeksiyon için %90 ve periodontitis için %87,5 oranında doğruluk göstermiştir [46].

Wen ve arkadaşları, derin öğrenme yaklaşımını uygulayarak diş eti iltihabı üzerine çalışmışlardır. DenseNet tabanlı bir evrişimsel sinir ağı mimarisi uygulamışlardır. Çalışmaları kapsamında, geliştirdikleri modeli 826 hastanın ağız içi görüntüleri üzerinde uygulayarak, beş dişeti iltihabını $0,727 \pm 0,117$ oranında ortalama IoU (Birleşim Üzerindeki Kesişme Oranı), %73,68 ile %79,22 oranında da doğruluk ile tespit etmişlerdir [47].

Hashem ve Youssef, çalışmalarında gelişmiş makine öğrenimi tekniklerinin büyük veri ile uygulanmasıyla, manuel hatalar azaltılıp daha hızlı klinik kararlar alınması sağlanarak diş enfeksiyonlarının erken tespiti üzerine bir model önermişlerdir. Çalışmada gürültü giderme ve özellik çıkarma yöntemleri kullanılarak 120 dental radyografik görüntü işlenmiştir. Uygulanan segmentasyon teknikleri arasında, MSR yaklaşımı %95,8 F1 skoru elde etmiştir. BORN, DANN, GONN ve ADNN sinir ağları uygulanmış, BORN modeli %98,1 doğruluk ve 0,92 ROC (alıcı işletim karakteristiği) değeri ile en yüksek sonucu elde etmiştir [48].

Li ve arkadaşları, ağız fotoğraflarından diş eti iltihabı, diş taşı ve yumuşak birikintileri tespit etmek için Çok Görevli Öğrenme (Multi-Task Learning) ESA modeli önermişlerdir. Çalışmada, 625 hastaya ait 3.932 oral görüntünün analizi ile diş eti iltihabı, diş taşı ve yumuşak birikinti tespiti için

sırasıyla %87,11 ve %80,11 ve %78,57 AUC değerleri elde edilmiştir. Çalışmalarında, halk ağız sağlığı bilinci ve erken teşhis için akıllı telefon gibi cihazların kullanımıyla erişilebilir kamu diş sağlığı taramasının derin öğrenme yöntemi ile yaygınlaştırılması vurgulamaktadır [49].

Dhingra, BT ve MRI görüntüleri ile sinonazal-dental yapıların analizi için UNet kullanarak Kronik Odontojenik Rinosinüzit (CORS) teşhisi üzerine çalışmıştır. Diş enfeksiyonlarından kaynaklanan ve paranasal sinüsleri etkileyen bu durum, geleneksel rinosinüzit ile semptom örtüşmesi nedeniyle tanısız zorluklar ortaya çıkarmaktadır. Çalışma, %92 oranındaki doğruluk ile geleneksel yöntemlerden daha iyi performans gösterdiğini vurgulamıştır [50].

Alalharith ve arkadaşları, ortodonti hastalarında diş eti iltihabının erken tespiti için DHB-ESA kullanarak derin öğrenme tabanlı bir yaklaşım geliştirmiştir. Çalışmada, eğitim (%80) ve test (%20) veri kümelerine bölünmüş, 134 ağız içi görüntü kullanılmıştır. Çalışma kapsamında biri %100 doğruluk oranı ile diş tespiti için, diğeri %77,12 doğruluk ve %88,02 hassasiyet oranı ile iltihap tespiti olmak üzere iki DHB-ESA modeli uygulanmıştır. Yaklaşım, ilgilenilen bölgeyi kırparak maksiller orta kesici dişlerdeki diş eti iltihabını belirlemeye odaklanmıştır [51].

1.1.7. Çürük Tespiti Üzerine Yapılan Çalışmalar

Imak ve arkadaşları tarafından gerçekleştirilen bir çalışmada, periapikal görüntüler aracılığıyla diş çürüğünün otomatik teşhisi için çoklu girişli derin evrimsel sinir ağı modeli önerilmiştir. Bu yenilikçi model, periapikal görüntülerden elde edilen veriler ile %99.13 doğruluk oranına ulaşarak diş çürüğünü tespit etmiştir. Elde edilen bu bulgular, yapay zekâ tabanlı sistemlerin diş hastalıklarının teşhisindeki etkinliğini ortaya koymakta ve geleneksel yöntemlerin sınırlamalarını aşmak için yeni teknolojilerin entegrasyonunun önemini vurgulamaktadır [52].

Park ve arkadaşları çalışmalarında 445 hastadan alınan 2348 ağız içi görüntü üzerinde evrimsel sinir ağları (UNet, ResNet-18 ve DHB-ESA) yöntemlerini uygulayarak segmentasyon sınıflandırma doğruluğunu 0,813'e ve ROC eğrisi altındaki alanı 0,837'ye yükseltmiştir. Çürük lezyonlarını 0,890 ile 0,889 oranları aralığında hassasiyet ve 0,865 ile 0,868 oranları aralığında kesinlik elde etmiştir [53].

Geetha ve arkadaşları, çalışmalarında Laplacian filtreleme, adaptif eşikleme, morfolojik işlemler ve geri yayılım sinir ağını içeren bir sistemi geliştirmişlerdir. Çalışmada ağız içi dijital radyografiden elde edilen 105 görüntü, yapay bir sinir ağı ile 10-fold çapraz doğrulama kullanarak %97,1 doğruluk, %2,8 yanlış pozitif oranı ve 0,987 ROC alanı elde etmişlerdir [54].

Saini ve arkadaşları tarafından gerçekleştirilen bir çalışmada, tele-diş hekimliği sistemleri kullanılarak diş çürüğünün erken tespiti üzerine odaklanılmıştır. Tele- diş hekimliği uygulamaları aracılığıyla, coğrafi engellerin aşılması ve daha geniş bir hasta kitlesine ulaşma imkânı, sağlık hizmetlerinin erişilebilirliğini artırma potansiyeline sahiptir. Çalışma, modern diş hekimliği uygulamalarında dijital teknolojilerin entegrasyonunu vurgulayarak, uzaktan diş muayenesi

imkânlarının faydalarından bahsetmektedir. Çalışmada, derin öğrenme modelleri olan VGG16, VGG19, Inception-V3 ve ResNet50 kullanılarak diş çürüğü tespiti gerçekleştirilmiş ve bu modellerin performansı karşılaştırılmıştır. Elde edilen sonuçlar, en yüksek doğruluk oranının %99.89 ile Inception-V3 modeli ile elde edildiğini göstermektedir. Bu tür sistemlerin, zamanla hastaların tedavi süreçlerinin hızlandırılmasına ve maliyetlerin düşürülmesine katkıda bulunabileceği üzerinde durulmuştur [55].

Goswami ve arkadaşları, diş sağlığının önemli bir parçası olan diş çürüğü ve oral kanser tespiti üzerine çalışmışlardır. Çalışmada, 598 intraoral görüntü kullanılarak, "Normal dişler", "Çürük" ve "Oral kanser" olmak üzere görüntülerin üç sınıfa ayrılması sağlanmıştır. Kullanılan derin öğrenme algoritmalarının performansı, elde edilen doğruluk oranı ile ölçülmekte olup, bu oran %83 ile %94 arasında değişmektedir. Bu doğruluk oranları, sistemin diş hekimliğinde erken teşhis süreçlerine olan katkısını vurgulamaktadır [56].

Verma ve arkadaşları, hibrit bir derin öğrenme ve makine öğrenimi yöntemlerini panoramik diş görüntüleri üzerinde uygulayarak diş hastalıklarının tespiti üzerine çalışmışlardır. Özellik çıkarıcı olarak ESA ve sınıflandırıcı için DVM (Destek Vektör Makineleri) kullanılan çalışmada, veri artırma yöntemi uygulanmış veri kümesi üzerinde analiz edilerek belirgin çürük, enfeksiyon veya kemik kaybı olan "Normal" ve "Anormal" hastalıklar tespit edilmiştir. ESA-DVM modeli, Vanilla-ESA'lardan ve manuel özellik tabanlı DVM'lerden daha iyi performans göstererek %98,69 doğruluk elde etmiştir [57].

Yang ve arkadaşları, 196 hastadan alınan periapikal X-ray görüntüleri kullanılarak diş tedavisi sonuçlarının değerlendirilmesine üzerine çalışmışlardır. Çalışma kapsamında görüntüler, 'iyileşen', 'kötüleşen' veya 'belirgin bir değişiklik olmayan' şeklinde uzman tarafından etiketlenerek bir veri kümesi elde edilmiştir. Etiketlenen görüntüler üzerinde evrimsel sinir ağı uygulanarak analiz edilmiş, modelde 0,749 oranında F1 skoru elde edilmiştir [58].

1.2. Önerilen Sistemin Genel Çerçevesi

Diş hekimliği uygulamalarında panoramik radyografi, ağız ve çene bölgesine ilişkin anatomik yapıların ve hastalıkların değerlendirilmesinde kritik bir rol oynamaktadır. Geleneksel teşhis yöntemleri genellikle manuel olarak gerçekleştirilmekte olup bu durum zaman alıcı olmasının yanı sıra insan hatasına açık bir süreç yaratmaktadır. Büyük ölçekli sağlık merkezlerinde yoğun hasta trafiği, tanı süreçlerini daha da zorlaştırmakta ve zamanında müdahaleyi engelleyebilmektedir. Ayrıca radyografik değerlendirmeler, diş hekiminin deneyim ve bilgi birikimine bağlı olarak değişiklik gösterebilmekte ve bu durum da teşhis sürecinde tutarsızlıklara yol açabilmektedir. Bu bağlamda, yapay zekâ tabanlı sistemlerin geliştirilmesi, diş hekimliği alanında otomatik teşhis ve analiz süreçlerine olanak sağlamaktadır. Yapay zekâ ile desteklenen bu sistemler, hem teşhis doğruluğunu artırarak diş hekimlerine yardımcı olmakta hem de tedavi süreçlerini hızlandırarak

hasta memnuniyetini artırmaktadır. Bu tez çalışmasında, yüksek çözünürlüklü panoramik diş görüntülerine dayalı olarak diş hastalıkları ve ilgili anatomik yapıların otomatik tespiti için özgün hibrit derin öğrenme tabanlı yöntemler önerilmiştir. Çalışma kapsamında, kamuya açık veri kümelerinden seçilen görüntüler diş hekimi eşliğinde etiketlenerek karma bir veri kümesi oluşturulmuş ve ayrıca etik kurul onayı alınarak oluşturulan özgün bir veri kümesi de geliştirilmiştir. Aşağıdaki bölümlerde tez çalışmasının amaçları, çıktılarına ek olarak sistemin özgün katkıları detaylı şekilde ele alınmıştır.

1.2.1. Tezin Amacı

Bu tez çalışmasının temel amacı, panoramik diş radyografi görüntülerinde hastalıkların ve ilgili anatomik yapıların tespitine yönelik yenilikçi derin öğrenme yöntemleri geliştirmektir. Çalışma, diş hekimlerinin teşhis sürecini daha hızlı ve güvenilir bir şekilde gerçekleştirmesine olanak sağlayarak sağlık hizmetlerinin etkinliğini artırmayı hedeflemektedir.

Günümüzde erişime açık panoramik diş görüntüsü veri kümelerinin sayıca yetersiz oluşu, bu çalışmanın önemli bir ihtiyaçtan doğduğunu göstermektedir. Bu nedenle, etik kurulu onayı alınarak oluşturulan özgün veri kümesi, uzman diş hekimlerinin rehberliğinde titizlikle etiketlenmiştir. Bu özgün veri kümesi, yalnızca çalışmanın başarısına katkı sağlamakla kalmayıp, aynı zamanda yapay zekâ tabanlı uygulamalar geliştirmek isteyen diğer araştırmacılar için de önemli bir kaynak olabilmektedir.

1.2.2. Tezin Çıktıları ve Yenilikçi Yönleri

Bu tez çalışması kapsamında, panoramik diş radyografi görüntülerinde hastalıkların ve ilgili anatomik yapıların yapay zekâ tabanlı yöntemlerle tespiti üzerine özgün hibrit yaklaşımlar geliştirilmiştir. Literatürde mevcut yöntemler detaylı bir şekilde incelenmiş, güçlü ve zayıf yönleri analiz edilerek çalışma sürecine katkı sağlanmıştır. Bu doğrultuda, derin öğrenmeye dayalı yeni modeller önerilmiş ve performansları mevcut yöntemlerle karşılaştırılmıştır. Elde edilen sonuçlar, önerilen modellerin yüksek başarı sağladığını ortaya koymuştur.

Literatürde açık erişimli veri kümelerinin sınırlı olması sebebiyle, etik kurul onayı alınarak özgün bir veri kümesi oluşturulmuş ve bu veri kümesi uzman diş hekimi eşliğinde titizlikle etiketlenmiştir. Geliştirilen modeller, diş hekimlerinin tanı süreçlerini hızlandırarak hata oranlarını düşürmekte önemli bir potansiyel sunmaktadır. Ayrıca, oluşturulan bu özgün veri kümesi literatüre önemli bir katkı sağlamaktadır ve ileride bu alanda çalışmak isteyen araştırmacılar için değerli bir kaynak olarak kullanılabilecektir.

1.2.3. Tezin Organizasyonu

Bu tez çalışması, toplam 7 ana bölümden oluşmaktadır. Her bölüm, çalışmanın amacını, kullanılan yöntemleri ve elde edilen sonuçları detaylı bir şekilde açıklamak amacıyla düzenlenmiştir. Aşağıda, her bir bölümün içeriği özetlenmiştir:

Bölüm 1’de, tez konusu ile ilgili genel bilgiler verilmiş ve kapsamlı bir literatür incelemesi gerçekleştirilmiştir. Sağlık ve diş hekimliği alanında yapay zekâ çalışmalarına odaklanılmış, derin öğrenme yöntemlerinin tıbbi görüntüleme alanındaki kullanımına ilişkin güncel çalışmalar incelenmiştir. Ayrıca, gömülü diş, enfeksiyon ve çürük tespiti üzerine yapılan çalışmalar detaylandırılmıştır. Son olarak, tezin amacı, çıktıları, yenilikçi yönleri ve organizasyonu açıklanmıştır.

Bölüm 2’de, diş görüntüleme teknikleri, diş anatomisi, görüntü segmentasyon yöntemleri ve performans metrikleri detaylı bir şekilde açıklanmıştır. Özellikle panoramik radyografi ve piksel tabanlı segmentasyon yöntemleri üzerinde durulmuştur.

Bölüm 3’de, literatürde bulunan mevcut veri kümeleri incelenmiş ve gömülü diş, enfeksiyon ve çürük gibi diş hastalıklarına yönelik veri kümeleri listelenmiştir. Ayrıca, özgün veri kümesinin oluşturulma süreci ve etik kurul onayına dayalı veri etiketleme işlemleri detaylandırılmıştır.

Bölüm 4’de, gömülü dişlerin tespiti üzerine önerilen yöntem ve veri kümesi sunulmuş, geliştirilen modelin deneysel sonuçları paylaşılmıştır. Gömülü diş tespiti üzerine yapılan çalışmalar literatürle karşılaştırılmıştır.

Bölüm 5’de, enfeksiyon tespiti üzerine geliştirilen yöntemler bu bölümde açıklanmıştır. Önerilen modellerin performansı literatürdeki diğer çalışmalarla karşılaştırılarak elde edilen sonuçlar tartışılmıştır.

Bölüm 6’de, çürük tespiti için önerilen yöntemler ve kullanılan veri kümeleri sunulmuş, yapılan deneysel çalışmalar ve sonuçları detaylı bir şekilde ele alınmıştır. Literatürdeki mevcut çalışmalarla performans karşılaştırmaları yapılmıştır.

Bölüm 7’de, tez çalışmasının genel sonuçları ve bu sonuçların literatüre katkıları bu bölümde sunulmuştur. Ayrıca, gelecekte yapılacak çalışmalar için önerilere yer verilmiştir.


2. MATERYAL VE METOT

2.1. Diş Görüntüleme Teknikleri

Diş hekimliğinde teşhis ve tedavi planlamasında kullanılan çeşitli görüntüleme teknikleri, klinik çalışanlara hastaların ağız ve diş sağlığı hakkında detaylı bilgiler sunmaktadır. Bu teknikler arasında bitewing röntgen, periapikal röntgen, konik ışınlı bilgisayarlı tomografi ve panoramik röntgen bulunmaktadır. Her bir yöntem, farklı klinik durumlar için avantaj ve sınırlamalar içermektedir [59, 66].

2.1.1. Bitewing Radyografi

Diş hekimliğinde teşhis aracı olan bitewing radyografi, öncelikle arka dişlerin (premolar ve molar dişler) kronlarını ve komşu alveolar kemik seviyelerini değerlendirmek için kullanılmaktadır. Bu görüntüleme tekniği özellikle interproksimal çürüklerin tespit edilmesinde, mevcut restorasyonların değerlendirilmesinde ve periodontal kemik kaybının izlenmesinde etkili olmaktadır. Hem maksiller hem de mandibular arkları tek bir görüntüde yakalayan bitewing radyografiler, karşılaştırmalı analizleri kolaylaştırarak tanısal doğruluğu artırmaktadır. Şekil 2.1’de bitewing (ısıırma) yöntemi kullanılarak ortaya çıkarılmış diş röntgeni çeşidi sunulmuştur [59].



Şekil 2.1. Bitewing röntgen görüntüsü [59]

Dijital bitewing radyografiler anında görüntü elde edilmesini sağlayarak hasta bekleme sürelerini azaltmakta ve klinik verimliliği artırmaktadır. Ayrıca, dijital sistemler geleneksel film radyografisine kıyasla daha düşük radyasyon dozları gerektirdiğinden hasta güvenliğini artırabilmektedir [60].

BDT sistemlerinin dijital bitewing radyografi ile entegrasyonu, teşhis yeteneklerini daha çok artırmaktadır. BDT sistemleri, radyografi görüntüleri analiz etmek için gelişmiş algoritmalar kullanmakta ve daha fazla değerlendirme gerektirebilecek endişe verici alanları belirlemede hekimlere yardımcı olmaktadır. Son çalışmalar, derin öğrenme modellerinin bitewing radyografilerindeki proksimal çürükleri tespit edebildiğini ve klinik uygulamalara yardımcı olduğunu göstermiştir. Bu gelişmelere rağmen, bazı sınırlamalar devam etmektedir. Dijital bitewing radyografiler, geleneksel muadilleri gibi, üç boyutlu yapıların iki boyutlu gösterimlerini sağlar, bu da anatomik özelliklerin üst üste binmesine ve potansiyel teşhis zorluklarına neden olabilmektedir. Ayrıca, dijital radyografi ekipmanının başlangıç maliyeti ve sürekli yazılım güncellemeleri ve bakım ihtiyacı, diş hekimliği muayenahaneleri için mali hususlar oluşturmaktadır [61].

2.1.2. Periapikal Radyografi

Periapikal radyografi, diş hekimliğinde bir veya daha fazla dişin hem kron ve köklerini hem de çevresindeki alveolar kemiği kapsayan ayrıntılı görüntülerini yakalamak için tasarlanmış görüntüleme tekniğidir. Bu yöntem özellikle endodontik değerlendirmelerde önem kazanmakta ve klinisyenlerin kök kanalı morfolojisini incelemesine, periapikal lezyonları tanımlamasına ve tedavi sonrası periapikal dokuların durumunu değerlendirmesine olanak sağlamaktadır [62]. Şekil 2.2’de periapikal röntgen çeşidi ile ortaya çıkan diş röntgeni türü sunulmuştur.



Şekil 2.2. Periapikal röntgen görüntüsü [63]


Geleneksel periapikal radyografiler, sınırlamaları olmasına rağmen diş teşhisinde önemli bir rol oynamaktadır. Bu görüntülerin iki boyutlu olması, anatomik yapıların üst üste binmesine ve kritik ayrıntıların gizlenmesine yol açabilmektedir. Ayrıca, görüntü alımı sırasında açılanmadaki değişiklikler distorsiyona neden olarak tanısal doğruluğu etkileyebilmektedir. Dijital periapikal radyografinin ortaya çıkışı bu zorlukların birçoğunu ele almaktadır. Dijital sistemler, diş yapılarının

ayrıntılı incelenmesine yardımcı olan kontrast ve parlaklığın değiştirilmesi gibi işlem sonrası ayarlamalarla gelişmiş görüntü kalitesi sağlamaktadır. Ayrıca, dijital radyografi genellikle geleneksel film yöntemlerine kıyasla daha düşük radyasyon dozları içermektedir. Dijital görüntülerin anında elde edilebilmesi, teşhis sürecini de kolaylaştırarak hızlı klinik karar verme sürecini kolaylaştırmaktadır [64].

Son gelişmeler, yapay zekâ ve derin öğrenme tekniklerinin diş hekimliği radyografilerinin analizine dâhil edilmesini sağlamıştır. Özellikle bitewing radyografiler, dişler arası çürüklerin ve erken dönem patolojilerin tespitinde yapay zekâ destekli sistemlerle daha hızlı ve doğru bir şekilde analiz edilebilmektedir. Bu teknolojiler, klinisyenlere görsel inceleme sırasında gözden kaçabilecek ince detayları yakalama konusunda önemli bir destek sağlamaktadır. Benzer şekilde, periapikal radyografilerin analizinde de derin evrışimli sinir ağlarının uygulanması, periapikal lezyonların tespitinde tanısal doğruluğu artırmada umut verici sonuçlar ortaya koymuştur. Periapikal radyografilerin yorumlanması yüksek düzeyde uzmanlık gerektirmektedir, çünkü yanlış yorumlama yanlış teşhislere ve tedavi planlarına yol açabilmektedir. Yapay zekâ teknolojileriyle desteklenen dijital radyografiye geçiş, hem bitewing hem de periapikal görüntülemenin tanısal potansiyelini artırarak hasta sonuçlarının iyileştirilmesine katkıda bulunmaktadır [63, 65].

2.1.3. Konik Işınlı Bilgisayarlı Tomografi (KİBT)

KİBT, dental ve maksillofasiyal yapıların üç boyutlu görüntülenmesini sağlamaktadır. Bu görüntüleme yöntemi implantoloji, endodonti, ortodonti ve ağız cerrahisi dâhil olmak üzere çeşitli diş hekimliği uzmanlık alanlarında kullanılmaktadır. KİBT, anatomik yapıların değerlendirilmesini sağlayarak doğru teşhis ve tedavi planlamasını kolaylaştırmaktadır [66]. Şekil 2.3'te konik ışınlı bilgisayarlı tomografi röntgen çeşidi ile ortaya çıkan diş röntgeni türü sunulmuştur.



Şekil 2.3. Konik Işınlı Bilgisayarlı Tomografi röntgen görüntüleri. (A) aksiyal (B) koronal (C) sagittal (D) ortogonal görünüm [66]

İmplant işleminde KİBT, kemik kalitesini ve miktarını değerlendirmek, hayati anatomik işaretleri tanımlamak ve implant konumlandırmasını belirlemek için önem arz etmektedir. 3B görüntüler,

klinisyenlerin önerilen implant bölgeleri ile inferior alveolar sinir ve maksiller sinüs gibi komşu anatomik yapılar arasındaki uzamsal ilişkileri değerlendirmelerine ve böylece cerrahi riskleri en aza indirmelerine olanak tanımaktadır [67].

Endodontistler karmaşık kök kanalı anatomilerini incelemek, periapikal lezyonları tespit etmek ve tedavi sonuçlarını değerlendirmek için KIBT kullanmaktadırlar. Yüksek çözünürlüklü görüntüler, geleneksel iki boyutlu radyografilerde görülemeyen kök kırıklarının, ek kanalların ve diğer anormal durumların tanımlanmasını kolaylaştırmaktadır. Ortodontide KIBT, kraniyofasiyal morfoloji hakkında kapsamlı bilgi sağlayarak maloklüzyonların teşhisine ve bireyselleştirilmiş tedavi planlarının geliştirilmesine yardımcı olmaktadır. Ortodontik teşhis ve tedavi planlamasında kritik faktörler olan gömülü dişlerin kesin lokalizasyonuna ve hava boyutlarının değerlendirilmesine olanak sağlamaktadır [67].

KIBT, ayrıca eklem kemik bileşenlerinin ayrıntılı görüntüleri ile temporomandibular eklem (TME) bozukluklarının değerlendirilmesinde kullanılabilir. Bu durum, eklem morfolojisinin değerlendirilmesini, dejeneratif değişikliklerin tespit edilmesini kolaylaştırmakta ve TME patolojilerinin teşhisine yardımcı olmaktadır [67]. KIBT'nin avantajları arasında yüksek uzaysal çözünürlük, geleneksel BT'ye kıyasla nispeten düşük radyasyon dozu ve tüm boyutlarda tek tip görüntü kalitesi sağlayan izotropik voksellerle görüntü üretme yeteneği yer almaktadır. Hızlı tarama süreleri, hareket artefaktları olasılığını azaltarak görüntü netliğini artırmaktadır [68]. Devam eden teknolojik gelişmeler ile birlikte KIBT görüntüleme yapay zekâ uygulamaları, tanısal doğruluğu ve verimliliği artırmak için araştırılmaktadır [69].


2.1.4. Panoramik Radyografi

Panoramik radyografi, diş hekimliğinde yaygın olarak kullanılan bir görüntüleme yöntemidir ve maksillofasiyal bölgenin kapsamlı iki boyutlu genel görünümünü sağlamaktadır. Tüm diş yapısını, alveolar kemiği, TME ve çevresindeki anatomik yapıları tek bir görüntüde yakalayarak genel ağız sağlığının değerlendirilmesini kolaylaştırmaktadır. Bu görüntüleme tekniği özellikle gömülü dişler, süpernümerer dişler ve gelişimsel bozukluklar gibi dental anormal durumların tespitinde kullanılmaktadır. Periodontal kemik seviyelerinin değerlendirilmesine, kist ve tümörlerin tanımlanmasına ve maksiller sinüs patolojisinin değerlendirilmesine yardımcı olduğu bilinmektedir [70].

Panoramik radyografinin avantajları arasında geniş bir kapsama alanı, tam ağız içi radyografilere kıyasla düşük radyasyon dozu ve hızlı görüntü elde etme kolaylığı yer almaktadır. Dijital panoramik sistemler, anında görüntü kullanılabilirliği ve gelişmiş tanısal yorumlama için görüntü parametrelerini ayarlama yeteneği sunarak bu avantajları daha da geliştirebilmektedir [71].

Yapay zekâ uygulamaları, çürük ve periodontal hastalık gibi diş patolojilerinin tespit edilmesine ve anatomik işaretlerin tanımlanmasına yardımcı olabilmekte, böylece klinisyenleri tanısal karar

vermede destekleyebilmektedir [72]. Ayrıca, otomatik pozlama kontrolü ve gelişmiş görüntü işleme tekniklerine sahip dijital panoramik ünitelerin geliştirilmesi, görüntü netliği ve kontrastında önemli iyileşmelere yol açmıştır [71]. Şekil 2.4'te bu tez kapsamında elde edilen veri kümesinde bulunan panoramik radyografi örneği yer almaktadır.



Şekil 2.4. Panoramik röntgen görüntüsü

2.2. Diş Anatomisi

Diş anatomisinin kapsamlı bir şekilde anlaşılması, çeşitli ağız sağlığı durumlarının teşhis edilmesi ve yönetilmesi için önem arz etmektedir. Bu bölümde diş çürükleri, diş enfeksiyonları ve gömülü dişler olmak üzere üç kritik alan ele alınmaktadır.

2.2.1. Diş Çürükleri

Diş çürükleri, tüm yaş gruplarındaki bireyleri etkileyen sağlık sorunlarından bir tanesidir. Ağız boşluğunda bulunan bazı bakterilerin gıda parçacıklarının fermentasyonu sonucu ürettiği asitlerin dişin sert yapısını tahrip etmesi ile oluşmaktadır. Bu süreç, tedavi edilmediği takdirde dişin daha derin katmanlarına ilerleyebilen mine ve dentinin demineralizasyonu ile başlar. Zamanla lezyon genişleyebilir ve ciddi rahatsızlığa, kalıcı ağrıya ve ciddi vakalarda pulpa dokusunda canlılık kaybına neden olabilir. Diş çürümesinin ileri aşamaları apse oluşumu, sistemik enfeksiyonlar ve hatta diş kaybı gibi komplikasyonlara neden olabilmektedir. Bu durum, erken teşhisin ve bu durumun tedavisinde zamanında müdahalenin kritik önemini vurgulamaktadır [73].

Diş çürüğünün ilerlemesi farklı aşamalara ayrılabilir:

- İlk Demineralizasyon: Bakteriye metabolizmadan kaynaklanan asidik yan ürünler minere mineral içeriğinin kaybına yol açarak beyaz nokta lezyonları şeklinde kendini gösterir.
- Mine Çürümesi: Demineralizasyonun devam etmesi minenin parçalanmasına ve çürüklerin oluşmasına neden olur.
- Dentin Tutulumu: Tedavi edilmezse, çürük dentine nüfuz ederek hassasiyete ve ağrıya neden olur.
- Pulpal Tutulum: İlerlemiş çürükler diş pulpasına ulaşarak iltihaplanmaya (pulpitis) yol açar ve potansiyel olarak nekrozla sonuçlanır.

Çürük, başlangıç aşamasında tespit edildiğinde florür tedavisi ve beslenme alışkanlıklarının değiştirilmesiyle tekrar sertleşme sağlanabilmektedir. Bu gibi durumlarda erken teşhis ve müdahale büyük önem taşımaktadır. Ancak ilerlemiş çürükler genellikle dolgu veya kaplama gibi tedavilerle onarılır ve dişin işlevi ile estetiği geri kazandırılır. Görüntüleme teknolojilerindeki yenilikler, çürüğün erken aşamalarını tespit etmeyi kolaylaştırmış ve bu sayede daha az müdahale gerektiren tedavi yöntemlerini mümkün kılmıştır [74].

Dişlerin temiz tutulması, şekerli yiyecek tüketiminin sınırlandırılması ve düzenli diş muayenesi önleyici yöntemler olabilmektedir. Florür, dişleri güçlendirmeye ve zararlı bakterilerin aktivitesini azaltmaya yardımcı olduğu için diş çürümesini önlemenin önemli bir parçasıdır. Son çalışmalar ayrıca, çürümeye neden olan bakterilerin büyümesini azaltmak için probiyotik olarak bilinen yararlı bakterilerin kullanımını da inceleyerek bu yöntemlerin desteklenmesine vurgu yapmaktadır [75].

2.2.2. Diş Enfeksiyonları

Diş enfeksiyonları genellikle tedavi edilmemiş diş çürüğü, diş eti hastalığı veya diş yaralanması sonucu olarak ortaya çıkmaktadır. Ağızdaki bakteriler dişin iç katmanlarına veya çevreleyen dokulara girdiğinde ağrıya, şişmeye ve diğer sorunlara yol açabilir. Bu durum, genellikle bakteriyel etkenler tarafından tetiklenir ve tedavi edilmediği takdirde ciddi sağlık sorunlarına yol açabilir. Diş enfeksiyonlarının önlenmesi ve tedavisi, multidisipliner bir yaklaşım gerektiren karmaşık bir süreçtir. Bu bağlamda, diş enfeksiyonlarının tanı ve tedavisinde kullanılan çeşitli teknolojiler ve yöntemler üzerine yapılan araştırmalar, bu alandaki gelişmeleri anlamak açısından önem arz etmektedir [76].

Diş enfeksiyonlarının tedavi yöntemleri, enfeksiyonun türüne ve ciddiyetine bağlı olarak değişiklik göstermektedir. Dental implantların değerlendirilmesinde kullanılan BT yönteminin, implant yerleştirme öncesi diş enfeksiyonlarının tedavisinde önemli bir rol oynamaktadır. Ayrıca, diş enfeksiyonlarının tedavisinde antibiyotik kullanımı da yaygın bir uygulama olmaktadır [77]. Diş enfeksiyonlarının yaygın nedenleri arasında sistemik hastalıklar bulunmaktadır. Diş enfeksiyonu olan hastalarda diyabet ve diğer risk faktörlerinin prevalansı incelendiğinde diyabetin diş enfeksiyonları ile yüksek oranda ilişkili olduğu görülmektedir [78]. Diş enfeksiyonlarının tedavisi

genellikle enfeksiyonun kaynağının ele alınmasıyla başlar. Bu süreç, enfekte bölgeyi kök kanal prosedürüyle temizlemeyi veya etkilenen dişi çıkarmayı içerebilir. Enfeksiyonu kontrol etmeye yardımcı olmak için antibiyotikler reçete edilebilir, ancak bakterinin kaynağını ortadan kaldırmadıkları için tek başına bir tedavi olarak kullanılmazlar. Diş enfeksiyonlarının erken teşhis ve tedavisi, komplikasyonlardan kaçınmak ve ağız sağlığını korumak açısından önem arz etmektedir [79].

2.2.3. Gömülü Dişler

Gömülü dişler, genellikle dişlerin normal pozisyonlarına ulaşmadan çene içinde kalmalarıyla karakterize olmalarından kaynaklanmaktadır. Bu durum, çeşitli sebeplerden kaynaklanabilir ve tedavi yöntemleri, dişin konumuna ve hastanın genel sağlık durumuna bağlı olarak değişiklik gösterebilir. Gömülü dişlerin tespiti ve tanısı, modern görüntüleme teknikleri ve klinik değerlendirmelerle yapılmaktadır. Gömülü dişlerin en yaygın sebeplerinden biri, dişlerin çene yapısının yetersizliği veya dişlerin normal gelişim sürecinde yaşanan anormalliklerdir. Özellikle üçüncü molar dişler (yirmilik dişler) sıklıkla gömülü kalma eğilimindedir [80].

Gömülü dişlerin tedavi yöntemleri, genellikle cerrahi müdahale gerektirir. Cerrahi olarak gömülü dişin açığa çıkarılması ve ortodontik mekanizmaların uygulanması, dişin diş arkına hizalanması için kritik öneme sahip olmaktadır. Bu süreç, dişin destekleyici yapılarında hasar riskini artırabilmekte ve tedavi süresini uzatabilmektedir. Erken teşhis ve müdahale, tedavi sürecinin başarısı açısından hayati öneme sahip olmaktadır [81].

Gömülü dişlerin tespiti, genellikle panoramik röntgenler ve diğer görüntüleme teknikleri ile yapılmaktadır. Gömülü dişlerin yönetimi, multidisipliner bir yaklaşım gerektirmekte ve erken tanı ile müdahale, tedavi sürecinin başarısını artırmaktadır [82].

2.3. Görüntü Segmentasyon Teknikleri

Yapay zekâ, çeşitli karmaşık zorlukların üstesinden gelmek için gelişmiş ve esnek yaklaşımlar sunarak görüntü işleme metodolojilerini dönüştürmede etkili rol oynamıştır. Bu gelişmeler nesne algılama, sınıflandırma ve özellikle segmentasyon gibi görevlerde önemli ilerlemeler kaydedilmesini kolaylaştırmıştır. Görüntü işlemede yapay zekânın evrimi, geleneksel yöntemlere kıyasla karmaşık görsel verileri gelişmiş bir hassasiyetle yorumlama ve analiz etme becerisiyle karakterize edilmektedir. Geleneksel görüntü işleme teknikleri genellikle kapsamlı manuel müdahale ve alan uzmanlığı gerektiren kural tabanlı veya sezgisel modellere dayanmaktadır. Ancak, yapay zekâ tabanlı yaklaşımlar, dikkate değer düzeyde doğruluk ve uyarlanabilirlik elde etmek için başta derin öğrenme çerçeveleri olmak üzere veri odaklı algoritmalarla yararlanmaktadır. Anlamlı analizi kolaylaştırmak için bir görüntüyü farklı bölgelere veya nesnelere

ayırma işlemi olan görüntü segmentasyonu, görsel verilerden anlamlı ve eyleme geçirilebilir içgörülerin çıkarılmasını sağlayan çok önemli bir süreç olarak ortaya çıkmıştır. Bu süreç, içgörülerin elde edilmesinde ve yüksek hassasiyet ve doğruluk gerektiren görevlerin yerine getirilmesinde çok önemli bir rol oynamaktadır. Tıbbi görüntülerdeki anormalliklerin tespit edilmesi, otonom araçlardaki nesnelerin tanımlanması ve endüstriyel ürünlerdeki kusurların izlenmesi gibi doğru ve güvenilir sonuçlar gerektiren uygulamalar için gerekli olmaktadır. Segmentasyon yönteminin seçimi, hesaplama kaynakları, istenen doğruluk ve uygulamanın özel gereksinimleri gibi faktörlere bağlı olmaktadır. Uygulamanın hız, doğruluk veya hesaplama verimliliği gibi gereksinimlerine bağlı olarak çeşitli segmentasyon teknikleri kullanılabilmektedir [83]. Bu bölümde, başlıca segmentasyon stratejileri ele alınmaktadır.

2.3.1. Bölge Tabanlı Segmentasyon Yöntemleri

Bölge tabanlı yöntemler, bir görüntü içindeki belirli ilgi alanlarını tanımlamaya odaklanır ve görüntüdeki nesneleri tanımlamak için belirli bölgeleri analiz eder. Bu yöntemler sınırlayıcı kutular veya tanımlanmış bölgeler içerir, bu durum onları nesne algılama ve örnek segmentasyon görevleri için etkili kılmaktadır [84]. Bu bölümde öne çıkan bölge tabanlı segmentasyon yöntemleri ve bunların avantajları ve sınırlamaları anlatılmaktadır.

B-ESA

Bölge tabanlı Evrişimsel Sinir Ağları (B-ESA), görüntülerdeki ilgi alanlarını belirlemek ve sınıflandırmak için evrişimsel sinir ağlarından yararlanan veri odaklı bir çerçeve sunmaktadır. B-ESA, bir görüntüdeki nesneleri sistematik olarak konumlandırmak ve sınıflandırmak için tasarlanmış çok aşamalı bir işlem hattı aracılığıyla çalışmaktadır. İlk aşama, seçici bir arama algoritması kullanarak bölge önerileri oluşturmayı içermektedir. Bu öneriler, ilgili nesneleri içeren sınırlayıcı kutuları tanımlamaktadır. Sonraki aşamada, her bir sınırlayıcı kutu içindeki görüntü sabit bir boyuta yeniden boyutlandırılarak özellik çıkarımı için ESA'dan geçirilmektedir. Son olarak, genellikle DVM kullanılarak uygulanan bir sınıflandırıcı, önerilen her bölge içindeki nesnelerin varlığını ve kategorisini belirleyebilmektedir. Bölge önerme tekniklerini derin öğrenme ile birleştiren B-ESA, geleneksel nesne algılama yöntemleri ile modern sinir ağı mimarileri arasındaki boşluğu başarıyla doldurabilmektedir. Ayrıca bölge önerme, özellik çıkarma ve sınıflandırma için ayrı aşamalara güvenmek, önemli hesaplama ek yüküne neden olmaktadır [85].

DHB-ESA

DHB-ESA, özellik çıkarma ve sınıflandırmayı uçtan uca bir çerçeveye entegre ederek fazlalığı azaltmakta yaklaşımını daha da geliştirerek geleneksel seçim arama algoritması yerine doğrudan ESA çerçevesi içinde bölge önerileri oluşturan bir RPN (Bölge Öneri Ağı) sunarak özellik çıkarma

sürecinin bir parçası olarak bölge önerilerinin oluşturulmasını sağlamıştır. Bölge önerileri doğrudan ESA'ya uygulanmak yerine, görüntü önce ESA'ya uygulanır ve elde edilen özellik haritası üzerinden bölge önerileri çıkarılır. Bu durum, hesaplama yükünü azaltmakta ve işlem hızını iyileştirebilmektedir. Böylece bu yöntemi yüksek doğruluk ve verimlilik gerektiren görevler için tercih edilen bir seçenek haline getirmektedir [86].

Maskeli B-ESA

Maskeli B-ESA (Maskeli Bölgesel Evrişimsel Sinir Ağları), nesne algılama çerçevesine örnek segmentasyon yetenekleri eklemek için tasarlanmış DHB-ESA'nın önemli bir uzantısını temsil etmektedir. Sınırlayıcı kutulara ve sınıf etiketlerine ek olarak piksel düzeyinde nesne maskelerini tahmin ederek algılama işlem hattını geliştirir. Bu katman, tıbbi görüntüleme, robotik ve otonom sistemler gibi hassas nesne tanımlama gerektiren görevlerde uygulanmasını sağlamaktadır. Maskeli B-ESA'nın mimarisi, maske tahminine adanmış paralel bir dal ekleyerek elde edilmiştir. DHB-ESA RPN kullanarak nesneleri tespit etmeye ve sınırlayıcı kutuları iyileştirmeye odaklanırken, Maskeli B-ESA her nesne için ikili bir maske tahmin eden küçük, FCN ekler. Bölge hizalama ile ilgili zorlukları aşmak için Maskeli B-ESA, İlgi Bölgesi (RoI) Hizalama işlemini sunmaktadır. Niceleme hatalarına neden olabilen DHB-ESA'daki orijinal RoI Pooling'in aksine RoI Align, bilineer enterpolasyon kullanarak uzamsal hizalamayı korur. Bu değişiklik, özellikle küçük veya ince taneli nesneler için maske tahmin doğruluğunu önemli ölçüde artırmaktadır [87].

YOLO

You Only Look Once (YOLO), görüntüyü bir ızgaraya bölerek sınırlayıcı kutuları ve sınıf olasılıklarını aynı anda tahmin etmektedir. YOLO'nun birleşik mimarisi uçtan uca optimizasyonu kolaylaştırarak hem işlem hızında hem de tahmin doğruluğunda iyileştirmelere katkıda bulunur. YOLO modeli, giriş görüntüsünü bir $S \times S$ ızgarasına bölerek her bir ızgara hücresine B sınırlayıcı kutularını, güven puanlarını ve sınıf olasılıklarını tahmin etme sorumluluğu verilir. Güven puanı, modelin bir sınırlayıcı kutunun bir nesne içerdiğine dair tahminini ve sınırlayıcı kutu tahmininin kesinliğini yansıtır. Bu tasarım, YOLO'nun görüntüyü bütünsel olarak analiz etmesine ve tahminlerde bulunurken bağlamsal bilgileri dâhil etmesine olanak tanır. YOLO'nun en önemli özelliklerinden biri işlem hızı olarak bilinmektedir. Temel YOLO modeli görüntüleri saniyede 45 kare hızında işleyebilir ve daha küçük bir versiyon olan Hızlı YOLO saniyede 155 kareye kadar hızlara ulaşabilmektedir. Bu performans seviyesi, YOLO'nun otonom sürüş ve video gözetimi gibi neredeyse gerçek zamanlı işleme gerektiren uygulamalar için çok uygun olabileceğini göstermektedir. Avantajlarına rağmen, YOLO'nun bazı sınırlamaları bulunmaktadır. Bazı tespit sistemlerine kıyasla daha fazla lokalizasyon hatası yaptığı ve görüntülerdeki küçük nesneleri doğru bir şekilde tespit etmede zorluklarla karşılaştığı gözlemlenmiştir [88].

2.3.2. Piksel Tabanlı Segmentasyon Yöntemleri


Piksel tabanlı yöntemler, bir görüntüdeki her pikseli analiz ederek her bir pikseli segmente etmeye odaklanmaktadır. Bu durum görüntüdeki tüm piksellerin bir kategoriye atanmasını sağlayarak daha ayrıntılı segmentasyon gerektiren durumlar için uygun hale getirmektedir. Piksel düzeyinde bilgi sağlayarak, özellikle semantik segmentasyon ve yoğun nesne algılama uygulamalarında avantaj sunmaktadır [89].

UNet

FCN'ler ailesine ait olan UNet, ilk olarak biyomedikal görüntülerin segmentasyonunda uygulanmıştır. Mimarinin küçük veri kümeleriyle yüksek hassasiyet sunma yeteneği, onun tıbbi görüntüleme araştırmalarında tercih edilmesine sebep olmaktadır. Daralma yolu ve genişleme yolu olmak üzere birbirine bağlı iki bileşen etrafında toplanmıştır. Bu bileşenler, bağlamsal bilgileri çıkarmak ve görüntüler içinde doğru konumlandırma sağlamak için birlikte çalışmaktadır [90].

UNet mimarisi, adını aldığı 'U' şeklindeki tasarıma benzeyen simetrik bir yapı sergilemektedir. Genellikle kodlayıcı olarak adlandırılan daralma yolu, özellik çıkarma işleminden sorumlu olmaktadır. Bu yol, bir dizi evrimsel katmandan oluşmakta ve her birinin ardından Doğrultulmuş Lineer Birim (ReLU) gibi bir aktivasyon fonksiyonu ve bir maksimum havuzlama işlemi gelmektedir. Bu adımlar, özellik haritalarının derinliğini artırırken uzamsal çözünürlüğü kademeli olarak azaltarak ağın üst düzey soyut özellikleri yakalamasını sağlamaktadır [90]. Öte yandan, genişleyen yol veya kod çözücü, orijinal girdinin uzamsal çözünürlüğünü yeniden oluşturmak için özellik haritalarını yukarı örneklemekle görevli olmaktadır. Bu, kodlayıcıda gerçekleştirilen uzamsal indirgemeyi tersine çeviren transpoze evrimsel yollarla elde edilmektedir. UNet'in ayırt edici bir özelliği, kodlayıcı ve kod çözücüdeki ilgili katmanları doğrudan birbirine bağlayan atlama bağlantılarını kullanmasıdır. Bu bağlantılar, kenarlar ve dokular gibi düşük seviyeli özelliklerin kodlayıcıdan kod çözücüye aktarılmasını kolaylaştırır, böylece ince taneli uzamsal ayrıntıları korur ve genel segmentasyon doğruluğunu artırır [91].


UNet mimarisi çok çeşitli biyomedikal görüntüleme görevlerinde yaygın olarak kullanılmaktadır. Tümör segmentasyonu, organ tanımlama ve hücre yapısı analizi gibi alanlarda iyi performans göstermektedir. Hesaplama verimliliğini korurken ilgilenilen bölgeleri doğru bir şekilde segmentlere ayırma yeteneği, gerçek zamanlı veya gerçek zamana yakın analizin gerekli olduğu klinik ortamlarda önemli bir avantaj oluşturmaktadır [92]. UNet mimarisine ait detaylar Şekil 2.5'te sunulmuştur.



Şekil 2.5. UNet ağ mimarisi [90]

Attention UNet


Attention UNet, UNet'in klasik kodlayıcı-kod çözücü yapısını korumaktadır. Kodlayıcı, evrimsel ve havuzlama katmanları aracılığıyla özellik çıkarırken, kod çözücü bu özellikleri yukarı örnekleyerek segmentasyon haritasını yeniden yapılandırır. Tıbbi görüntüleme görevlerinde segmentasyon hassasiyetini artırmak amacıyla Dikkat Geçidi (AG) eklenerek geleneksel UNet mimarisi geliştirilmiştir. AG'ler, ilgili kodlayıcı ve kod çözücü katmanları arasındaki atlama bağlantılarına gömülüdür. Bu kapılar hem kodlayıcının özellik haritalarından hem de kod çözücünün yukarı örneklenmiş çıktılarından girdi alarak hangi kodlayıcı özelliklerinin mevcut kod çözme aşamasıyla alakalı olduğunu öğrenmelerini sağlamaktadır. Bu mekanizma, ağın farklı şekil ve boyutlardaki hedef yapılara odaklanmasını sağlayarak segmentasyon performansını artırmaktadır [93]. Attention UNet mimarisine ait detaylar Şekil 2.6'da sunulmuştur.



Şekil 2.6. Attention Unet model mimarisi [93]

R2U-Net

R2U-Net, özellik çıkarma ve segmentasyon performansını artırmak için tekrarlayan bağlantıları (recurrent connections) ve artık blokları (residual blocks) yapısına dâhil eden geleneksel UNet mimarisinin gelişmiş bir çeşididir. UNet'in klasik kodlayıcı-kod çözücü yapısını temel alırken, bağlamsal bilgileri yakalamak ve derin ağlarda sıklıkla karşılaşılan kaybolan gradyan probleminden kaçınmak için yeni yaklaşımlar sunmaktadır. R2U-Net'in kodlayıcı yolu, evrimsel katmanın girişinin çıkışına eklenerek kısayol bağlantısı oluşturduğu artık blokları kullanır. Bu artık bloklar, modelin kimlik eşlemelerini öğrenmesini sağlayarak gradyan bozulmasını azaltmakta ve daha derin ağların eğitimi kolaylaştırmaktadır. Kodlayıcıdan kod çözücüye atlama bağlantıları korunarak düşük seviyeli uzamsal özelliklerin daha yüksek çözünürlüklü katmanlara aktarılması sağlanmaktadır [94]. R2U-Net mimarisine ait detaylar Şekil 2.7'de sunulmuştur.




Şekil 2.7. R2U-Net model mimarisi [94]

U2-Net

U2-Net, özellik çıkarımı için önceden eğitilmiş omurgalara dayanan geleneksel mimarilerin aksine hem derinlik hem de yüksek çözünürlüklü özellik haritalarını elde etmesini sağlayan artık U-blokları (RSU) ile tasarlanmıştır. Özellik haritalarını aşamalı olarak yükseltir ve bunları atlama bağlantıları aracılığıyla ilgili kodlayıcı çıktılarıyla birleştirir. Bu bloklar, her aşamada evrimsel katmanları UNet benzeri yapılarla birleştirerek çok ölçekli özellik çıkarımını geliştirir. Özellik haritaları kodlayıcıda ilerledikçe, uzamsal çözünürlükleri azalırken anlamsal derinlikleri artar ve


küresel bağlamı etkili bir şekilde yakalar. Kod çözücü, beş aşamalı RSU ile kodlayıcı yapısını yansıtır. Özellik haritalarını aşamalı olarak yükseltir ve bunları atlama bağlantıları aracılığıyla ilgili kodlayıcı çıktılarıyla bütünleştirir. Her kod çözücü aşamasında ve son kodlayıcı aşamasında, belirginlik olasılığı haritaları (Saliency Map Fusion) oluşturulmaktadır. Bu haritalar daha sonra 1×1 evrişimsel katman ile birleşmektedir [95]. U2-Net mimarisine ait detaylar Şekil 2.8’de sunulmuştur.



Şekil 2.8. U2-Net model mimarisini [95]

UNet 3+

UNet 3+, tam ölçekli atlama bağlantıları ile derin süpervizyon kullanarak çok ölçekli özellik haritalarını birleştiren klasik UNet mimarisini gelişmiş hali olarak ifade edilmektedir. Sınıflandırma Tabanlı Modül (CGM), giriş görüntünün hedef nesneyi içerip içermediğini tahmin etmekte ve segmentasyon sonuçlarını buna göre ayarlamaktadır. Tam Ölçekli Atlama Bağlantıları: tüm kodlayıcı ve kod çözücü seviyelerinden özellik haritalarını toplamaktadır. Bu yaklaşım, daha düşük seviyeli katmanlardan gelen ince taneli ayrıntıları daha derin katmanlardan gelen yüksek seviyeli anlamsal bilgilerle birleştirir. Derin denetimle, kod çözücü aşaması, gerçek tarafından denetlenen segmentasyon tahminleri çıkarılarak sınır hassasiyetini artırılmaktadır [96] . UNet3+ mimarisine ait detaylar Şekil 2.9’da sunulmuştur.



Şekil 2.9. Unet 3+ model mimarisi [96]

V-Net

V-Net, 3B tıbbi görüntü segmentasyonu için tasarlanmış tam evrişimli sinir ağı olarak ifade edilmektedir. Geleneksel 2B yöntemlerden farklı olarak, V-Net tüm 3B hacmi işleyerek boyutlar arası uzamsal bağımlılıkları yakalar. Kodlayıcı bölümünde 3B evrişimler ve artık bağlantılarla özellik çıkarılırken, kod çözücü bölümünde ters evrişimler ve atlama bağlantıları ile segmentasyon haritası yeniden oluşturulur [97].


PSPNet

Piramit Sahne Ayrıştırma Ağı (PSPNet), birden fazla ölçekte bağlamsal bilgiyi yakalamak için piramit havuzlama modülü kullanan anlamsal segmentasyon modeli olarak tanımlanmaktadır. PSPNet, küresel ve yerel bağlamsal özellikleri entegre ederek sahne ayrıştırma, çevre izleme ve tıbbi görüntüleme gibi çeşitli uygulamalarda segmentasyon doğruluğunu artırmayı amaçlamaktadır. PSPNet mimarisi, özellik çıkarma ağı yapıları kullanır ve genellikle ResNet veya DenseNet olarak adlandırılan bir omurga ağı üzerine inşa edilmiştir. Bu özellik haritaları, PSPNet'in ayırt edici özelliklerinden biri olan piramit havuzlama modülü aracılığıyla işlenmektedir. Farklı seviyelerdeki bu özellik haritaları bilineer enterpolasyon yoluyla yukarı örneklemeye tabi tutulur ve ardından birleştirilir. Ağ, piramit havuzlama modülü sayesinde bağlamsal bilgileri öğrenme yeteneğine sahiptir. Piramit havuzlama modülü, genellikle 1×1 , 2×2 , 3×3 ve 6×6 olmak üzere birden fazla ızgara ölçeğinde havuzlama işlemleri gerçekleştirmektedir. Havuzlama ile boyutu azaltmak için 1×1 evrişimsel işlem uygulanır. Piramit ağırlıklandırma modülünü kullanarak farklı bağlamlardan gelen bilgileri birleştirerek yüksek derecede doğruluk elde etmeyi amaçlayan anlamsal segmentasyon haritası PSPNet'i üretmek için bir evrişimsel katman kullanılmaktadır. Bir ESA türü olan PSPNet, farklı boyutlardaki özellikleri ayrıştırabilmektedir. Böylece farklı

ölçeklerdeki bilgileri birleştirerek nesnelerin daha doğru tanınmasını sağlayabilmektedir. PSPNet'in çok ölçekli özellikleri bir araya getirme yeteneği, bağlamsal öğrenme yeteneklerini geliştirerek farklı boyutlarda olan nesneler içeren sahneleri bölümlere ayırabilmektedir [98]. Bu özellik, PSPNet'i nesne deformasyonu ve uzamsal ölçekteki değişimleri ele almak için uygun hale getirmektedir. Benzer şekilde PSPNet, çok ölçekli bağlamsal bilgileri birleştirerek yüksek çözünürlüklü görüntüleri uzaktan algılama ile tarım alanlarının tanımlanmasını da sağlayabilmektedir [99].

$$R = \sum (Mi + Ni) \otimes Ki \quad C \quad i=1 \quad (2.1)$$

Denklem 2.1, önceden eğitilmiş özellik haritaları Mi ve normalleştirme haritaları Ni ile bunlara karşılık gelen öğrenilmiş matrisler Ki 'nin eleman bazında çarpımını toplayarak PSPNet modelinin çıktısını hesaplar; burada i , 1 ile toplam sınıf sayısı C arasında değişir. PSPNet mimarisine ait detaylar Şekil 2.10'da sunulmuştur.



Şekil 2.10. PSPNet model mimarisi [98]


FPN

Özellik Piramidi Ağı (FPN), nesne algılama ve görüntü segmentasyonu gibi alanlarda görüntülerin birden fazla ölçekte analizini geliştirmek için tasarlanmış bir derin öğrenme mimarisi olarak ifade edilmektedir. Ağın farklı seviyelerinden gelen bilgileri entegre eden bir özellik piramidi oluşturarak farklı boyutlardaki nesneleri tespit etme zorluğunu ele almaktadır. Bu durum, modelin hem ince

taneli hem de üst düzey anlamsal özellikleri yakalamasını sağlayarak girdi görüntüsünün kapsamlı bir şekilde anlaşılmasını sağlamaktadır [100].

FPN, farklı ölçeklerdeki özellik haritalarını aşağıdan yukarıya yollar ve yanıl bağlantılarla birleştirerek bir özellik piramidi oluşturur. FPN mimarisi aşağıdan yukarıya yol ve yukarıdan aşağıya yol olmak üzere iki temel bileşene dayanmaktadır. FPN'de aşağıdan yukarıya yol, görüntünün derin evrişimsel ağ altyapısından elde edilen özellik haritalarından oluşmaktadır. Bu haritalar, ResNet tabanlı modellerde “C2, C3, C4 ve C5” olarak adlandırılan ağın farklı aşamalarından elde edilen çıktıları ifade etmektedir. Bu seviyeler, C2'nin düşük seviyeli ayrıntıları yakalaması ve C5'in yüksek seviyeli, anlamsal bilgilere odaklanmasıyla daha derin özellikleri temsil eder [100, 101].

Buna karşılık, yukarıdan aşağıya yol, daha derin, anlamsal olarak daha zengin özellik haritalarını yukarı örnekleyerek uzamsal çözünürlüğü artırmayı amaçlamaktadır. Bu süreç sırasında, yanıl bağlantılar aşağıdan yukarıya yolundaki özellik haritalarını yukarıdan aşağıya yolundaki karşılık gelen daha yüksek çözünürlüklü haritalarla birleştirir. Bu yanıl bağlantılar, kanal sayısını azaltmak ve farklı yollardan gelen özellik haritalarının birleştirilebilmesini sağlamak için evrişimsel işlemleri içermektedir. Özellikle RPN ve HB-ESA gibi sistemlerde FPN'nin özellik piramidi, farklı boyut ve ölçeklerdeki nesnelerin daha iyi kapsanmasını sağlamaktadır. FPN, farklı ölçeklerdeki özelliklerin çıkarılmasını sağlar ve bu özellikleri entegre ederek ağın öğrenme yeteneğini artırır [102, 103]. FPN mimarisine ait detaylar Şekil 2.11'de sunulmuştur.

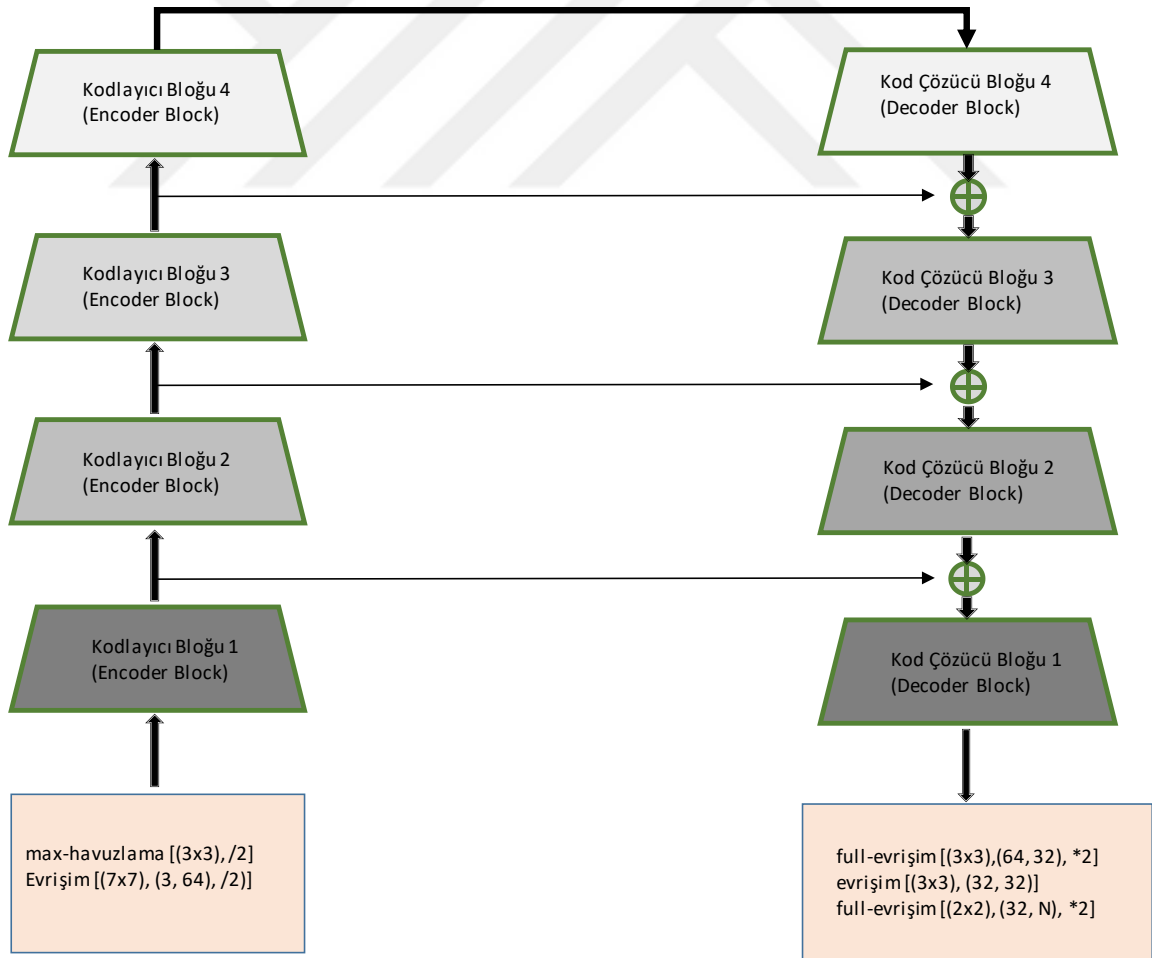


Şekil 2.11. FPN model mimarisi [100]

LinkNet

LinkNet, ağı, hesaplama verimliliğini korurken doğru segmentasyon sonuçları elde etmek için evrişimsel katmanlar, alt örnekleme ve üst örnekleme mekanizmalarından yararlanmaktadır. Her bir evrişimsel katmanı toplu normalizasyon ve ReLU aktivasyon fonksiyonu takip ederek eğitim sırasında kararlılığı sağlamakta ve ağın yakınsamasını iyileştirmektedir. LinkNet, giriş görüntüsünden hiyerarşik özellikleri çıkarmak için bir kodlayıcı ve bu özellikleri orijinal çözünürlüğün bir segmentasyon haritasına yeniden yapılandırmak için bir kod çözücü kullanmayı içermektedir. Bu süreç, kodlayıcıyı kod çözücüye doğrudan bağlayan atlama bağlantıları aracılığıyla

ara özellikleri kodlayıcıdan kod çözüciye doğrudan aktarır. Atlama bağlantılarının kullanımı, ağın daha derin özellikleri öğrenmesini ve ardından bu özellikleri doğru segmentasyon elde etmek için kullanmasını sağlamaktadır. Bu bağlamda, LinkNet, ara özellikleri kod çözüciye aktarmak için hızlı bir yol sunarak, ağın özellik haritalarını hızlı bir şekilde dönüştürme olasılığını arttırmaktadır. Bu yapı, alt örnekleme ($/2$) ve üst örnekleme ($*2$) işlemleri ile birlikte, her bir evrişimsel katmanı takip eden toplu normalizasyon ve ReLU aktivasyon fonksiyonları kullanmaktadır. LinkNet'in kodlayıcı kısmı, 3×3 maksimum havuzlama kullanarak 7×7 boyut ve adım 2 ile başlar. Bu yapı, ResNet18 gibi daha hafif ancak daha üstün bir kodlayıcı olarak hizmet vermektedir. ResNet18, derin öğrenme alanında yaygın olarak kullanılan bir mimari olup, derinlik ve performans arasında bir denge kurarak daha karmaşık özelliklerin öğrenilmesine olanak tanımaktadır. Ağın bir kodlayıcı olarak ResNet18'e dayanması, ResNet18'in derinlik ve parametre verimliliği arasında iyi bir denge sunması nedeniyle bu tür uygulamalar için uygunluğunu daha da güçlendirmektedir. Ek olarak, kodlayıcı, kaybolan gradyan problemi için daha derin ağ mimarilerini kolaylaştıran artık blokları içermektedir [104]. LinkNet mimarisine ait detaylar Şekil 2.12'de sunulmuştur.



Şekil 2.12. LinkNet model mimarisi [104]

2.3.3. Omurga Modelleri

Omurga modeller derin öğrenmede, özellikle bilgisayarlı görüde, çoğunlukla büyük bir veri kümesi üzerinde eğitilmiş ve genel özellikleri öğrenmiş, birincil özellik çıkarıcılar olan ağ yapılarıdır [105]. Büyük veri kümeleri üzerinde önceden eğitilen bu modeller segmentasyon, genel nesne tanıma, sınıflandırma ve özellik çıkarma gibi görevlerde yaygın olarak kullanılmaktadır. Uygun bir omurga modelinin seçilmesi, genel sistemin performansını ve verimliliğini önemli ölçüde etkileyebilmektedir. Önceden eğitilmiş bir omurga modeli kullanmak transfer öğrenme avantajları sağlamaktadır. Bu transfer öğrenme, genel özelliklerin zaten öğrenilmiş olduğu ve öğrenme sürecinin daha hızlı ve verimli bir şekilde gerçekleşebileceği anlamına gelmektedir. Özellikle segmentasyonda, önceden eğitilmiş bu modeller daha az etiketli veri ile yüksek performans elde edilmesini sağlamaktadır. Bu modellerin başarısı, belirli bir segmentasyon görevi için uygunlukları ve performansları değerlendirilirken dikkate alınması gerekmektedir. Bu nedenle, omurga modellerinin dikkatli bir şekilde seçilmesi ve uygulanması, görüntü segmentasyonunun genel performansını önemli ölçüde etkileyebilmektedir. Omurga modelleri, öğrenilen genel özelliklerden yararlanarak daha az hesaplama ile yüksek performans elde edebilmektedir [106].

VGG

VGG (Görsel Geometri Grubu), derinliğin artırılmasıyla daha iyi özellik çıkarımı sağlamak amacıyla tasarlanmıştır. Mimari, derinliği artırmak için istiflenmiş bir dizi 3x3 evrişimli katman ve ardından uzamsal azaltma için maksimum havuzlama katmanları kullanmaktadır. Bu tasarım, ağırlı derin hiyerarşik temsiller aracılığıyla karmaşık özellikleri yakalamasını sağlamaktadır. VGG-11 ve VGG-16 gibi versiyonları, derin öğrenme yöntemleri ile yaygın olarak kullanılmaktadır. VGG16 nispeten basit bir mimari sergilemekte ancak daha az parametre ile bile yüksek doğruluk elde edebilmektedir [46]. Orijinal VGG modelleri olan VGG16 ve VGG19, sırasıyla 16 ve 19 ağırlık katmanı içermektedir. VGG16 ve VGG19, genelleştirilebilir özellikleri öğrenme yetenekleri nedeniyle transfer öğrenmede yaygın olarak kullanılmaktadır. Bununla birlikte, mimarilerinin basitliği bir değiş tokuşla birlikte gelmekte: modeller hesaplama açısından pahalı, önemli bellek ve işlem gücü gerektirmektedir [107].

ResNet

ResNet, derin ağların eğitiminde karşılaşılan kaybolan gradyan problemini çözmek için tasarlanmış bir mimari olarak ifade edilmektedir. Artık bağlantılar içeren ResNet, gradyanların belirli katmanları atlmasına izin vererek derinliği önemli ölçüde artırılmış ağların eğitimini kolaylaştırmaktadır. Artık bağlantılar, kaybolan gradyanlarla ilgili sorunları etkili bir şekilde azaltarak 100 katmanı aşan ağların performans düşüşü olmadan eğitilmesini sağlamaktadır. ResNet'teki en önemli yenilik, geriye yayılma sırasında gradyanın belirli katmanları atlmasına izin

veren artık bağlantıların kullanılmasıdır. Bu mimari, ResNet50 ve ResNet101 gibi derin ağların performans düşüşü olmadan eğitilmesini kolaylaştırır. ResNet50, ResNet modelinin bir versiyonudur ve daha derin ağlardaki optimizasyon sorunlarını ele almak için atlama bağlantıları içermektedir. Atlama bağlantılarının dâhil edilmesi optimizasyonu geliştirerek ağın daha verimli bir şekilde öğrenmesini sağlamaktadır [108].

Inception

Inception mimarisi, her modülde çok dallı bir yapı kullanarak ağın aynı anda birden fazla ölçekte bilgi işlemesine olanak tanımaktadır ve farklı boyutlarda filtrelerin aynı katmanda kullanılmasına olanak tanıyarak, modelin daha esnek ve güçlü olmasını sağlamaktadır. Bu tasarım, çeşitli özelliklerin yakalanmasını sağlayarak modelin karmaşık örüntüleri tanıma becerisini artırmaktadır. Inception-v3 ve Inception-v4 gibi versiyonları, çarpanlara ayrılmış evrişimler ve azaltılmış ızgara boyutu gibi optimizasyonlar getirerek mimarinin yeteneklerini daha da geliştirmiştir [109]. InceptionV3, paralel olarak işlenen farklı ölçeklerdeki özellik haritalarını birleştirerek karmaşık bilgileri daha etkili bir şekilde temsil ederken, InceptionResNetV2 modeli Inception mimarisini daha derin ağlarla birleştirerek daha fazla derinlik ve verimlilik sağlar [110].

ResNeXt

ResNeXt, gruplandırılmış evrişimler kullanarak doğruluğu ve verimliliği artırmak için tasarlanmış evrişimsel sinir ağı mimarisi olarak ifade edilmektedir. Bir yapı bloğunu birden çok kez tekrarlayan modüller bir tasarım sunar ve her blok girişi paralel evrişimsel yollarla işler. Ağın derinliğini veya genişliğini artırmaya odaklanan ResNet'in aksine, ResNeXt doğruluğu artırmak için çok dallı topolojiyi vurgular. ResNeXt'teki her dal, girdi üzerinde dönüşümler gerçekleştirir ve çıktıları toplanarak modelin hesaplama verimliliğini korurken çeşitli özellik temsillerini öğrenmesine olanak tanımaktadır [111].

DenseNet

DenseNet, her katmanı ileri beslemeli bir şekilde diğer tüm katmanlara bağlamaktadır. Bu model, katmanlar arasında maksimum bilgi akışı sağlayarak özelliklerin yeniden kullanımını ve gradyan yayılımını iyileştirir. DenseNet'in, diğer mimarilere göre daha az parametre ile daha iyi performans sağlayabilmektedir. Bu özellik, DenseNet'in özellikle sınırlı veri setleri ile çalışırken avantaj sağladığını göstermektedir. DenseNet121 ve DenseNet169 gibi versiyonları bulunmaktadır. Bunlardan DenseNet121, katmanlar arasındaki yoğun bağlantılarıyla bilinen, özelliğin yeniden kullanımını kolaylaştıran ve parametre verimliliğini artıran her iki evrişimli sinir ağı mimarisidir [112].

Squeeze-and-Excitation Modeli

SE modeli, her bir özellik haritasının önemini öğrenerek, ağı daha etkili bir şekilde çalışmasına ve kanal bazında özelliklerin yeniden kalibrasyonuna odaklanmaktadır. SE blokları, kanallar arasındaki karşılıklı bağımlılıkları modelleyerek özellik yanıtlarını uyarlamalı olarak yeniden kalibre etmekte ve ağı temsil kapasitesini artırmaktadır. SEResNeXt50 modeli ResNeXt ile birleşimi ile oluşturulmuştur [113].

EfficientNet

EfficientNet, bir dizi sabit ölçeklendirme katsayısı kullanarak ağ derinliğini, genişliğini ve çözünürlüğünü eşit şekilde ölçeklendiren bileşik ölçeklendirme yöntemi önermektedir. Özellikle hesaplama kaynaklarının sınırlı olduğu durumlarda avantaj sağlamaktadır. EfficientNetB7 bileşik ölçeklendirme yoluyla performansı artırmaktadır. EfficientNet'in, diğer mimarilere göre daha az hesaplama gücü ile daha iyi sonuçlar sağladığı görülmüş olup EfficientNet, mobil ve gömülü sistemler gibi kaynak kısıtlı durumlarda yüksek doğruluk elde edebilmektedir [114].

MobileNet

MobileNet, mobil ve gömülü cihazlarda çalıştırılmak üzere tasarlanmıştır. Parametre sayısını ve hesaplama maliyetini azaltmak için derinlemesine ayrılabilir evrişimler kullanmaktadır. MobileNetV2 ve MobileNetV3 versiyonları, ters çevrilmiş artıklar ve doğrusal darboğazlar gibi optimizasyonlar sunmaktadır. MobileNet modelleri hafif tasarımları, düşük bellek ayak izleri ve minimum işlemci gereksinimleri nedeniyle mobil gerçek zamanlı uygulamalarda tercih edilmektedir [115].

Swin Transformer

Swin Transformer, geleneksel Vision Transformer yapısını geliştirmek amacıyla, lokal pencere temelli bir mekanizma ve kaydırılmış pencere yaklaşımı kullanmaktadır. Swin Transformer, giriş görüntüsünü sabit boyutlu pencerelere bölerek her bir pencere içinde dikkat mekanizmalarını uygular ve bu sayede hesaplama karmaşıklığını önemli ölçüde azaltmaktadır. Modelin dikkat hesaplamasında kullandığı temel bileşen "Scaled Dot-Product Attention" formülü ile ifade edilmektedir [116]:

$$Attention(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (2.2)$$

Burada Q (Sorgu), K (Anahtar) ve V (Değer) giriş tensörlerini, d_k ise dikkat vektörünün boyutunu temsil etmektedir. Swin Transformer'ın en önemli yeniliklerinden biri olan kaydırılmış pencere mekanizması, pencereler arasındaki bilgi akışını artırmak için her bir katmanda pencerelerin sınırlarını değiştirir. Bu yaklaşım, küçük boyutlu nesnelerin veya detayların daha iyi temsil

Tablo 2.1. Karmaşıklık Matrisi

		Tahmin Edilen Değer	
		Pozitif	Negatif
Gerçek Değer	Pozitif	DP	YN
	Negatif	YP	DN

Tablo 2.1’de yer alan satırlar, test verilerinin gerçek sınıflarını; sütunlar ise modelin yaptığı tahminleri ifade etmektedir. DP, doğru şekilde pozitif sınıfa atanan pikselleri; DN, doğru şekilde negatif sınıfa atananları; YP, yanlış şekilde pozitif sınıfa atanan pikselleri ve YN, yanlış biçimde negatif sınıfa atanan pikselleri temsil etmektedir. Bu çalışmada, karmaşıklık matrisi kullanılarak doğruluk, hassasiyet, kesinlik, IoU, hassasiyet, özgüllük ve F1 skor metrikleri hesaplanmıştır. IoU değeri tahmin edilen segmentasyon haritası ile gerçek etiketli görüntü arasındaki örtüşmeyi ölçer ve bu örtüşmenin kesişen alanın yüzdesi olarak ifade edilir. Doğruluk metriği, doğru tahminlerin toplam tahmin sayısına oranı üzerinden modelin genel başarı düzeyini belirler. Kesinlik, tahmin edilen tüm pozitifler arasında doğru tanımlanan pozitif örneklerin oranını değerlendirerek pozitif tahminlerin doğruluğunu ortaya koyar. Hassasiyet ise, doğru şekilde tespit edilen gerçek pozitiflerin oranını ölçer ve özellikle yanlış negatiflerin en aza indirmenin kritik olduğu sağlık hizmetleri gibi alanlarda uygulanmaktadır. F1 skoru, hassasiyet ve kesinlik değerlerini tek bir metrikte birleştirerek modelin dengesiz veri kümelerini işleme kapasitesini bütünsel bir şekilde temsil eder. Özgüllük metriği, negatif sınıfa ait örneklerin doğru bir şekilde tespit edilme oranını ölçerek, yanlış pozitifleri en aza indirme yeteneğini değerlendirir ve özellikle yanlış pozitiflerin maliyetinin yüksek olduğu durumlarda kritik bir metrik olarak öne çıkar. ROC eğrisi hassasiyet ve özgüllük arasındaki ilişkiyi grafiksel olarak sunarak modelin farklı eşik değerlerindeki performansını görselleştirir. AUC, sınıflandırma modelinin genel performansını temsil eder; AUC’nin 1’e yakın olması, modelin daha yüksek performans gösterdiğinin bir göstergesi olarak kabul edilir [117]. Tüm bu performans metrikleri, modelin gücünü ve zayıf yönlerini daha ayrıntılı şekilde değerlendirmek için kullanılmaktadır. Bu performans metrikleri ile ilgili matematiksel ifadeler şu şekilde tanımlanmıştır:

$$IoU = \frac{DP}{(DP+YP+YN)} \quad (2.4)$$

$$F1 \text{ Skor} = 2 * \frac{Kesinlik * Hassasiyet}{Kesinlik + Hassasiyet} \quad (2.5)$$

$$Doğruluk = \frac{DP+DN}{DP+DN+YP+YN} \quad (2.6)$$

$$Kesinlik = \frac{DP}{DP+YP} \quad (2.4)$$

$$Hassasiyet = \frac{DP}{DP+YN} \quad (2.8)$$

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (2.9)$$



3. Diş HASTALIKLARI VERİ KÜMESİNİN HAZIRLANMASI

3.1. Literatürde Yer Alan Veri Kümeleri


Bu tez çalışması kapsamında, literatürde bulunan açık erişimli üç farklı veri kümesi detaylı bir şekilde incelenmiştir. İncelenen bu veri kümeleri, panoramik diş röntgen görüntülerinden oluşmaktadır. Bu veri kümelerindeki görüntüler ayrıntılı olarak analiz edilmiş ve anatomik yapıların tespiti için yüksek çözünürlüklü görüntüler seçilerek yeni bir veri kümesi oluşturulmuştur. Bu panoramik diş görüntülerinden oluşan veri kümesi gömülü dişlerin yüksek kaliteli görüntülerini içermektedir. Her bir veri kümesi, uzman tarafından özenle etiketlenmiş ve çalışmanın hedeflerine uygun bir formata dönüştürülmüştür. Etiketleme sürecinde, diş hastalıkları ve dişlerin anatomik yapıları detaylı bir şekilde tanımlanmış, böylece veri kümeleri daha kapsamlı bir inceleme ve analiz ortamı oluşturulacak şekilde hazırlanmıştır. Böylece, çalışmanın sonuçlarının daha geniş bir diş popülasyonuna uygulanabilirliği artırılarak, gelecek çalışmalara temel oluşturacak nitelikte bir veri kümesi oluşturulmuştur. Oluşturulan veri kümesine ait ayrıntılı bilgi Tablo 3.1’de sunulmuştur.

Tablo 3.1. Literatürde yer alan veri kümelerinden oluşturulan yeni veri kümesi detayları

Kaynak	Veri Kümeleri	Veri Miktarı	Veri Türü	Kullanılan Veri Sayısı
[45]	Veri Kümesi-1	304 adet	540x380, png	304
[118]	Veri Kümesi-2	598 adet	2041x1024, jpg	53
[119]	Veri Kümesi-3	116 adet	3100x1300, png	50

3.1.1. Gömülü Diş Veri Kümesi

Gömülü dişlerin tespiti için oluşturulan veri kümesi, üç farklı kaynaktan elde edilen panoramik radyografi görüntülerinden oluşmaktadır. Veri Kümesi-1’deki panoramik radyografi görüntüler yerel bir diş kliniğinden elde edilmiştir, bu veri kümesinden 304 adet görüntü seçilmiştir. Veri Kümesi-2 açık erişimli bir dental görüntü havuzundan elde edilmiştir ve bu veri kümesinden 53 adet görüntü seçilmiştir. Özel bir dental görüntüleme laboratuvarından elde edilen Veri Kümesi-3, anatomik yapıların ayrıntılı bir şekilde görülebilmesini sağlayan yüksek çözünürlüklü görüntülerden oluşmuştur, bu veri kümesinden 50 adet görünüşü seçilmiştir. Her görüntü, alanında uzman tarafından dikkatlice seçilerek etiketlenmiştir. Matlab Image Labeler programı kullanılarak marjinler, kronlar ve kökler dâhil olmak üzere gömülü diş bölgelerinin manuel olarak işaretlenmesi için kullanılmıştır. Şekil 3.1’de oluşturulan veri kümesinden seçilen gerçek panoramik radyografi görüntüleri ve bu panoramik radyografilerde gömülü dişin etiketlenmiş maskeleri gösterilmektedir.



Şekil 3.1. Birleştirilmiş veri kümesinden örnek görüntüler (gömülü diş)

Etiketli maskeler, gömülü dişler beyaz pikselleri ve arka plan siyah pikselleri ifade etmek üzere ikili segmentasyon haritalarından oluşmaktadır. Bu maskeler segmentasyona ve modelin eğitilmesine olanak sağlamıştır. Şekil 3.1'de kısmen gömülü dişler ve anatomik olarak karmaşık vakalar da dâhil olmak üzere veri kümesinden çeşitli örnekler gösterilmektedir. Farklı kaynaklardan alınan veri kümelerinin bir araya getirilmesi, modelin farklı klinik senaryolarda etkili bir şekilde genelleme yapabilmesini sağlamıştır. Veri Kümesi-3'teki yüksek çözünürlüklü görüntüler modelin ince taneli segmentasyon görevlerindeki performansını önemli ölçüde artırırken, Veri Kümesi-2'nin sağladığı çeşitlilik modelin sağlamlığını artırmıştır.

3.2. Toplanan Veri Kümelerinin Diş Hastalıklarına Göre Listelenmesi

Tez çalışması kapsamında, ayrıca diş hastalıklarının tespiti ve analizi amacıyla özel olarak hazırlanan veri kümeleri kullanılmıştır. Bu veri kümeleri, çürük diş ve enfeksiyon olmak üzere bu iki diş hastalıklarını kapsayacak şekilde etik kurallar çerçevesinde oluşturulmuş ve uzman denetiminde detaylı bir şekilde etiketlenmiştir. Veri kümelerinin hazırlanması sırasında hem klinik gereklilikler hem de yapay zekâ tabanlı analizlerde ihtiyaç duyulan kriterler göz önünde bulundurulmuştur. Ayrıca etik kurulumuzdan gerekli onay alınarak çalışmanın hem bilimsel hem de etik gerekliliklere uygun şekilde yürütülmesi sağlanmıştır. Her iki veri kümesi de yapay zekâ tabanlı yöntemlerin geliştirilmesi ve test edilmesi amacıyla kullanılmıştır. Bu veri kümeleri, diş hastalıklarının teşhisinde yüksek doğruluk oranlarına ulaşılmasını sağlamanın yanı sıra gelecekteki çalışmalar için bir temel oluşturmayı hedeflemektedir. Bu bağlamda, çalışmamızda kullanılan veri kümesinin özgünlüğü ve etik kurallara uygun olarak hazırlanmış olması, araştırmanın bilimsel değerini artırmaktadır. Toplanan panoramik görüntülerden oluşturulan veri kümelerine ait ayrıntılı bilgiler Tablo 3.2'de sunulmuştur.


Tablo 3.2. Toplanan özgün veri kümeleri detayları

Veri Kümeleri	Veri Sayısı	Veri Türü
Çürük	474 adet	540x380, png
Enfeksiyon	378 adet	1784x797, png

3.2.1. Enfeksiyon Veri Kümesi

Enfeksiyonların tespiti için hazırlanan veri kümesinde, diş enfeksiyonları ve çevre dokular üzerindeki etkileri içeren panoramik görüntüler yer almaktadır. Uzman bir diş hekiminin gözetiminde, enfeksiyonların türüne ve yayılımına göre detaylı bir etiketleme işlemi gerçekleştirilmiştir. Etiketleme sırasında enfeksiyon bölgeleri, etkilenen dokular ve olası komplikasyonlar dikkatlice işaretlenmiştir. Bu veri kümesi, toplamda 378 adet görüntü içermektedir ve enfeksiyon çeşitliliği açısından zengin bir yapıya sahiptir. Veri kümesi, enfeksiyonların erken teşhisi ve ilerlemiş vakaların sınıflandırılması açısından önemli bir kaynak olarak kullanılmaktadır.

Tez çalışması kapsamında oluşturulan veri kümesi odontojenik enfeksiyonların tespiti için, panoramik diş röntgenlerinin etiketleme sürecinde enfeksiyonun yayılım alanları ve lezyon bölgeleri detaylı bir şekilde uzman desteğiyle işaretlenmiştir. Bu amaçla, Matlab Image Labeler programı kullanılarak enfeksiyonun sınırları ve etkilediği bölgeler manuel olarak belirlenmiştir. Uzman eşliğinde, radyografik bulgulara dayanarak enfeksiyonun yoğunluk ve yayılım durumlarını değerlendirerek, çalışmanın analiz ihtiyaçlarına uygun bir veri kümesi hazırlanmıştır. Panoramik radyografilerin yer aldığı bu veri kümesi enfeksiyonun ayrıntılı bir şekilde görülebilmesini sağlayan yüksek çözünürlüklü görüntülerden oluşmaktadır. Şekil 3.2’de oluşturulan veri kümesine ait örnek görüntüler yer almaktadır.



Şekil 3.2. Özgün veri kümesinden örnek görüntüler (enfeksiyon)


Etiketli maskeler, enfeksiyon bölgelerini beyaz pikseller ve arka planı siyah pikseller olarak ifade etmek üzere ikili segmentasyon haritalarından oluşmaktadır. Bu maskeler, segmentasyon ve modelin eğitilmesine olanak sağlamıştır. Şekil 3.2’de odontojenik enfeksiyonların yayılım

alanlarını ve lezyon bölgelerini içeren veri kümesinden çeşitli örnekler gösterilmektedir. Tek bir kaynaktan elde edilen yüksek çözünürlüklü panoramik görüntüler, enfeksiyonun detaylı bir şekilde analiz edilmesine olanak sağlamış ve modelin ince taneli segmentasyon görevlerindeki performansını önemli ölçüde artırmıştır. Uzman desteğiyle oluşturulan bu veri kümesi, enfeksiyon tespiti için güvenilir ve kapsamlı bir eğitim ortamı sağlamıştır.

3.2.2. Çürük Diş Veri Kümesi

Çürük dişlerin tespiti için hazırlanan veri kümesi, ağız içi panoramik görüntülerden oluşmaktadır. Bu veri kümesi, diş çürüklerinin farklı aşamalarını ve tiplerini içerecek şekilde uzman diş hekimi eşliğinde etiketlenmiştir. Etiketleme sürecinde çürüklerin sınıflandırılması için klinik kriterler temel alınmış ve görüntüler üzerinde her bir çürük bölgesi işaretlenmiştir. Toplamda, farklı yaş grubundaki bireylerden elde edilen 474 adet görüntü kullanılmıştır. Veri kümesi, çürüklerin derinlik, yayılım ve etkilediği diş yapısını dikkate alarak kapsamlı bir şekilde hazırlanmıştır. Bu süreç, hem teşhis algoritmalarının doğruluğunu artırmak hem de daha genel uygulanabilirliği olan bir model geliştirmek için kritik önem taşımaktadır.

Tez çalışması kapsamında oluşturulan veri kümesi, çürük dişlerin tespiti için panoramik diş röntgenlerinin etiketleme sürecinde çürük alanlarının konumları ve boyutları detaylı bir şekilde uzman desteğiyle işaretlenmiştir. Bu amaçla, Matlab Image Labeler programı kullanılarak çürük bölgelerinin sınırları ve etkilediği diş yapıları manuel olarak belirlenmiştir. Uzman eşliğinde, radyografik bulgulara dayanarak çürüğün yayılma derecesi ve yoğunluğunu değerlendirerek, çalışmanın analiz ihtiyaçlarına uygun bir veri kümesi hazırlanmıştır. Panoramik radyografların yer aldığı bu veri kümesi, çürük dişlerin ayrıntılı bir şekilde görülebilmesini sağlayan yüksek çözünürlüklü görüntülerden oluşmaktadır. Şekil 3.3'te oluşturulan veri kümesine ait örnek görüntüler yer almaktadır.



Şekil 3.3. Özgün veri kümesinden örnek görüntüler (çürük diş)

Etiketli maskeler, çürük alanlarını beyaz pikseller ve arka planı siyah pikseller olarak ifade eden ikili segmentasyon haritalarından oluşmaktadır. Bu maskeler, çürük tespiti segmentasyonu ve

modelin eğitilmesine olanak sağlamıştır. Şekil 3.3'te veri kümesinden alınan çeşitli panoramik diş görüntüleri ile birlikte çürük bölgelerinin belirgin şekilde işaretlenmiş örnekleri gösterilmektedir. Tek bir kaynaktan elde edilen bu veri kümesinin yüksek çözünürlüklü görüntüler içermesi, çürüklerin ince taneli detaylarının doğru bir şekilde segmentasyonunu sağlamış ve modelin performansını önemli ölçüde artırmıştır. Uzman tarafından özenle etiketlenmiş veri kümesi, modelin doğruluk ve genelleme yeteneğini güçlendirmiştir, böylece çürük tespiti için sağlam bir temel oluşturulmuştur.




4. PANORAMİK DİŞ RÖNTGENLERİNDE GÖMÜLÜ DİŞ TESPİTİ

Bu bölümde panoramik radyografi görüntülerinden gömülü diş tespiti için UNet, FPN, PSPNet ve LinkNet segmentasyon modelleri karşılaştırılmıştır. Gömülü diş segmentasyonu için dört segmentasyon modellerinin her birine VGG16, ResNet101, ResNeXt101, InceptionV3, InceptionResNetV2, DenseNet121, SEResNet101, SEResNeXt101, MobileNet ve EfficientNetB7 olmak üzere 10 farklı omurga ağı uygulanmıştır. Modellerin performansı kesinlik, hassasiyet, IoU skoru ve F1 skoru performans metrikleri ile değerlendirilmiştir. Tez kapsamında gerçekleştirilen bu çalışma, panoramik radyografi görüntülerinde gömülü diş tespiti için daha fazla araştırma ve model geliştirmenin önemini vurgulamaktadır.

4.1. Veri Kümesi

Bu çalışmada, panoramik radyografi görüntüleri içeren üç veri kümesi kullanılmıştır. Bu veri kümelerindeki görüntüler ayrıntılı olarak analiz edilmiş ve gömülü diş tespiti için toplamda 407 adet yüksek çözünürlüklü görüntü seçilerek yeni bir veri kümesi oluşturulmuştur. Bu veri kümesi ile çalışmanın sonuçlarının daha geniş bir diş popülasyonuna uygulanması amaçlanmaktadır.

Eğitim ve değerlendirme için dengeli bir veri kümesi sağlamak amacıyla 407 görüntüden oluşan veri kümesi üç alt kümeye ayrılmıştır. Veri kümesinin %80'ini eğitim için ayrılmış 325 görüntü içermekte, %5'i doğrulama için ayrılmış 21 görüntü içermekte ve son olarak %15'i test için ayrılmış 61 görüntü içermektedir. Çalışmada kullanılan veri kümesine ait örnek görüntüler Şekil 4.1'de gösterilmiştir.




Şekil 4.1. Veri kümesine ait örnek görüntüler

4.2. Önerilen Yöntem


Bu çalışmada, panoramik radyografi görüntüleri kullanılarak derin öğrenmeye dayalı gömülü dişlerin tespiti için kapsamlı bir çerçeve sunulmuştur. Bu kapsamda, dört farklı segmentasyon modeli ve bu yöntemlere dayalı on farklı omurga ağının (önceden eğitilmiş derin mimariler)

performansı üzerinde detaylı deneysel analizler gerçekleştirilmiştir. Bu deneysel çalışmalara ilişkin kapsamlı bir çerçeve Şekil 4.2'de detaylı olarak sunulmuştur.



Şekil 4.2. Mevcut çalışmaya genel bakış

Bu çalışmada kullanılan segmentasyon modellerinin genel gösterimleri Şekil 4.3'te verilmiştir.



Şekil 4.3. Uygulanan Segmentasyon modelleri (a) UNet, (b) LinkNet, (c) PSPNet, (d) FPN

Önceden eğitilmiş bir omurga modeli kullanmak transfer öğrenme avantajları sağlamaktadır. Bu, genel özelliklerin önceden öğrenilmiş olduğu ve öğrenme sürecinin daha hızlı ve verimli bir şekilde gerçekleşebileceği anlamına gelmektedir. Özellikle segmentasyon uygulamalarında, önceden eğitilmiş bu modeller daha az etiketli veri ile yüksek performans elde edilmesini sağlamaktadır. Bu modellerin başarısı, belirli bir segmentasyon görevi için uygunlukları ve performansları değerlendirilirken dikkate alınmalıdır. Bu nedenle, omurga modellerinin dikkatli bir şekilde seçilmesi ve uygulanması, görüntü segmentasyonunun genel performansını önemli ölçüde etkileyebilmektedir. Bu çalışmada segmentasyon modelleri ile birlikte uygulanan farklı özelliklere sahip önceden eğitilmiş omurga ağı mimarileri Tablo 4.1'de özetlenmiştir.

Tablo 4.1. Omurga ağı mimarilerinin özellikleri

Omurga Ağı	Yıl	Derin	Parametre (Milyon)	Giriş Boyutu	Özellikleri	Kaynak
ResNet50	2015	50	23.5	224 x 224 x 3	3x3 evrişim, artık bağlantı	[108]
ResNeXt50	2016	50	23.5	224 x 224 x 3	3x3 evrişim, artık bağlantı, darboğaz	[111]
InceptionV3	2015	22	237	299 x 299 x 3	1x1, 3x3, 5x5 evrişim, maksimum havuzlama, inception modülü	[110]
InceptionResNetV2	2016	152	54.4	299 x 299 x 3	1x1, 3x3, 5x5 evrişim, maksimum havuzlama, inception modülü, artık bağlantı	[110]
DenseNet121	2016	121	10.2	224 x 224 x 3	3x3 evrişim, yoğun bağlantı	[112]
VGG16	2014	16	138	224 x 224 x 3	3x3 evrişim, maksimum havuzlama	[107]
SEResNeXt50	2017	10	-	320 x 320 x 3	ResNet blokları, öz-dikkat katmanları	[113]
MobileNet	2017	22	4.2	224 x 224 x 3	1x1 evrişim katmanları, sıkıştırma ve uyarım katmanları	[115]
EfficientNetB7	2019	600	66.0	512 x 512 x 3	EfficientNet serisi, ölçeklenebilir mimari	[114]

4.3. Deneysel Çalışmalar ve Sonuçları

Bu çalışmada, panoramik radyografi görüntüleri üzerinde deneysel çalışmalar gerçekleştirilmiştir. Deneysel çalışmaların amacı, önerilen hibrit yöntemlerin doğruluğunu ve etkinliğini test ederek performanslarını değerlendirmektir. Bu bölümde uygulama süreçlerine dair detaylar, kullanılan performans metrikleri ve deneysel çalışmaların görsel ve sayısal sonuçları yer almaktadır. Deneysel analizler RTX 6000 grafik kartı ile donatılmış bir iş istasyonunda gerçekleştirilmiştir. Deneysel çalışmalar sırasında Python programlama dili derin öğrenme alanında yaygın olarak kullanılan TensorFlow, PyTorch ve NumPy gibi kütüphaneler kullanılmıştır. Tablo 4.2, deneysel çalışmalarda kullanılan derin öğrenme modeline ait parametrelerin detaylı bir özetini sunmaktadır. Bu tabloda, özellikle modelin ağırlık değerleri, öğrenme oranları, aktivasyon fonksiyonları gibi önemli parametrelerin değerleri yer almakta olup, model performansının belirleyici unsurlarını ortaya

koymaktadır. Deneysel çalışmaların tüm aşamaları, ilgili literatürden elde edilen bilgiler ve önerilen yöntemlerin uyarlanmasıyla titizlikle gerçekleştirilmiştir.

Tablo 4.2. Deneysel çalışmalarda kullanılan görüntü segmentasyon model hiper parametreleri

Parametre	Konfigürasyon
Optimizasyon	Adam
Learning Rate	0.001
Ağırlıklar	ImageNet
Epok	300
Eğitim, Doğrulama, Test	80%, 5%, 15%
Aktivasyon Fonksiyonu	Sigmoid


Tablo 4.2'de listelenen derin öğrenme parametreleri çalışma kapsamında gerçekleştirilen 40 adet deneysel çalışmaların tamamında uygulanmıştır. Ayrıca, deneysel çalışmaların temelini oluşturmak için 413 panoramik radyografi görüntüsü kullanılmıştır. Bu veri kümesi gömülü dış tespit modelinin eğitilmesi ve değerlendirilmesi için kapsamlı bir temel sağlamıştır. Etiketli veri kümesi deneysel çalışmada üç bölüme ayrılmıştır: Eğitim için %80 (326), doğrulama için %5 (20) ve test için %15 (61). Bu ayırım modelin eğitim, doğrulama ve performans değerlendirmesinde kullanılmıştır. Bu ayırımın sadece bir kez yapıldığını ve tüm deneysel çalışmalarda aynı veri kümelerinin kullanıldığını belirtmek önemlidir. Bu ayırım, elde edilen sonuçların karşılaştırılabilirliğini ve güvenilirliğini sağlamak için dikkatle yapılmıştır.

Bu çalışmada, her bir segmentasyon modelinin (UNet, LinkNet, PSPNet, FPN) dış tespit performansı çeşitli omurga ağları kullanılarak değerlendirilmiştir. Bu kapsamda omurga ağ için farklı yapı ve özelliklere sahip önceden eğitilmiş 10 farklı derin mimari seçilmiştir. Modellerin performansını kapsamlı bir şekilde analiz etmek amacıyla kesinlik, hassasiyet, IoU skoru ve F1 skoru gibi metrikler kullanılmıştır. Kesinlik, modelin gömülü dışları yanlışlıkla başka yapılar olarak etiketleme olasılığını minimize etmek için önemli bir metrik olarak değerlendirilmiştir. Hassasiyet ise gömülü dışların kaçırılmamasını sağlamak ve yanlış negatif sonuçları en aza indirmek amacıyla kullanılmıştır. IoU skoru, segmentasyonun doğruluğunu ve tahmin edilen bölgelerin gerçek bölgelerle ne kadar iyi örtüştüğünü ölçmek için tercih edilmiştir. F1 skoru ise hem kesinlik hem de hassasiyet dengesini göz önünde bulundurarak modelin genel performansını değerlendirmek amacıyla kullanılmıştır. Bu metrikler, modellerin gömülü dış tespitindeki başarısını kapsamlı ve dengeli bir şekilde ölçmek için bir arada değerlendirilmiştir. Tablo 4.3, UNet tabanlı performans bulgularını ayrıntılı olarak sunmakta ve bu çalışma için toplanan verileri içermektedir.

Tablo 4.3. UNet tabanlı performans sonuçları (%)

Omurga Ağları	F1 Skor	Kesinlik	Hassasiyet	Ortalama IoU Skoru
VGG16	88.58	90.53	86.75	79.75
ResNet101	89.34	93.68	85.51	80.89
ResNeXt101	88.23	91.85	85.03	79.18
InceptionV3	90.17	94.03	86.69	82.19
InceptionResNetV2	90.43	91.06	89.87	82.60
DenseNet121	91.07	93.13	89.29	83.75
SEResNet101	90.05	93.70	86.74	81.98
SEResNeXt101	89.78	93.25	86.66	81.64
MobileNet	89.66	91.86	87.66	81.33
EfficientNetB7	92.02	92.73	91.37	85.29

Tablo 4.3'te görüldüğü üzere, ortalama %85,29 IoU skoru ile öne çıkan EfficientNetB7 mimarisinin, farklı bir UNet tabanlı omurga ağ olarak kullanılan önceden eğitilmiş derin mimariler arasında en yüksek performansı elde ettiği görülmektedir. Ayrıca, DenseNet121 mimarisi %83,75 IoU skoru ile ikinci en iyi performansı gösterirken, ResNeXt101 modeli IoU skoru (%79,18) ve F1 skoru (%88,23) açısından diğer modellerden daha düşük performans göstermiştir. Bununla birlikte, yaklaşık %81 IoU skoru ile SEResNet101, SEResNeXt101 ve MobileNet modelleri benzer performans göstermiştir. Şekil 4.4'te UNet modelini temel alan bu omurga mimarilerinin her birinden elde edilen görsel sonuçlar sunulmuştur.

**Şekil 4.4.** UNet tabanlı görsel sonuçlar


Şekil 4.4, çalışma kapsamında uygulanan tüm omurga ağı tabanlı UNet modelleri için her bir görsel tahmin sonucunu göstermektedir. Bu bulgular arasında, Örnek 1, Örnek 2, Örnek 3 ve Örnek 4'teki modellerin çoğunun gömülü dişleri doğru tespit etmesine rağmen, az sayıda modelin gömülü olmayan dişleri yanlışlıkla gömülü olarak tespit ettiği görülmüştür. Ayrıca, veri kümesinin küçük bir yüzdesi Örnek 5'teki zor ve nadir görülen gömülü dişleri içermektedir. Bu nedenle, çoğu model bu gömülü dişleri tespit edemezken, DenseNet121, MobileNet ve EfficientNetB7'nin doğru tespiti sağladığı görülmüştür.

PSPNet tabanlı performans sonuçları, bu çalışma kapsamında elde edilen verileri içeren Tablo 4.4'te ayrıntılı olarak sunulmuştur.

Tablo 4.4. PSPNet tabanlı performans sonuçları (%)

Omurga Ağları	F1 Skor	Kesinlik	Hassasiyet	Ortalama IoU Skoru
VGG16	87.83	91.44	84.57	78.59
ResNet101	86.74	89.14	84.57	76.68
ResNetxt101	87.47	90.56	84.74	77.93
InceptionV3	88.35	89.29	87.46	79.23
InceptionResNetV2	89.41	90.29	88.58	80.94
DenseNet121	88.80	89.10	88.55	80.05
SEResNet101	88.20	93.63	83.47	78.99
SEResNeXt101	87.73	87.70	87.88	78.30
MobileNet	83.36	87.54	79.70	71.52
EfficientNetB7	90.67	91.73	89.68	83.10

Tablo 4.4'te görüldüğü üzere PSPNet tabanlı farklı omurga ağları olarak kullanılan önceden eğitilmiş derin mimariler arasında en yüksek performans %83,10 IoU skoru ile EfficientNetB7 mimarisi ile elde edilmiştir. Ayrıca, InceptionResNetV2 mimarisi %80,94 IoU skoru ile diğer modellerden daha iyi performans gösterirken, MobileNet modeli hem ortalama IoU skoru (%71,52) hem de F1 skoru (%83,36) açısından diğerlerinden daha kötü performans göstermiştir. Öte yandan, SEResnet101, SEResNeXt101 ve VGG16 modelleri yaklaşık %78 IoU skoru ile benzer bir performans sergilemiştir. Şekil 4.5, PSPNet tabanlı omurga mimarilerinin her birinden elde edilen sonuçları göstermektedir.



Şekil 4.5. PSPNet tabanlı görsel sonuçlar


PSPNet tabanlı modellerin performansı Şekil 4.5'te yer alan görsel sonuçlar üzerinde değerlendirilmiştir. Bu değerlendirmede Örnek 1, Örnek 2, Örnek 3 ve Örnek 4 için çoğu modelin gömülü dişleri başarıyla tespit ettiği gözlemlenmiştir. Ancak bazı modellerin, gömülü olmayan dişleri yanlışlıkla gömülü olarak tespit ettiği görülmüştür. İnce detayların kaybedilmesi veya yanlış pozitif sonuçların ortaya çıkması gibi sınırlılıklar gözlemlenmiştir. Benzer şekilde, Örnek 5'te, VGG16 ve EfficientNetB7 gibi modellerin gömülü dişleri tanımlamada diğer modellere kıyasla daha yüksek doğruluk oranları sunduğu gözlemlenmiştir. Bu gömülü dişlerin, ResNet101, InceptionV3, InceptionResNetV2 ve MobileNet gibi modeller tarafından kesin olmasa da başarılı bir şekilde konumlandırıldığı tespit edilmiştir. Ancak, nadir ve zor bulunan gömülü dişlerin tanımlanmasında diğer modellerin sınırlı başarı gösterdiği belirlenmiştir.

FPN tabanlı modellerin performans sonuçları, bu çalışmada detaylı olarak ele alınmış ve ilgili veriler Tablo 4.5'te ayrıntılı şekilde sunulmuştur. FPN tabanlı modellerin performans analizinde, gömülü dişlerin doğru şekilde tanımlanmasıyla birlikte, yanlış pozitif ve yanlış negatif tespitlerin dağılımı da dikkatle incelenmiştir. Bu sonuçlar, modellerin güçlü ve zayıf yönlerini daha net bir şekilde değerlendirme fırsatı sunmaktadır. Tablo 4.5, farklı modellerin F1 skor, kesinlik, hassasiyet ve ortalama IoU skoru metrikleri açısından nasıl bir performans sergilediğini ortaya koymaktadır.

Tablo 4.5. FPN tabanlı performans sonuçları (%)

Omurga Ağları	F1 Skor	Kesinlik	Hassasiyet	Ortalama IoU Skoru
VGG16	88.06	93.42	83.38	78.94
ResNet101	87.42	93.18	82.49	77.96
ResNeXt101	89.76	92.58	87.26	81.56
InceptionV3	90.62	92.78	88.60	82.99
InceptionResNetV2	89.77	92.52	87.31	81.59
DenseNet121	89.41	92.16	86.86	81.00
SEResNet101	87.81	90.05	85.84	78.34
SEResNeXt101	90.03	93.18	87.21	82.07
MobileNet	90.51	91.17	89.96	82.75
EfficientNetB7	91.76	93.19	90.45	84.84

Tablo 4.5, EfficientNetB7 mimarisinin %84,84 IoU skoru ile çeşitli FPN tabanlı omurga ağları olarak kullanılan tüm önceden eğitilmiş derin mimariler arasında en iyi performansı gösterdiğini ortaya koymaktadır. Ayrıca, InceptionV3 mimarisi %82,99 IoU skoru ile ikinci en iyi performansı sergilerken, ResNet101 modeli F1 skoru (%87,42) ve IoU skoru (%77,96) ile diğer modellere kıyasla daha düşük bir performans göstermiştir. Şekil 4.6, her bir FPN tabanlı omurga mimarisinden elde edilen görsel çıktıları sunmaktadır.

**Şekil 4.6.** FPN tabanlı görsel sonuçlar


Şekil 4.6, FPN'ye dayalı modellerin performansının ayrıntılı olarak incelenmesinin görsel sonuçlarını göstermektedir. Sonuçlarda UNet tabanlı modellerle karşılaştırıldığında benzer eğilimler görülmektedir. Örnek 1, Örnek 2, Örnek 3 ve Örnek 4'te modellerin çoğunluğu gömülü dişleri doğru tespit ederken, birkaç modelin gömülü olmayan dişleri yanlışlıkla gömülü olarak tespit ettiği görülmüştür. Ayrıca, Örnek 5'teki nadir ve bulunması zor gömülü dişler veri kümesinde sınırlı sayıda mevcuttur. Bu durum çoğu modelin bu gömülü dişleri tespit edememesine neden olurken, DenseNet121, MobileNet ve EfficientNetB7 gibi modellerin bunları doğru konumlandırmada başarılı olduğu tespit edilmiştir.

LinkNet tabanlı modellerin performans bulguları, bu çalışma için toplanan verileri içeren Tablo 4.6'da verilmiştir.

Tablo 4.6. LinkNet tabanlı performans sonuçları (%)

Omurga Ağları	F1 Skor	Kesinlik	Hassasiyet	Ortalama IoU Skoru
VGG16	88.17	91.17	85.60	79.08
ResNet101	88.54	92.58	84.89	79.63
ResNeXt101	89.20	91.38	87.25	80.60
InceptionV3	89.32	92.08	86.78	80.87
InceptionResNetV2	89.29	94.43	84.80	80.80
DenseNet121	90.05	93.89	86.54	82.09
SEResNet101	87.61	89.81	85.61	78.16
SEResNeXt101	89.17	91.91	86.73	80.55
MobileNet	89.64	92.73	86.81	81.34
EfficientNetB7	91.49	93.56	89.59	84.41

Tablo 4.6, LinkNet tabanlı omurga ağları olarak kullanılan önceden eğitilmiş derin mimariler arasında EfficientNetB7 mimarisinin %84,41 IoU skoru ile en yüksek performansı elde ettiğini göstermektedir. Ayrıca, DenseNet121 mimarisi %82,09 IoU skoru ile ikinci en iyi performansı gösterirken, VGG16 modeli hem IoU skoru (%79,08) hem de F1 skoru (%88,17) açısından diğer modellerden daha iyi performans göstermiştir. Öte yandan, ResNeXt101, InceptionV3, InceptionResnetV2, SEResNeXt101 ve MobileNet mimarileri yaklaşık %80 IoU skoru ile karşılaştırılabilir bir performans göstermiştir. Şekil 4.7, LinkNet modeline dayalı tüm bu omurga mimarilerinden elde edilen görsel sonuçları göstermektedir.



Şekil 4.7. LinkNet tabanlı görsel sonuçlar

Şekil 4.7'deki görsel sonuçlarda LinkNet tabanlı modellerin performansı ayrıntılı olarak analiz edilmiştir. Modellerin çoğunluğu Örnek 1, Örnek 2, Örnek 3 ve Örnek 4'te gömülü dişleri tespit etmede başarılı olurken, birkaç modelin gömülü olmayan dişleri yanlışlıkla gömülü olarak tespit ettiği görülmüştür. Ayrıca, Örnek 5'teki nadir görülen gömülü dişler veri kümesinde sınırlı sayıda bulunmaktadır. Bu da modellerin çoğunun bu gömülü dişleri tespit etmekte zorlandığını göstermektedir. Diğer modellerle karşılaştırıldığında DenseNet121, MobileNet, EfficientNetB7 ve ResNet101 gibi modellerin doğru konumlandırmada başarılı olduğu görülmüştür. Bu bulgular, gömülü dişlerin tespit edilmesi söz konusu olduğunda LinkNet tabanlı modeller ile UNet tabanlı modellerin benzer performans gösterdiğini ortaya koymaktadır.

UNet, PSPNet, LinkNet ve FPN modelleri kapsamlı deneysel incelemeler sonucunda her bir omurga ağı için özelleştirilmiş ve her bir modelin tespit performansı dikkatle değerlendirilmiştir. Her bir segmentasyon modeli için ortalama IoU skoru performans sonuç değerleri Tablo 4.7'de gösterilmektedir. Bu tablo, segmentasyon modellerinin çeşitli omurga konfigürasyonlarındaki performanslarının karşılaştırılması için detaylı bir ölçüt olmaktadır. Burada sunulan çalışma, gelecekteki çalışmaları veya endüstriyel kullanımları yönlendirmeye yardımcı olabilecek ve hatta belirli bir uygulamada hangi modelin daha iyi çalıştığını belirlemeye yardımcı olabilecek önemli bilgiler sunmaktadır.

Tablo 4.7. Tüm modellerin performans karşılaştırması (%)

Omurga Ağları	LinkNet	UNet	PSPNet	FPN	Ortalama
VGG16	79.08	79.75	78.59	78.94	79.09
ResNet101	79.63	80.89	76.68	77.96	78.79
ResNeXt101	80.60	79.18	77.93	81.56	79.82
InceptionV3	80.87	82.19	79.23	82.99	81.32
InceptionResNetV2	80.80	82.60	80.94	81.59	81.48
DenseNet121	82.09	83.75	80.05	81.00	81.72
SEResNet101	78.16	81.98	78.99	78.34	79.37
SEResNeXt101	80.55	81.64	78.30	82.07	80.64
MobileNet	81.34	81.33	71.52	82.75	79.24
EfficientNetB7	84.41	85.29	83.10	84.84	84.41

Tablo 4.7'deki bilgilere dayanarak, EfficientNetB7'nin tüm segmentasyon modellerinde genel olarak en iyi omurga mimarisine sahip olduğu belirlenmiştir. InceptionV3, InceptionResNetV2 ve DenseNet121 mimarileri yaklaşık %81 IoU skoru ile ikinci en iyi performansı göstermiştir. Ancak ResNet101 mimarisi diğer modellere kıyasla daha düşük bir IoU skoru (%78,79) elde etmiştir. Öte yandan, yaklaşık %79 IoU skoru ile MobileNet, VGG16, ResNeXt101 ve SEResNeXt101 tasarımları karşılaştırılabilir bir performans göstermiştir. Omurga mimarisinin segmentasyon modellerinin genel performansını nasıl etkilediğini daha iyi anlamak için bu veriler değerli bir referans noktası sunmaktadır.

Kapsamlı deneysel araştırmalarda, segmentasyon modelleri için UNet, LinkNet, PSPNet ve FPN kullanılmış ve her bir modelin tespit performansları titizlikle değerlendirilmiştir. Bu değerlendirme sürecinde, her bir segmentasyon modelinin performansı, kullanılan omurga ağlarının çeşitliliği ve bu ağların farklı veri kümelerinde gösterdiği başarı düzeyleri üzerinden analiz edilmiştir. Çalışmanın sonuçlarına göre, tüm segmentasyon modelleri arasında en iyi performansı gösteren omurga ağının EfficientNetB7 olduğu tespit edilmiştir.


Elde edilen bulgular, her segmentasyon modelinin farklı omurga mimarileri ile nasıl bir performans gösterdiğine dair kapsamlı bir karşılaştırma sunmakta ve verimliliği artırmak için en uygun yapının seçilmesinde önemli bir rehber niteliği taşımaktadır. Tablo 4.8, bu bulguları ayrıntılı olarak sunarak modellerin farklı metrikler açısından nasıl bir başarı sergilediğini detaylı bir şekilde ortaya koymaktadır. Bu analiz, segmentasyon modellerinin seçim ve geliştirme süreçlerine yön vermekle kalmayıp, ilgili endüstrilerde veya araştırma alanlarında pratik uygulamalar için değerli bir kaynak görevi üstlenmektedir. Her model için F1 skoru, kesinlik, hassasiyet ve ortalama IoU skoru gibi temel ölçütleri sunmaktadır. Bu metrikler, modellerin performansını kapsamlı bir şekilde değerlendirmek amacıyla kullanılmıştır. Kesinlik, yanlış pozitifleri; hassasiyet, eksik tespitleri; F1 skoru, kesinlik ve hassasiyet dengesini; ortalama IoU ise konumlandırma doğruluğunu ölçmek için kullanılmıştır.

Tablo 4.8. Segmentasyon modellerinin performans karşılaştırması (%)

Segmentasyon Modelleri	Omurga Ağı	F1 Skor	Kesinlik	Hassasiyet	Ortalama IoU Skoru
UNet	EfficientNetB7	92.02	92.73	91.37	85.29
LinkNet		91.49	93.56	89.59	84.41
PSPNet		90.67	91.73	89.68	83.10
FPN		91.76	93.19	90.45	84.84


Tablo 4.8’de, farklı segmentasyon modellerinin performansını karşılaştırılmaktadır. Genel olarak, EfficientNetB7 tabanlı segmentasyon modelleri yaklaşık %83-%85 aralığında ortalama IoU skorları elde etmiştir. Ayrıca, UNet mimarisi en yüksek performansı gösterirken, PSPNet mimarisi ortalama %83 IoU skoru ile en düşük sonuçları üretmiştir. Öte yandan, LinkNet ve FPN mimarileri neredeyse eşit performans göstermiştir. Bu gözlemler, her bir modelin hangi metriklerde daha iyi performans gösterdiğini belirlemek için önemli bir karşılaştırma sağlar ve araştırmacılara ve uygulayıcılara segmentasyon modeli seçimlerinde yol gösterebilmektedir.

Eğitim ve doğrulama veri kümeleri üzerinden değerlendirildiğinde tüm modeller arasında üstün performans gösteren UNet + EfficientNetB7 modelinin performansını gösteren grafikler Şekil 4.8’de gösterilmektedir. Bu grafikten de görülebileceği gibi, eğitim ve doğrulama performansı başlangıçta hızlı bir gelişme göstermiştir. Buna ek olarak, 75 iterasyondan sonra öğrenme hızı daha yavaş bir şekilde devam etmiştir. Bu da hızlı bir öğrenme aşamasının ardından modelin daha istikrarlı ve sağlam bir performans sergilediğini göstermektedir. Modelin eğitim süreci dinamikleri ve performansının zaman içindeki gelişimi bu grafiklerde daha ayrıntılı olarak incelenmiştir.

**Şekil 4.8.** UNet+EfficientNetB7 tabanlı segmentasyon modelinin eğitim/doğrulama grafikleri

Deneysel araştırmanın kapsamlı bir incelemesinden sonra, EfficientNetB7 modelinin UNet, LinkNet, PSPNet ve FPN modelleri için en iyi performansı ürettiği gözlemlenmiştir. Bununla birlikte, tüm test görüntüleri incelendikten sonra her modelin bazı kısıtlamalara sahip olduğu görülmüştür. Bu kısıtlamalar, özellikle belirli durumlarda görsel tahminlerin doğruluğu üzerinde etkili olmaktadır. Örneğin, bazı gömülü dişlerin tespit edilmesinde zorluklar yaşanabilir veya bazı durumlarda yanlış pozitif sonuçlar elde edilebilir. Bu kısıtlamaların görsel tahminler üzerindeki etkilerini daha derinlemesine incelemek için Şekil 4.9’da gösterilen görüntüler üzerinde bir analiz

yapılmıştır. Bu görüntüler, her bir modelin performansını görsel olarak karşılaştırmak ve ilgili sınırlamaları daha iyi anlamak için kullanılmıştır.



Şekil 4.9. Segmentasyon modellerinin başarısız tespitine örnekler

Şekil 4.9'daki görsel sonuçlar EfficientNetB7 tabanlı UNet, LinkNet, FPN ve PSPNet modellerinin çıktılarını göstermektedir. Veri kümesinde bu örnek görüntülerden sınırlı sayıda bulunmaktadır ve gömülü dişlerin genellikle ağzın üst ve alt kısımlarında, bazen de nadiren orta kısımlarda (Örnek 1, 2 ve 4) bulunduğu tespit edilmiştir. Ayrıca Örnek 3'te FPN ve PSPNet tasarımlarının gömülü dişlerin yerlerini kısmen tanıyabildiği, UNet ve LinkNet mimarilerinin ise gömülü dişleri hiç tespit edemediği görülmüştür. Bu, modelin genel etkinliği ve belirli durumlara uyum sağlama yeteneği hakkında daha fazla araştırma yapılmasını gerektiren önemli bir bulgudur.

Bu çalışmanın temel amacı, panoramik radyografi görüntülerinde gömülü dişlerin doğruluğunu ölçmek için derin öğrenme tabanlı bir model geliştirmektir. Bu kapsamda, gömülü diş tespiti için en iyi yapıları bulmak amacıyla, önceden eğitilmiş UNet, LinkNet, PSPNet ve FPN modellerinin çeşitli mimariye entegrasyonu incelenmiştir. Özellikle kesinlik, hassasiyet ve IoU skorları açısından yapılan kapsamlı performans değerlendirmesi, geliştirilen modelin gömülü dişleri etkin bir şekilde tanıma ve sınıflandırma konusunda başarılı olduğunu göstermiştir. Modelin gömülü diş tespitinde yüksek hassasiyet ve özgüllüğe sahip olması, bu alandaki mevcut teknolojileri aşma potansiyelini ortaya koymaktadır. Model, deneysel değerlendirmeler ve uygulama detaylarının da gösterdiği gibi, gerçek zamanlı diş görüntülerini hızlı bir şekilde ve mükemmel doğruluk oranlarıyla işleyebilmektedir. Bu da modelin klinik uygulanabilirliğini artırarak diş hekimliği alanında etkili bir yardımcı araç olarak kullanılma potansiyelini yükseltmektedir.

Sonuç olarak, bu çalışmanın derin öğrenme tabanlı gömülü diş tespit modelinin başarıları, diş hekimliğindeki teknolojik ilerlemelerin klinik uygulamalara nasıl fayda sağlayabileceğinin önemli bir örneğini sunmaktadır. Geliştirilen model, diş tespit süreçlerini optimize ederek diş hekimlerine daha hızlı, daha güvenilir ve daha etkili teşhis desteği sağlama potansiyeline sahiptir. Ayrıca model, gerçek zamanlı diş görüntülerini hızlı bir şekilde işleyebildiğinden yoğun klinik ortamlarda veya acil durumlarda kullanım için önerilmektedir.

5. PANORAMİK DİŞ RÖNTGENLERİNDE ENFEKSİYON TESPİTİ


Bu bölümde, panoramik diş görüntülerindeki odontojenik enfeksiyonların segmentasyonu için önerilen derin öğrenme tabanlı yaklaşım, ilgili deneysel sonuçlarla birlikte kapsamlı bir şekilde sunulmaktadır. Bu çalışmanın temel amacı, EfficientNetB4 tabanlı Swin UNet modelinin uygulanması ile odontojenik enfeksiyon segmentasyonunun doğruluğunu ve verimliliğini artırmaktır. Bu model, panoramik diş görüntülerindeki enfeksiyona eğilimli bölgeleri belirlemek ve segmentlere ayırmak için özel olarak tasarlanmıştır. EfficientNet'in detaylı çok ölçekli özellik çıkarma yeteneği, Swin Transformer'ın dikkat mekanizmalarıyla birleştirilerek odontojenik enfeksiyonun görüntüden yüksek doğrulukla segmentasyonu sağlanmıştır. Önerilen yöntem, segmentasyon sürecini kolaylaştırırken teşhis doğruluğunu artırmış ve manuel analizle ilişkili hata olasılığını önemli ölçüde indirmiştir. Bu yöntem, özellikle enfeksiyon sınırlarının sağlıklı yapılarla örtüştüğü durumlarda, karmaşık enfeksiyon alanlarının tanımlanmasını sağlar. Bu çalışma, özellikle diş radyografisi alanında tıbbi görüntü segmentasyonunda kayda değer bir ilerlemeyi ve klinik teşhislerde gelişmiş derin öğrenme tekniklerinin faydalarını vurgulamaktadır.

5.1. Veri Kümesi

Bu çalışmada kullanılan veri kümesi, veri kalitesini ve klinik uygunluğu sağlamak için seçilmiş 378 adet yüksek çözünürlüklü panoramik diş görüntüsünden oluşmaktadır. Her bir görüntü, odontojenik enfeksiyon odaklı detaylı etiketleme sürecine tabi tutulmuş ve bu süreç uzman diş hekimlerinin rehberliğinde gerçekleştirilmiştir. Veri kümesi, önerilen modelin çeşitli klinik senaryolarda uygulanabilirliğini sağlamak amacıyla hafiften şiddetliye çeşitli odontojenik enfeksiyon vakalarını içermektedir.

Bölüm 3'te ayrıntılı olarak açıklandığı üzere, bu çalışma kapsamında kullanılan tüm görüntüler için tıbbi araştırma standartlarına bağlı kalınarak etik onay alınmıştır. Ayrıca, veri kümesinin dengeli bir şekilde dağıtılması sağlanmış; görüntüler eğitim (%80), doğrulama (%10) ve test (%10) alt kümelerine bölünmüştür. Bu yöntem, modelin hem eğitim hem de test süreçlerinde adil bir performans değerlendirmesi yapılabilmesi için önemli bir adım olmuştur.

Mevcut birçok yaklaşımın aksine, bu çalışmada ham girdi görüntülerine herhangi bir ön işlem uygulanmamıştır. Bu tercih, modelin gerçek dünya koşullarındaki performansını daha gerçekçi bir şekilde değerlendirme imkânı sunmuş ve aynı zamanda modelin sağlamlığını ve klinik uygulanabilirliğini ortaya koymuştur. Etiketleme, dağılım ve değerlendirme süreçlerinde izlenen metodoloji, araştırmanın güvenilirliğini artırmış ve elde edilen sonuçların klinik geçerliliğini desteklemiştir. Şekil 5.1'de panoramik görüntü örnekleri ve bunlara karşılık gelen gerçek maskeleri yer almaktadır.




Şekil 5.1. Veri kümesinden örnek panoramik diş görüntüleri ve maskeleri

5.2. Önerilen Yöntem

Odontojenik enfeksiyonların segmentasyonu için önerilen yöntemde, yüksek doğrulukta segmentasyon sonuçları elde etmek amacıyla Swin Transformer mimarisi ile EfficientNet tabanlı bir omurga bir araya getirilmiştir. Bu mimari, özellik çıkarma aşamasında çok ölçekli, yüksek çözünürlüklü özellikler elde etmek için EfficientNetB4 uygulanmıştır. Elde edilen bu özellikler, bağlamsal bilgileri etkili bir şekilde yakalayabilmek için Swin Transformer blokları tarafından işlenmiştir. Önerilen modelin genel yapısı; EfficientNetB4 tabanlı bir kodlayıcı, bir darboğaz ve Swin Transformer tabanlı bir kod çözücünden oluşmaktadır.

Kodlayıcı kısmında EfficientNetB4 mimarisi kullanılarak segmentasyon için gerekli olan düşük ve yüksek seviyeli özellik haritaları çıkarılmıştır. Düşük seviyeli özellik haritaları, kenar, renk ve doku gibi uzamsal detayları içerirken, yüksek seviyeli özellik haritaları, semantik bilgileri temsil etmektedir. Bu aşamada elde edilen çok katmanlı özellikler, segmentasyon doğruluğunu artırmada önemli bir rol oynamaktadır.

Kod çözücü kısmında ise, geleneksel evrişim katmanları yerine Swin Transformer blokları ve patch expanding katmanları kullanılmıştır. Swin Transformer, özellik haritalarını işlemekte yüksek performans gösterirken, patch expanding katmanları ile bu özellik haritalarının boyutları artırılmış ve orijinal çözünürlüğe geri dönmüştür. Bu yapı, hem detay seviyesinde doğruluğu artırmakta hem de bağlamsal bilgilerin korunmasını sağlamaktadır. Önerilen EfficientNetB4 tabanlı Swin UNet mimarisi Şekil 5.2’de gösterilmektedir.



Şekil 5.2. EfficientNetB4 tabanlı Swin UNet mimarisi

Literatürde yer alan geleneksel yaklaşımların aksine, panoramik görüntülere herhangi bir ön işlem uygulanmamış ve modele ham verileri uygulanmıştır. Girdi görüntüleri, enfeksiyona eğilimli bölgeleri belirlemek için EfficientNet omurgası kullanılmıştır. Çıkarılan bu özellikler daha sonra kod çözücü aşamasında, segmentasyon hassasiyetini artırmak için çok ölçekli dikkat mekanizmalarını kullanan Swin Transformer blokları aracılığıyla işlenmiştir. Önerilen yöntem, hem yerel hem de küresel bağlamsal bilgileri yakalayıp, karmaşık durumlarda bile enfeksiyon bölgelerine doğru bir şekilde segmentasyon yeteneğini göstermektedir.

Panoramik dış görüntülerindeki karmaşık özellikler için kodlayıcı olarak EfficientNetB4, kod çözücü olarak Swin Transformer modülleri uygulanmıştır. Bu modüller, hem küresel hem de yerel özellikleri yakalamak için hiyerarşik ve çok ölçekli dikkat mekanizmalarını kullanarak enfeksiyon bölgelerinin hassas bir şekilde tanımlanmasını sağlamaktadır. Bu ikili dikkat mekanizması, modelin görüntüdeki önemli alanlara dinamik olarak odaklanmasını sağlayarak düşük kontrastlı veya üst üste binen bölgeler gibi zorlu senaryolarda bile segmentasyon doğruluğunu artırabilmektedir. Tablo 5.1’de uygulanan modelin konfigürasyon ve ara bağlantıları özetlenerek kodlayıcı-kod çözücü mimarinin yapısı vurgulanmıştır. EfficientNetB4 tabanlı Swin UNet modeli, TensorFlow çerçevesi kullanılarak Python’da uygulanmıştır. Aşırı öğrenme sorununu aşmak ve

optimum model performansını sağlamak için eğitim sırasında erken durdurma işlemi (early stop) uygulanmıştır. Model eğitimi esnasında kullanılan parametreler Tablo 5.1’de sunulmuştur.

Tablo 5.1. Önerilen model mimarisine ait hiper parametreler

Bileşenler	Açıklama
EfficientNet Omurga Ağı	Özellik çıkarımı
Patch Embedding	Görüntüyü bölütleme
Swin Transformer Bloğu	Global bilgi işleme
UNet Kodlayıcı/Kod Çözücü	Çok ölçekli işleme
Çıkış Katmanı	Tahmin oluşturma

Tablo 5.1, her katmanın yapılandırmasını gösterirken önerilen modelin ayrıntılı mimarisini sunmaktadır. Kodlayıcı, çeşitli ölçeklerde zengin özellik haritaları çıkaran EfficientNetB4’e dayanmaktadır. Bu özellik haritaları, uzun menzilli bağımlılıkları ve bağlamsal bilgileri yakalamak için darboğaz içindeki Swin Transformer katmanlarına beslenir. Kod çözücü, bölümlere ayrılmış bölgelerin doğru bir şekilde yeniden yapılandırılmasını sağlamak için atlama bağlantılarını kullanarak bu özellikleri birleştirir.

378 adet etiketli görüntüden oluşan veri kümesi eğitim için %80’e, doğrulama için %10’a ve test için %10 olmak üzere 3 alt kümeye bölünmüştür. Eğitim sırasında, önerilen model Adam optimize edicisini 0,001’lik bir başlangıç öğrenme oranıyla kullanmış ve doğrulama performansı düştüğünde bu oran 0,1 kat azaltılmıştır.

5.3. Deneysel Çalışmalar ve Sonuçları

Tüm deneyler Kaggle platformu üzerinde gerçekleştirilmiştir. Kaggle, model eğitimi ve kullanılan veri kümelerinin yönetimini kolaylaştıran ve yüksek hesaplama gücü sunan bir ortam sağlamıştır. Deneysel çalışmalar sırasında Kaggle’ın sunduğu 16 GB RAM ve NVIDIA Tesla P100 GPU gibi teknik kaynaklar, özellikle derin öğrenme modellerinin eğitimi için yeterli performansı sağlamıştır. Önerilen model, hem EfficientNetB4’ün gelişmiş özellik çıkarma hem de Swin Transformer’ın hiyerarşik dikkat mekanizmalarının güçlü yönlerinden yararlanmıştır. Bu kombinasyon, özellikle üst üste binen sınırlara ve düşük kontrastlı bölgelere sahip karmaşık senaryolarda enfeksiyona eğilimli bölgeleri doğru bir şekilde segmentlere ayırmada oldukça etkili olduğunu kanıtlamıştır. Modelin etkinliğini değerlendirmek için 378 yüksek çözünürlüklü panoramik dış görüntüsünden oluşan veri kümesi eğitim (%80), doğrulama (%10) ve test (%10) alt kümelerine ayrılmıştır. Görüntüler, uzman bir dış hekiminin gözetiminde titizlikle etiketlenmiş ve böylece temel gerçek verilerinin doğruluğu ve güvenilirliği sağlanmıştır. Önerilen modelin segmentasyon performansı doğruluk, kesinlik, hassasiyet, F1 skoru, özgüllük ve AUC metrikleri kullanılarak değerlendirilmiştir. Doğruluk, genel doğru tahmin oranını; kesinlik, yanlış pozitifleri; hassasiyet,


eksik tespitleri; F1 skoru, kesinlik ve hassasiyet dengesini; özgülük, yanlış negatifleri; AUC ise modelin sınıflandırma yeteneğini ölçmek için kullanılmıştır. UNet, PSPNet, LinkNet ve FPN olmak üzere 4 farklı modelle karşılaştırmalı değerlendirmeler yapılmıştır.

Tablo 5.2. Segmentasyon modellerinin performans karşılaştırması

Segmentasyon Modeli	Doğruluk	Kesinlik	Hassasiyet	F1 Skor	Özgüllük	AUC
UNet	%85	%65	%45	%54	%90	%68
PSPNet	%88	%70	%40	%52	%92	%67
LinkNet	%80	%60	%45	%52	%88	%65
FPN	%75	%55	%35	%43	%85	%60
Eff-Swin-UNet (önerilen)	%99	%84	%53	%65	%99	%76


Tablo 5.2'de sunulan sonuçlar, önerilen Eff-Swin-UNet modelinin, panoramik dış görüntülerinden oluşan veri kümesi üzerinde gerçekleştirilen segmentasyon işleminde diğer modellere kıyasla belirgin şekilde üstün bir performans sergilediğini ortaya koymaktadır. Bu sonuçlar, önerilen EfficientNetB4-Swin Transformer modelinin mevcut yöntemlere göre daha yüksek doğruluk ve etkinlik sunduğunu açıkça göstermektedir.

Deneysel sonuçlar EfficientNet-Swin Transformer modelinin odontojenik enfeksiyonların doğru bir şekilde segmentasyonundaki etkinliğini kanıtlamaktadır. Özellikle, %99 doğruluk oranı ve %84 kesinlik değeri, modelin sınıflandırma görevini başarılı bir şekilde tamamladığını göstermektedir. Önerilen Eff-Swin-UNet modeli, en yüksek %76 AUC değerine ulaşarak, genel segmentasyon başarısını tutarlı bir şekilde artırmıştır. Bu durum, modelin segmentasyon işlemlerinde doğru pozitifleri etkili bir şekilde ayırt ettiğini ve hata oranını minimize ettiğini vurgulamaktadır. Bu sonuçlar, Eff-Swin-UNet modelinin, EfficientNet ve Swin Transformer mimarilerinin avantajlarını birleştirerek, daha derin ve daha geniş özelliklerini öğrenmesine olanak tanımasından kaynaklanmaktadır. Ayrıca, modelin hiper parametrelerinin dikkatli bir şekilde ayarlanması da bu başarılı sonuçta etkili olmuştur. UNet, PSPNet ve LinkNet gibi yaygın olarak kullanılan modellerin de belirli ölçüde başarılı olduğu görülmektedir. Ancak, bu modellerin performansı, Eff-Swin-UNet modeline kıyasla daha düşüktür. Özellikle hassasiyet ve F1 skoru metriklerindeki düşük değerler, bu modellerin pozitif örnekleri doğru bir şekilde tespit etmekte zorlandığını göstermektedir. Diğer yandan FPN modeli, diğer modellere kıyasla en düşük performansı sergilemiştir. Bu durum, FPN modelinin özellikle bu veri kümesi ve görev için uygun olmadığını veya hiper parametrelerin yeterince optimize edilmediğini göstermektedir. Şekil 5.3'te önerilen EfficientNetB4 tabanlı Swin-UNet mimarisi için hesaplanan performans parametrelerine ait görsel grafik gösterilmektedir.



Şekil 5.3. EfficientNetB4 tabanlı Swin Transformer UNet için performans parametrelerine ait görsel grafik

Şekil 5.4'te EfficientNetB4 tabanlı Swin-Unet mimarisinin panoramik dental görüntülerde enfeksiyon alanlarının segmentasyonu üzerindeki performansı detaylı bir şekilde incelenmiştir. Test sonuçları, mimarinin küçük enfeksiyon alanlarının segmentasyonunda sınırlı bir başarı gösterdiğini, ancak daha büyük enfeksiyon alanlarını tespit etmede önemli ölçüde daha etkili olduğunu ortaya koymaktadır. Bu durum, modelin düşük boyutlu ve ince ayrıntılara sahip bölgelerin özelliklerini yeterince temsil edemediğini, ancak geniş ve belirgin enfeksiyon alanlarının tespitinde yüksek hassasiyetle çalıştığını göstermektedir. Segmentasyon doğruluğundaki bu farklılıklar, modelin büyük nesneleri daha belirgin bir şekilde öğrenme eğiliminde olduğunu ve küçük enfeksiyon bölgelerinin modelin dikkat mekanizmalarından kaçabileceğini işaret etmektedir. Bu bulgular, model performansının küçük enfeksiyon bölgelerinin segmentasyonunda iyileştirilmesi için ek yöntemlere ihtiyaç duyulduğunu ortaya koymaktadır. Bu çalışma, gelişmiş klinik tanı araçlarının geliştirilmesine katkı sağlamakta ve hasta takip/tedavi süreçlerini iyileştirmeyi amaçlamaktadır. Deneysel çalışmalarda uygulanan bu yöntemlerin karşılaştırıldığı görsel sonuçlar sunulmuştur.



Şekil 5.4. Önerilen mimarinin görsel sonuçları

Model performansını ölçmek için kullanılan değerlendirme ölçütleri arasında doğruluk, kesinlik, hassasiyet, F1 skoru, özgüllük ve AUC değerleri yer almaktadır. Bu metrikler, önerilen modelin dengeli performansını ortaya koymuş ve yanlış pozitifleri en aza indirirken enfeksiyonlu bölgeleri tespit etmede yüksek doğruluk sağlamıştır. Önerilen yöntemin diğer yöntemlerden daha yüksek enfeksiyon segmentasyonu sergilediği gözlemlenmiştir. Geleneksel UNet ve türevlerinin aksine,

EfficientNetB4 tabanlı Swin Transformer, sürekli olarak temel gerçekle yakından uyumlu segmentasyon çıktıları sunmuştur.

Deneysel bulgular, önerilen modelin klinik ortamlarda pratik uygulanabilirliğini ve güvenilirliğini vurgulamaktadır. Model, odontojenik enfeksiyonları doğru bir şekilde segmente ederek diş hekimlerine kolaylık sunmakta, teşhis hatalarının önüne geçerek tedavi sonuçlarını iyileştirmektedir. Tez kapsamında gerçekleştirilen bu çalışma, dental radyografilerde odontojenik enfeksiyon segmentasyonu için gelecekteki çalışmalar için güçlü bir temel oluşturmakta ve daha erken ve daha etkili müdahalelere olanak sağlamaktadır.

Tez kapsamında gerçekleştirilen bu çalışma, odontojenik enfeksiyon analizinde gelişmiş segmentasyon modellerinin etkinliğini vurgulamakta ve daha karmaşık vakaları içeren gelecek araştırmalar için zemin hazırlamaktadır. Bulgular, panoramik diş görüntülerindeki enfeksiyonların belirlenmesinde EfficientNetB4 tabanlı Swin Transform modelinin başarımını vurgulamaktadır. Deneysel çalışmalarda uygulanan diğer modellere kıyasla önerilen modelin yüksek segmentasyon performansı, bu modelin gerçek dünyadaki klinik uygulamalar için teşhis hatalarını azaltarak etkili tedavi planlamasında başarı sağlaması ve diş hekimlerine etkili bir şekilde teşhis koyma ve tedavi planlama konusunda büyük ölçüde yardımcı olması hedeflenmektedir. Ayrıca, modelin zor vakalardaki güvenilirliği, klinik uygulamada enfeksiyon tespitinin doğruluğunu ve verimliliğini artırmak için bilgisayar destekli tanı sistemlerine katkı sağlayabileceğini göstermektedir.

6. PANORAMİK DİŞ RÖNTGENLERİNDE ÇÜRÜK TESPİTİ


Dış çürükleri yaygın ağız sağlığı sorunlarından biridir, her yaştan bireyi etkiler ve tedavi edilmediği takdirde genellikle ciddi komplikasyonlara yol açar. Doğru ve zamanında tespit, çürüğün ilerlemesini önlemek ve etkili tedavi sağlamak için çok önemlidir. Geleneksel olarak, çürüklerin tespiti diş hekimleri tarafından panoramik radyografi görüntüleri kullanılarak manuel olarak gerçekleştirilmektedir. Bu yöntem yaygın olarak uygulanmakla birlikte, karmaşık görüntüleri yorumlamanın doğasında var olan zorluklar, zaman kısıtlamaları ve yüksek hacimli hastaları verimli bir şekilde yönetme ihtiyacı nedeniyle hatalara maruz kalabilir. Bu faktörler bazen teşhisin gecikmesine yol açarak çürüğün daha ileri aşamalara ilerlemesine izin verebilir ve bu da ciddi enfeksiyonlara, kalıcı ağrıya ve hatta diş kaybına neden olabilir. Bu çalışma kapsamında teşhis hızı ve doğruluğu artırılabilir, hasta bekleme sürelerini azaltılabilir ve genel bakım verimliliği artırılabilir. Manuel teşhisin sınırları göz önüne alındığında, dış çürüklerinin daha güvenilir ve verimli bir şekilde tespit edilmesinde diş hekimlerine yardımcı olmak için çeşitli sinir ağları üzerine çalışmalar gerçekleştirilmiştir. Bu çalışma, gelişmiş derin öğrenme tekniklerinin uygulanmasını araştırmaktadır. Segmentasyon performansını artırmak için uygulanan her modele, iyi özellik çıkarma yeteneğine sahip EfficientB3 omurga ağıyla entegre edildi. Deneysel sonuçlar, önerilen modelin diğer modellerden daha iyi performans göstererek en yüksek hassasiyeti elde ettiğini göstermiştir.

Bu çalışmanın bulguları, çürük tespitinin doğruluğunu ve tutarlılığını artırmada derin öğrenme yöntemlerinin başarısının altını çizmektedir. Bu yöntemler, manuel yorumlamaya olan ihtiyacı azaltarak teşhis hatalarını azaltmaya yardımcı olabilir ve çürüklerin daha erken aşamalarda tespit edilmesini sağlayarak hızlı tedaviyi ve daha iyi hasta sonuçlarını sağlayabilir. Ayrıca, gelişmiş segmentasyon modellerinin iyi omurga ağlarıyla entegrasyonu, dış görüntülemeye gelecekteki araştırma ve geliştirme için umut verici bir yolu temsil etmektedir. Model performansı, modellerin aşırı yanlış pozitifler üretmeden çürükleri doğru bir şekilde tanımlama becerisinin açık bir göstergesini sağladığı için birincil değerlendirme ölçütü olarak hassasiyet kullanılarak değerlendirilmiştir. Sonuçlar yalnızca önerilen yaklaşımın etkinliğini doğrulamakla kalmamakta, aynı zamanda klinik iş akışlarını desteklemek ve genel ağız sağlığı hizmetlerini iyileştirmek için bu alanda daha fazla ilerlemenin önemini vurgulamaktadır.

6.1. Veri Kümesi

Bu çalışmada kullanılan veri kümesi Mersin Üniversitesi'nden etik onay alınarak elde edilmiş ve dış çürüklerinin tespiti için özel olarak düzenlenmiştir. Çürüklerin doğru bir şekilde etiketlenmesini sağlamak için deneyimli diş hekimi eşliğinde etiketlenen 474 hastaya ait 474 adet yüksek


özünürlüklü panoramik radyografi görüntüden oluşmaktadır. Model performansını arttırmak ve verilerin dengeli bir şekilde dağılmasını sağlamak için veri kümesi üç alt kümeye (%70, %15, %15) ayrılmıştır. Çalışma, eğitim, doğrulama ve test setleri arasında dengeli bir dağılım sağlayarak yanlılığı en aza indirmeyi ve sonuçların güvenilirliğini artırmayı amaçlamıştır. Çalışmada kullanılan veri kümesine ait örnek görüntüler Şekil 6.1’de gösterilmiştir.



Şekil 6.1. Veri kümesine ait örnek görüntüler

6.2. Önerilen Yöntem

Bu çalışma, derin öğrenme tabanlı yaklaşım kullanılarak panoramik radyografilerde diş çürüklerini tespit etmek için yeni bir çerçeve sunmaktadır. Önerilen yöntem, yüksek segmentasyon doğruluğu elde etmek için EfficientNetB3 tabanlı UNet 3+ modelini kullanmaktadır. Çerçeve şu aşamalardan oluşmaktadır: model eğitimi ve değerlendirme; bunların her biri performansı arttırmak ve doğru çürük tespiti elde etmek için dikkatlice tasarlanmıştır. Önerilen EfficientNetB3 tabanlı UNet 3+ modeli Şekil 6.2’de gösterilmiştir.



Şekil 6.2. Eff-UNet 3+ mimarisinin yapısı

EfficientNetB3 omurgası, giriş görüntülerinden hem düşük hem de yüksek seviyeli özellikleri verimli bir şekilde yakalayarak özellik çıkarma yetenekleri sağlamaktadır. Bu omurga, ince ayrıntıların doğru segmentasyonda kritik bir rol oynadığı tıbbi görüntüleme görevleri için önerilmektedir. UNet 3+ mimarisi, hem küresel hem de yerel bağlamsal bilgileri verimli bir şekilde işleyen çok ölçekli bir tasarım içererek segmentasyon sürecini geliştirir. Bu, modelin çürük bölgeleri doğru bir şekilde tanımlamasını sağlarken, alakasız arka plan ayrıntılarını bastırarak hassas segmentasyonlara sağlayabilmektedir.

UNet 3+ modeli bir kodlayıcı-kod çözücü yapısından oluşmaktadır. Kodlayıcı giriş görüntülerinden özellikleri çıkarırken, kod çözücü bölümlenmiş çıktıyı yeniden yapılandırır. Kodlayıcı ve kod çözücü arasındaki atlama bağlantıları, etkili özellik yayılımını kolaylaştırır ve uzamsal bilgileri korur. EfficientNetB3 tabanlı model, dış çürükleriyle ilişkili karmaşık desenleri etkili bir şekilde yakalamaktadır. Bu özellikler UNet 3+'ın çok ölçekli tasarımı ile daha da geliştirilerek çürük bölgelerin belirlenmesinde güçlü performans sağlanmıştır.

EfficientNetB3 omurgasının önceden eğitilmiş ağırlıklarından yararlanmak için eğitim sürecinde transfer öğrenimi kullanılmıştır. Bu yaklaşım, öğrenme sürecini önemli ölçüde hızlandırmış ve özellikle sınırlı sayıda etiketli verilerle çalışırken model performansını artırdığı gözlemlenmiştir. Önceden eğitilmiş model, 474 panoramik radyografi görüntüden oluşan etiketli veri kümesi kullanılarak uygulanmıştır. Veri kümesi, Bölüm 6.1'de açıklandığı gibi eğitim, doğrulama ve test

olmak üzere üç alt kümeye bölünerek önerilen modelin dengeli ve kapsamlı bir şekilde değerlendirilmesi sağlanmıştır. Bu ayırım sadece bir kez yapılmıştır ve tüm deneysel çalışmalarda aynı veri kümesi kullanılmıştır. Ayrıca bu ayırım, elde edilen sonuçların karşılaştırılabilirliğini ve güvenilirliğini sağlamak için dikkatle yapılmıştır.

Önerilen EfficientNetB3 tabanlı UNet 3+ modelinin performansı, aşırı yanlış pozitifler üretmeden çürük bölgeleri doğru bir şekilde tanımlamadaki önemi göz önüne alındığında, birincil metrik olarak hassasiyet kullanılarak değerlendirilmiştir. Diğer segmentasyon modelleriyle yapılan karşılaştırmalı deneyler, önerilen yöntemin Tablo 6.1'de belirtildiği gibi üstün sonuçlar elde ettiğini göstermiştir. Kesinlik skorları, modelin klinik uygulamalar için kritik olan çürük bölgeleri çürük olmayan bölgelerden ayırt etmedeki etkinliğini doğrulamıştır. Tablo 6.1'de sunulan derin öğrenme parametreleri tüm deneylerde aynı şekilde uygulanmıştır. EfficientNetB3 tabanlı UNet 3+ modeli, TensorFlow çerçevesi kullanılarak Python'da uygulanmıştır. Ayrıca, aşırı öğrenme problemini aşmak ve optimum model performansını sağlamak için eğitim sırasında erken durdurma işlemi (early stop) uygulanmıştır. Bu tablo, eğitim ve değerlendirme sürecini standartlaştırmak için kullanılan konfigürasyonlara kısa bir genel bakış sunmakta, sonuçların tutarlılığını ve karşılaştırılabilirliğini detaylıca açıklamaktadır.

Tablo 6.1. Deneysel çalışmalarda kullanılan görüntü segmentasyon model hiper parametreleri

Katman	Katman Türü	Detaylar
Giriş Katmanı	Giriş	Boyut: 256×256×3, RGB
Kodlayıcı Blok 1	EfficientNetB3 (Omurga Ağı)	Çok ölçekli özellik haritalarını çıkarır. Çıktı seviyeleri: 128×128×144, 64×64×192, 32×32×288
Köprü Bloğu	Birleştirme + Konv2D	Kodlayıcıdan gelen çok ölçekli özellikleri birleştirir.
Çözücü Blok 1	Konv2DTranspoze	Özellik haritalarını 64×64×64 boyutlarına genişleterek üst düzey özelliklerin birleştirilmesini sağlar.
Normalizasyon 1	Toplu Normalizasyon	Çözücü Blok 1'in çıktısını normalleştirir.
Aktivasyon 1	ReLU	Toplu Normalizasyon 1 çıktısına doğrusal olmayan aktivasyon fonksiyonu uygular.
Füzyon Bloğu 1	Birleştirme + Konv2D	Çok ölçekli özellikleri birleştirir ve 64×64×128 boyutlarında bir çıktı üretir, ardından özellik boyutunu düşürmek için evrişim uygulanır.
Çözücü Blok 2	Konv2DTranspoze	Özellik haritalarını 128×128×64 boyutlarına genişleterek hiyerarşik üst örnekleme gerçekleştirir.
Füzyon Bloğu 2	Birleştirme + Konv2D	Çözücü Blok 2 ve önceki seviyelerden gelen özellikleri birleştirir, 128×128×128 boyutlarında bir çıktı oluşturur.
Çözücü Blok 3	Konv2DTranspoze	Özellik haritalarını 256×256×256 boyutlarına genişleterek sonuç yeniden yapılandırmayı gerçekleştirir.
Normalizasyon 2	Toplu Normalizasyon	Çözücü Blok 3'ün çıktısını normalleştirir.
Aktivasyon 2	ReLU	Toplu Normalizasyon 2 çıktısına doğrusal olmayan aktivasyon fonksiyonu uygular.
Sonuç Katman	Konv2D + Aktivasyon	256×256×1 boyutlarında, sigmoid aktivasyon fonksiyonu ile ikili sınıflandırma için son çıktı segmentasyon haritasını üretir.

Önerilen çerçeve, panoramik radyografilerde diş çürüğü tespiti için çeşitli avantajlar sunmaktadır. EfficientNetB3 omurgasının kullanımı özellik çıkarma verimliliğini artırırken, UNet 3+ modeli ilgili bölgelere odaklanmak için çok ölçekli mimarisinden yararlanarak hassas segmentasyon sağlamıştır. Bu kombinasyon sadece segmentasyon doğruluğunu artırmakla kalmayarak, aynı zamanda diş hekimleri tarafından manuel yorumlama için gereken süreyi de azaltabilmektedir. Ayrıca, transfer öğrenme yaklaşımı, modelin daha küçük bir veri kümelerinde bile yüksek performans elde etmesini sağlayarak gerçek dünya uygulamalara olan uygunluğunu gösterebilmektedir.

6.3. Deneysel Çalışmalar ve Sonuçları

Bu çalışmada, deneysel analizler Kaggle platformu kullanılarak gerçekleştirilmiştir. Kaggle, veri bilimciler ve araştırmacılar için güçlü bir altyapı sağlayarak, model eğitimi ve değerlendirme süreçlerinde kullanılan veri kümelerinin yönetimini kolaylaştıran bir ortam sunmaktadır. Çalışmalar sırasında Kaggle'ın sunduğu 16 GB RAM ve NVIDIA Tesla P100 GPU gibi teknik kaynaklar, özellikle derin öğrenme modellerinin eğitimi için yeterli performans ortamı sağlamıştır. Kaggle'ın sağladığı bu yüksek hesaplama gücü, özellikle karmaşık segmentasyon modellerinin eğitimi sırasında kritik bir avantaj sağlamıştır.

Deneysel çalışmalar, tümü EfficientNetB3 omurgası ile entegre edilmiş altı farklı segmentasyon modeli kullanılarak gerçekleştirilmiştir. Bu modeller arasında UNet, Attention Unet, V-Net, R2U-Net, U2-Net ve önerilen UNet 3+ yer almaktadır. Önerilen EfficientNetB3 tabanlı UNet 3+ modeli, ayrıntılı bağlamsal bilgileri yakalamak ve giriş görüntülerinin ilgili bölgelerini vurgulamak için tasarlanmış olup, yüksek segmentasyon doğruluğu elde etmek amacıyla optimize edilmiştir. Modellerin ve bunlara karşılık gelen omurga ağının detaylı listesi Tablo 6.2'de özetlenmiştir.

Eğitim sürecinde transfer öğrenme stratejisi benimsenmiştir. EfficientNetB3 omurgası, ImageNet veri kümesinden önceden eğitilmiş ağırlıklarla başlatılmış ve bu, özellikle sınırlı etiketli veri kümesiyle çalışırken öğrenme sürecini hızlandırmıştır. Bu yaklaşım, özellikle etiketli veri kümesinin sınırlı boyutu göz önüne alındığında, öğrenme sürecini hızlandırmış ve model performansını iyileştirmiştir. Eğitim sırasında aşırı uyumu önlemek ve modellerin genelleme kabiliyetini artırmak için erken durdurma tekniği uygulanmıştır. Böylece, modellerin yalnızca eğitim verilerine uyum sağlamakla kalmayıp, test verilerinde de tutarlı performans göstermesi hedeflenmiştir.





















































Tablo 6.2, EfficientNetB3 omurgasını kullanan farklı segmentasyon modellerinin kesinlik, hassasiyet ve F1 skoru gibi performans metrikleri açısından karşılaştırmalı sonuçlarını sunmaktadır. Kesinlik, yanlış pozitifleri azaltmayı; hassasiyet, eksik tespitleri en aza indirmeyi; F1 skoru ise kesinlik ve hassasiyet arasındaki dengeyi ölçerek modellerin genel performansını değerlendirmek için kullanılmıştır. Bu karşılaştırma, her bir modelin güçlü ve zayıf yönlerini

detaylı bir şekilde ortaya koyarak, önerilen UNet 3+ modelinin üstün performansını vurgulamaktadır.

Tablo 6.2. Segmentasyon modellerinin performans karşılaştırması


Segmentasyon Modeli	Omurga Ağı	Kesinlik	Hassasiyet	F1 Skor
UNet	EfficientB3	%62	%42	%50
VNet	EfficientB3	%59	%20	%29
Attention UNet	EfficientB3	%62	%14	%23
R2U-Net	EfficientB3	%53	%32	%40
U2-Net	EfficientB3	%62	%19	%29
UNet 3+ (önerilen)	EfficientB3	%81	%75	%78

Sonuçlar, önerilen UNet 3+ modelinin diğer modellerden daha iyi performans gösterdiğini ve en yüksek kesinlik (%81), hassasiyet (%75) ve F1 skorunu (%78) elde ettiğini göstermektedir. Bu performans, önerilen modelin panoramik dış görüntülerinde çürüğe eğilimli bölgeleri doğru bir şekilde segmentasyonundaki etkinliğini vurgulamaktadır. Buna karşılık, UNet, V-Net ve Attention UNet gibi alternatif modeller, kapsamlı çürük bölgelerini yakalamada zorluklara işaret eden önemli ölçüde daha düşük hassasiyet ve F1 skorları sergilemiştir. Tablo 6.2'de sunulan sonuçlar, önerilen EfficientNetB3 tabanlı UNet 3+ modelinin diğer modellere kıyasla daha iyi performans gösterdiğini ve çürük bölgeleri tutarlı bir şekilde yüksek doğrulukla tanımladığını göstermektedir. Çeşitli test görüntülerine ait çalışma kapsamında uygulanan segmentasyon modellerinin ve önerilen UNet 3+ modelinin görsel sonuçları Şekil 6.3'te sunulmuştur.

Gerçek Görüntü	Gerçek Maske	UNet3+	R2UNet	VNet	UNet	Attention UNet	U2Net
							
							
							
							
							
							
							
							
							
							


Şekil 6.3. Segmentasyon modellerine ait görsel sonuçlar

Şekil 6.3, model tarafından oluşturulan segmentasyon maskeleri ile temel gerçek etiketleri arasında bir karşılaştırma sunmaktadır. Şekil 6.3 incelendiğinde önerilen modelin çürük bölgeleri doğru bir şekilde tespit edebildiği gözlemlenmiştir. Tüm modeller için eğitim ve doğrulama süreçleri dikkatle izlenmiştir. Şekil 6.4'te önerilen UNet 3+ modeli için hesaplanan performans parametrelerine ait görsel grafik sunulmuştur.



Şekil 6.4. UNet3+ için performans parametrelerine ait görsel grafik

Şekil 6.4, önerilen UNet 3+ modeli için kesinlik, hassasiyet ve F1 skoru değerlendirme metriklerini göstermektedir. Model %81 oranında kesinlik değerine ulaşarak yanlış pozitifler olmadan çürük dışları belirlemede yüksek doğruluk oranına sahip olduğunu göstermiştir. %75 hassasiyet değeri, gerçek çürük dış alanlarının önemli bir kısmını tespit etme kabiliyetini göstermektedir. Son olarak, %78 F1 skoru değeri, kesinlik ve hassasiyet arasındaki dengeli performansı yansıtmakta ve önerilen modelin çürük dış segmentasyonundaki başarısını doğrulamaktadır. Şekil 6.5'te önerilen modele ait doğruluk grafiği yer almaktadır.



Şekil 6.5. UNet3+ modeline ait doğruluk grafiği

Şekil 6.5, önerilen UNet 3+ modelinin eğitim ve doğrulama doğruluğunu göstermektedir. UNet3+ modeline ait doğruluk grafiği, hem eğitim hem de doğrulamada tutarlı bir iyileşme olduğunu göstermektedir. İki eğri arasındaki minimum boşluk, düşük aşırı uyum ile iyi genelleştirilmiş bir modele işaret etmektedir. Bu sonuç, eğitim sürecinin etkinliğini ve modelin görülmeyen veriler üzerinde yüksek performansı sürdürme kabiliyetini vurgulamaktadır.

Önerilen modelin performansını aynı EfficientNetB3 omurgasını kullanan UNet, V-Net, Attention UNet, R2U-Net ve U2-Net gibi diğer segmentasyon modelleri ile değerlendirmek için karşılaştırmalı bir analiz yapılmıştır. Tablo 6.2'de özetlenen sonuçlar, önerilen UNet 3+ modelinin tutarlı bir şekilde en yüksek hassasiyet puanını elde ettiğini ve çürük bölgeleri doğru bir şekilde tanımladığını göstermektedir.

Önerilen model, otomatik diş çürüğü tespiti için birkaç önemli avantaj sunmaktadır. İlk olarak, EfficientNetB3 omurgası verimli ve sağlam özellik çıkarımı sağlayarak modelin doğru segmentasyon için gerekli olan hem düşük hem de yüksek seviyeli özellikleri yakalamasını sağlamıştır. İkinci olarak, UNet 3+ modeli kritik bölgeleri öne çıkararak ve alakasız arka plan bilgilerini bastırarak segmentasyon performansını artırmış, yüksek ve güvenilir sonuçlar sağlamıştır.

Sonuç olarak, transfer öğrenmenin kullanılması, modelin nispeten küçük bir veri kümesiyle bile yüksek performans elde etmesini sağlayarak gerçek dünya uygulamaları için pratik ve ölçeklenebilir bir çözüm haline getirmektedir. Deneysel sonuçlar ve bunların karşılaştırmalı analizi, bu yaklaşımın önemini pekiştirmekte ve gelecekteki araştırmalar ve klinik uygulamalar için bir temel oluşturmaktadır.

7. SONUÇLAR

Tıbbi görüntüleme teknolojilerindeki hızlı gelişmeler, sağlık alanında hastalıkların erken teşhisi ve tedavi süreçlerini kolaylaştırarak hekimlerin iş yükünü önemli ölçüde hafifletmesi hedeflenmiştir. Diş hekimliği uygulamaları da bu ilerlemeden faydalanan alanlardan birisi olmaktadır. Ancak, diş röntgen görüntülerinin değerlendirilmesinde deneyim ve dikkate dayalı manuel süreçler, teşhis sürecinde zaman kaybına ve hata riskine neden olabilmektedir. Bu durum, yapay zekâ tabanlı otomatik sistemlerin önemini vurgulamaktadır.

Bu tez çalışması kapsamında, panoramik diş röntgen görüntülerinden hastalıkların ve ilgili anatomik yapıların otomatik olarak tespit edilmesine yönelik derin öğrenme tabanlı özgün hibrit modeller geliştirilmiştir. Literatürde bu alanda açık erişimli veri kümelerinin yetersiz olması nedeniyle, etik kurul onayı alınarak uzman diş hekimi eşliğinde veriler üzerinde detaylı şekilde etiketlemeler yapılmış ve özgün bir veri kümesi oluşturulmuştur. Bu veri kümesi, diş hekimliği alanında çalışacak araştırmacılar için önemli bir kaynak sunmaktadır. Çalışmanın çıktıları, literatürdeki veri kümesi eksikliği sorununa çözüm sunan özgün bir veri kümesi oluşturularak hem bilimsel katkı sağlamış hem de diş hekimliği alanında yapay zekâ tabanlı uygulamaların gelişimine olanak tanımıştır.

Tez çalışmasında, gömülü dişlerin tespiti için önerilen model %92 başarımla oranı ile yüksek sonuçlar elde etmiştir. Enfeksiyonların tespitinde kullanılan model ile %72 başarımla oranı elde edilmiştir. Çürük tespiti için önerilen model ise %81 başarımla oranı ile yüksek sonuçlar sağlamış ve çürüklerin ilerleme seviyesini ayırt etmede yüksek performans göstermiştir.

Elde edilen bu bulgular, yapay zekâ tabanlı sistemlerin diş hekimliğinde tanı süreçlerini iyileştirerek klinik uygulamalarda kullanılabilir olduğunu ortaya koymuştur. Ayrıca, bu yöntemlerin, diğer tıbbi görüntüleme uygulamalarına da uyarlanabileceği ve genel tanı süreçlerine katkı sağlayabileceği vurgulanmıştır.

Sonuç olarak, bu tez çalışması, panoramik diş röntgen görüntülerinde hastalık ve anatomik yapıların tespitine yönelik önemli bir bilimsel katkı sunmuş, yeni ve özgün hibrit modellerin geliştirilmesi ile literatürdeki önemli bir boşluğu doldurmuştur. Bu çalışmanın sonuçları, gelecekteki araştırmalar için rehberlik edecek bir temel oluşturmuş ve diş hekimliği alanında yapay zekâ uygulamalarının gelişimine katkıda bulunmuştur.

KAYNAKLAR

- [1] Sivari, E., Senirkentli, G. B., Bostanci, E., Guzel, M. S., Acici, K., Asuroglu, T. (2023). Deep learning in diagnosis of dental anomalies and diseases: A systematic review. *Diagnostics*, 13(15), 2512.
- [2] Chen, I. D. S., Yang, C. M., Chen, M. J., Chen, M. C., Weng, R. M., & Yeh, C. H. (2023). Deep learning-based recognition of periodontitis and dental caries in dental x-ray images. *Bioengineering*, 10(8), 911.
- [3] Almalki, Y. E., Din, A. I., Ramzan, M., Irfan, M., Aamir, K. M., Almalki, A., Alotaibi, S., Alaglan, Alshamrani, G., H. A., Rahman, S. (2022). Deep learning models for classification of dental diseases using orthopantomography X-ray OPG images. *Sensors*, 22(19), 7370.
- [4] Thanh, M. T. G., Van Toan, N., Ngoc, V. T. N., Tra, N. T., Giap, C. N., Nguyen, D. M. (2022). Deep learning application in dental caries detection using intraoral photos taken by smartphones. *Applied Sciences*, 12(11), 5504.
- [5] Mureşanu, S., Hedeşiu, M., Iacob, L., Eftimie, R., Olariu, E., Dinu, C., Jacobs, R., Team Project Group. (2024). Automating Dental Condition Detection on Panoramic Radiographs: Challenges, Pitfalls, and Opportunities. *Diagnostics*, 14(20), 2336.
- [6] Faure, J., Engelbrecht, A. (2021). Impacted tooth detection in panoramic radiographs. In *Advances in Computational Intelligence: 16th International Work-Conference on Artificial Neural Networks, IWANN 2021, Virtual Event, June 16–18, 2021, Proceedings, Part I* 16 (pp. 525-536). Springer International Publishing.
- [7] Alharbi, S. S., Alhasson, H. F. (2024). Exploring the Applications of Artificial Intelligence in Dental Image Detection: A Systematic Review. *Diagnostics*, 14(21), 2442.
- [8] Bazel, M. A., Mohammed, F., Alsabaiy, M., Abualrejal, H. M. (2021). The role of internet of things, blockchain, artificial intelligence, and big data technologies in healthcare to prevent the spread of the Covid-19. In *2021 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT)* (pp. 455-462). IEEE.
- [9] Zhang, Y., Qiu, M., Tsai, C. W., Hassan, M. M., Alamri, A. (2015). Health-CPS: Healthcare cyber-physical system assisted by cloud and big data. *IEEE Systems Journal*, 11(1), 88-95.
- [10] Kunt, M. M., Karaca, M. A., Erbil, B., Akpınar, E. (2021). Acil Tıp ve Yapay Zeka. *Anatolian Journal of Emergency Medicine*, 4(3), 114-117.
- [11] Öncel, C., Aslan, A. (2024). The potential of artificial intelligence and machine learning algorithms in the field of cardiovascular diseases. *Acta Medica Alanya*, 8(2), 91-92.
- [12] Şimşek, E., Uğraş, E. (2024). Birinci Basamak Sağlık Hizmetlerinde Yenilikçi Yaklaşımlar: Öğrenen Sağlık Sistemleri. *Turkish Journal of Family Practice*, 28(3), 110-111.
- [13] Rehman, A., Naz, S., Razzak, I. (2022). Leveraging big data analytics in healthcare enhancement: trends, challenges and opportunities. *Multimedia Systems*, 28(4), 1339-1371.
- [14] Parekh, A. D. E., Shaikh, O. A., Manan, S., Al Hasibuzzaman, M. (2023). Artificial intelligence (AI) in personalized medicine: AI-generated personalized therapy regimens based on genetic and medical history. *Annals of Medicine and Surgery*, 85(11), 5831-5833.
- [15] Manias, G., Den Akker, H. O., Azqueta, A., Burgos, D., Capocchiano, N. D., Crespo, B. L., Dalianis, A., Damiani, A., Filipov, K., Giotis, G., Kalogerini, M., Kostadinov, R., Kranas, P., Kyriazis, D., Lophatananon, A., Malwade, S., Marinos, G., Melillo, F., Mas, V. M., Muir, K., Nieroda, M., Nigro, A. D., Pandolfo, C., Patiño-Martinez, M., Picioroaga, F., Pnevmatikakis, A., Syed-Abdul, S., Tomson, T., Vicheva, D., Wajid, U. (2021). iHELP: Personalised Health Monitoring and Decision Support Based on Artificial Intelligence and Holistic Health Records. In *2021 IEEE Symposium on Computers and Communications (ISCC)* (pp. 1-8). IEEE.
- [16] Çelik, Ö., Kaya, E. (2024). Artificial Intelligence and Ethics in Healthcare: A Bibliometric Analysis. *Süleyman Demirel Üniversitesi Vizyoner Dergisi*, 15(43), 1046-1062.

- [17] Mehta, N., Pandit, A., Shukla, S. (2019). Transforming healthcare with big data analytics and artificial intelligence: A systematic mapping study. *Journal of biomedical informatics*, 100, 103311.
- [18] Bonny, T., Al Nassan, W., Obaideen, K., Al Mallahi, M. N., Mohammad, Y., El-Damanhoury, H. M. (2023). Contemporary role and applications of Artificial Intelligence in Dentistry. *F1000Research*, 12, 1179.
- [19] Mallineni, S. K., Sethi, M., Punugoti, D., Kotha, S. B., Alkhayal, Z., Mubarak, S., Almotawah, F. N., Kotha, L., Sajja, R., Nettam, V., Thakare, A. A., Sakhamuri, S. (2024). Artificial Intelligence in Dentistry: A Descriptive Review. *Bioengineering*, 11(12), 1267.
- [20] Dhopte, A., Bagde, H. (2023). Smart smile: revolutionizing dentistry with artificial intelligence. *Cureus*, 15(6).
- [21] Ergüven, S. S., Kılınç, Y., Çizmeci Şenel, F., Karaoğlanoğlu, S. (2021). Diş Çekimi Öncesi Durumluk, Sürekli Ve Dental Kaygı Düzeylerinin Değerlendirilmesi. *Medical Journal of Ankara Training & Research Hospital*, 54(1).
- [22] Bacanlı, G., Savaştaer, E. F., Çelik, M. E. (2022). Dental filling detection using deep learning in periapical radiography. In *2022 International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)* (pp. 721-724). IEEE.
- [23] Siddiqui, T. A., Sukhia, R. H., Ghandhi, D. (2022). Artificial intelligence in dentistry, orthodontics and Orthognathic surgery: A literature review.
- [24] Khanagar, S. B., Al-Ehaideb, A., Maganur, P. C., Vishwanathaiah, S., Patil, S., Baeshen, H. A., Sarode, S. C., Bhandi, S. (2021). Developments, application, and performance of artificial intelligence in dentistry—A systematic review. *Journal of dental sciences*, 16(1), 508-522.
- [25] Batra, P., Tagra, H., Katyal, S. (2022). Artificial intelligence in teledentistry. *Discoveries*, 10(3), 153.
- [26] Ducret, M., Mörch, C. M. (2022). Focus on artificial intelligence ethics in dentistry. *Journal of Dental Sciences*, 18(3), 1409.
- [27] Suzuki, K. (2017). Overview of deep learning in medical imaging. *Radiological physics and technology*, 10(3), 257-273.
- [28] Puttagunta, M., Ravi, S. (2021). Medical image analysis based on deep learning approach. *Multimedia tools and applications*, 80(16), 24365-24398.
- [29] Guo, Z., Li, X., Huang, H., Guo, N., Li, Q. (2019). Deep learning-based image segmentation on multimodal medical imaging. *IEEE Transactions on Radiation and Plasma Medical Sciences*, 3(2), 162-169.
- [30] Kim, M., Yun, J., Cho, Y., Shin, K., Jang, R., Bae, H. J., Kim, N. (2019). Deep learning in medical imaging. *Neurospine*, 16(4), 657.
- [31] Ahmad, H. M., Khan, M. J., Yousaf, A., Ghuffar, S., Khurshid, K. (2020). Deep learning: a breakthrough in medical imaging. *Current Medical Imaging*, 16(8), 946-956.
- [32] Kim, C., Jeong, H., Park, W., Kim, D. (2022). Tooth-related disease detection system based on panoramic images and optimization through automation: development study. *JMIR Medical Informatics*, 10(10), e38640.
- [33] Al Kheraif, A. A., Wahba, A. A., Fouad, H. (2019). Detection of dental diseases from radiographic 2d dental image using hybrid graph-cut technique and convolutional neural network. *Measurement*, 146, 333-342.
- [34] Murata, M., Ariji, Y., Ohashi, Y., Kawai, T., Fukuda, M., Funakoshi, T., Kise, Y., Nozawa, M., Ariji, E. (2019). Deep-learning classification using convolutional neural network for evaluation of maxillary sinusitis on panoramic radiography. *Oral radiology*, 35, 301-307.
- [35] Elgarba, B. M., Van Aelst, S., Swait, A., Morgan, N., Shujaat, S., Jacobs, R. (2023). Deep learning-based segmentation of dental implants on cone-beam computed tomography images: A validation study. *Journal of Dentistry*, 137, 104639.
- [36] Kohlakala, A., Coetzer, J., Bertels, J., Vandermeulen, D. (2022). Deep learning-based dental implant recognition using synthetic X-ray images. *Medical & Biological Engineering & Computing*, 60(10), 2951-2968.

- [37] Kim, H. G., Lee, K. M., Kim, E. J., San Lee, J. (2019). Improvement diagnostic accuracy of sinusitis recognition in paranasal sinus X-ray using multiple deep learning models. *Quantitative imaging in medicine and surgery*, 9(6), 942.
- [38] Muresan, M. P., Barbura, A. R., Nedevschi, S. (2020). Teeth detection and dental problem classification in panoramic X-ray images using deep learning and image processing techniques. In *2020 IEEE 16th International Conference on Intelligent Computer Communication and Processing (ICCP)* (pp. 457-463). IEEE.
- [39] Mertoğlu, D., Keser, G., Pekiner, F. M. N., Bayrakdar, İ. Ş., Çelik, Ö., Orhan, K. (2023). A Deep Learning Approach to Automatic Tooth Detection and Numbering in Panoramic Radiographs: An Artificial Intelligence Study. *Clinical and Experimental Health Sciences*, 13(4), 883-888.
- [40] Fukuda, M., Inamoto, K., Shibata, N., Arijji, Y., Yanashita, Y., Kutsuna, S., Fujita, H., Arijji, E. (2020). Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography. *Oral radiology*, 36, 337-343.
- [41] Hossam, A., Mohamed, K., Tarek, R., Elsayed, A., Mostafa, H., Selim, S. (2021). Automated dental diagnosis using deep learning. In *2021 16th International Conference on Computer Engineering and Systems (ICCES)* (pp. 1-5). IEEE.
- [42] Arijji, Y., Mori, M., Fukuda, M., Katsumata, A., Arijji, E. (2022). Automatic visualization of the mandibular canal in relation to an impacted mandibular third molar on panoramic radiographs using deep learning segmentation and transfer learning techniques. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, 134(6), 749-757.
- [43] Jeon, K. J., Ha, E. G., Choi, H., Lee, C., Han, S. S. (2022). Performance comparison of three deep learning models for impacted mesiodens detection on periapical radiographs. *Scientific reports*, 12(1), 15402.
- [44] Zhang, W., Li, J., Li, Z. B., Li, Z. (2018). Predicting postoperative facial swelling following impacted mandibular third molars extraction by using artificial neural networks evaluation. *Scientific reports*, 8(1), 12281.
- [45] Imak, A., Çelebi, A., Polat, O., Türkoğlu, M., Şengür, A. (2023). ResMIBCU-Net: an encoder-decoder network with residual blocks, modified inverted residual block, and bi-directional ConvLSTM for impacted tooth segmentation in panoramic X-ray images. *Oral Radiology*, 39(4), 614-628.
- [46] Prajapati, S. A., Nagaraj, R., Mitra, S. (2017). Classification of dental diseases using CNN and transfer learning. In *2017 5th International Symposium on Computational and Business Intelligence (ISCBI)* (pp. 70-74). IEEE.
- [47] Wen, C., Bai, X., Yang, J., Li, S., Wang, X., Yang, D. (2024). Deep learning based approach: automated gingival inflammation grading model using gingival removal strategy. *Scientific Reports*, 14(1), 19780.
- [48] Hashem, M., Youssef, A. E. (2020). Teeth infection and fatigue prediction using optimized neural networks and big data analytic tool. *Cluster Computing*, 23(3), 1669-1682.
- [49] Li, W., Liang, Y., Zhang, X., Liu, C., He, L., Miao, L., Sun, W. (2021). A deep learning approach to automatic gingivitis screening based on classification and localization in RGB photos. *Scientific Reports*, 11(1), 16831.
- [50] Dhingra, L. (2023). Smart Decision Support Framework for Precise Diagnosis of Chronic Odontogenic Rhinosinusitis using U-Net Segmentation. In *2023 IEEE International Conference on ICT in Business Industry & Government (ICTBIG)* (pp. 1-6). IEEE.
- [51] Alalharith, D. M., Alharthi, H. M., Alghamdi, W. M., Alsenbel, Y. M., Aslam, N., Khan, I. U., Shahin, S. Y., Dianišková, S., Alhareky, M. S., Barouch, K. K. (2020). A deep learning-based approach for the detection of early signs of gingivitis in orthodontic patients using faster region-based convolutional neural networks. *International Journal of Environmental Research and Public Health*, 17(22), 8447.
- [52] Imak, A., Celebi, A., Siddique, K., Turkoglu, M., Sengur, A., Salam, I. (2022). Dental caries detection using score-based multi-input deep convolutional neural network. *IEEE Access*, 10, 18320-18329.

- [53] Park, E. Y., Cho, H., Kang, S., Jeong, S., Kim, E. K. (2022). Caries detection with tooth surface segmentation on intraoral photographic images using deep learning. *BMC Oral Health*, 22(1), 573.
- [54] Geetha, V., Aprameya, K. S., Hinduja, D. M. (2020). Dental caries diagnosis in digital radiographs using back-propagation neural network. *Health information science and systems*, 8, 1-14.
- [55] Saini, D., Jain, R., Thakur, A. (2021). Dental caries early detection using convolutional neural network for tele dentistry. In *2021 7th International Conference on Advanced Computing and Communication Systems (ICACCS)* (Vol. 1, pp. 958-963). IEEE.
- [56] Goswami, M., Maheshwari, M., Baruah, P. D., Singh, A., Gupta, R. (2021). Automated detection of oral cancer and dental caries using convolutional neural network. In *2021 9th international conference on reliability, infocom technologies and optimization (trends and future directions)(ICRITO)* (pp. 1-5). IEEE.
- [57] Verma, D., Puri, S., Prabhu, S., Smriti, K. (2020). Anomaly detection in panoramic dental x-rays using a hybrid Deep Learning and Machine Learning approach. In *2020 IEEE region 10 conference (TENCON)* (pp. 263-268). IEEE.
- [58] Yang, J., Xie, Y., Liu, L., Xia, B., Cao, Z., Guo, C. (2018). Automated dental image analysis by deep learning on small dataset. In *2018 IEEE 42nd annual computer software and applications conference (COMPSAC)* (Vol. 1, pp. 492-497). IEEE.
- [59] Johnson, K. B., Mol, A., Tyndall, D. A. (2021). Extraoral bite-wing radiographs: A universally accepted paradox. *The Journal of the American Dental Association*, 152(6), 444-447.
- [60] Grieco, P., Jivraj, A., Da Silva, J., Kuwajima, Y., Ishida, Y., Ogawa, K., Ohyama, H., Ishikawa-Nagai, S. (2022). Importance of bitewing radiographs for the early detection of interproximal carious lesions and the impact on healthcare expenditure in Japan. *Annals of translational medicine*, 10(1), 2.
- [61] Pérez de Frutos, J., Holden Helland, R., Desai, S., Nymoen, L. C., Langø, T., Remman, T., Sen, A. (2024). AI-Dentify: deep learning for proximal caries detection on bitewing x-ray-HUNT4 Oral Health Study. *BMC Oral Health*, 24(1), 344.
- [62] Arslan, Z. B., Demir, H., Berker Yıldız, D., Yaşar, F. (2020). Diagnostic accuracy of panoramic radiography and ultrasonography in detecting periapical lesions using periapical radiography as a gold standard. *Dentomaxillofacial Radiology*, 49(6), 20190290.
- [63] Pereira, S. A., Corte-Real, A., Melo, A., Magalhães, L., Lavado, N., Santos, J. M. (2024). Diagnostic Accuracy of Cone Beam Computed Tomography and Periapical Radiography for Detecting Apical Root Resorption in Retention Phase of Orthodontic Patients: A Cross-Sectional Study. *Journal of Clinical Medicine*, 13(5), 1248.
- [64] Gliga, A., Imre, M., Grandini, S., Marruganti, C., Gaeta, C., Bodnar, D., Dimitriu, B. A., Foschi, F. (2023). The limitations of periapical X-ray assessment in endodontic diagnosis—a systematic review. *Journal of Clinical Medicine*, 12(14), 4647.
- [65] Srivastava, M. M., Kumar, P., Pradhan, L., Varadarajan, S. (2017). Detection of tooth caries in bitewing radiographs using deep learning. *arXiv preprint arXiv:1711.07312*.
- [66] Venkatesh, E., Elluru, S. V. (2017). Cone beam computed tomography: basics and applications in dentistry. *Journal of Istanbul University Faculty of Dentistry*, 51(3 Suppl 1), 102-121.
- [67] Baccher, S., Gowdar, I. M., Guruprasad, Y., Solanki, R. N., Medhi, R., Shah, M. J., Mehta, D. N. (2024). CBCT: A comprehensive overview of its applications and clinical significance in dentistry. *Journal of Pharmacy and Bioallied Sciences*, 16(Suppl 3), S1923-S1925.
- [68] Kaasalainen, T., Ekholm, M., Siiskonen, T., Kortensniemi, M. (2021). Dental cone beam CT: An updated review. *Physica Medica*, 88, 193-217.
- [69] Sarwar, S., Jabin, S. (2023). AI Techniques for Cone Beam Computed Tomography in Dentistry: Trends and Practices. In *2023 International Conference on Recent Advances in Electrical, Electronics & Digital Healthcare Technologies (REEDCON)* (pp. 226-231). IEEE.

- [70] Różyło-Kalinowska, I. (2021). Panoramic radiography in dentistry. *Clinical Dentistry Reviewed*, 5(1), 26.
- [71] Izzetti, R., Nisi, M., Aringhieri, G., Crocetti, L., Graziani, F., Nardi, C. (2021). Basic knowledge and new advances in panoramic radiography imaging techniques: a narrative review on what dentists and radiologists should know. *Applied Sciences*, 11(17), 7858.
- [72] Dave, M. (2024). EBD spotlight: Artificial intelligence and dental panoramic radiography. *BDJ Team*, 11(6), 244-245.
- [73] Moussa, D. G., Ahmad, P., Mansour, T. A., Siqueira, W. L. (2022). Current state and challenges of the global outcomes of dental caries research in the meta-omics era. *Frontiers in Cellular and Infection Microbiology*, 12, 887907.
- [74] Abdelaziz, M. (2023). Detection, diagnosis, and monitoring of early caries: the future of individualized dental care. *Diagnostics*, 13(24), 3649.
- [75] Zhang, J., Wang, Q., Duan, Z. (2024). Preventive effects of probiotics on dental caries in vitro and in vivo. *BMC Oral Health*, 24(1), 915.
- [76] Ye, G., Zhang, Q., Li, Y., Wang, G., Zhang, J., Fang, J., Pan, H., Sun, K., Wang, J., Pan, J., Zhu, W. (2013). Treatment of oral pathogenic bacteria with non-thermal plasma activated water as a new type mouthwash. In *2013 Abstracts IEEE International Conference on Plasma Science (ICOPS)* (pp. 1-1). IEEE.
- [77] Goncalves, S. B., Correia, J. H., Costa, A. C. (2013). Evaluation of dental implants using computed tomography. In *2013 IEEE 3rd Portuguese Meeting in Bioengineering (ENBENG)* (pp. 1-4). IEEE.
- [78] Bayat, M., Khoshniat Nikoo, S. M., Afshar Hezarkhani, F. (2013). Prevalence of systemic diseases in patients with dental infections. *Journal of Dental Medicine*, 25(4).
- [79] Patel, J., Le, R. T., Haymes, D., Rao, D., Fiester, P., Hernandez, M., Jenson, M. (2021). Imaging of dental infections. *Emergency Radiology*, 1-9.
- [80] Pawinru, A. S. (2017). Angulation change of the third molar tooth in orthodontic treatment. *J Dentomaxillofac Sci*, 2(1), 40-5.
- [81] Manne, R., Gandikota, C., Juvvadi, S. R., Rama, H. R. M., Anche, S. (2012). Impacted canines: Etiology, diagnosis, and orthodontic management. *Journal of Pharmacy and Bioallied Sciences*, 4(Suppl 2), S234-S238.
- [82] da Silva Menezes, C. G., Sartoretto, S. C., Louro, R. S., de Moraes, J. B., Moraschini, V. (2024). Prevalence of impacted teeth: A radiographical retrospective Rio de Janeiro population-based study. *Journal of Maxillofacial and Oral Surgery*, 23(1), 75-80.
- [83] Shi, F., Wang, J., Shi, J., Wu, Z., Wang, Q., Tang, Z., He, K., Shi, Y., Shen, D. (2020). Review of artificial intelligence techniques in imaging data acquisition, segmentation, and diagnosis for COVID-19. *IEEE reviews in biomedical engineering*, 14, 4-15.
- [84] Hu, Q., Souza, L. F. D. F., Holanda, G. B., Alves, S. S., Silva, F. H. D. S., Han, T., Reboucas Filho, P. P. (2020). An effective approach for CT lung segmentation using mask region-based convolutional neural networks. *Artificial intelligence in medicine*, 103, 101792.
- [85] Girshick, R., Donahue, J., Darrell, T., Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 580-587).
- [86] Ren, S., He, K., Girshick, R., Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 28.
- [87] He, K., Gkioxari, G., Dollár, P., Girshick, R. (2017). Mask r-cnn. In *Proceedings of the IEEE international conference on computer vision* (pp. 2961-2969).
- [88] Redmon, J., Farhadi, A. (2017). YOLO9000: better, faster, stronger. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 7263-7271).
- [89] Ning, J., Zhang, L., Zhang, D., Wu, C. (2010). Interactive image segmentation by maximal similarity based region merging. *Pattern Recognition*, 43(2), 445-456.
- [90] Ronneberger, O., Fischer, P., Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *Medical image computing and computer-assisted intervention—MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18* (pp. 234-241). Springer international publishing.

- [91] Çiçek, Ö., Abdulkadir, A., Lienkamp, S. S., Brox, T., Ronneberger, O. (2016). 3D U-Net: learning dense volumetric segmentation from sparse annotation. In *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2016: 19th International Conference, Athens, Greece, October 17-21, 2016, Proceedings, Part II* 19 (pp. 424-432). Springer International Publishing.
- [92] Isensee, F., Jaeger, P. F., Kohl, S. A., Petersen, J., Maier-Hein, K. H. (2021). nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. *Nature methods*, 18(2), 203-211.
- [93] Oktay, O., Schlemper, J., Folgoc, L. L., Lee, M., Heinrich, M., Misawa, K., Mori, K., McDonagh, S., Hammerla, N. Y., Kainz, B., Glocker, B., Rueckert, D. (2018). Attention u-net: Learning where to look for the pancreas. *arXiv preprint arXiv:1804.03999*.
- [94] Alom, M. Z., Hasan, M., Yakopcic, C., Taha, T. M., Asari, V. K. (2018). Recurrent residual convolutional neural network based on u-net (r2u-net) for medical image segmentation. *arXiv preprint arXiv:1802.06955*.
- [95] Qin, X., Zhang, Z., Huang, C., Dehghan, M., Zaiane, O. R., Jagersand, M. (2020). U2-Net: Going deeper with nested U-structure for salient object detection. *Pattern recognition*, 106, 107404.
- [96] Huang, H., Lin, L., Tong, R., Hu, H., Zhang, Q., Iwamoto, Y., Han, X., Chen, Y. V., Wu, J. (2020). Unet 3+: A full-scale connected unet for medical image segmentation. In *ICASSP 2020-2020 IEEE international conference on acoustics, speech and signal processing (ICASSP)* (pp. 1055-1059). IEEE.
- [97] Milletari, F., Navab, N., Ahmadi, S. A. (2016). V-net: Fully convolutional neural networks for volumetric medical image segmentation. In *2016 fourth international conference on 3D vision (3DV)* (pp. 565-571). IEEE.
- [98] Zhao, H., Shi, J., Qi, X., Wang, X., Jia, J. (2017). Pyramid scene parsing network. In *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR)* (pp. 2881-2890).
- [99] Sun, Y., Zheng, W. (2023). HRNet-and PSPNet-based multiband semantic segmentation of remote sensing images. *Neural Computing and Applications*, 35(12), 8667-8675.
- [100] Lin, T. Y., Dollár, P., Girshick, R., He, K., Hariharan, B., Belongie, S. (2017). Feature pyramid networks for object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR)* (pp. 2117-2125).
- [101] Park, H. J., Kang, J. W., Kim, B. G. (2023). ssFPN: Scale sequence (S 2) feature-based feature pyramid network for object detection. *Sensors*, 23(9), 4432.
- [102] Li, Z., Xu, X., Shen, F., Chen, H. (2020). CR-FPN: channel relation feature pyramid network for object detection. *Wireless Networks*, 1-10.
- [103] Üzen, H., Sel, İ., Türkoğlu, M., Hanbay, D. (2021). Derinlemesine Özellik Piramit Ağı Kullanarak Yüzey Hata Tespiti. *Computer Science*, (Special), 109-115.
- [104] Chaurasia, A., Culurciello, E. (2017). Linknet: Exploiting encoder representations for efficient semantic segmentation. In *2017 IEEE visual communications and image processing (VCIP)* (pp. 1-4). IEEE.
- [105] Li, H., Xiong, P., Fan, H., Sun, J. (2019). Dfanet: Deep feature aggregation for real-time semantic segmentation. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (CVPR)* (pp. 9522-9531).
- [106] Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Lin, S., Guo, B. (2021). Swin transformer: Hierarchical vision transformer using shifted windows. In *Proceedings of the IEEE/CVF international conference on computer vision (ICCV)* (pp. 10012-10022).
- [107] Simonyan, K., Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- [108] He, K., Zhang, X., Ren, S., Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR)* (pp. 770-778).

- [109] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR)* (pp. 2818-2826).
- [110] Szegedy, C., Ioffe, S., Vanhoucke, V., Alemi, A. (2017). Inception-v4, inception-resnet and the impact of residual connections on learning. In *Proceedings of the AAAI conference on artificial intelligence* (Vol. 31, No. 1).
- [111] Xie, S., Girshick, R., Dollár, P., Tu, Z., He, K. (2017). Aggregated residual transformations for deep neural networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR)* (pp. 1492-1500).
- [112] Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR)* (pp. 4700-4708).
- [113] Hu, J., Shen, L., Sun, G. (2018). Squeeze-and-excitation networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 7132-7141).
- [114] Tan, M., Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning* (pp. 6105-6114). PMLR.
- [115] Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- [116] Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Lin, S., Guo, B. (2021). Swin transformer: Hierarchical vision transformer using shifted windows. In *Proceedings of the IEEE/CVF international conference on computer vision* (pp. 10012-10022).
- [117] Taha, A. A., Hanbury, A. (2015). Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool. *BMC medical imaging*, 15, 1-28.
- [118] Román, J. C. M., Fretes, V. R., Adorno, C. G., Silva, R. G., Noguera, J. L. V., Legal-Ayala, H., Mello-Román, J. D., Escobar Torres, R. D., Facon, J. (2021). Panoramic dental radiography image enhancement using multiscale mathematical morphology. *Sensors*, 21(9), 3110.
- [119] Abdi, A. H., Kasaei, S., Mehdizadeh, M. (2015). Automatic segmentation of mandible in panoramic x-ray. *Journal of Medical Imaging*, 2(4), 044003-044003.

EKLER

EK- 1: ETİK KURUL RAPORU



T.C.
SAĞLIK BAKANLIĞI
Türkiye İlaç ve Tıbbi Cihaz Kurumu



Sayı : E-68869993-000-1366974
Konu : 2024-005

29.01.2024

Sayın Doç. Dr. Adalet ÇELEBİ
Mersin Üniversitesi Diş Hekimliği Fakültesi
Ağız, Diş ve Çene Cerrahisi Anabilim Dalı
Yenişehir/MERSİN

İlgi : Kurum evrak kayıt 09.01.2024 tarihli ve E-61749811-000-2857003 sayılı başvurunuz.

Sorumlu araştırmacısı olduğunuz “Ağız Bölgesi ile İlgili Hastalık ve Anatomik Yapıların Yapay Zeka Tabanlı Tespit Edilmesi” isimli ilgede kayıtlı araştırma başvurunuz incelenmiştir.

Bilindiği üzere ülkemizde klinik araştırmalar ile ilgili hususlar 3359 sayılı Sağlık Hizmetleri Temel Kanunu, 08.07.2022 tarih ve 31890 sayılı Resmi Gazete’ de yayımlanan Tıbbi Cihaz Klinik Araştırmaları Yönetmeliği ve diğer meri kanuni düzenlemelere göre yapılmaktadır. İlgili yönetmeliğin 4. Maddesinin r bendinde Tıbbi Cihaz Klinik Araştırması “Bir veya daha fazla merkezde, tıbbi cihazın güvenlik, etkinlik veya performansını değerlendirmek için gönüllüler üzerinde yürütülen sistematik araştırma veya çalışmaları,” olarak tanımlanmıştır.

Başvurunuzda yer alan belgelerin incelenmesi neticesinde, başvuru formunda “Panoramik görüntüler üzerinde istenilen alanlar MATLAB programı kullanılarak etiketlenecektir. Etiketlenen her bölge data olarak depolanacaktır. Depolanan veriler, geliştirilecek bölgesel tabanlı evrimsel sinir ağ modeli kullanılarak sistem eğitilecektir.” ibaresi görülerek ilgili ürünün henüz geliştirilme aşamasında olduğu ve araştırmacının bir hipotezin doğrulanmasına yönelik planlandığı anlaşılmış olup bu doğrultuda ilgili araştırmanın bir tıbbi cihazın güvenlik, etkinlik veya performansını değerlendirmeye yönelik tasarlanmadığı görülmüştür. Bu doğrultuda ilgili araştırmanın 08.07.2022 tarihli ve 31890 sayılı Resmi Gazete’ de yayımlanan Tıbbi Cihaz Klinik Araştırmaları Yönetmeliği kapsamında değerlendirilemeyeceği mütalaa edilmiştir.

Ancak ilerleyen dönemlerde ilgili ürünün tasarım detaylarının belirlenmesi ve ürün gerçekleşmesinin ardından 02.06.2021 tarih ve 31499 sayılı Resmi Gazete’ de yayımlanan Tıbbi Cihaz Yönetmeliği gereği ilgili tüm test ve verilerin tamamlanması neticesinde adı geçen tıbbi cihazın gönüllüye uygulanması aşamasında tıbbi cihaz olarak klinik araştırma amacıyla insan üzerinde kullanılması planlanacak olursa öncelikle Kurumumuz tarafından yetkilendirilmiş bir klinik araştırma etik kurulunun uygun görüşü sonrasında Kurumumuza klinik araştırma izni için başvuru yapılmasının uygun olacağı hususunda;

Bilgilerinizi ve gereğini rica ederim.

Fatih TOPUZ
Kurum Başkanı a.
Daire Başkanı





T.C.
MERSİN ÜNİVERSİTESİ REKTÖRLÜĞÜ
KLİNİK ARAŞTIRMALAR ETİK KURULU



Sayı : 78017789/050.01.04/2665365
Konu : Etik Kurul Kararı

13.3/2024

Sayın Doç. Dr. Adalet ÇELEBİ
Mersin Üniversitesi Diş Hekimliği Fakültesi
Ağız, Diş ve Çene Cerrahisi Ana Bilim Dalı

Sorumluluğunuzda yapılması tasarlanan "Ağız Bölgesi ile İlgili Hastalık ve Anatomiik Yapıların Yapay Zeka Tabanlı Tespit Edilmesi" adlı araştırmaya ilişkin 06/03/2024 tarihli ve 2024/247 sayılı Kurul Kararı ile Klinik Araştırmalar Etik Kurulu Karar Formu ekte sunulmuştur.

Bilgilerinizi arz/rica ederim.

Doç. Dr. Mustafa ZÖĞÜLÜ
Kurul Başkanı

EKLER:

- 1-Kurulun 06/03/2024 tarihli ve 2024/247 sayılı kararı (1 sayfa)
- 2- Klinik Araştırmalar Etik Kurulu Karar Formu (3 sayfa)

Adres : MEÜ Çiftlikköy Kampüsü 33343 Yenişehir / MERSİN Ayrıntılı bilgi için irtibat:
Tel : 03243610001-4417 Fax :
e-posta : Elektronik Ağ : www.mersin.edu.tr



MEÜ.ID.FR-001/03

Sayfa 1/1

Yayın Tarihi: 22 / 11 / 2013

T.C.
MERSİN ÜNİVERSİTESİ REKTÖRLÜĞÜ
KLİNİK ARAŞTIRMALAR ETİK KURULU

Karar Tarihi	Toplantı Sayısı	Karar Sayısı
06/03/2024	05	247

Mersin Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Cerrahisi Ana Bilim Dalı öğretim üyesi Doç. Dr. Adalet ÇELEBLİ'nin sorumluluğunda yapılması tasarlanan "Ağız Bölgesi ile İlgili Hastalık ve Anatomi Yapıların Yapay Zeka Tabanlı Tespit Edilmesi" adlı araştırma için hazırlanmış olan ve 28/02/2024 tarihinde sunulan Girişimsel Olmayan Klinik Araştırmalar İçin Başvuru Formu ile ilgili belgeler araştırmanın gerekçe, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiş, araştırmanın yapılabilmesi için izin alınması durumunda gereken izin yazısının başvuru dosyasına eklenmesi, araştırmanın yürürlükte olan yasal düzenlemelere uyularak yürütülmesi ve sonuçlandırılması koşulu ile gerçekleştirilmesinde etik sakınca bulunmadığına toplantıya katılanların oy birliği ile karar verilmiştir

İmza
Doç. Dr. Mustafa AZİZOĞLU
Başkan

Katılmadı
Doç. Dr. R. Nalan TİFTİK
Başkan Yardımcısı

İmza
Prof. Dr. Murat BOZLU
Üye

İmza
Prof. Dr. İsmail ÜN
Üye

İmza
Prof. Dr. Mehmet Sami SERİN
Üye

İmza
Prof. Dr. Ataman KÖSE
Üye

Katılmadı
Prof. Dr. Gülhan TEMEL
Üye

İmza
Prof. Dr. Serdal ARSLAN
Üye

İmza
Prof. Dr. Nimet KARAGÜLLE
Üye

İmza
Doç. Dr. Özlem TEZOL
Üye

İmza
Dr. Öğr. Üyesi Selda OKUYAZ
Üye

İmza
Dr. Öğr. Üyesi Hatice YILDIRIM
YAROĞLU
Üye

İmza
Uzm. Dr. Mehtap PEKTAŞ
Üye

Katılmadı
H. Betül LEVENT ERDAL
Üye

İmza
Lale DAĞLI
Üye

Doç. Dr. [Redacted] AZİZOĞLU
A. [Redacted] DİR

ÖZGEÇMİŞ

Meryem DURMUŞ

Öğrenim Durumları

Yıl	Okul
2023	Çukurova Üniversitesi Mühendislik Fakültesi
2022	Çukurova Üniversitesi Mühendislik Fakültesi
2021	Çukurova Üniversitesi Mühendislik Fakültesi
2020	Çukurova Üniversitesi Mühendislik Fakültesi
2019	Çukurova Üniversitesi Mühendislik Fakültesi
2018	Çukurova Üniversitesi Mühendislik Fakültesi

Çalışma Durumları

Yıl	Çalışma Yeri
2023	Çukurova Üniversitesi Mühendislik Fakültesi
2022	Çukurova Üniversitesi Mühendislik Fakültesi

Öğretim Üyesi

Yıl	Öğretim Yeri
2023	Çukurova Üniversitesi Mühendislik Fakültesi
2022	Çukurova Üniversitesi Mühendislik Fakültesi
2021	Çukurova Üniversitesi Mühendislik Fakültesi
2020	Çukurova Üniversitesi Mühendislik Fakültesi
2019	Çukurova Üniversitesi Mühendislik Fakültesi
2018	Çukurova Üniversitesi Mühendislik Fakültesi

Öğretim Yardımcısı

Yıl	Öğretim Yeri
2023	Çukurova Üniversitesi Mühendislik Fakültesi
2022	Çukurova Üniversitesi Mühendislik Fakültesi

Öğretim Görevleri

Yıl	Öğretim Yeri
2023	Çukurova Üniversitesi Mühendislik Fakültesi
2022	Çukurova Üniversitesi Mühendislik Fakültesi

AKADEMİK FAALİYETLER

Makaleler:

1. Durmuş, M., Ergen, B., Çelebi, A., & Türkoğlu, M. (2023). Panoramik diş görüntülerinde derin evrişimsel sinir ağına dayalı gömülü diş tespiti ve segmentasyonu. Çukurova Üniversitesi Mühendislik Fakültesi Dergisi, 38(3), 713-724. <https://doi.org/10.21605/cukurovaumfd.1377733>
2. Durmuş, M., Ergen, B., Çelebi, A., & Türkoğlu, M. (2024). ResNet Tabanlı PSPNet Kullanarak Panoramik Görüntülerde Gömülü Diş Segmentasyon Analizi. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 36(1), 159-166. <https://doi.org/10.35234/fumbd.1404979>
3. Durmuş, M., Ergen, B., Çelebi, A., & Türkoğlu, M. (2024). Comparative Analysis of Pixel-Based Segmentation Models for Accurate Detection of Impacted Teeth on Panoramic Radiographs. IEEE Access. <https://doi.org/10.1109/ACCESS.2024.3523816>