



T.C.

BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

BİLGİSAYAR MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI

**DERİN ÖĞRENME İLE RADYOGRAFİK DIŞ GÖRÜNTÜLERİNİN
SEGMENTASYONUNDA GÖRÜNTÜ ÖN İŞLEME YÖNTEMLERİNİN ETKİSİNİN
ARAŞTIRILMASI**

YÜKSEK LİSANS TEZİ

NESLİHAN SOGUR

TEZ DANIŞMANI

DR. ÖĞR. ÜYESİ NİHAN KAZAK ÇERÇEVİK

BİLECİK, 2025

10761240

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI

**DERİN ÖĞRENME İLE RADYOGRAFİK DIŞ GÖRÜNTÜLERİNİN
SEGMENTASYONUNDA GÖRÜNTÜ ÖN İŞLEME YÖNTEMLERİNİN ETKİSİNİN
ARAŞTIRILMASI**

YÜKSEK LİSANS TEZİ

NESLİHAN SOGUR

TEZ DANIŞMANI

DR. ÖĞR. ÜYESİ NİHAN KAZAK ÇERÇEVİK

BİLECİK, 2025

10761240

BEYAN

Derin Öğrenme ile Radyografik Diş Görüntülerinin Segmentasyonunda Görüntü Ön İşleme Tekniklerinin Etkisinin Araştırılması başlıklı yüksek lisans tezinin hazırlık ve yazım aşamasında bilimsel araştırma ve etik kurallarına uyduğumu, [Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Faaliyetlerinde Üretken Yapay Zekâ Kullanımına Dair Etik Rehberine](#) uygun olarak tez/dönem projemi hazırladığımı, başkalarının eserlerinden yararlandığım bölümlerde bilimsel etik kurallarına uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, çalışmamın herhangi bir kısmının başka bir tez/dönem projesi olarak sunulmadığını, aksinin tespit edilmesi durumunda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Neslihan SOGUR

Tarih

.../.../2025

İmza

ÖN SÖZ

Akademik bir çalışmanın ortaya çıkışı, çoğu zaman yalnızca bireysel gayretle değil, farklı alanlarda destek sağlayan insanların katkılarıyla mümkün olmaktadır. Bu süreçte, bilgi ve deneyimleriyle her adımda bana yol gösteren, yapıcı eleştirileri ve yönlendirmeleriyle tezimin şekillenmesine büyük katkı sunan danışman Sayın hocam Dr. Öğr. Üyesi Nihan KAZAK ÇERÇEVİK'e en içten teşekkürlerimi sunarım.

Hayatım boyunca olduğu gibi yüksek lisans sürecimde de yanımda olan aileme, sabırları, anlayışları ve koşulsuz destekleri için minnettarım. Aynı şekilde, tez sürecinin zorlu anlarında motivasyonumu artıran ve moral desteğini esirgemeyen arkadaşlarıma, Yalova Üniversitesi Bilgisayar Mühendisliği bölüm hocalarıma ve çalışma arkadaşlarıma da teşekkürlerimi sunarım.

Bu noktada, ev ortamında çalışmamı zorlaştırarak beni kütüphanede daha verimli bir akademik yolculuğa yönlendiren kedilerime ayrıca dolaylı bir teşekkürü borçluyum.

Neslihan Sogur

2025

ÖZET

DERİN ÖĞRENME İLE RADYOGRAFİK DİŞ GÖRÜNTÜLERİNİN SEGMENTASYONUNDA GÖRÜNTÜ ÖN İŞLEME YÖNTEMLERİNİN ETKİSİNİN ARAŞTIRILMASI

Diş hekimleri, ağız ve diş sağlığına ilişkin hastalıkların tespitinde çeşitli görüntüleme tekniklerinden yararlanmaktadır. Ancak elde edilen görüntülerde artefaktlar, bulanıklık ve aydınlatma sorunları gibi unsurlar, yorumlamayı ve otomatik analiz süreçlerini olumsuz yönde etkileyebilmektedir. Bu tez çalışmasında, panoramik diş radyografilerinin bölütleme performansını artırmaya yönelik yenilikçi, alan tabanlı bir çerçeve önerilmektedir.

Önerilen çerçeve; ön işleme, ilgi alanı çıkarımı, görüntülerin bölünmesi, U-Net tabanlı segmentasyon ve son işleme olmak üzere beş temel aşamadan oluşmaktadır. Ön işleme adımında, geleneksel ve karma yaklaşımlar dâhil olmak üzere toplam 14 yöntem uygulanmış, bu yöntemlerin segmentasyon ile entegrasyonu sistematik biçimde incelenmiştir. Analizler sonucunda en başarılı bulunan üç yöntem, orijinal panoramik radyografilere uyarlanmıştır. İlgi alanı çıkarımıyla elde edilen ilgi bölgeleri, 512×512 boyutlu yama yapılarına ayrılarak modele giriş için uygun hale getirilmiştir. Segmentasyon aşamasında, her bir yama ResNet50, VGG19 ve EfficientNetB4 omurga ağlarını temel alan özel U-Net mimarileri ve klasik U-Net modeli kullanılarak işlenmiştir. Son aşamada ise tahmin edilen yamalar birleştirilerek bütünsel maskeler elde edilmiştir.

Önerilen çerçevenin etkinliği, Tufts Diş Veritabanı üzerinde gerçekleştirilen deneyler ile ortaya konulmuştur. Sonuçlar, geliştirilen çerçevenin segmentasyon başarımını anlamlı düzeyde iyileştirdiğini kanıtlamaktadır. Özellikle EfficientNetB4 tabanlı U-Net mimarisinin, panoramik diş radyografilerinin segmentasyonunda diğer yaklaşımlara kıyasla daha yüksek performans sergilediği belirlenmiştir. Elde edilen bulgular, diş görüntülerinin kalitesinin segmentasyon performansı üzerindeki etkisini vurgulamakta ve önerilen çerçevenin, diş radyografilerinin otomatik analizi için önemli bir katkı sağlayacağını göstermektedir.

Anahtar Kelimeler: Panoramik Diş Radyografisi, Görüntü Ön İşleme, Segmentasyon, U-Net, Derin Öğrenme

ABSTRACT

INVESTIGATING THE IMPACTS OF IMAGE PREPROCESSING METHODS ON SEGMENTATION OF RADIOGRAPHIC DENTAL IMAGES WITH DEEP LEARNING

Dentists use various imaging techniques to diagnose diseases related to oral and dental health. However, elements such as artifacts, blurring, and lighting issues in the obtained images can negatively affect interpretation and automatic analysis processes. In this thesis study, an innovative, domain-based framework is proposed to improve the segmentation performance of panoramic dental radiographs.

The proposed framework consists of five main stages: preprocessing, region of interest extraction, image segmentation, U-Net-based segmentation, and postprocessing. In the preprocessing step, a total of 14 methods, including traditional and hybrid approaches, were applied, and the integration of these methods with segmentation was systematically investigated. The three most successful methods were adapted to the original panoramic radiographs. The regions of interest obtained through region of interest extraction were divided into 512×512 patch structures to make them suitable for input into the model.

During the segmentation phase, each patch was processed using custom U-Net architectures based on ResNet50, VGG19, and EfficientNetB4 backbones, as well as the classic U-Net model. In the final phase, the predicted patches were combined to obtain holistic masks.

The effectiveness of the proposed framework was demonstrated through experiments conducted on the Tufts Dental Database. The results show that the developed framework significantly improves segmentation performance. In particular, it was determined that the EfficientNetB4-based U-Net architecture exhibits higher performance in the segmentation of panoramic dental radiographs compared to other approaches. The findings emphasize the impact of dental image quality on segmentation performance and demonstrate that the proposed framework will make a significant contribution to the automatic analysis of dental radiographs.

Keywords: Panoramic Dental Radiograph, Image Preprocessing, Segmentation, U-Net, Deep Learning

İÇİNDEKİLER

	Sayfa
ÖN SÖZ.....	i
ÖZET	ii
ABSTRACT	iii
İÇİNDEKİLER.....	iv
TABLolar LİSTESİ.....	vii
ŞEKİLLER LİSTESİ.....	viii
KISALTMALAR VE SİMGELER LİSTESİ.....	x
1. GİRİŞ	1
1.1 Segmentasyonun Diş Hekimliğindeki Önemi.....	1
1.2 Görüntü Kalitesi ve Ön İşleme Süreci	2
1.3 Tezin Yapısı.....	3
2. LİTERATÜR TARAMASI	4
2.1 Literatürdeki Boşluk ve Bu Tezin Katkısı	7
3. U-NET MODELLERİNE GENEL BAKIŞ	10
3.1 U-Net'in Ortaya Çıkışı	10
3.2 Temel Mimari Yapısı.....	11
3.3 U-Net Varyantları.....	12
3.4 Omurga Tabanlı U-Net'ler	12
3.5 Tıbbi Görüntü Segmentasyonundaki Uygulamaları	13
3.6 Diş Radyografilerinde Kullanımı	14
4. ÖNERİLEN YÖNTEM	15
4.1 Girdi Standardizasyonu ve Veri Özellikleri.....	16
4.2 İlgili Bölgesi Tabanlı Ön İşleme	17
4.3 Sabit Boyuta Getirme ve Sıfır-Dolgulama.....	17
4.4 Yama-Tabanlı Ayrıştırma ve Normalizasyon	17
4.5 U-Net Tabanlı Segmentasyon Mimarisi	17
4.6 Eğitim Stratejisi ve Metrikler.....	18

4.7	Yordamlama, Birleştirme ve Son İşlem.....	18
5.	TUFTS DIŞ VERİ TABANI	20
6.	GÖRÜNTÜ KALİTESİ VE ÖN İŞLEME YÖNTEMLERİ.....	22
6.1	Görüntü Kalitesi Ölçütleri	22
6.1.1	Entropi.....	23
6.1.2	Kontrast.....	24
6.1.3	Parlaklık.....	25
6.1.4	Keskinlik	25
6.1.5	Kenar yoğunluğu	26
6.1.6	Histogram çarpıklığı	27
6.2	Analiz Sonuçlarının Değerlendirilmesi.....	27
6.3	Ön İşleme Yöntemleri	30
6.3.1	Tuz biber gürültüsü	31
6.3.2	Histogram eşitleme	31
6.3.3	CLAHE.....	32
6.3.4	Kontrast germe	33
6.3.5	Gauss bulanıklığı.....	34
6.3.6	Gauss gürültüsü.....	34
6.3.7	Gürültü giderme + Gauss bulanıklığı.....	35
6.3.8	CLAHE + HE.....	36
6.3.9	CLAHE + GC	36
6.3.10	CLAHE + MF	37
6.3.11	CLAHE + GB.....	38
6.3.12	CS + GB.....	39
6.3.13	CLAHE + MF + GC	39
6.3.14	CLAHE + MF + CS.....	40
6.4	Görüntü Kalitesi Değerlendirme Metrikleri	41
6.4.1	Ortalama mutlak hata	41
6.4.2	Ortalama hatalar karesi	41
6.4.3	Yapısal benzerlik indeksi	42
6.4.4	Tepe sinyal-gürültü oranı.....	42
6.5	Performans Analizi.....	43

7. SEGMENTASYON ANALİZİ.....	50
7.1 Değerlendirme Metrikleri	50
7.1.1 Dice katsayısı	50
7.1.2 Kesişim bölü birleşim.....	50
7.1.3 Piksel doğruluğu	51
7.2 Performans Analizi.....	52
8. SONUÇ VE TARTIŞMA	61
KAYNAKÇA	63

TABLULAR LİSTESİ

	Sayfa
Tablo 6.2 Ön işlem yöntemleri	30
Tablo 6.3 Ön işleme yöntemlerinin değerlendirilmesinin sayısal sonuçları.....	45
Tablo 7.4 Dört U-Net varyantında 14 farklı ön işleme yönteminin segmentasyon performansı karşılaştırması.....	53
Tablo 7.5 Önerilen modelin seçilen ön işleme yöntemleriyle segmentasyon performansı	55
Tablo 7.6 Önerilen yöntem ile mevcut çalışmaların karşılaştırılması	60

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 3.1 Orijinal U-Net Mimarisi (Ronneberger vd., 2015)	11
Şekil 4.2 Önerilen Yöntemin Çalışma Prensibi	15
Şekil 4.3 Önerilen Yöntemin Algoritması	16
Şekil 5.4 Tufts Dış Veri Setinin Bileşenleri.....	20
Şekil 6.5 Görüntü Kalitesi Metriklerinin Dağılımı	28
Şekil 6.6 (a) Orijinal Görüntü, (b) Tuz ve Biber Gürültüsü Eklenmiş Görüntü.....	31
Şekil 6.7 (a) Orijinal Görüntü, (b) Histogram Eşitleme Uygulanmış Görüntü	32
Şekil 6.8 (a) Orijinal Görüntü, (b) CLAHE Uygulanmış Görüntü.....	33
Şekil 6.9 (a) Orijinal Görüntü, (b) Kontrast Germe Uygulanmış Görüntü.....	33
Şekil 6.10 (a) Orijinal Görüntü, (b) Gauss Bulanıklığı Uygulanmış Görüntü	34
Şekil 6.11 (a) Orijinal Görüntü, (b) Gauss Gürültüsü Uygulanmış Görüntü	35
Şekil 6.12 (a) Orijinal Görüntü, (b) Gürültü Giderme + Gauss Bulanıklığı Uygulanmış Görüntü	35
Şekil 6.13 (a) Orijinal Görüntü, (b) CLAHE + HE Uygulanmış Görüntü	36
Şekil 6.14 (a) Orijinal Görüntü, (b) CLAHE + GC Uygulanmış Görüntü	37
Şekil 6.15 (a) Orijinal Görüntü, (b) CLAHE + MF Uygulanmış Görüntü.....	37
Şekil 6.16 (a) Orijinal Görüntü, (b) CLAHE + GB Uygulanmış Görüntü	38
Şekil 6.17 (a) Orijinal Görüntü, (b) CS + GB Uygulanmış Görüntü.....	39
Şekil 6.18 (a) Orijinal Görüntü, (b) CLAHE + MF + GC Uygulanmış Görüntü	40
Şekil 6.19 (a) Orijinal Görüntü, (b) CLAHE + MF + CS Uygulanmış Görüntü.....	41

Şekil 6.20 Ön İşleme Yöntemleri Uygulanmış Görüntüler.....	44
Şekil 6.21 MAE'ye Dayalı Ön İşleme Yöntemlerinin Karşılaştırılması	46
Şekil 6.22 MSE'ye Dayalı Yöntemlerin Karşılaştırılması.....	46
Şekil 6.23 PSNR'ye Dayalı Yöntemlerin Karşılaştırılması	47
Şekil 6.24 SSIM'ye Dayalı Yöntemlerin Karşılaştırılması.....	48
Şekil 7.25 Önerilen Modelin Örnek Segmentasyon Çıktısı.....	56
Şekil 7.26 ResNet50 Omurga ile Doğrulama Dice Katsayısı- Eğitim Döngüsü Değişimi.....	57
Şekil 7.27 EfficientNetB4 Omurga ile Doğrulama Dice Katsayısı - Eğitim Döngüsü Değişimi	57
Şekil 7.28 VGG19 Omurga ile Doğrulama Dice Katsayısı- Eğitim Döngüsü Değişimi.....	58
Şekil 7.29 Özelleştirilmiş U-Net ile Doğrulama Dice Katsayısı - Eğitim Döngüsü Değişimi	58
Şekil 7.30 Önerilen Yöntemin Varyantları Arasında Dice Değerlerinin Dağılımı.....	59

KISALTMALAR VE SİMGELER LİSTESİ

BT	: Bilgisayarlı Tomografi
CLAHE	: Contrast Limited Adaptive Histogram Equalization
CNN	: Convolutional Neural Network
CS	: Contrast Streching
De	: Denoising
Dice	: Dice Coefficient
GAN	: Generative Adversarial Network
GB	: Gaussian Blur
GC	: Gamma Correction
GN	: Gaussian Noise
HE	: Histogram Equalization
IoU	: Intersection over Union
MAE	: Mean Absolute Error
MF	: Median Filter
MRG	: Manyetik Rezonans Görüntüleme
MSE	: Mean Square Error
PA	: Pixel Accuracy
PSNR	: Peak Signal-to-Noise Ratio
ReLU	: Rectified Linear Unit
ROI	: Region of Interest
SPN	: Salt and Pepper Noise
SSIM	: Structural Similarity Index
TDD	: Tufts Dental Dataset

1. GİRİŞ

Görüntü işleme, dijital ortamda yer alan görsel verilerin incelenmesi, iyileştirilmesi ve anlamlı bilgiler elde edilmesi sürecidir. Gelişen teknoloji ile, bu alan özellikle sağlık sektöründe önemli uygulama alanları bulmuştur. Medikal görüntü işleme (Li vd., 2023), Bilgisayarlı Tomografi (BT), Manyetik Rezonans Görüntüleme (MRG), ultrason ve dijital radyografi gibi teknikler aracılığıyla elde edilen görüntülerin analizini sağlamaktadır. Bu analiz süreci, teşhis, tedavi planlaması ve hasta takibi gibi klinik işlemlerin daha hızlı, güvenilir ve nesnel bir biçimde gerçekleştirilmesine katkıda bulunmaktadır.

Diş hekimliğinde ise radyolojik görüntüler, tanı ve tedavi süreçlerinin ayrılmaz bir parçası haline gelmiştir. Panoramik diş radyografileri, alt ve üst çene yapısını tek bir karede gösterebilme özelliğiyle klinik değerlendirmelerde sıkça tercih edilir. Bu tür görüntüler, dişlerin dizilimi, çene kemiği yapısı, gömülü dişler, lezyonlar ve diğer patolojik oluşumlar hakkında detaylı bilgiler sunar. Ancak, bu yüksek bilgi yoğunluğu, görüntülerin manuel olarak analiz edilmesini zorlaştırmakta ve uzman değerlendirmesine olan talebi artırmaktadır.

Geleneksel yöntemlerle gerçekleştirilen manuel analizler, zaman alıcı, uzmanlık gerektiren ve yorumlama açısından kişiden kişiye değişkenlik gösterebilen süreçlerdir (Scarfe & Farman, 2008). Bu nedenle, medikal görüntülerin otomatik olarak analiz edilebilmesi önemli bir araştırma alanı haline gelmiştir. Bu noktada görüntü işleme algoritmaları ile makine öğrenmesi ve derin öğrenme temelli yaklaşımlar devreye girmektedir.

1.1 Segmentasyonun Diş Hekimliğindeki Önemi

Görüntü segmentasyonu, dijital görüntülerde belirli yapıların veya bölgelerin otomatik olarak ayrıştırılıp sınıflandırılmasını sağlayan önemli bir görüntü işleme tekniğidir (Pham vd., 2000). Bu süreç, her bir pikselin ait olduğu bölgeye göre etiketlenmesini mümkün kılar; böylece görüntü içindeki anlamlı yapılar detaylı bir şekilde analiz edilebilir hale gelir. Özellikle tıbbi görüntülerde, segmentasyon klinik açıdan önemli yapıların (örneğin tümörler, organlar, lezyonlar) hassas bir biçimde tespitini sağlar.

Diş hekimliğinde ise segmentasyon, panoramik radyografiler gibi bilgi yoğunluğu yüksek görüntülerde dişlerin, kök kanallarının, çene kemiği yapısının ve periodontal boşlukların doğru bir şekilde tanımlanmasına olanak tanır. Bu işlemin başarısı, tanı ve tedavi süreçlerinin kalitesini doğrudan etkiler. Örneğin; Periodontal hastalıkların erken tespiti, kemik kaybının bölgesel olarak belirlenmesini gerektirir ki bu da segmentasyon sayesinde

mümkündür. Ortodontik tedavi planlaması, dişlerin konumlarının ve çene yapısıyla olan ilişkilerinin doğru bir biçimde analiziyle mümkündür. Dental implant yerleşimi için çene kemiğinin hacim ve yoğunluk gibi unsurlarının detaylı değerlendirilmesi gerekir; bu da ilgili bölgelerin otomatik olarak tespit edilmesini zorunlu kılar. Kök kanal tedavilerinde kök yapılarının belirlenmesi büyük bir önem arz eder. Gömülü dişlerin konumlarının tespit edilmesi ve çene kemiğiyle olan ilişkilerinin belirlenmesi segmentasyon sayesinde daha hassas bir şekilde yapılabilir.

Geleneksel yöntemlerde bahsedilen süreçler uzmanlar tarafından manuel olarak gerçekleştirilmektedir, bu da zaman kaybına, yoruma dayalı hatalara ve hasta yoğunluğu olan kliniklerde verimsizliğe yol açabilmektedir. Otomatik segmentasyon ise bu süreci hızlandırmakla kalmaz, aynı zamanda standardize ederek hata payını azaltır (Litjens vd., 2017). Ayrıca, otomatik sistemlerin kullanımı yalnızca tanı süreçlerinde değil; hasta takibi ve tedavi sonrası karşılaştırmalar gibi uzun vadeli klinik uygulamalarda da önemli avantajlar sağlar. Radyografilerin dönemsel olarak karşılaştırılması ve değişikliklerin nesnel bir şekilde tespit edilmesi, segmentasyonun sunduğu maskeler sayesinde mümkün hale gelir.

Son yıllarda, derin öğrenme algoritmalarının, özellikle U-Net gibi tıbbi görüntü segmentasyonu için özelleştirilmiş mimarilerin kullanılmasıyla alanda büyük başarılar elde edilmiştir. Derin öğrenme tabanlı sistemler; düşük kontrast, farklı pozlamalar ve parazit içeren görüntülerde bile yüksek doğrulukla segmentasyon yapabilmekte, böylece hem klinik etkinliğini artırmakta hem de kullanıcı memnuniyetini sağlamaktadır. Bu bağlamda, diş hekimliğindeki segmentasyon, sadece bir teknolojik araç olmanın ötesinde, modern sağlık hizmetlerinin daha verimli, doğru ve erişilebilir hale gelmesini sağlayan önemli bir unsurdur.

1.2 Görüntü Kalitesi ve Ön İşleme Süreci

Segmentasyon işlemlerinin başarısı, büyük ölçüde modelin eğitildiği veri setlerinin kalitesine bağlıdır (Shen vd., 2017). Diş radyografileri; düşük kontrast, gürültü, parazit, eşit olmayan aydınlatma gibi pek çok problem içerebilir. Bu problemler, segmentasyon modelinin ilgilenilen bölgeyi doğru tanımlayamamasına neden olabilir. Bu noktada, ön işleme yöntemleri devreye girmekte ve görüntünün segmentasyon için daha uygun hale getirilmesini sağlamaktadır. Geleneksel görüntü iyileştirme teknikleri olan Histogram Eşitleme (Histogram Equalization, HE), Kontrast Uyarlamalı Histogram Eşitleme (Contrast Limited Adaptive Histogram Equalization, CLAHE), Gauss Bulanıklığı (Gaussian Blur, GB), Gamma Düzeltme (Gamma Correction, GC), Gürültü Giderme (Denoising, De) gibi geleneksel görüntü

iyileştirme teknikleri; görüntü kontrastını artırma, keskinlik ayarı yapma, gürültüyü azaltma gibi işlemlerle modelin daha verimli çalışmasına katkı sağlar. Bu tekniklerin bir kısmı tek başına, bir kısmı ise kombinasyon hâlinde kullanıldığında farklı segmentasyon sonuçları doğurabilir. Ancak literatürde, bu tür ön işleme yöntemlerinin dış radyografilerindeki segmentasyon başarısına etkisi sistematik biçimde karşılaştırılmamıştır. Bu nedenle, her yöntemin segmentasyon çıktısına etkisinin deneysel olarak test edilmesi gerekmektedir.

1.3 Tezin Yapısı

Bu tez sekiz ana bölümden oluşmaktadır. 1. Bölüm olan Giriş kısmında problemin tanımı, hedefler, kapsam ve çalışmanın sunduğu özgün katkılar açıklanmış; tezin genel yapısı aktarılmıştır. 2. Bölüm olan Literatür Taraması bölümünde görüntü iyileştirme yöntemleri ve derin öğrenmeye dayalı segmentasyon teknikleri, özellikle dış radyografi bağlamında mevcut araştırmalar doğrultusunda gözden geçirilmiştir. 3. Bölüm olan U-Net Modellerine Genel Bakış bölümünde klasik U-Net ile onun çeşitli versiyonlarının mimari özellikleri ve bu yöntemlerin dış segmentasyonundaki işlevi özetlenmiştir. 4. Bölüm olan Önerilen Yöntem bölümünde bölge kılavuzlu ön işleme çerçevesi, ilgi alanı (Region of Interest, ROI) çıkartma ve yamanın temelli iş akışı ile farklı tasarımlara sahip U-Net modelleri (ResNet50, VGG19, EfficientNetB4) ve son işleme aşamaları detaylı bir şekilde açıklanmıştır. 5. Bölümde kullanılan bu tezde kullanılan Tufts Dış Veri Tabanı'nını örnekleme ve ayırma yöntemleri ile etik konulara değinilmiştir. 6. Bölüm olan Görüntü Kalitesi ve Ön İşleme Yöntemleri kısmında belirtilen kalite kriterleri ile gerçekleştirilen incelemeler sonucu incelenen 14 ön işleme tekniği tanıtılmış ve Kontrast Germe (Contrast Streching, CS), GB, CS+GB yöntemlerinin öne çıktığı belgelenmiştir. 7. Bölüm olan Segmentasyon Analizi'nde ise deney düzenekleri, metrikler ve karşılaştırmalı sonuçlar tablo ve görsellerle sunulmuş; 8. Bölüm Sonuç ve Tartışma'da ise elde edilen veriler bütünsel olarak değerlendirilmiş, sınırlamalar ve ilerideki araştırmalar için öneriler paylaşılmıştır.

2. LİTERATÜR TARAMASI

Dental görüntü işleme, modern diş hekimliği uygulamalarında tanı doğruluğunu artırmak, tedavi süreçlerini optimize etmek ve hasta memnuniyetini yükseltmek amacıyla vazgeçilmez bir araç haline gelmiştir. Geleneksel yöntemlerin sunduğu sınırlı çözünürlük ve insan algısına dayalı yorum hataları, daha nesnel ve tekrarlanabilir analiz yöntemlerinin geliştirilmesine olan ihtiyacı doğurmuştur (Harsh vd., 2021; Kumar vd., 2021). Özellikle dental panoramik radyografi gibi geniş alanlı görüntülerde, detayların doğru bir şekilde ayırt edilmesi, tanı süreçlerinin başarısını doğrudan etkilemektedir. İlk dönem çalışmalarda, dental radyografilerin kontrastını artırarak anatomik yapıların görünürliğini iyileştirmek amacıyla temel görüntü işleme teknikleri kullanılmıştır. HE, CLAHE ve çok ölçekli morfolojik işlemler gibi yöntemler, dental radyografilerde önemli ölçüde iyileştirme sağlamıştır (Mehdizadeh vd., 2023; Mello Román vd., 2021). Özellikle CLAHE yöntemi, küçük detayların öne çıkarılmasında diğer tekniklere göre üstünlük göstermiş ve dental çürüklerin, periodontal boşlukların veya kırık hatlarının daha kolay tespit edilmesine olanak sağlamıştır (Datta vd., 2023; Yoshimi vd., 2024). Bununla birlikte, aşırı kontrast artırımı nedeniyle yapay artefaktlar oluşması gibi sorunlar da rapor edilmiş, bu da ön işleme tekniklerinin dikkatli bir şekilde optimize edilmesi gerektiğini göstermiştir.

Gürültü azaltımı ve detay koruma arasında hassas bir denge sağlanması gerektiği gerçeği, gürültü giderme tabanlı yöntemlerin geliştirilmesine zemin hazırlamıştır. Özellikle adaptif morfolojik dalgacık (wavelet) gürültü giderme yönteminin kullanıldığı çalışmalarda (Rajee & Mythili, 2023), dental görüntülerde gürültü etkisi minimize edilirken yapısal bilgiler büyük ölçüde korunmuş ve sonrasında uygulanan segmentasyon adımlarının doğruluğunda belirgin bir artış sağlanmıştır. Bu tür iyileştirme yöntemleri, doğrudan tanı süreçlerine olumlu katkı sunmuş ve dental yapay zekâ tabanlı sistemlerin gelişimine zemin hazırlamıştır.

Görüntü iyileştirmenin ardından gelen en kritik adım olan segmentasyon çalışmalarında ise, başlangıçta klasik eşikleme ve bölütleme yöntemleri ön planda olmuştur. Bağlantılı bileşenler analizi ve Otsu yöntemi gibi teknikler, basit yapıların ayrıştırılmasında hızlı ve etkili çözümler sunmuş, özellikle tekil dişlerin ayrıştırılması gibi görevlerde başarılı sonuçlar elde edilmiştir (Nafi'iyah vd., 2020; Setianingrum vd., 2017). Ancak bu yöntemler, kompleks dental anatomik yapılar üzerinde, özellikle mandibula gibi çok bileşenli bölgelerde ciddi başarısızlıklar göstermiştir. Bu eksiklikler, kontur tabanlı yöntemlerin, özellikle aktif kontur modellerinin kullanımını teşvik etmiştir (Park & Kwak, 2019).

Klasik yöntemlerin sınırlamalarına rağmen, bu erken dönem çalışmalar dental görüntü işleme alanında önemli bir temel oluşturmuş, ancak kompleks klinik ihtiyaçlar karşısında yetersiz kalmıştır. Özellikle düşük kontrastlı ve küçük boyutlu anomalilerin doğru segmentasyonu konusunda klasik yöntemlerin başarısız olması, literatürde daha sofistike, öğrenme temelli yaklaşımlara geçişi hızlandırmıştır.

Derin öğrenmenin medikal görüntü analizine entegre edilmesiyle birlikte, dental görüntü işleme alanında da önemli bir paradigma değişimi yaşanmıştır. U-Net mimarisi gibi kodlayıcı (encoder) – kod çözücü (decoder) yapılar, özellikle sınırlı miktarda veriye sahip medikal görüntüler için ideal bir çözüm sunarak dental radyografilerde diş, kemik yapıları ve çürük bölgelerin segmentasyonunda büyük başarı elde etmiştir (Rocha & Endo, 2022). Bununla birlikte, klasik U-Net modelleri küçük ve düşük kontrastlı yapıları doğru şekilde yakalama konusunda bazı sınırlamalara sahip olmuş, bu da Nested U-Net (U-Net++) gibi gelişmiş ağ yapılarına olan ihtiyacı doğurmuştur (Alharbi vd., 2023).

Nested U-Net modelleri, çoklu yoğun bağlantı stratejileri kullanarak, segmentasyon doğruluğunu önemli ölçüde artırmış ve özellikle sınırlı görsel kontrastın bulunduğu dental anomalilerin daha hassas bir şekilde tespit edilmesini mümkün kılmıştır (Alharbi vd., 2023). Öte yandan, Inception-ResNetV2 gibi daha derin ve kompleks ağ mimarileri, dental segmentasyonu yalnızca piksel düzeyinde değil, aynı zamanda anomali sınıflandırması gibi çoklu görev öğrenmeleriyle birlikte optimize etmiştir (Rajee & Mythili, 2023).

Literatürde ayrıca hafif yapılı (lightweight) derin öğrenme modellerinin geliştirilmesine yönelik ciddi bir eğilim gözlemlenmiştir. Özellikle mobil cihazlarda veya düşük kaynaklı sistemlerde hızlı segmentasyon yapılabilmesi amacıyla geliştirilen hafif modeller, dental görüntü analizini daha geniş klinik kullanım alanlarına taşıma potansiyeli göstermiştir (Marconato Stringhini vd., 2021).

Diğer yandan, veri seti sınırlamaları dental görüntü işleme çalışmalarının ortak bir problemi olmaya devam etmektedir. Sınırlı örneklem büyüklüğü ve sınırlı anotasyon kalitesi, model eğitimi sürecinde aşılması gereken önemli bir bariyer olarak öne çıkmıştır. Bu durumu aşmak için Üretici Çekişmeli Ağ (Generative Adversarial Network, GAN) tabanlı veri artırma yöntemleri geliştirilmiş ve dental segmentasyonda başarılı sonuçlar elde edilmiştir (Manzari vd., 2024). Özellikle Denta-GAN gibi modeller, küçük veri setlerinde bile segmentasyon başarısını belirgin şekilde artırarak literatürde önemli bir boşluğu doldurmuştur.

Ancak tüm bu gelişmelere rağmen, dental görüntülerde düşük kontrastlı yapıların segmentasyonu, küçük anomalilerin doğru şekilde tespiti ve sınırlı veri setleriyle yüksek doğruluk elde etme gibi problemler halen tam anlamıyla çözülememiştir. Bu bağlamda, dikkat mekanizmalarının entegre edildiği yeni nesil derin öğrenme mimarilerinin, dental görüntü işleme alanında daha iyi sonuçlar üretmesi beklenmektedir (Bhat vd., 2024).

Son yıllarda dikkat mekanizmalarının entegre edildiği modeller, dental görüntü segmentasyonunda önemli performans iyileştirmeleri sağlamıştır. Özellikle Attention U-Net gibi yapılar, dental panoramik radyografilerde küçük boyutlu ve düşük kontrastlı bölgelerin daha doğru şekilde segmentasyonunu mümkün kılmıştır (Harsh vd., 2021). Dikkat mekanizmaları, modelin önemli bölgelere daha fazla odaklanmasını sağladığı için, dental radyografilerde diş ve kemik gibi ince yapısal ayrımların daha başarılı bir şekilde yapılabilmesine imkân tanımıştır (Bhat vd., 2024).

Bunun yanında, dental segmentasyon problemleri için GAN tabanlı alternatif çözümler de geliştirilmiştir. Denta-GAN çalışmasında olduğu gibi, sahte segmentasyon örnekleri üreterek modelin daha geniş bir veri çeşitliliği üzerinde eğitilmesi sağlanmış ve küçük veri setleriyle dahi anlamlı doğruluk artışları elde edilmiştir (Manzari vd., 2024). GAN tabanlı yaklaşımlar, özellikle veri artırımı ve gerçekçi segmentasyon çıktıları üretimi açısından dental görüntü analizi literatüründe giderek daha fazla önem kazanmaktadır.

Öte yandan, doğadan ilham alan optimizasyon algoritmalarının da dental segmentasyonda etkili bir şekilde kullanıldığı gözlemlenmiştir. Çiçek Tozlaşması (Flower Pollination) Algoritması gibi teknikler, dental görüntü segmentasyonunda parametre optimizasyonu ve model eğitimi süreçlerinde başarı sağlamıştır (Awari vd., 2024). Bu tür doğadan esinlenen yöntemler, model hiperparametrelerinin ayarlanmasında etkili alternatifler sunmuş ve segmentasyon doğruluğunda önemli iyileşmeler sağlamıştır (Houssein vd., 2024).

Dental görüntülerin otomatik segmentasyonu yanında, bu segmentasyon çıktılarının tanı süreçlerine entegrasyonu da literatürde önemli bir yer tutmaktadır. Özellikle periodontal kemik kaybı gibi spesifik dental anomalilerin otomatik tespiti için geliştirilen sistemler, klasik görüntü işleme yöntemlerinin derin öğrenme modelleriyle desteklenmesi sonucu daha hassas sonuçlar üretmiştir (Vigil & Bharathi, 2021). Benzer şekilde, çürük tespiti ve dental anomali sınıflandırması üzerine yapılan çalışmalar da segmentasyon sonrası tanı adımının otomatikleştirilmesinin mümkün olduğunu göstermiştir (Kumari vd., 2022.; L. Leo vd., 2023). Ayrıca, dental segmentasyonun ötesinde yapılan çalışmalarda, dental radyografilerde

anomalilerin sınıflandırılması ve tedavi planlamasının desteklenmesi amaçlanmıştır. Üç boyutlu dental görüntüler üzerinde segmentasyon ve sınıflandırmayı birleştiren derin öğrenme tabanlı çalışmalar, dental veri analizi alanında yeni bir perspektif sunmuştur (Awari vd., 2024). Bu çoklu görevli yaklaşımlar hem segmentasyon doğruluğunu artırmakta hem de dental anomalilerin sınıflandırılması gibi ileri düzey görevleri başarıyla gerçekleştirmektedir. Ancak tüm bu ilerlemelere rağmen, dental görüntü işleme alanındaki temel zorlukların sürdüğü görülmektedir. Veri seti çeşitliliğinin yetersizliği, anotasyon hataları ve farklı görüntüleme cihazlarından kaynaklanan varyasyonlar, geliştirilen modellerin genellenebilirliğini sınırlayan temel faktörler arasında yer almaktadır (Salih & Duffy, 2022; Wang vd., 2024). Bu doğrultuda, literatürde transfer öğrenme, öz denetimli öğrenme ve alan uyarlaması yöntemlerinin dental görüntü analizine daha güçlü bir şekilde entegre edilmesi gerekliliği özellikle vurgulanmaktadır.

Özetle, dental görüntü işleme alanı, klasik yöntemlerden derin öğrenme temelli modellere doğru önemli bir evrim geçirmiştir. Segmentasyon doğruluğunu artırmaya yönelik geliştirilen yeni yaklaşımlar, dikkat mekanizmaları, hafif derin öğrenme modelleri ve GAN tabanlı veri artırma stratejileri gibi inovasyonlarla desteklenmiş; ancak düşük kontrastlı yapılar, sınırlı veri setleri ve gerçek dünya genellenebilirliği gibi temel zorluklar tam anlamıyla aşılabilmiş değildir. Bu durum, dental görüntü analizi alanında halen önemli araştırma fırsatları bulunduğunu göstermektedir. Bu tez çalışması da literatürde tanımlanan bu boşluklardan yola çıkarak, dental panoramik radyografilerde segmentasyon doğruluğunu artırmaya yönelik yeni bir yaklaşım geliştirmeyi amaçlamaktadır. Özellikle ön işleme tekniklerinin etkin kullanımı, derin öğrenme tabanlı segmentasyon modellerinin optimizasyonu ve sınırlı veri setleri üzerinde daha yüksek doğruluk elde edilmesi hedeflenmektedir.

2.1 Literatürdeki Boşluk ve Bu Tezin Katkısı

Diş radyografisi üzerinde gerçekleştirilen görüntü segmentasyonu çalışmalarının büyük bir bölümü, ağırlıklı olarak belirli bir ön işleme tekniği ya da seçilmiş bir model mimarisi çerçevesinde şekillenmektedir. Bununla birlikte, panoramik diş radyografileri gibi düşük kontrastlı, parazit içeren ve aydınlatma koşulları bakımından heterojenlik gösteren görüntüler, yalnızca mimari düzeydeki iyileştirmelerle tatmin edici sonuçlar elde edilmesini güçleştirmektedir. Bu nedenle, segmentasyon başarısının artırılmasında ön işleme adımının oynadığı rol, görmezden gelinemeyecek derecede kritiktir. Mevcut literatür tarandığında, ön işleme yöntemlerinin segmentasyon performansı üzerindeki etkilerinin çoğunlukla sınırlı

sayıda yöntem üzerinden değerlendirildiği ve bu yöntemlerin sistematik biçimde karşılaştırılmadığı dikkat çekmektedir. Özellikle birden fazla ön işleme tekniğinin kombine kullanıldığı yapıların segmentasyon çıktıları üzerindeki etkileri literatürde yeterince temsil edilmemektedir. Bu durum, alan yazında giderilmeyi bekleyen önemli bir boşluğa işaret etmektedir. Bu tez çalışması, bahsi geçen boşluğun doldurulmasına katkı sunmayı amaçlamakta ve bu doğrultuda, farklı ön işleme stratejilerinin segmentasyon başarımına etkisini deneysel olarak inceleyen kapsamlı bir çalışma sunmaktadır. Tufts Diş Veri Tabanı kullanılarak yürütülen deneysel süreçte, hem özelleştirilmiş U-Net mimarisi, hem de üç farklı omurga (backbone) kullanarak oluşturulmuş U-Net mimarileri olmak üzere 4 farklı model mimarisi değerlendirmeye alınmış; bu mimariler üzerinde toplam 14 farklı ön işleme yöntemi ve kombinasyonu test edilmiştir.

Çalışmanın öne çıkan katkıları aşağıda maddeler hâlinde özetlenmiştir:

- Yöntemsel çeşitlilik ve kapsam: Segmentasyon modeli girişlerine uygulanan 14 farklı ön işleme yöntemi ve bu yöntemlerin çeşitli kombinasyonları, sistematik biçimde modellenmiş ve karşılaştırmalı olarak değerlendirilmiştir.
- Model mimarisi karşılaştırması: Hem özelleştirilmiş U-Net yapısı hem de önceden eğitilmiş EfficientNetB4, VGG19, ResNet50 omurgaları ile ayrı ayrı güçlendirilmiş U-Net mimarileri ile üç farklı model mimarisi üzerinde aynı deneysel protokol uygulanmış, bu sayede ön işleme yöntemlerinin model mimarileri arasındaki etkileri gözlemlenebilmiştir.
- Çok boyutlu performans değerlendirmesi: Model çıktıları, sadece segmentasyon doğruluğunu yansıtan Dice Katsayısı (Dice Coefficient, Dice), Kesişim Bölü Birleşim (Intersection over Union, IoU) ve Piksel Doğruluğu (Pixel Accuracy, PA) gibi metriklerle değil, aynı zamanda görüntü kalitesini ölçen Ortalama Mutlak Hata (Mean Absolute Error, MAE), Ortalama Hatalar Karesi (Mean Square Error, MSE), Tepe-Sinyal-Gürültü Oranı (Peak Signal Noise Ratio, PSNR) ve Yapısal Benzerlik Oranı (Structral Similarity Index, SSIM) gibi istatistiksel değerlendirme ölçütleri ile birlikte çok yönlü olarak analiz edilmiştir.
- Görsel analiz destekli sunum: Elde edilen nicel bulgular, segmentasyon maskeleri, orijinal ve işlenmiş görüntüler, histogram analizleri ve karşılaştırmalı görsel örneklerle desteklenmiş; böylece yöntemlerin etkisi yalnızca sayısal düzeyde değil, aynı zamanda görsel bağlamda da somut biçimde ortaya konulmuştur.

Bu yönüyle bu tez çalışması, ön işleme süreçlerinin segmentasyon başarısına olan etkilerini bütüncül bir çerçevede ele almakta ve diş radyografisi gibi medikal görüntü analizinde yüksek doğruluk gerektiren uygulamalara katkı sunacak özgün bir yaklaşım önermektedir.

3. U-NET MODELLERİNE GENEL BAKIŞ

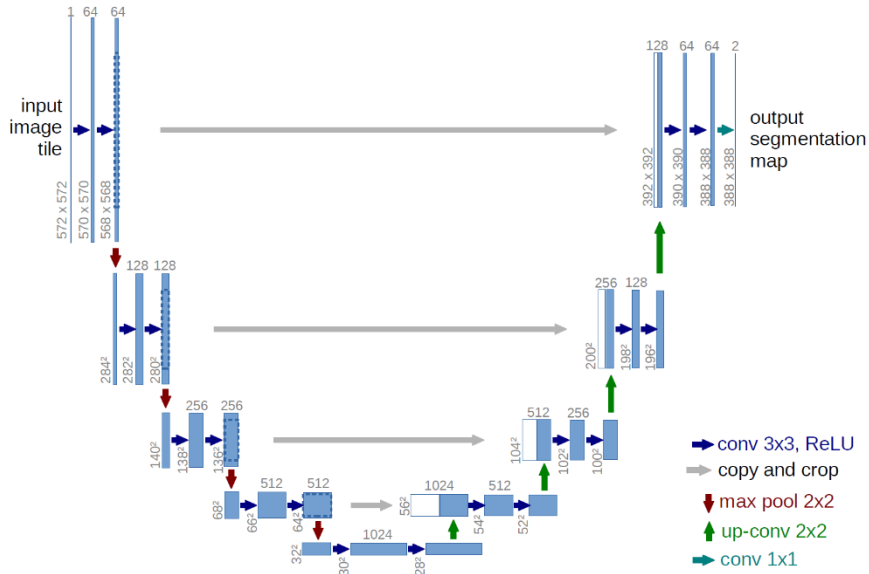
U-Net tasarımı, derin öğrenmeye dayalı segmentasyon projelerinde anahtar bir yapı olarak görülmekte ve özellikle sağlık görüntüleri işleme alanında büyük bir önem taşımaktadır. Bu bölümde, mimarinin gelişimi, temel yapısal özellikleri ve zaman içinde ortaya çıkan çeşitli varyantları detaylı bir şekilde incelemektedir. Ayrıca, önceden eğitilmiş ağların kullanıldığı temel yaklaşım ile U-Net'in tıbbi görüntü segmentasyonundaki genel kullanımları ve dış röntgenlerine sağladığı katkılar değerlendirilmektedir.

3.1 U-Net'in Ortaya Çıkışı

Derin öğrenmenin tıbbi görüntü işleme alanındaki etkisinin artışı, özellikle evrişimli sinir ağlarının (Convolutional Neural Network, CNN) üstün performansı ile hız kazanmıştır. Ancak 2010'ların başlarında tıbbi görüntü segmentasyonu için en önemli zorluklardan biri, etiketli veri eksikliğidir ve yüksek çözünürlüklü görüntülerin klasik CNN mimarileriyle işlenmesinde yaşanan sıkıntılardır. Bu bağlamda, 2015 yılında Ronneberger vd. tarafından geliştirilen U-Net yapısı, biyomedikal görüntü segmentasyonu için özel olarak tasarlanmış ilk derin öğrenme tabanlı yapılar arasında yer almıştır (Ronneberger vd., 2015). U-Net, adından da anlaşılacağı üzere "U" harfine benzeyen simetrik kodlayıcı - kod çözücü yapısıyla öne çıkmaktadır. Modelin önemli bir yeniliği, yalnızca sınıflandırma yapmak yerine piksel düzeyinde tahminler gerçekleştirerek segmentasyon yapabilmesi ve özellikle sınırlı anotasyona sahip veri setleri için bile başarılı sonuçlar elde edebilmesidir. Ronneberger geliştirdikleri yapıyı ISBI 2015 hücre izleme yarışmasında denemiş ve dönemin diğer tüm yöntemlerini geride bırakarak segmentasyon doğruluğunda çarpıcı bir başarı göstermiştir (Ronneberger vd., 2015). Ayrıca, U-Net'in geliştirilmesinin temel sebeplerinden biri de klinik uygulamalarda veri eksikliği olmasına rağmen güvenilir modeller oluşturma ihtiyacıdır. Geleneksel teknikler büyük miktarda manuel anotasyon ve karmaşık özellik mühendisliği gerektirirken, U-Net güçlü bir uçtan uca öğrenme yaklaşımıyla bu gereksinimleri azaltmıştır. Üstelik ağ yapısında bulunan atlama bağlantısı (skip connection), segmentasyon sonuçlarında hassas anatomik detayların korunmasına yardımcı olmuş ve bu özellik, yöntemin mikroskopik görüntülerden makroskopik medikal görüntülere kadar geniş bir yelpazede hızla benimsenmesine yol açmıştır.

3.2 Temel Mimari Yapısı

U-Net mimarisi, adını aldığı “U” şeklindeki yapısıyla dikkat çekmektedir. Bu yapı iki ana bölümden oluşur: kodlayıcı ve kod çözücü. Kodlayıcı kısmında, arka arkaya gelen konvolüsyon katmanları, ReLU aktivasyon fonksiyonu ve maksimum havuzlama (max-pooling) işlemleri ile görüntünün boyutu azaltılırken daha soyut ve üst düzey özellikler elde edilir. Böylece model, farklı ölçeklerdeki yapıları temsil edebilecek güçlü bir özellik seti geliştirmiş olur. Kod çözücü kısmında ise, bu düşük boyutlu özellik haritaları, transpoze konvolüsyonlar (up-convolution) veya yeniden örnekleme katmanları kullanılarak büyütülür ve orijinal çözünürlüğe yakın bir segmentasyon maskesi oluşturulmuş olur (Ronneberger vd., 2015). U-Net’in en yenilikçi bileşenlerinden biri, atlama bağlantıları (skip connection) olarak bilinen yapıdır. Şekil 3.1’de de görüldüğü gibi kodlayıcı yapısında her bir katmandan elde edilen yüksek çözünürlüklü özellik haritaları, kodlayıcılardaki karşılık gelen katmanlara doğrudan aktarılır. Bu sistem, yalnızca anlamsal bilgiyi değil, aynı zamanda ince kenar detaylarını ve yerel yapısal bilgileri de koruyarak segmentasyon kalitesini önemli ölçüde geliştirmektedir. Böylece ağ hem geniş ölçekli bağlamı hem de detaylı yerel bilgileri aynı anda göz önünde bulundurabilir.



Şekil 3.1. Orijinal U-Net Mimarisi (Ronneberger vd., 2015)

Bu mimarinin bir diğer önemli özelliği ise, parametre verimliliği ve hızlı bir şekilde eğitilebilmesidir. U-Net, derinliği görece sınırlı olmasına rağmen, simetrik tasarımı ve veri artırma yöntemleri sayesinde az sayıda etiketli örnekle bile yüksek doğrulukta sonuçlar elde edebilmektedir. Bu açıdan, geleneksel CNN tabanlı sınıflandırma ağlarından farklıdır; çünkü

amacı sadece görüntüyü sınıflandırmak değil, piksel bazında haritalama yaparak ilgili anatomik yapıları tam olarak ortaya koymaktır (Çiçek vd., 2016).

3.3 U-Net Varyantları

U-Net'in 2015 yılında tanıtılmasının ardından, bu mimarinin etkisi, çeşitli veri türleri ve klinik gereksinimler için pek çok varyantın ortaya çıkmasına neden olmuştur. Bu varyantların ana hedefi, klasik U-Net'in avantajlarını koruyarak daha derin bağlamsal bilgiler elde etmek, dikkati amaçlanan yapıya yönlendirmek veya genelleme yeteneğini güçlendirmektir. Bu varyantların bazıları aşağıdakiler gibidir.

- **Attention U-Net:** Attention U-Net, kodlayıcı ile kod çözücü arasında bulunan dikkat kapıları (attention gate) sayesinde alakasız alanları azaltırken, önemli alanları vurgular. Böylece model, özellikle hedef yapının boyut ve şeklinin farklılık gösterdiği durumlarda daha fazla hassasiyet sunmaktadır (Oktay vd., 2018).
- **Residual U-Net (R2U-Net):** Geleneksel U-Net yapısına artı bağlantılar ve tekrar eden parçalar ekleyerek, gradyan kaybını azaltmayı başarmış ve daha derin ağların eğitimini kolaylaştırmıştır. Bu mimari, özellikle hassas anatomik sınırların ayrıştırılmasında dikkat çekici bir performans sergilemektedir (Alom vd., 2018).
- **Nested U-Net (U-Net++):** Bu yapı kodlayıcı ve kod çözücü arasında çok katmanlı (nested) ve yoğun (dense) atlama bağlantıları oluşturarak, çeşitli düzeylerdeki özelliklerin daha etkili bir şekilde bir araya getirilmesini sağlar. Bu sayede anlam boşluğu (semantic gap) azaltılmakta ve özellikle tıbbi görüntülerde daha yüksek Dice/IoU skorları elde edilmektedir (Zhou vd., 2018a).
- **nnU-Net:** nnU-Net, belirli bir yapı önerisinde bulunmak yerine, veri kümesinin niteliklerine göre otomatik olarak ayarlanan bir segmentasyon süreci sağlamıştır. Ön işlem, veri artırma, ağ ayarları ve eğitim taktiklerini kendi kendine adapte edebilmesi sayesinde, çeşitli tıbbi görüntü veri setlerinde yaygın bir standart olmuştur. (Isensee vd., 2021)

Bu varyasyonlar, U-Net'in ana ilkelerini koruyarak farklı iyileştirmelerle daha karmaşık yapıların ihtiyaçlarına hitap edebilmiş ve bilimsel yayınlarda yaygın bir kabul elde etmiştir.

3.4 Omurga Tabanlı U-Net'ler

Klasik U-Net yapısı, başlangıçtan itibaren oluşturulan bir kodlayıcı kullanırken, son zamanlarda daha önceden eğitilmiş CNN yapılarının bir kodlayıcı olarak kullanılma oranı

artmıştır. Bu yöntem, transfer öğrenimi sayesinde geniş ölçekli doğal görüntü veri setlerinde (örneğin, ImageNet) elde edilen zengin özelliklerin tıbbi görüntü segmentasyonuna aktarılmasını mümkün kılmaktadır. Aşağıda literatürde sıklıkla kullanılan omurga tabanlı U-Net mimarilerinden örnekler verilmiştir.

- **VGG19 tabanlı U-Net:** VGG19, derin ama basit yapıdaki konvolüsyon blokları ile donatıldığında, kodlayıcı olarak işlev gördüğünde tutarlı bir özellik elde etme yeteneği sunar. Özellikle az sayıda veri içeren setlerde dengeli bir performans sergileyerek dikkat çekmiştir (Çiçek vd., 2016).
- **ResNet50 tabanlı U-Net:** Artık (Residual) bloklar aracılığıyla gradyan parazitlenmesini azaltan ResNet50, daha derin sinir ağlarının eğitimini kolaylaştırır. ResNet50 temelinde geliştirilen U-Net, özellikle karmaşık yapılar içeren tıbbi görüntülerde daha etkili sonuçlar alınmasına yardımcı olmaktadır (Zhang vd., 2018).
- **EfficientNetB4 tabanlı U-Net:** Parametre etkinliğini öncelikli hedef olarak belirleyen EfficientNet ailesinin ölçeklendirme yöntemi (compound scaling) sayesinde, EfficientNetB4 temel alınarak oluşturulan U-Net, düşük hesaplama maliyeti ile yüksek hassasiyetle segmentasyon yapabilmektedir. Bu durum, özellikle yüksek çözünürlüklü görüntülerle çalışırken büyük bir avantaj sağlamaktadır (Tan & Le, 2019).

Omurga tabanlı U-Net yapıları, geleneksel U-Net'in mimarisindeki esnekliği sürdürerek, etkili özellik çıkarma yetenekleri ile tıbbi segmentasyon alanında giderek daha fazla ilgi görmektedir.

3.5 Tıbbi Görüntü Segmentasyonundaki Uygulamaları

U-Net ve onun varyantları, önerilerinin ardından kısa sürede tıbbi görüntülerin segmentasyonu alanında en yaygın yöntemlerden biri haline gelmiştir. Bu durumun en önemli sebebi, mimarinin hem genel bağlam bilgisini hem de küçük anatomik detayları eş zamanlı olarak yakalayabilmesi ve sınırlı etiketli veri ile bile yüksek doğruluk sunabilmesidir. Farklı görüntüleme türlerinde başarılı sonuçlar elde edildiği bildirilmiştir.

MRG verilerinde beyin tümörleri (Ghadimi vd., 2025) ve kalp yapıları gibi karmaşık anatomilerin segmentasyonu (C. Chen vd., 2020), BT görüntülerinde akciğer nodülleri (Çallı vd., 2021) ve karaciğer lezyonlarının tespit edilmesi (Wei vd., 2024), ultrason verilerinde fetal ve kalp yapılarını ayırt etme (Nurmaini vd., 2021) ile radyografi görüntülerinde kemik veya akciğer bölgelerinin tanımlanması (Din vd., 2025; Fok vd., 2024) örnek olarak gösterilebilir. Özellikle, ultrason gibi düşük kontrast ve gürültülü verilere sahip

durumlarda, dikkat mekanizmalı U-Net türevleri daha güvenilir sonuçlar sağlamıştır. Genel değerlendirildiğinde, U-Net ailesi, tıbbi görüntü segmentasyonu için modaliteye bağlı olmayan bir yaklaşım sunmakta olup hem akademik hem de klinik araştırmalarda yaygın olarak tercih edilmektedir (Isensee vd., 2021; Ronneberger vd., 2015).

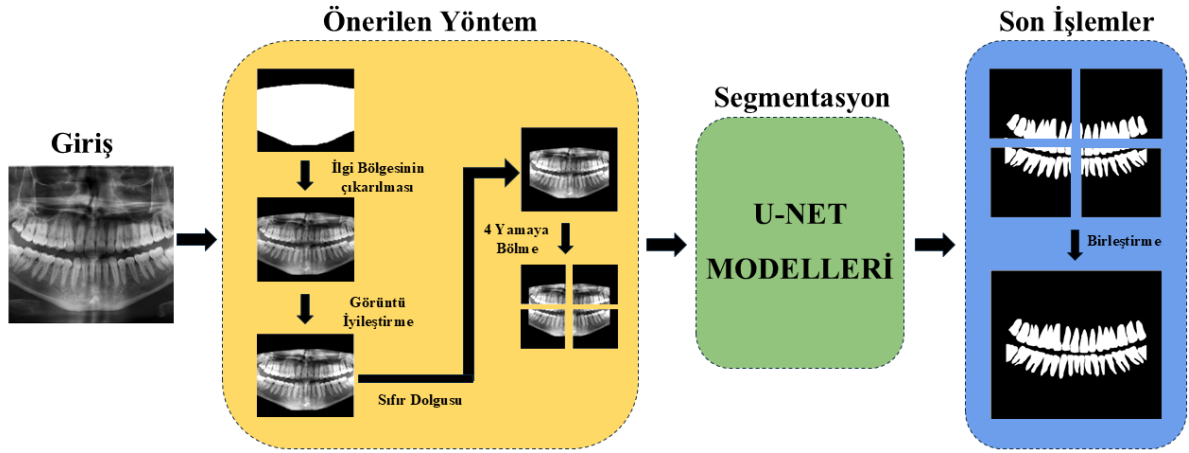
3.6 Diş Radyografilerinde Kullanımı

Diş hekimliğinde panoramik radyografiler, alt ve üst çenenin yapılarının tek bir görüntü altında incelenmesini sağladığı için tanı ve tedavi planları için sıklıkla tercih edilmektedir. Ancak, bu görüntülerdeki düşük kontrast, örtüşen anatomik yapıların varlığı ve gürültü gibi problemler, elle segmentasyon işlemlerini zorlaştırmakta ve zaman alıcı hale getirmektedir. Bu nedenle, U-Net ve onun varyantları, diş radyografilerinde otomatik segmentasyon için en yaygın yöntemlerden biri olarak öne çıkmıştır.

U-Net tabanlı modeller; dişlerin, mandibula ve maksilla gibi ana çene yapılarını veya periodontal bölgeleri segmentasyonunda başarılı sonuçlar elde etmiştir. Literatürde klasik U-Net'in yanı sıra Attention U-Net gibi dikkati artıran yöntemler, gereksiz alanları bastırarak hedef yapıları daha iyi vurgulamış (T. Ma vd., 2024; Oktay vd., 2018); Nested U-Net gibi derin bağlantı yapıları ise diş çürükleri ya da kök kanalları gibi küçük anatomik detayların daha hassas bir şekilde ayrıştırılmasına yardımcı olmuştur (Alharbi vd., 2023; Zhou vd., 2018). Ayrıca, omurga tabanlı U-Net varyantları (örneğin, ResNet50, EfficientNetB4) (Aung vd., 2024) daha zengin özellik çıkarımı sağladığı için panoramik radyografilerde diş segmentasyonunun doğruluğunu artırmıştır.

4. ÖNERİLEN YÖNTEM

Bu tez çalışmasında panoramik diş radyografilerinin segmentasyon başarımını artırmak üzere tasarlanan ilgi alanı bölgelerinin çıkarılması tabanlı ön işleme ile yama tabanlı eğitim stratejilerini birleştiren bir yöntem sunulmaktadır. Önerilen yöntem, ham görüntülerin işlenmesinden nihai segmentasyon maskesinin Şekil 4.2’de gösterildiği gibi elde edilmesine kadar uzanan uçtan uca bir iş akışına sahiptir.



Şekil 4.2. Önerilen Yöntemin Çalışma Prensibi

Şekil 4.2’de önerilen yöntemin kaba kodu Şekil 4.3’de gösterilmektedir. Burada 1. adımda girdi görüntüsü, 1615×840 piksel boyutundan 840×840 kare formatına dönüştürülerek merkez kırpma boyutu modelin giriş ölçülerinin standart hale gelmesi sağlanır. 2. adımda ilgi alanı bölgeleri maskesi yardımıyla dişlerin yer aldığı anatomik alan ayrıştırılır ve ilgili olmayan kısımlar çıkartılır, izolasyonu gerçekleştirilir. 3. adım ön işleme yöntemlerinin (CS, GB, CS+GB) ilgi alanı bölgesine uygulanarak kontrast artırılır, gürültü azaltılır ve netlik artırılır. 4. adım sıfır dolgulama adımdır ve burada ilgi alanı bölgesi 1024×1024 boyutuna sıfır eklenerek büyütülür ve bu, yama bölme için uygun bir kare yapı oluşturur. 5. adım yama bölme işlemi gerçekleştirilir. Görüntü, 2×2 ızgara ile dört adet 512×512 piksel yamaya ayrılır. Bu yöntem, modelin yüksek çözünürlüklü detayları öğrenmesini kolaylaştırır. 6–9. Adımlarda for döngüsü içerisinde toplam görüntü sayısı kadar normalizasyon ve tahmin işlemleri yapılmaktadır. Bu döngüde her bir yama normalize edilip U-Net tabanlı model aracılığıyla tahmin maskeleri elde edilir. 10–11. adımlar yama birleştirme yapmaya yarar. Dört yamadaki tahminler yeniden 2×2 düzeninde birleştirilerek 1024×1024 boyutunda bütünleşik bir maske oluşturulur. 12. adımda

nihai maske, sıfır dolgulardan arındırılarak 840×840 boyutuna geri getirilir. 13. adım yani çıktı kısmında ise son segmentasyon maskesi elde edilir.

```
Girdi: Panoramik diş radyografisi I, ROI maskesi M  
Çıktı: Nihai segmentasyon maskesi S  
1: I' ← Merkez kırpma (I, boyut=840×840)  
2: R ← İlgi Bölgesi izolasyonu (I', M)  
3: R' ← Önİşleme (R, yöntem ∈ {CS, GB, CS+GB})  
4: P ← SıfırDolgulama (R', boyut=1024×1024)  
5: {p1, p2, p3, p4} ← YamaBöl (P, grid=2×2, boyut=512×512)  
6: for her yama pi ∈ {p1, p2, p3, p4} do  
7: pi_norm ← Normalize(pi)  
8: si ← U-Net_Model_Tahmin(pi_norm)  
9: end for  
10: S_yama ← {s1, s2, s3, s4}  
11: S ← YamaBirleştir (S_yama, grid=2×2)  
12: S ← DolguKaldır (S, boyut=840×840)  
13: return S
```

Şekil 4.3. Önerilen Yöntemin Algoritması

4.1 Girdi Standardizasyonu ve Veri Özellikleri

Tez çalışması kapsamında Tufts Diş Veri Tabanına (Panetta vd., 2022) ait panoramik 1000 adet X-Ray görüntüsü kullanılmıştır. Ham görüntüler 1615×840 piksel çözünürlüğe sahiptir ve geniş bir bakış açısını temsil eden yapısal bir özellik taşır. Derin öğrenme tabanlı segmentasyon modellerinin genellikle sabit boyutlu ve kare formatlı giriş gereksinimleri olduğu için, ilk aşamada görüntüler merkezde hizalanarak 840×840 kare formatına dönüştürülmüştür. Bu kesme işlemi yalnızca girdi boyutunun standartlaştırılması amacıyla yapılmış, görüntülerin tanısal değerini koruyacak şekilde anatomik bilgi kaybı en aza indirgenmiştir. Böylece hem

modelin eğitilebilirliği artırılmış hem de sonraki ön işleme ve segmentasyon adımlarında tutarlı bir veri yapısı sağlanmıştır.

4.2 İlgi Bölgesi Tabanlı Ön İşleme

Veri setinde her bir görüntü için önceden hazırlanmış ilgi bölgesi maskeleri mevcuttur. Bu maskeler, dişlerin yer aldığı anatomik bölgeyi belirler ve iki temel amaç taşır: (i) İlgi alanı bölgeleri görüntüden ayrıştırılması, (ii) Ön işleme adımlarının yalnızca ilgi alanı bölgeleri üzerinde gerçekleştirilmesi. Böylelikle kontrast artırma, gürültü azaltma ve netleştirme gibi işlemler anlamlı doku bölgelerinde etkili bir şekilde uygulanırken, İlgi alanı bölgeleri dışındaki alanlar ise bozulmamış olarak kalır.

Bu tezde Bölüm 6.3'de açıklanacak olan 14 farklı ön işleme tekniği incelenmiştir. Bu tekniklerden CS, GB ve CS + GB kombinasyonu Tablo 7.4'de gösterildiği gibi en tutarlı sonuçları sağlamıştır. Önerilen yaklaşım, İlgi alanı bölgelerinin ayrıştırılmasının ardından belirlenen iyileştirme adımlarını bu özel bölgede uygular.

4.3 Sabit Boyuta Getirme ve Sıfır-Dolgulama

İlgi alanı bölgeleri üzerinde ön işleme gerçekleştirildikten sonra, görüntü 1024×1024 boyutuna sıfır dolgu ile genişletilir. Bu işlem, asıl içeriği yani görüntünün orta bölgesi korurken, bir sonraki yamaya bölme adımı için elverişli bir ızgara yapısı oluşturur.

4.4 Yama-Tabanlı Ayrıştırma ve Normalizasyon

1024×1024 boyutuna ayarlanan resim, 2×2 ızgara kullanılarak dört tane 512×512 yama haline bölünür. Yama temelli yöntem, modelin yüksek çözünürlükteki yerel detayları daha etkili bir şekilde öğrenmesi sağlarken, hesaplama maliyetlerinin dengelenmesine de yardımcı olur. Her bir yama, ayrı bir şekilde normalleştirilir (yoğunluk yeniden ölçeklendirme ve/veya z-skorlama), bu sayede aydınlatmadaki değişiklikler ve yerel kontrast farklılıkları karşısında modelin dayanıklılığı artırılır.

4.5 U-Net Tabanlı Segmentasyon Mimarisi

Tablo 7.4'de analiz sonuçları verilen deneylerin incelenmesi sonrasında EfficientNetB4 temel alınarak oluşturulan U-Net yapısı tercih edilmiştir. EfficientNet-B4'ün çok katmanlı özellikler elde etmesi, kod çözücü kısmında ise atlama bağlantılarıyla uzamsal detayların yeniden elde edilmesi amaçlanmıştır. Bu yapı, panoramik radyografilerdeki ince diş sınırları ve kök yapısı gibi detayların tespitinde başarılı sonuçlar vermektedir.

4.6 Eğitim Stratejisi ve Metrikler

Önerilen yaklaşımda eğitim aşaması, her biri 512×512 boyutunda olan yamaların bağımsız örnekler olarak işlenmesine dayanmaktadır. Bu sayede, yüksek çözünürlüklü detayların öğrenilmesi mümkün hale getirilmiş ve büyük panoramik görüntülerin doğrudan eğitim sürecine katılmasının oluşturacağı bellek sınırlamaları da aşılmıştır. Eğitim sırasında kayıp fonksiyonu olarak Dice Kaybı seçilmiştir. Bu fonksiyonun tercih edilmesinin başlıca sebebi, dış segmentasyonu sorununda pozitif sınıfın (dış pikseli) negatif sınıfa oranla oldukça az olmasıdır. Geleneksel kayıp fonksiyonları bu dengesiz veri dağılımı karşısında etkisiz kalabilirken, Dice Kaybı alan örtüşmesine odaklanarak küçük hedef yapıların daha hassas bir şekilde öğrenilmesine olanak tanır.

Modelin performansını değerlendirmek için üç ana metrik kullanılmıştır: Dice, IoU ve PA. Dice değeri, modelin tahmin ettiği alan ile gerçek maske arasındaki örtüşme miktarını ölçerken, IoU tahmin edilen ve gerçek segmentlerin kesişim ve birleşim oranını hesaplamaktadır. PA ise tüm pikseller üzerinden doğru tahmin oranını gösteren daha genel bir ölçüt olarak karşımıza çıkmaktadır. Bu üç ölçütün bir arada kullanılması hem bölgesel örtüşmeyi hem de genel doğruluğu kapsamlı bir şekilde inceleme imkânı sağlamıştır.

Eğitim süresi boyunca modelin doğrulama kümesindeki performansı sürekli olarak takip edilmiş ve erken durdurma (early stopping) stratejisi ile aşırı uyum (overfitting) riski azaltılmıştır. Bunun yanı sıra, her eğitim döngüsü sonunda en yüksek Dice değeri elde eden model ağırlıkları kaydedilmiş ve bu en iyi modeller sonraki analizlerde kullanılmıştır.

4.7 Yordamlama, Birleştirme ve Son İşlem


Tahmin sürecinde her bir görüntü için dört farklı yamanın segmentasyon sonuçları alınır. Bu yama maskeleri, 2×2 düzeninde birleştirilerek 1024×1024 boyutunda tek bir birleşik maske oluşturulur. Gerekirse, ek alanlar çıkarılarak maske, merkezden kırpma yöntemiyle 840×840 boyutuna geri getirilir. Bu aşama, modelin sonuçlarının görsel bütünlük ve pratik açıdan kullanılabilir bir şekilde sahip olmasına yardımcı olur. Şekil 4.3’de önerilen yöntemin kaba kodu gösterilmiştir. Burada 1. adımda girdi görüntüsü, 1615×840 piksel boyutundan 840×840 kare formatına dönüştürülerek merkez kırpma boyutu modelin giriş ölçülerinin standart hale gelmesi sağlanır. 2. adımda ilgi alanı bölgeleri maskesi yardımıyla dışların yer aldığı anatomik alan ayrıştırılır ve ilgili olmayan kısımlar çıkartılır, izolasyonu gerçekleştirilir. 3. adım ön işleme yöntemlerinin (CS, GB, CS+GB) ilgi alanı bölgesine uygulanarak kontrast artırılır, gürültü azaltılır ve netlik artırılır. 4. adım sıfır dolgulama adımıdır ve burada ilgi alanı bölgesi

1024×1024 boyutuna sıfır eklenerek büyütülür ve bu, yama bölme için uygun bir kare yapı oluşturur. 5. adım yama bölme işlemi gerçekleştirilir. Görüntü, 2×2 ızgara ile dört adet 512×512 piksel yamaya ayrılır. Bu yöntem, modelin yüksek çözünürlüklü detayları öğrenmesini kolaylaştırır. 6–9. Adımlarda for döngüsü içerisinde toplam görüntü sayısı kadar normalizasyon ve tahmin işlemleri yapılmaktadır. Bu döngüde her bir yama normalize edilip U-Net tabanlı model aracılığıyla tahmin maskeleri elde edilir. 10–11. adımlar yama birleştirme yapmaya yarar. Dört yamadaki tahminler yeniden 2×2 düzeninde birleştirilerek 1024×1024 boyutunda bütünleşik bir maske oluşturulur. 12. adımda nihai maske, sıfır dolgulardan arındırılarak 840×840 boyutuna geri getirilir. 13. adım yani çıktı kısmında ise son segmentasyon maskesi elde edilir.

5. TUFTS DIŐ VERİ TABANI

Tezde kullanılan veri seti, Tufts Diő Veritabanı (Tufts Dental Database, TDD) (Panetta vd., 2022) olarak bilinen, diő hekimliđine yönelik kapsamlı ve çok modellenli bir panoramik X-ray görüntü koleksiyonudur. TDD, oral ve dental sađlıkla ilgili çeřitli durumların tanılanması ve tedavisinin iyileştirilmesi amacıyla oluşturulmuş olup, araştırma ve geliştirme çalışmalarında sıkça referans alınan nitelikli bir kaynak olarak öne çıkmaktadır. Tufts Üniversitesi Diő Hekimliđi Fakültesi tarafından derlenen bu veri seti, yaklaşık 1000 adet panoramik X-ray görüntüsünü içermekte olup, her biri 1615×840 piksel çözünürlüđe sahiptir. Görsellerin bu yüksek çözünürlüklü yapısı, detaylı anatomik yapıların analizine imkân tanımakta ve segmentasyon gibi piksel hassasiyeti gerektiren derin öğrenme görevleri için uygun bir zemin oluşturmaktadır. Sırasıyla bahsi geçen maddelerin örnekleri Şekil 5.4'te gösterilmiştir.

- a) Panoramik radyografi görüntüleri,
- b) Uzmanlar tarafından etiketlenmiş segmentasyon maskeleri,
- c) Göz izleyici (eye-tracker) cihazlarıyla oluşturulmuş dikkat haritaları,
- d) Her bir X-ray için açıklayıcı metin bilgileri,
- e) Belirli anatomik yapılar için tanımlanmış diő maskeleri,
- f) Maksillomandibular bölgeyi tanımlayan ilgi alanı bölgesi maskeleri.



Şekil 5.4 TDD'nin Bileşenleri

Bu çok katmanlı yapı, yalnızca segmentasyon değil, aynı zamanda dikkat analizi, açıklayıcı metin sınıflandırması ve çoklu görevli öğrenme gibi farklı yapay zekâ temelli araştırmalara olanak tanımaktadır. Ayrıca, ilgi alanı bölgesi maskelerinin hazır şekilde sunulması, bu

tezde olduđu gibi blge tabanlı analizlerin yapılmasını kolaylařtırmakta ve iř ykn nemli lde azaltmaktadır.

Gerekleřtirilen bu tez alıřması kapsamında, TDD'de en iyi maske ile analiz elde etmek amacıyla panoramik radyografiler ile bunların etiketlenmiř maskeleri ve ilgi alanı blgesi maskeleri kullanılmıřtır. Bu veri seti, farklı nesne sınıfları ve yksek znrlkl grntleri barındırdıđı iin, grnt segmentasyon modellerinin eđitimi ve deđerlendirilmesi aısından mkemmел bir tercihtir.

Yapılan arařtırmalarda da panoramik diř radyografilerinin otomatik olarak ayrıřtırılması iin TDD sıklıa kullanılan bir referans veri seti olmuřtur. Bu veri seti, diř ve evresindeki anatomik yapıları ayırmak amacıyla derin đrenme temelli tekniklerin etkinliđini lmek iin eřitli řekillerde deđerlendirilmiřtir (Adnan vd., 2024). Bir arařtırmada, panoramik diř rntgenlerinin segmentasyonu iin oklu model derin đrenme yntemleri geliřtirilmiř ve bu yntemlerin etkinliđini deđerlendirmek iin TDD veri seti kullanılmıřtır. Arařtırmacılar, Tufts veri setinin zengin rnek eřitliliđi ve klinik olarak nemli etiketlemeleri sayesinde modellerin genel performansının artırıldıđını ve daha isabetli segmentasyon sonularının elde edildiđini belirtmiřlerdir (Bhat vd., 2025a; Mrginean vd., 2024a).

6. GÖRÜNTÜ KALİTESİ VE ÖN İŞLEME YÖNTEMLERİ

Panoramik diş radyografilerinin otomatik olarak segmentasyona uygun hale getirilmesi, görüntü kalitesinin detaylı bir şekilde değerlendirilmesini ve uygun ön işleme yöntemlerinin belirlenmesini gerektirir. Bu bağlamda, ilk olarak kaliteyi belirleyen kriterler tanımlanmış, daha sonra elde edilen analiz sonuçlarına göre veri setinin özellikleri incelenmiştir. Ardından, literatürde sıkça kullanılan geleneksel ve hibrit ön işleme teknikleri araştırılmış ve uygun yöntemler seçilmiştir. Son olarak, kalite değerlendirme metrikleri aracılığıyla yapılan performans analizi ile belirlenen tekniklerin etkinliği gösterilmiştir.

6.1 Görüntü Kalitesi Ölçütleri

Diş radyografisi görüntülerinde gerçekleştirilen segmentasyon işlemlerinin başarısı, büyük ölçüde modelin giriş olarak aldığı görüntünün kalitesine bağlıdır. Özellikle tıbbi görüntüleme uygulamalarında, düşük kontrast, bulanıklık, aydınlatma dengesizlikleri gibi çeşitli bozulmalar, derin öğrenme tabanlı modellerin yapısal ayrıntıları öğrenmesini ve doğru sınırlamalar yapmasını olumsuz etkileyebilmektedir. Bu nedenle, ön işleme aşamaları, yalnızca görüntünün görsel kalitesini artırmakla kalmayıp, aynı zamanda görüntüdeki anlamlı dokusal bilgileri koruyarak segmentasyon modelinin daha verimli öğrenmesini sağlayacak biçimde tasarlanmalıdır. Bu tez kapsamında, kullanılan ön işleme tekniklerinin belirlenmesinde istatistiksel olarak tanımlanmış görüntü kalitesi bozulmalarına dayanan bir yaklaşım benimsenmiştir. Bu kapsamda, radyografilerde sık karşılaşılan görsel kusurların tespiti amacıyla çeşitli görüntü kalitesi metrikleri kullanılmıştır. Her bir kalite metriği, belirli bir bozulma türünü tanımlamakta ve görüntüdeki bilgi yoğunluğu, kontrast düzeyi, parlaklık dengesi, keskinlik, kenar zenginliği ve histogram simetrisi gibi temel nitelikleri nicel olarak değerlendirmektedir.

Belirlenen metrikler doğrultusunda, her biri bir görüntü kusurunu hedef alan uygun ön işleme yöntemleri dikkatlice seçilmiştir. Örneğin; düşük entropi değeri, yapısal bilgi eksikliğini; düşük kenar yoğunluğu ise sınırlayıcı konturların belirsizliğini işaret etmektedir. Bu tür kusurlar için kontrast artırıcı, kenar belirginleştiren veya gürültü gideren yöntemler kullanılmıştır.

Aşağıda detaylı olarak tanımlanan her bir görüntü kalite ölçütü, literatürde kabul görmüş tanımlarla desteklenmiş olup, ilgili hesaplama formülleriyle birlikte sunulmaktadır. Böylece, seçilen ön işleme stratejilerinin yalnızca sezgisel değil, aynı zamanda istatistiksel ve sayısal

temellere dayandığı gösterilmektedir. Bu yaklaşım, dental radyografilerde segmentasyon başarısını artırmak amacıyla sağlam ve sistematik bir ön işleme planının oluşturulmasına olanak tanımaktadır.

6.1.1 Entropi

Entropi, dijital görüntü işleme alanında sıkça başvurulan ve bir görüntüdeki bilgi miktarını ve gri seviye yoğunluklarının çeşitliliğini nicel olarak değerlendiren önemli bir istatistiksel ölçüttür. Temelini Shannon'ın bilgi teorisinden alan bu kavram, bir görüntüde yer alan gri tonların dağılımındaki düzensizlik ve çeşitlilik derecesini belirlemeye yardımcı olur. Başka bir ifadeyle, entropi bir görüntünün ne kadar “bilgi yüklü” olduğunu matematiksel olarak ifade eder. Görüntüdeki piksel yoğunluklarının benzer tonlarda toplanması durumunda entropi değeri düşer; bu da görsel bilginin sınırlı olduğu, yani görüntünün homojen yapıda ve detaylardan yoksun olduğunu gösterir. Öte yandan, farklı gri tonlarının yoğunlukta yer aldığı ve dokusal çeşitliliğin bulunduğu görüntüler yüksek entropi değerlerine sahiptir. Bu durum, görüntünün daha fazla yapısal bilgi taşıdığı ve analiz için daha elverişli olduğu anlamına gelir. Bu nedenle, entropi hem görüntü kalitesinin genel düzeyini değerlendirmede, hem de ön işleme ihtiyacını saptamada etkili bir gösterge olarak kullanılmaktadır. Tezin bu kısmında da entropi değeri, dental radyografilerdeki bilgi yoğunluğu ve dokusal çeşitlilik düzeyini analiz etmek amacıyla temel metriklerden biri olarak seçilmiştir. Denklem 6.1’de gösterildiği üzere entropi değeri, bir görüntüdeki gri tonların olasılık dağılımına bağlı olarak hesaplanmaktadır. Bu bağlamda literatürdeki çeşitli çalışmalar da entropinin önemi üzerinde durmaktadır. Örneğin, yapılan bir çalışmada (Sparavigna, 2019) entropiyi özellikle doku ve bilgi yoğunluğu analizlerinde etkili bir metrik olarak tanımlamakta; düşük entropi sahibi görüntülerin genellikle bilgi içeriği açısından zayıf olduğunu ve analiz için ideal adaylar olmadığını vurgulamaktadır. Başka bir çalışmada (Chen vd., 2019) ise, entropiyi “algılanan görüntü kalitesini” ölçmede temel bir kriter olarak ele almış ve düşük entropi değerlerinin genellikle düşük algısal kaliteyle doğrudan ilişkili olduğunu bildirmiştir.

Tüm bu nedenlerle birlikte, entropi değeri yalnızca bir sayısal ölçüm aracı değil, aynı zamanda ön işleme stratejisinin yönlendirilmesinde kullanılabilecek anlamlı bir kalite göstergesi olarak değerlendirilmiştir. Dental radyografiler gibi düşük kontrast ve sınırlı ayrıntı içerebilen tıbbi görüntülerde, entropi analizi sayesinde hangi görüntülerin ön işleme ihtiyaç duyduğunu sistematik biçimde belirlemek mümkün hale gelmiştir.

$$Entropi = - \sum_{i=0}^{L-1} p_i \cdot \log_2(p_i) \quad (6.1)$$

Buradaki i , gri ton değerini; p_i ise gri ton değerinin görüntüde ortaya çıkma olasılığını ifade etmektedir. Bu olasılıklar görüntünün histogramının normalize edilmesiyle elde edilmektedir. L genellikle 8 bitlik görüntülerde 256'dır ve gri tonlama miktarını verir.

6.1.2 Kontrast

Görüntü işleme alanında, kontrast, bir görüntüdeki en karanlık (düşük yoğunluklu) ve en aydınlık (yüksek yoğunluklu) alanlar arasındaki ışık farklılığı olarak tanımlanmaktadır. Bu farklılık, görüntünün algılanabilirliğini ve görsel kalitesini etkileyen önemli bir özellik olarak kabul edilir (Gonzalez & Woods, 2018). Yüksek kontrast, görüntüdeki ayrıntıların daha belirgin bir şekilde ayırt edilmesini sağlarken, nesne ile arka plan arasındaki farkın daha net belirlenmesine yardımcı olur. Bunun aksine, düşük kontrast, görüntüdeki detayların belirsiz hale gelmesine ve nesnelerin ayırt edilmesinin zorlaşmasına sebep olabilir. Bu durum, özellikle tıbbi görüntüleme gibi hayati öneme sahip alanlarda, doğru tanı ve analiz süreçlerini olumsuz etkileyebilir. Bu nedenle, kontrast değeri görsel estetik açısından değil, aynı zamanda sayısal görüntü analizlerinde bilgi yoğunluğu ve ayrıntı seviyesinin bir göstergesi olarak da önem taşımaktadır. Düşük kontrasta sahip görüntüler, sıkça bilgi kaybı riski barındıran, yapısal olarak zayıf ve segmentasyon için uygun olmayan örnekler olarak kabul edilmektedir. Dolayısıyla, görüntülerdeki kontrast düzeyinin nicel olarak değerlendirilmesi, segmentasyon gibi daha karmaşık işlemlerden önce kalite kontrol aracı olarak işlev görebilir.

Bu tez kapsamında, kontrast ölçümü, görüntüdeki gri tonlu piksellerin parlaklık değerlerinin, ortalama yoğunluk etrafında nasıl dağıldığını inceleyen istatistiksel bir yöntemle gerçekleştirilmiştir. Bu yöntemde, kontrast, Denklem 6.2'de de gösterildiği üzere piksel yoğunluklarının standart sapmasına dayanarak hesaplanmakta ve böylelikle görüntüyü oluşturan parlaklık çeşitliliği sayısal olarak ifade edilmektedir.

$$Kontrast = \sqrt{\frac{1}{N} \sum_{i=1}^N (I_i - \mu)^2} \quad (6.2)$$

Burada μ görüntü üzerinde ortalama parlaklığı ve N ise görüntüdeki toplam piksel sayısını ifade etmektedir.

6.1.3 Parlaklık

Parlaklık, dijital görüntü işleme alanında bir görüntünün genel aydınlık düzeyini tanımlayan temel fotometrik bir özelliktir. Gri tonlamalı bir görüntüdeki tüm piksellerin yoğunluk (parlaklık) değerlerinin aritmetik ortalaması alınarak hesaplanır; bu ortalama değer, görüntünün genel olarak ne kadar açık ya da koyu olduğunu nicel olarak ifade eder. Özellikle düşük ışık koşullarında elde edilen tıbbi görüntülerde, parlaklık seviyesi görüntü kalitesinin değerlendirilmesinde önemli bir kriter olarak öne çıkar. Bezryadin vd. (2007) tarafından yapılan çalışmada parlaklık yalnızca temel bir görüntü özelliği olarak değil, aynı zamanda insan görsel algısıyla doğrudan ilişkili bir değerlendirme ölçütü olarak ele alınmıştır. Burada düşük parlaklık seviyelerinin, görüntüdeki detayların algılanmasını güçleştirdiği ve bu durumun analiz doğruluğunu olumsuz etkileyebileceği ifade edilmiştir (Bezryadin vd., 2007). Bu nedenle parlaklık hem görsel kalite değerlendirmelerinde hem de segmentasyon, sınıflandırma ve kenar tespiti gibi daha karmaşık görüntü işleme görevlerinde yaygın olarak kullanılan bir girdi özelliği olarak önem arz etmektedir. Bu tezde, gri tonlamalı dental radyografi görüntülerinin parlaklık seviyesi, Denklem 6.3'te gösterilen formül ile hesaplanmıştır. Söz konusu formül, görüntünün tüm satır ve sütunlarında yer alan piksel yoğunluklarının ortalamasını alarak parlaklık değerini tek bir skaler büyüklükle ifade eder. Bu yöntem, farklı ön işleme tekniklerinin parlaklık üzerindeki etkilerini karşılaştırmalı olarak değerlendirmek için kullanılmaktadır.

$$Parlaklık = \frac{1}{N} \sum_{i=1}^N I_i \quad (6.3)$$

Burada , I_i boyutundaki görüntünün koordinatındaki pikselin gri seviye yoğunluğunu ifade etmektedir. Bütün piksellerin yoğunluk değerinin ortalaması alınarak, görüntünün genel parlaklık seviyesi hesaplanmaktadır.

6.1.4 Keskinlik

Keskinlik, bir görüntüde yer alan kenar geçişlerinin netliği ve ani ton değişimlerinin belirginliği ile doğrudan ilişkili bir görüntü kalitesi göstergesidir. Başka bir ifadeyle, bir görüntüdeki yapısal ayrıntıların ne derece keskin ya da bulanık olduğu, keskinlik düzeyini belirler. Bu özellik, özellikle tıbbi görüntülerde yer alan anatomik yapıların sınırlarının ve dokular arası geçişlerin ne ölçüde korunabildiğini değerlendirmek açısından büyük önem taşır. Düşük keskinlik değerine sahip görüntülerde konturlar bulanık hâle gelirken, yüksek keskinlik değerleri daha net sınırlar ve detaylı yapılarla ilişkilidir. Bu bağlamda, keskinlik yalnızca görsel algı açısından değil, aynı zamanda görüntü işleme süreçlerinin başarısı üzerinde de belirleyici

bir rol oynar. Özellikle segmentasyon görevlerinde, modelin öğrenmesi gereken nesne sınırlarının belirginliği, doğrudan görüntünün keskinliği ile bağlantılıdır. Bulanık görüntüler, sınıflar arasındaki geçişleri belirsiz hâle getirerek modelin öğrenmesini zorlaştırabilir. Bu nedenle, keskinlik analizi, ön işleme ihtiyacının belirlenmesinde ve görüntülerin işlenmeye uygunluğunun değerlendirilmesinde temel bir metrik olarak kullanılmaktadır. Keskinlik değeri, çoğunlukla bir kenar algılama filtresi (örneğin, Laplacian operatörü) uygulandıktan sonra elde edilen piksel değerlerinin istatistiksel varyansı ile hesaplanmaktadır (Bkz. Denklem 6.4). Varyansın yüksek olması, görüntüdeki kenar geçişlerinin daha keskin ve kontrastlı olduğunu gösterir; bu da görüntünün içerdiği yapısal bilgilerin daha belirgin olduğu anlamına gelir. Nitekim literatürde yapılan çalışmalar da bu yöntemin güvenilirliğini desteklemektedir. Bir çalışmada (Ferzli & Karam, 2009), Laplacian tabanlı tekniklerin, özellikle kenar bilgisi açısından zengin olan görüntülerde, keskinliğin nicel olarak analiz edilmesinde oldukça etkili ve güvenilir bir yöntem olduğu belirtilmiştir. Bu nedenle bu çalışmada da görüntülerin keskinlik düzeyi, segmentasyon başarısını etkileyebilecek önemli bir kalite bileşeni olarak ele alınmış ve ön işleme stratejilerinin belirlenmesinde temel karar verici kriterlerden biri olarak kullanılmıştır.

$$Keskinlik = Var(\nabla^2 I) \quad (6.4)$$

Burada , görüntüye uygulanan Laplacian filtresi ($\nabla^2 I$) ile elde edilen kenar tepkilerini ifade eder. Bu değerlere ait varyans (Var), görüntüdeki keskin kenarların yoğunluğunu ve belirginliğini temsil eder. Varyans değeri arttıkça, görüntüdeki keskinlik artar.

6.1.5 Kenar yoğunluğu

Kenar yoğunluğu, bir görüntüdeki kenar piksel sayısının toplam piksel sayısına olan oranını temsil eden yapısal bir ölçüdür. Bu ölçüm, görüntüdeki sınır geçişlerinin yoğunluğunu nicel olarak değerlendirmek için kullanılır ve sahnedeki görsel karmaşıklık, nesne ayrımı ve detay seviyesi hakkında önemli bilgiler sağlar. Yüksek kenar yoğunluğu, görüntüdeki nesnelerin kenarlarının belirgin olduğu ve dokusal çeşitliliğin fazla olduğu durumları ifade ederken; düşük kenar yoğunluğu genellikle daha düz, düzgün ve basit yapıları görüntülerle ilişkilendirilir.

Bu ölçüt, segmentasyon gibi kenar tespiti odaklı görevlerde, görüntünün ne derece detay barındırdığını anlamak ve modele verilecek verinin uygunluğunu değerlendirmek açısından önemli bir rol üstlenir. Özellikle düşük kenar yoğunluğuna sahip görüntülerde, nesne

kenarlarının belirsizliği modelin etkili bir şekilde öğrenmesini zorlaştırabilir. Bu nedenle, kenar yoğunluğu, ön işleme gereksiniminin belirlenmesinde faydalı bir kalite göstergesi olarak kabul edilmiştir.

Bu metriğin hesaplanması Denklem 6.5'te açık bir şekilde ifade edilmektedir. Kenar yoğunluğu, görüntü üzerinde bir kenar tespit algoritması (örneğin Canny, Sobel veya Laplacian) kullanılarak elde edilen kenar piksellerinin sayısının, toplam piksel sayısına bölünmesi ile hesaplanır.

$$\text{Kenar Yoğunluğu} = \frac{\text{Kenar Piksel Sayısı}}{\text{Toplam Piksel Sayısı}} \quad (6.5)$$

Kenar Piksel Sayısı, kenar tespiti yöntemiyle elde edilen 1 değerleridir. Toplam Piksel, resmin tüm piksel sayısını gösterir.

6.1.6 Histogram çarpıklığı

Histogram çarpıklığı, bir görselin parlaklık dağılımının simetrik olup olmadığını analiz eden bir istatistiksel göstergedir. Gri tonların dağılımının sağa veya sola ne ölçüde kaydığını ve asimetrikliğinin boyutunu ölçümsel olarak tanımlamaktadır. Çarpıklık değeri sıfıra yakınsa, histogram simetrik kabul edilir ve görüntünün parlaklık dağılımı dengede demektir. Pozitif çarpıklık, histogramın sağa kaydığını ve görüntünün genel olarak daha karanlık olduğunu işaret eder; negatif çarpıklık ise sola kayma anlamına gelir ve görüntünün çoğunlukla daha açık olduğunu gösterir. Denklem 6.6'da tanımlanan çarpıklık, bir görüntüdeki parlaklık dengesizliklerini tespit etmek için oldukça faydalıdır. Düşük ışık koşullarında çekilen ya da aşırı pozlama yapılmış dış röntgenlerinde parlaklık problemlerini belirlemek ve uygun ön işleme (örneğin, gamma düzeltme veya histogram eşitleme) seçmek amacıyla özellikle önem taşır.

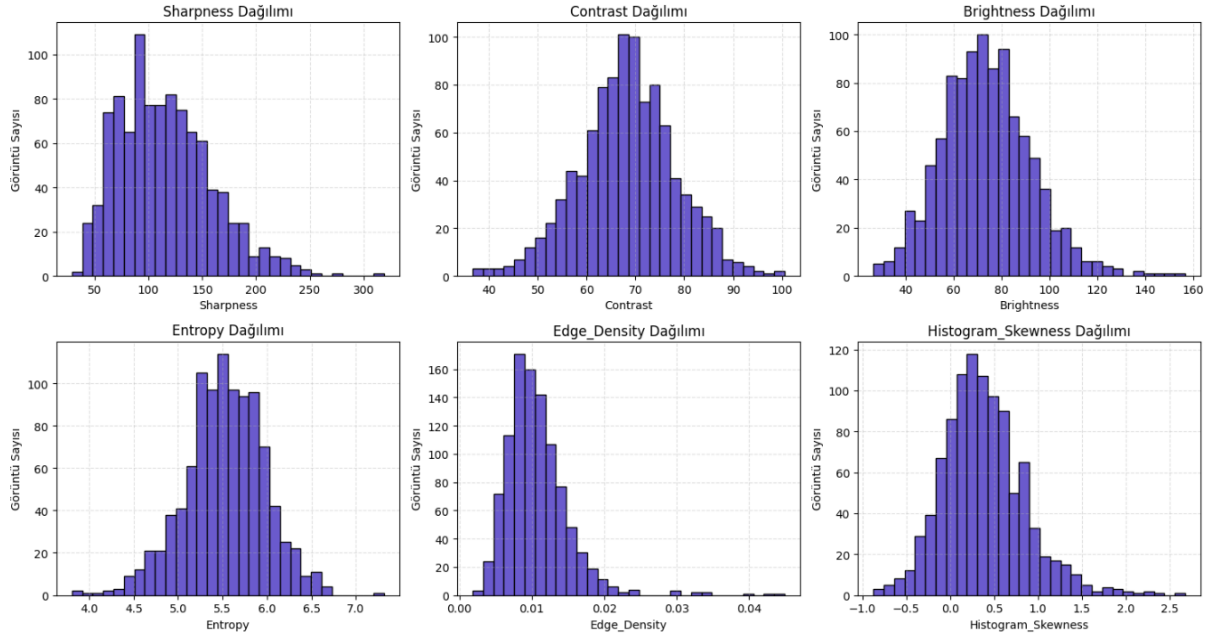
$$\text{Histogram Çarpıklığı} = \frac{1}{N} \sum_{i=1}^N \left(\frac{I_i - \mu}{\sigma} \right)^3 \quad (6.6)$$

I_i : i 'inci pikselin yoğunluk değeri, μ ortalama parlaklık, σ standard sapma ve N : toplam piksel sayısını temsil etmektedir.

6.2 Analiz Sonuçlarının Değerlendirilmesi

Tanımlanan görüntü kalitesi kriterlerinin teorik açıklamalarının yanı sıra, bunların veri kümesi içindeki dağılımının nicel olarak analiz edilmesi, ön işleme tekniklerinin

doğrulanmasında önemli bir rol oynamaktadır. Bu çerçevede, çalışmada yer alan her bir radyografi için belirtilen ölçütlerin değerleri hesaplanmış ve dağılımları Şekil 6.4'te sunulmaktadır.



Şekil 6.5 Görüntü Kalitesi Metriklerinin Dağılımı

Veri setindeki görüntülerin istatistiksel incelemeleri, çeşitli görsel özelliklerin dağılımını analiz etmek üzere histogram tabanlı bir yöntemle yapılmıştır. Bu çerçevede değerlendirilen entropi histogramı, çoğu görüntünün entropi değerlerinin 5,0'ın altında yoğunlaştığını göstermektedir. Bu durum, görüntülerdeki bilgi miktarının sınırlı olduğunu ve detay seviyesinin genel olarak düşük kaldığını düşündürmektedir. Özellikle tıbbi görüntüleme alanında detay kaybı, klinik incelemelerin doğruluğunu olumsuz etkileyebilir; bu nedenle bu bulgu dikkate değerdir.

Kontrast histogramı, yüzeysel olarak normal bir dağılım sergilese de 60 birimin altında belirgin bir yoğunlaşma gözlemlenmektedir. Bu, çok sayıda görüntünün düşük kontrastta olduğunu ve bu nedenle yapısal detayların yeterince belirgin olmayabileceğini ortaya koymaktadır. Parlaklık histogramı, veri setinde hem aşırı karanlık hem de aşırı parlak görüntülerin bulunduğunu açıkça gösteriyor; bu durum, parlaklık seviyelerinde ciddi bir dengesizlik olduğu ve görüntülerin homojen aydınlatmadığını işaret ediyor. Bu dağılımlar, yalnızca veri setinin kendine özgü yapısını yansıtmakla kalmamakta, aynı zamanda literatürde daha önce belirlenen bazı önemli eşiklerle de örtüşmektedir. Örneğin, (Chen vd., 2019) numunelerin algılanan bilgi içeriğinin entropi ölçüsü düştükçe azalabileceğini,

entropi tabanlı "referanssız" bir kalite değerlendirme yöntemi kullanarak göstermiştir. Ayrıca, uzaktan algılama uygulamalarındaki incelemeler, entropi temelli ölçümlerin düşük veri çeşitliliği ile bağlantılı olduğunu ve entropi temelli eşiklerin yapısal olarak zayıf görüntüleri tanımlamada etkili olduğunu ortaya koymuştur. Bu tür çalışmalar, entropinin yalnızca sayısal bir gösterge değil, ayrıca bilgi yoğunluğu ve görsel anlamın etkili bir ifadesi olduğunu gösterir. Amerikan Tıp Fizikçileri Derneği (AAPM) tarafından yayımlanan kalite kontrol yönergelerinde, 0,01'in altındaki kenar yoğunluğu değerleri, yapı detaylarının eksik olduğunu belirten bir durum olarak tanımlanmaktadır (Ezzell vd., 2003). Bu çalışmada elde edilen entropi ve kenar yoğunluğu histogramları, birçok görüntünün bu eşiklerin altında kaldığını göstermektedir. Parlaklık ve histogram eğriliğindeki asimetri, ışık dengesizliklerinin yaygın olduğunu belirtirken, kontrast ve keskinlik histogramları, düşük kontrast ve bulanıklığın çoğu görüntüyü etkilediğini desteklemektedir. Tüm bu bulgular, veri setinde segmentasyon doğruluğunu olumsuz yönde etkileyebilecek çok sayıda görüntü bulunduğunu ve ön işleme aşamalarının yalnızca sezgilere değil, istatistiksel verilere de dayandırılması gerektiğini vurgulamaktadır. Tespit edilen görüntü kalitesi ölçümlerinin dağılımı, düşük entropi, zayıf kontrast, dengesiz aydınlatma, keskinlik eksikliği, yetersiz kenar bilgisi ve histogram asimetrisi gibi çeşitli görsel bozulmaların veri setinde sıkça mevcut olduğunu göstermektedir. Bu sonuçlar doğrultusunda, veri setindeki istatistiksel olarak belirlenen görsel bozulmaları düzeltmek amacıyla çeşitli ön işleme yöntemleri düzenli bir şekilde seçilmiştir. Her yöntem, bu yaygın görsel sorunlar üzerinde doğrudan olumlu etkiler yaratacak şekilde tasarlanmıştır. Böylece, dış radyografilerinde segmentasyon başarısını artırmak için sağlam ve tutarlı bir ön işleme stratejisi oluşturulmuştur.

Aynı şekilde, keskinlik histogramındaki sola kayma, görüntülerin önemli bir kısmının bulanık olabileceğini önermektedir. Bu tür bulanıklıklar, kenar belirleme gibi görsel analizlerin doğru bir şekilde gerçekleştirilmesine engel olabilir. Kenar yoğunluğu değerlerinin çoğunlukla 0,01'in altında olması, görüntülerin yapısal olarak basit olduğunu ve zayıf kenar bilgisi taşıdığını göstermektedir. Bu durum, özellikle segmentasyon gibi kenar odaklı yöntemlerde modelin performansını doğrudan olumsuz yönde etkileyebilecek bir sorun olarak değerlendirilebilir.

Son olarak, histogram eğriliği değerlerinin asimetric bir dağılım sergilemesi, veri setinde parlaklık dengesizliği olan görüntülerin bulunduğunu göstermektedir. Bu da

görüntülerin ışık dağılımında homojenlikten yoksun olduğunu ortaya koymakta ve ön işleme aşamasında parlaklık dengeleme tekniklerinin önemini vurgulamaktadır.

6.3 Ön İşleme Yöntemleri

Belirlenen 14 ön işleme tekniği dört ana gruba ayrılır: kontrast arttırma, gürültü azaltma, gürültü ekleme ve karma yöntemler bulunmaktadır. Kontrast arttırma grubunda, düşük kontrastlı ve belirsiz yapıların netliğini arttırmayı hedefleyen CS, CLAHE, HE ve GC gibi yöntemler yer alır. Gürültü azaltma teknikleri arasında ise, bulanıklık ve rastgele parazitlerin etkilerini azaltarak segmentasyon güvenilirliğini arttırmayı hedefleyen GB, MF ve De + GB bulunmaktadır. Gürültü ekleme kategorisinde, modelin genelleme yeteneğini geliştirmek için kontrollü bozulmalar eklemek amacıyla Tuz ve Biber Gürültüsü (Salt and Pepper Noise, SPN) ile Gauss Gürültüsü (Gaussian Noise, GN) gibi teknikler kullanılmaktadır. Son olarak, aynı anda birden fazla kalite problemini çözmek için karma yöntemler oluşturulmuştur. Örneğin, CLAHE ile HE birleşimi kontrastı daha etkin bir biçimde artırırken, CLAHE ile MF ve GC kombinasyonu, kontrast arttırma, noktasal gürültü giderme ve parlaklık dengesini bir arada sunarak kapsamlı bir çözüm sağlar. Uygulanmış olan tüm ön işleme yöntemleri kategorize edilerek Tablo 6.2’de gösterilmektedir.

Tablo 6.1 Ön işlem yöntemleri


Kontrast Arttırma	Gürültü Azaltma	Gürültü Ekleme	Karma Yöntemler
CS	GB	SPN	CLAHE + HE
CLAHE	MF	GN	CLAHE + GC
HE	De		CS + GB
GC			CLAHE + MF + CS CLAHE + MF + GC

Bu yapı sayesinde her ön işleme stratejisi, veri setindeki istatistiksel olarak tanımlanmış bir ya da daha fazla görsel bozulmayı hedef alarak, dış radyografilerindeki segmentasyon başarısını artırmak için düzenli ve sistematik bir çerçeve oluşturur. Analizler sonucunda elde ettiğimiz verilere ve değerlendirmelere dayanarak görüntü kalitesini iyileştirmek, segmentasyon verimliliğini artırmak ve radyografik detayların

daha görünür olmasını sağlamak için belirlenmiş ve her bir yöntemin teknik açıklaması ve uygulama amacı detaylı bir şekilde verilmiştir.

6.3.1 Tuz biber gürültüsü


Tuz ve karabiber gürültüsü, tuz ve karabiberin siyah ve beyaz olması benzetmesinden adını alan bir gürültü oluşturma yöntemidir. Görüntü üzerinde rastgele dağılmış siyah ve beyaz pikselleri ifade eder. Bu tür filtreler, yüksek yoğunluklu gürültü durumlarında özellikle etkili olabilir. Ancak, çeşitli gürültü yoğunluklarında performans göstermede genellikle zorlanırlar ve bazı önemli kenarları ve ayrıntıları bulanıklaştırabilirler (H. Ma & Nie, 2018). Bu çalışmada ise tuz-biber gürültüsü, Şekil 6.5'teki örnekte gösterildiği gibi, segmentasyon modelinin gürültüye karşı dayanıklılığını test etmek amacıyla uygulanmıştır. Gerçek dünya klinik verilerinde karşılaşılabilecek sensör kaynaklı bozulmaların simülasyonu hedeflenmiştir. Böylece, modelin düşük kaliteli ve bozulmuş görüntüler karşısındaki performansı değerlendirilmiş, aynı zamanda gürültü önleyici ön işleme tekniklerinin gerekliliği sorgulanmıştır.



Şekil 6.6 (a) Orijinal Görüntü, (b) Tuz ve Biber Gürültüsü Eklenmiş Görüntü

6.3.2 Histogram eşitleme

Histogram eşitleme, görüntüdeki renk ve yoğunluk değerlerinin homojen bir şekilde dağılmadığı durumlarda kontrastı iyileştirmek için kullanılan geleneksel bir görüntü iyileştirme yöntemidir. Bu yöntemin temel amacı, görüntü histogramındaki her parlaklık seviyesinde yaklaşık olarak eşit sayıda piksel bulunmasını sağlamaktır. Böylece parlaklık seviyeleri, tüm yoğunluk aralığına yayılır ve görüntünün genel kontrastını artırır. Şekil 6.6'da da gösterilen bu yöntem, özellikle düşük dinamik aralığa sahip olan, yani çok karanlık veya çok aydınlık bölgeler içeren görüntülerde detayların görünürlüğünü artırmak için etkilidir (Robert Krutsch & David Tenorio, 2011).




Şekil 6.7 (a) Orijinal Görüntü, (b) Histogram Eşitleme Uygulanmış Görüntü

Medikal görüntülerde, tanısal öneme sahip yapısal ayrıntıların daha belirgin hale gelmesine katkı sağladığı için sıklıkla tercih edilmektedir. Ancak histogram eşitlemenin global bir yaklaşım olması, bazı durumlarda yerel detayların kaybına neden olabileceğinden dikkatli bir şekilde uygulanması gerekmektedir.

6.3.3 CLAHE

CLAHE, düşük kontrastlı görüntülerin kontrastını artırmak amacıyla geliştirilmiş etkili bir görüntü iyileştirme yöntemidir. Klasik histogram eşitleme yöntemine dayansa da CLAHE'nin en önemli farkı, aşırı kontrast artışını sınırlayarak daha dengeli bir iyileştirme sağlamasıdır. Medikal görüntü işleme alanında kullanılan bu yöntem, ilk olarak 1980'li yıllarda lokal kontrast iyileştirmesi amacıyla tanımlanmış ve zamanla çeşitli varyasyonlarla geliştirilmiştir (Pizer vd., 1987). Şekil 6.7'de de gösterilen bu yöntem, görüntüyü küçük bölgeler (karo) halinde ayırarak her bir bölgeye ayrı histogram eşitleme uygular. Ayrıca, bölge geçişlerinde meydana gelebilecek keskin değişiklikleri yumuşatmak için enterpolasyon işlemi gerçekleştirir. Bu açıdan, özellikle düşük aydınlatma koşullarına sahip veya aydınlatma dağılımı homojen olmayan görüntülerde oldukça başarılı sonuçlar elde etmektedir.


CLAHE algoritması, her bir pikselin parlaklık değerini çevresindeki piksellerin histogram bilgisine göre normalleştirir. Bu şekilde, histogramın belirlenen eşik değerini aşması engellenir ve lokal bölgelerde aşırı parlaklık artışının önüne geçilmiş olur. Medikal görüntüleme alanında, yapısal detayların korunması ve gürültüye karşı dayanıklılığın artırılması açısından sıklıkla tercih edilen bir yöntemdir (Mishra, 2021; Reza vd., 2004).



Şekil 6.8 (a) Orijinal Görüntü, (b) CLAHE Uygulanmış Görüntü

6.3.4 Kontrast germe

Kontrast germe, düşük kontrast gösteren görüntülerin gri seviye aralığını genişleterek önemli yapıların daha görünür olmasını sağlayan temel bir ön işleme tekniğidir. Bu yöntem, özellikle radyografik görüntülerde sık rastlanan dar dinamik aralık problemine çözüm üretme konusunda etkilidir. Şekil 6.8’de gösterilen bu yöntem, görüntüdeki en düşük ve en yüksek yoğunluk değerlerini belirli eşitliklere yeniden ölçeklendirerek aradaki gri seviyelerini daha geniş bir aralığa yayar; böylece kenar ve doku geçişleri daha belirgin hale gelir (Gonzalez & Woods, 2018).




Şekil 6.9 (a) Orijinal Görüntü, (b) Kontrast Germe Uygulanmış Görüntü

Tıbbi görüntülerde kontrast germe uygulamasının lezyon alanlarının çevre dokudan daha iyi ayrışmasını sağlayarak segmentasyon performansını artırdığını ortaya koymuştur. Ancak, kontrast germe sürecinin histogram dağılımı oldukça dengesiz olan görüntülerde aşırı doygunluk veya parlaklık değişikliklerine sebep olabileceği, bu nedenle parametrik eşiklerin dikkatli bir şekilde belirlenmesi gerektiği de belirtilmektedir.

6.3.5 Gauss bulanıklığı

Gauss bulanıklığı, görüntüdeki keskin kenarları yumuşatmak ve yüksek frekanslı gürültüyü azaltmak için kullanılan klasik bir filtreleme yöntemidir. Bu yöntemde her pikselin parlaklık değeri, çevresindeki komşu piksellerin uzaklıklarına dayalı olarak hesaplanan ağırlıklarla yeniden belirlenir. Ağırlıklar, Gauss dağılımına göre hesaplandığından, merkeze yakın pikseller daha fazla katkı sağlarken, uzaktaki piksellerin etkisi azalır. Bu yapı sayesinde görüntü daha yumuşak ve homojen bir görünüm kazanır. Şekil 6.9'da örnek bir görsel listelenmektedir.




Şekil 6.10 (a) Orijinal Görüntü, (b) Gauss Bulanıklığı Uygulanmış Görüntü

Özellikle medikal görüntüler gibi detayların önemli olduğu alanlarda, aşırı keskinlikten kaynaklanan bozulmaların giderilmesi ve segmentasyon öncesinde detay seviyesinin dengelenmesi amacıyla sıklıkla tercih edilmektedir. Gauss bulanıklığı, tuz-biber veya rastgele gürültü gibi istenmeyen parazitlerin etkisini azaltmak için etkili bir ön işleme tekniğidir (Szeliski, 2010; Gonzalez & Woods, 2018.).

6.3.6 Gauss gürültüsü


Gauss gürültü, görüntüdeki her pikselin parlaklık değerine sıfır ortalamalı ve belirli varyansa sahip normal dağılım kullanılarak rastgele bir varyasyon eklenmesiyle modellenen bir istatistiksel gürültü türüdür. Özellikle düşük kontrastlı ve homojen bölgelerde daha belirgin hale gelir ve görüntüdeki detayların algılanmasını zorlaştırarak genel kaliteyi düşürebilir. Genellikle sensör kaynaklı bozulmaların veya iletim sırasında oluşan parazitlerin simülasyonu amacıyla kullanılır (Gonzalez & Woods, 2018). Şekil 6.10'da ön işleme uygulanmış örnek görüntü gösterilmektedir.



Şekil 6.11 (a) Orijinal Görüntü, (b) Gauss Gürültüsü Uygulanmış Görüntü

6.3.7 Gürültü giderme + Gauss bulanıklığı

Gürültü giderme, dijital görüntülerdeki rastlantısal bozulmaları azaltarak genel görüntü kalitesini iyileştirmeyi amaçlayan temel bir ön işleme tekniğidir. Bu süreçte, özellikle Gauss gürültüsü gibi istatistiksel temelli parazitler ile impulsif gürültülerin etkisini en aza indirmek için çeşitli algoritmalar kullanılmaktadır. Gauss tabanlı gürültü giderme yöntemleri, düşük frekans bileşenlerini koruyarak görüntünün daha net ve homojen görünmesini sağlamaktadır (Buades vd., 2005). Şekil 6.11’de de görülen, gürültü giderme işleminden sonra uygulanan Gauss bulanıklaştırma ise, görüntüde kalan yüksek frekanslı pürüzleri yumuşatarak ince detaylardaki keskinliği azaltır ve genel yapıyı daha düzgün hale getirir.



Şekil 6.12 (a) Orijinal Görüntü, (b) Gürültü Giderme + Gauss Bulanıklığı Uygulanmış Görüntü

Bu iki tekniğin birlikte kullanımı, segmentasyon gibi hassas görevler öncesinde görüntünün daha dengeli ve tutarlı bir forma ulaşmasına olanak tanır. Böylece, gürültü temizliği görüntüdeki istenmeyen bilgi kırıntılarını ortadan kaldırırken, Gauss bulanıklaştırma da kalan düzensizlikleri düzleştirerek görüntünün daha estetik ve analiz edilebilir bir yapıya kavuşmasını sağlasa da görüntü kalitesindeki netlik oldukça düştüğü gözlemlenebilmektedir.

6.3.8 CLAHE + HE

CLAHE işleminden sonra kullanılan HE yöntemi, histogramı genişleterek genel kontrastı iyileştirebilmektedir. Bu yöntem, görüntünün tamamındaki piksel yoğunluk dağılımını yumuşatır, görüntünün dinamik aralığını artırır ve eşit bir parlaklık dağılımı sağlar. Bu setin amacı, görüntüdeki yerel ve genel çeşitliliği artırarak segmentasyon için en iyi görüntü kalitesini elde etmektir. CLAHE, görüntüdeki küçük ayrıntılar ve ince yapıların kontrastını iyileştirirken, histogram yumuşatma genel kontrastı artırır ve daha geniş bir parlaklık aralığı sağlar. Bu iki teknik birlikte kullanılması Şekil 6.12’de gösterilmiştir ve kullanıldığında, diş röntgenlerinde küçük ve büyük ölçekli ayrıntılar daha net bir şekilde ortaya çıkar. Bu, segmentasyon modelinin daha doğru sonuçlar üretmesini sağlar, çünkü model özellikleri daha iyi ve daha geniş bir şekilde izole edebilir.



Şekil 6.13 (a) Orijinal Görüntü, (b) CLAHE + HE Uygulanmış Görüntü

6.3.9 CLAHE + GC

CLAHE tekniği, düşük kontrastlı tıbbi görsellerde ayrıntıların daha belirgin olmasına yardımcı olurken bazen görüntünün parlaklık dengesini olumsuz etkileyerek aşırı kontrast artışına yol açabiliyor. Bu durum, özellikle koyu ve açık alanlar arasındaki ton farklılıklarının belirginleşmesiyle birlikte bazı yapısal ayrıntıların kaybolmasına yahut göz yoran bölgelerin ortaya çıkmasına neden olabilir. Bu tür problemleri engellemek için, genellikle CLAHE uygulamasından sonra GC işlemi tercih edilmektedir. GC insan gözünün parlaklık algısı üzerinden hareketle görüntüdeki parlaklık dağılımını yönetir. Parlaklık seviyeleri logaritmik bir biçimde ayarlanarak orta tonların ön plana çıkması sağlanmakta, bu sayede hem karanlık hem de aydınlık alanlardaki detayların daha belirgin hale gelmesi sağlanmaktadır. Bu yöntem, özellikle sınırlı kontrast aralığına sahip ve ışık dağılımı dengesiz olan diş radyografilerinin detay algısını geliştirmek açısından oldukça etkilidir. Çeşitli araştırmalarda da ifade edildiği üzere, CLAHE ile gerçekleştirilen çift yönlü GC, görüntülerin yapısal detaylarını


güçlendirirken parlaklık seviyesini dengeleyerek segmentasyon doğruluğunu önemli ölçüde artırmaktadır (Chang vd., 2018). Bu nedenle, Şekil 6.13'te de gösterilen CLAHE ve GC birleşimi, yalnızca kontrastı artırmakla kalmaz, aynı zamanda görüntünün genel parlaklık profilini de düzenleyerek daha dengeli, detay açısından zengin ve kullanışlı görüntüler elde edilmesine fırsat tanır. Bu tür ön işleme adımları, derin öğrenme tabanlı segmentasyon modellerinin başarısını artırmada oldukça kritik bir öneme sahiptir.



Şekil 6.14 (a) Orijinal Görüntü, (b) CLAHE + GC Uygulanmış Görüntü

6.3.10 CLAHE + MF

CLAHE, düşük kontrastta olan tıbbi görüntülerde detayları daha belirgin hale getirmek için yaygın olarak tercih edilen bir kontrast artırma tekniğidir. Fakat bu işlem, mevcut görüntünün daha belirgin hale gelmesine ya da yeni parazitlerin ortaya çıkmasına yol açabilir. Bu durumu engellemek için CLAHE uygulamasından sonra medyan filtre kullanmak, görüntü kalitesini artırmak için oldukça etkili bir yöntemdir. MF, genellikle 'tuz ve karabiber' olarak bilinen impulsif gürültüleri gidermede başarılı olurken, görüntüdeki yapısal ayrıntıları da koruma imkânı sunar. Örnek Şekil 6.14'te gösterilmektedir.




Şekil 6.15 (a) Orijinal Görüntü, (b) CLAHE + MF Uygulanmış Görüntü

MF, doğrusal olmayan bir filtreleme tekniği olup, her bir pikselin çevresindeki komşularının yoğunluklarına bakarak merkez değerini yeniden hesaplar. Bu süreç, keskin geçişleri bozmadan gürültüyü bastırarak görüntünün hem temiz hem de detay açısından zengin kalmasına olanak tanır. CLAHE ve MF'nin bir arada kullanımı, kontrastın artırılması ve gürültünün azaltılması gibi iki işlemi aynı anda gerçekleştirerek, özellikle segmentasyon gibi sonraki aşamalarda modelin performansını olumlu yönde etkileyen dengeli bir ön işleme yöntemi sağlar. Bu kombinasyonun tıbbi görüntülerde etkili bir şekilde kullanıldığı birçok çalışmada da yer almaktadır (Yakut vd., 2022).

6.3.11 CLAHE + GB

CLAHE, görüntüdeki yerel kontrastı artırarak özellikle az yoğunluk farklarına sahip yapıları belirginleştirir. Bu işlem, diş radyografilerinde diş yapılarının sınırlarının ve iç detaylarının ön plana çıkmasına yardımcı olur. Ancak CLAHE'nin uygulanması, yapay kontrast artışıyla mevcut gürültünün daha belirgin hale gelmesine veya yeni parazitlerin ortaya çıkmasına yol açabilir. Şekil 6.15'te de gösterilen bu durumda, kontrast iyileştirme işlemine takiben bir bulanıklaştırma tekniği kullanarak gürültüyü azaltmak faydalı olabilir.




Şekil 6.16 (a) Orijinal Görüntü, (b) CLAHE + GB Uygulanmış Görüntü

GB, yüksek frekanslı unsurları (örneğin aniden değişen parlaklıklar ve ince parazitler) yumuşatıp görüntünün genel kalitesini artırır. Bu yöntem, her bir pikselin çevresindeki piksellerle uygun ağırlıklar alarak pürüzsüz ve keskin olmayan geçişlerle iyi bir görüntü elde edilmesini sağlar. CLAHE ve GB kombinasyonu, detayları ön plana çıkarırken parazitleri de bastırarak daha istikrarlı ve işlenebilir görüntülerin ortaya çıkmasını sağlar. Bu şekilde, segmentasyon modelleri için hem kontrast hem de gürültü açısından optimize edilmiş giriş verileri sunmuş olur. Dental radyografiler gibi düşük kontrast ve yüksek parazit içerebilen görüntü türlerinde, bu kombinasyonun başarılı sonuçlar ortaya koyduğu gözlemlenir.

6.3.12 CS + GB

CS, görüntüdeki piksel yoğunluklarını belirli bir aralıkta ölçeklendirerek genel kontrastın artırılmasına yönelik bir lineer dönüşüm tekniğidir. Bu işlem, özellikle dar bir aralıkta yoğunlaşan gri seviye dağılımına sahip olan dental radyografi gibi tıbbi görüntülerde, yapısal detayların daha belirgin hale gelmesine yardımcı olur. Kontrastın artırılması, görüntünün daha iyi yorumlanmasını sağlasa da bazen düşük seviyeli rastgele gürültüleri de daha görünür hale getirebilir. Ön işleme uygulanmış örnek görüntü Şekil 6.16'da gösterilmektedir.



Şekil 6.17 (a) Orijinal Görüntü, (b) CS + GB Uygulanmış Görüntü


Bu sebeple, CS sonrasında GB uygulanması, yüksek frekanslı gürültülerin azaltılmasında oldukça yararlıdır. GB yöntemi, her pikselin değerini komşu piksellerle birlikte ağırlıklı bir şekilde hesaplayarak ani parlaklık değişimlerini yumuşatır ve görüntüdeki gürültüyü daha homojen bir hale getirir. Böylelikle hem detayların öne çıktığı hem de gürültülerin azaltıldığı etkili bir ön işleme süreci elde edilir. CS ve GB tekniklerinin bir arada kullanılması, dental radyografilerde hem kontrast hem de gürültü iyileştirmesi yaparak segmentasyon algoritmaları için daha istikrarlı ve güvenilir veri sağlar.

6.3.13 CLAHE + MF + GC

Bu üçlü kombinasyon, hem kontrastın iyileştirilmesi hem de gürültü ile parlaklığın dengesini aynı anda hedefleyen kapsamlı bir ön işleme yöntemi sunar. CLAHE, lokal kontrastı yükselterek, dental radyografilerde düşük yoğunluk farklılıklarına sahip anatomik yapıların daha belirgin hale gelmesini sağlar. Ancak, kontrast artırımı, özellikle düşük ışıkta kalan bölgelerde mevcut gürültünün daha belirgin olmasına neden olabilir. Bu durumdan dolayı, CLAHE uygulandıktan sonra impulsif gürültüyü etkili bir şekilde azaltan doğrusal olmayan bir

medyan filtresi kullanılmaktadır. MF, köşe bilgilerini koruyarak yapısal detayların bozulmasını önler ve görüntüdeki gürültü seviyesini segmentasyon öncesinde düşürür.

Şekil 6.17’de gösterilen bu işlem zincirinin final aşaması olan GC, görüntünün genel parlaklık dağılımını dengeleyerek hem karanlık hem de aydınlık alanlardaki detayların daha uyumlu gözükmesini sağlar. Özellikle dental görüntülerde karşılaşılan düşük dinamik aralıklı alanlarda gamma düzeltme, detay algısını artırarak görsel kalitenin iyileştirilmesine katkıda bulunmaktadır. Üç yöntemin ardışık olarak uygulanması sonucunda hem kontrast hem de parlaklık açısından dengelenmiş ve gürültü açısından sadeleştirilmiş yüksek kaliteli veri elde edilerek segmentasyon başarısı artırılabilir.



Şekil 6.18 (a) Orijinal Görüntü, (b) CLAHE + MF + GC Uygulanmış Görüntü

6.3.14 CLAHE + MF + CS

Bu kombinasyon, diş radyografilerinde kontrast eksiklikleri ve gürültü sorunlarını aynı anda ele almaya yönelik bir ön işleme dizisidir. CLAHE, yerel kontrastı artırarak düşük kontrastlı alanlardaki detayları vurgular. Bu işlem sırasında görüntüdeki ince yapılar netleşirken, olası impulsif gürültülerin bastırılması için medyan filtre kullanılır. MF, tuz ve karabiber türündeki parazitleri etkili bir şekilde ortadan kaldırırken, görüntünün keskinliğini ve yapısal bütünlüğünü korumaktadır.

Son adım olarak uygulanan CS işlemi, görüntüdeki yoğunluk dağılımını genişleterek genel kontrastı artırır. Bu aşama, CLAHE ile elde edilen yerel düzeydeki kontrast iyileştirmesini tüm görüntü için tamamlarken daha canlı ve detaylı bir görüntü sunar. Üçlü kombinasyonun birlikte kullanılması, diş radyografilerinde hem yerel hem de genel kontrastın artırılmasıyla gürültü miktarını azaltarak, görsel analiz ve otomatik segmentasyon süreçlerinde daha kararlı sonuçlar elde edilmesine yardımcı olmaktadır. Örnek görsel Şekil 6.18’de görülmektedir.



Şekil 6.19 (a) Orijinal Görüntü, **(b)** CLAHE + MF + CS Uygulanmış Görüntü

6.4 Görüntü Kalitesi Değerlendirme Metrikleri

Görüntülere uygulanan ön işleme yöntemlerinin sonuç kalitesini nesnel bir biçimde değerlendirmek için bu bölümde açıklanan ölçütler kullanılmaktadır. Bu ölçütler, görüntülerin yapısal, istatistiksel ve algısal özelliklerini inceleyerek yapılan işlemlerin görüntü üzerindeki etkilerini sayısal bir şekilde gösterir. Özellikle tıbbi görüntülerde, detayların korunması ve gürültünün azaltılması gibi unsurlar, ön işleme tekniklerinin başarısını belirlemede önemli bir rol oynamaktadır.

6.4.1 Ortalama mutlak hata

Ortalama mutlak hata (Mean Absolute Error, MAE), model tarafından tahmin edilen değerler ile gerçek değerler arasındaki mutlak ortalama farkı ölçen bir değerlendirme kriteridir. Bu istatistik, tahmin edilen değerlerin gerçek değerlerden ne kadar saptığını gösterir. Özellikle regresyon analizinde kullanılır. Denklem 6.7’de gösterilen MAE, tahmin hatalarının değerlerini zaten tahmin ettiğinden, yorumlanması çok kolaydır ve büyük hatalara karşı daha az duyarlıdır (Chai & Draxler, 2014).

$$MAE = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N |y_{ij} - \hat{y}_{ij}| \quad (6.7)$$

Burada M ve N görüntüdeki piksel boyutunu, y_{ij} gerçek görüntüdeki i, j pikselini, \hat{y}_{ij} ise tahmin edilen görüntüdeki i, j pikselini temsil etmektedir.

6.4.2 Ortalama hatalar karesi

Ortalama hatalar karesi (Mean Squared Error, MSE), bir model tarafından tahmin edilen değerler ile gerçek değerler arasındaki ortalama karesel farkı ölçen bir değerlendirme

metriğidir. MSE, her hata değerini kareler ve bu hataların ortalamasını alır, böylece daha büyük hatalara daha fazla ağırlık verir. Bu özellik, Denklem 6.8'de belirtilen MSE'yi regresyon problemlerinde yaygın olarak kullanılan bir metrik haline getirir.

$$MSE = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (y_{ij} - \hat{y}_{ij})^2 \quad (6.8)$$

MSE değeri küçüldükçe tahmin edilen görüntü ile gerçek görüntü arasındaki fark azalır ve dolayısıyla modelin başarımı artmaktadır.

6.4.3 Yapısal benzerlik indeksi

Yapısal benzerlik indeksi (Structural Similarity Index, SSIM), iki görüntü arasındaki benzerliği ölçen bir değerlendirme metriğidir. Geleneksel hata ölçümlerinden (MSE gibi) farklı olarak, SSIM görüntü kalitesini değerlendirir ve insan görme algısına yakındır. Denklem 6.9'da gösterilen SSIM üç ana alanda çalışır: parlaklık, kontrast ve doku. Bu parametrelere dayalı karşılaştırmalar, iki görüntü arasındaki yapısal benzerliği ortaya çıkarır.

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (6.9)$$

Bu formülde μ_x ve μ_y sırasıyla x ve y görüntülerinin ortalama parlaklık değerini, σ_x ve σ_y görüntülerin kontrastını temsil eden standart sapma değerini, σ_{xy} iki görüntü arasındaki kovaryansı, C_1 ve C_2 kararlılığı sağlamak amacıyla eklenen küçük sabitleri göstermektedir SSIM üç bileşeni (parlaklık, kontrast ve yapı) birleştirerek, insan görme algısına yakın bir benzerlik ölçüsü sağlar (Bakurov vd., 2022). SSIM değeri 1'e yaklaştıkça iki görüntü arasındaki yapısal benzerlik artar, dolayısıyla tahmin edilen görüntü gerçek görüntüye daha yakın hale gelir.

6.4.4 Tepe sinyal-gürültü oranı

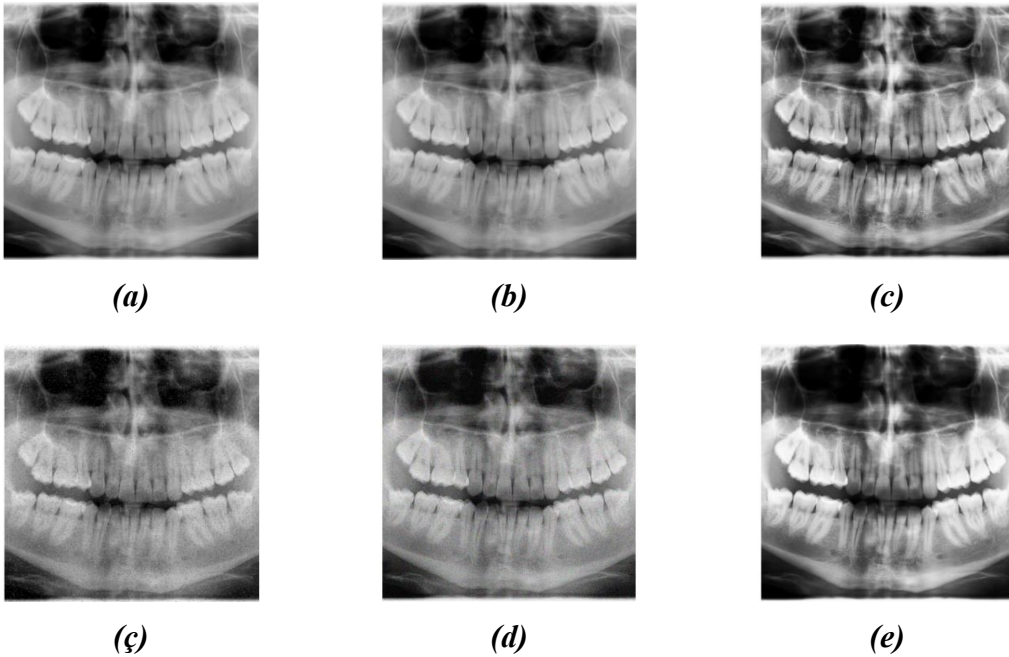
Tepe Sinyal-Gürültü Oranı (Peak Signal Noise Ratio, PSNR), iki görüntü arasındaki kalite farkını değerlendiren bir ölçüdür ve esas olarak sıkıştırılmış görüntülerin kalitesini değerlendirmek için kullanılır. Denklem 6.10'da verilen PSNR formülü, logaritmik ölçekte sinyal gücü ile görüntü gürültüsü arasındaki oranın bir ölçüsüdür. Daha yüksek bir PSNR değeri, görüntünün orijinal görüntüye daha yakın olduğunu gösterir. PSNR değeri genellikle desibel (dB) cinsinden ifade edilir ve değer ne kadar yüksekse, görüntü o kadar iyidir (Horé & Ziou, 2010).

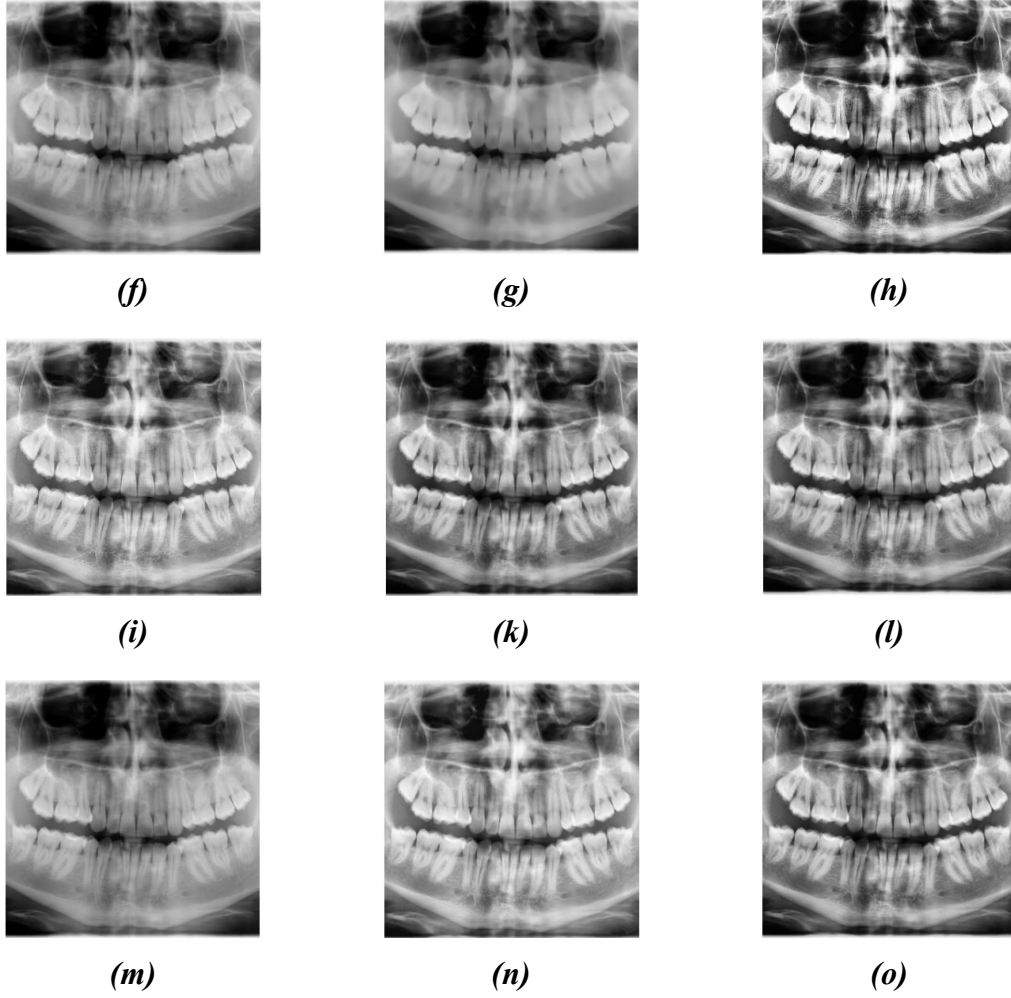
$$PSNR(f, g) = 10 \cdot \log\left(\frac{255^2}{MSE(f, g)}\right) \quad (6.10)$$

255, görüntüdeki maksimum piksel değerini, $MSE(f, g)$ ise iki görüntü arasındaki ortalama kare hatayı temsil etmektedir. Bu değer, iki görüntünün son derece benzer olduğunu gösterir. Genel olarak, 30 dB'nin üzerindeki PSNR değerleri iyi kaliteyi gösterir ve bu ölçüt özellikle gürültü azaltma gibi bozulma türlerini değerlendirmek için uygundur (Horé & Ziou, 2010).

6.5 Performans Analizi

Ön işleme tekniklerinin diş röntgenleri üzerindeki etkileri hem değerlendirme ölçekleri hem de görsel inceleme ile ayrıntılı bir biçimde incelenmiştir. Bu incelemelerin bulguları, her bir yöntem için MAE, MSE, PSNR ve SSIM değerlerinin karşılaştırmasını kapsamaktadır. Şekil 6.19'da, diş röntgen görüntülerine uygulanan çeşitli ön işleme yöntemlerinin örnek sonuçlarını tümü yansıtılmaktadır. Bazı yöntemler, dişlerin kenarlarını ve anatomik detaylarını belirginleştirerek kontrastı önemli ölçüde artırırken, fazla kontrast artışı bazı bölgelerde artefaktların oluşmasına ve doğal doku yapısının bozulmasına yol açmıştır. Örneğin, CS işlemi yapısal özellikleri ön plana çıkarmada etkili olurken, GB ise daha dengeli ve pürüzsüz bir görünüm sağlayarak gürültünün azaltılmasına yardımcı olmuştur. Nicel ölçütler ile görsel bulguların birlikte değerlendirilmesi, yöntemlerin güçlü ve zayıf yönlerini daha açık biçimde ortaya koymuştur.





Şekil 6.20 Ön İşleme Yöntemleri Uygulanmış Görüntüler (a) Orijinal Görüntü, (b) CS , (c) CLAHE, (ç) SPN, (d) GN, (e) HE, (f) GB, (g) De + GB, (h) CLAHE + HE , (i) CLAHE + GC , (k) CLAHE + MF, (l) CLAHE + GB, (m) CS + GB, (n) CLAHE + MF + GC, (o) CLAHE + MF + CS

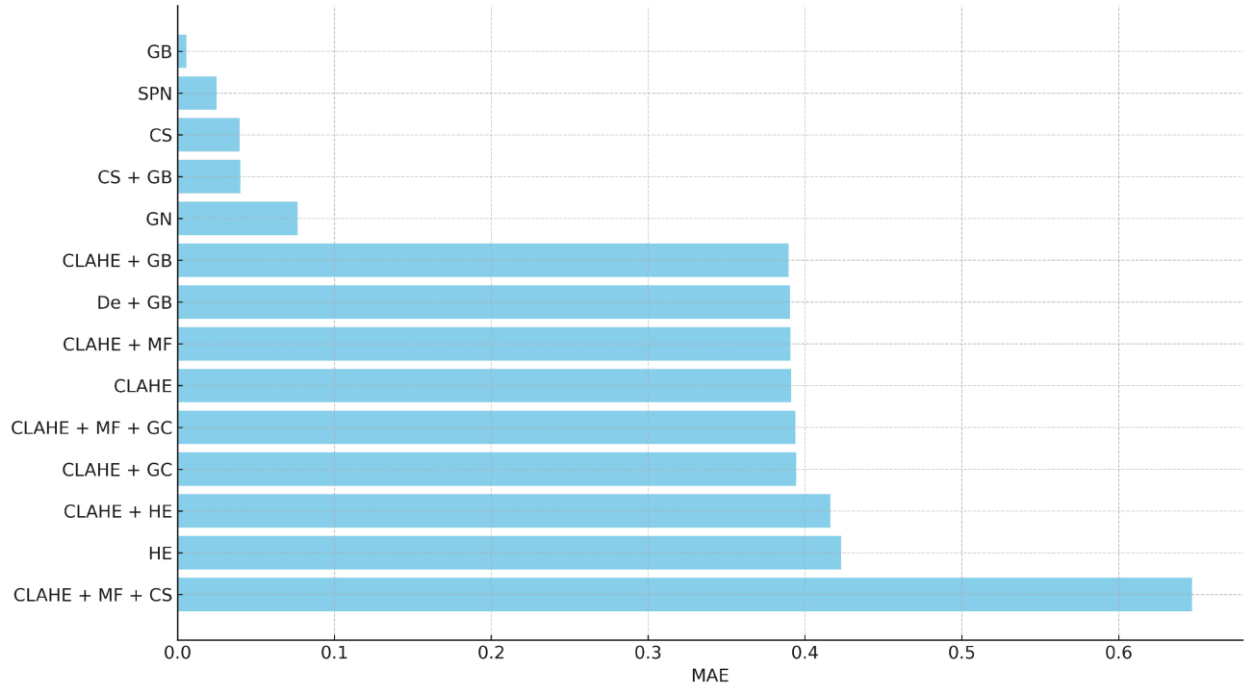
Görsellerini analiz ettiğimiz her bir ön işleme tekniği için hesaplanan MAE, MSE, SSIM ve PSNR değerleri, Tablo 6.20’te sunulmaktadır. Bu metriklerden elde edilen sayısal veriler, yapılan nitel gözlemleri desteklemekle birlikte, her bir yöntemin görüntü kalitesi üzerindeki etkisini nesnel olarak değerlendirmemize olanak tanımaktadır. Özellikle MAE ve MSE gibi hata tabanlı metrikler, işlenen görüntülerdeki piksel düzeyindeki farkları ortaya koyarken; SSIM ve PSNR metrikleri ise yapısal benzerlik ve sinyal-gürültü oranı üzerinden kaliteyi ölçmektedir. Böylece, farklı ön işleme tekniklerinin hem hata oranı hem de yapısal bütünlük açısından nasıl bir performans sergilediği çok boyutlu olarak analiz edilebilmiştir. Bu değerlendirmeler, yöntemlerin yalnızca görsel anlamda değil, istatistiksel doğruluk açısından

da karşılaştırılmasına imkân tanımaktadır. Elde edilen bu değerler, sonraki bölümde ayrıntılı olarak tartışılmış ve her bir ön işleme yönteminin segmentasyon başarısına olan etkisi kapsamlı biçimde analiz edilmiştir.


Tablo 6.2 Ön işleme yöntemlerinin değerlendirilmesinin sayısal sonuçları

	MAE	MSE	PSNR	SSIM
CS	0,0395	0,0031	28,9664	0,9739
CLAHE	0,3913	0,2236	6,5914	-0,1035
SPN	0,0250	0,0155	18,0951	0,2692
GN	0,0765	0,0093	20,2989	0,1950
HE	0,4232	0,2544	5,9652	-0,0652
GB	0,0056	0,0001	40,828	0,9736
De + GB	0,3905	0,2240	6,6469	0,2030
CLAHE + HE	0,4162	0,2474	6,0891	-0,118
CLAHE + GC	0,3944	0,2371	6,4618	-0,0478
CLAHE + MF	0,3908	0,2231	6,6021	-0,0571
CLAHE + GB	0,3895	0,2207	6,6492	-0,0423
CS + GB	0,0401	0,0031	28,1604	0,9553
CLAHE + MF + GC	0,3938	0,2368	6,4685	-0,0165
CLAHE + MF + CS	0,6468	0,2573	6,0000	-0,0707

Tablo 6.3'teki bu metriklerin genel performans karşılaştırmaları, Şekil 6.20-6.23'teki çubuk grafiklerle detaylı bir şekilde sunulmaktadır. Grafiklerde de diğer analizler gibi, MAE, MSE ve PSNR metriklerinde en etkili sonuçların GB ile alındığı, SSIM metriğinde ise en yüksek değerlerin CS'ye ait olduğu görülmektedir. Bu durum, görsel ve sayısal analizlerin birleşiminin, diş radyografisi segmentasyon süreçlerinde ön işleme yöntemlerinin potansiyel katkısını kapsamlı bir biçimde ortaya koyduğunu göstermektedir.




Şekil 6.21 MAE'ye Dayalı Ön İşleme Yöntemlerinin Karşılaştırılması




Şekil 6.22 MSE'ye Dayalı Yöntemlerin Karşılaştırılması

MAE ve MSE açısından incelendiğinde, GB tekniği en düşük hata rakamlarına ulaşarak bu kriterler için en etkili yöntem olarak öne çıkmaktadır. Düşük MAE ve MSE değerleri, işlenen

görüntünün orijinal görüntüye olan piksel seviyesindeki yakınlığının ve hata miktarının en aza indirilmiş olduğunu göstermektedir. GB'nin bu başarıyı yakalamasının ana nedeni, yöntemin doğal olarak gürültü azaltma ve pürüzsüzleştirme özelliklerine sahip olmasıdır. Gürültü, özellikle diş radyografileri gibi düşük kontrastlı ve ince detayların önemli olduğu görüntülerde segmentasyon başarısını olumsuz etkileyecek en büyük faktörlerden biridir. GB, yüksek frekanslı bileşenleri düşürerek görüntüde ani piksel değişimlerini yumuşatmakta ve bu sayede hem MAE hem de MSE değerlerinde bir azalma yaratmaktadır. Bu durum, orijinal görüntü ile işlenmiş görüntü arasındaki piksel farklılıklarının minimuma indirilmiş olduğunu ve sonuç olarak elde edilen görüntünün istatistiksel olarak orijinal görüntüye daha yakın olduğunu göstermektedir. Ayrıca, GB'nin bu etkisi yalnızca hata bazlı ölçümlerle sınırlı kalmayıp, sonraki segmentasyon süreçlerinde modelin gürültüye karşı daha dayanıklı bir şekilde öğrenmesine yardımcı olma potansiyeli taşımaktadır. Gaussian tabanlı filtrelerin tıbbi görüntüleme çalışmalarında gürültü azaltma amacıyla sıklıkla tercih edildiği ve hata temelli metriklerde olumlu sonuç verdiği literatürde belirtilmektedir (Gonzalez & Woods, 2018).



Şekil 6.23 PSNR'ye Dayalı Yöntemlerin Karşılaştırılması



Şekil 6.24 SSIM'ye Dayalı Yöntemlerin Karşılaştırılması

PSNR sonuçları incelendiğinde, en yüksek değer GB yöntemi ile elde edilmiştir. PSNR metriği, işlenmiş görüntülerdeki bozulmaları değerlendiren bir ölçüt olup, değer yükseldikçe görüntünün orijinal haline daha yakın olduğunu göstermektedir. Bu bağlamda, GB'nin yüksek PSNR değeri üretmesi, gürültüyü etkili bir şekilde azaltarak sinyal-gürültü oranını iyileştirdiğini ve görüntü kalitesini koruduğunu ortaya koymaktadır. Ayrıca, hata temelli metriklerde (MAE, MSE) de benzer biçimde en düşük değerlerin GB tarafından sağlanması, bu yöntemin gürültü bastırma konusunda genel olarak güçlü bir performans sergilediğini teyit etmektedir.

Öte yandan, SSIM açısından farklı bir eğilim dikkat çekmektedir. En yüksek SSIM değeri, CS yöntemi ile elde edilmiştir. SSIM, yalnızca piksel tabanlı farkları değil, aynı zamanda kontrast, parlaklık ve yapısal bütünlüğü de dikkate alarak insan görsel sistemine daha yakın bir değerlendirme sunmaktadır. CS'nin yüksek SSIM sonucu elde etmesi, bu yöntemin kontrastı artırarak görüntüdeki yapısal bilgiyi netleştirdiğini, görsel algılanabilirliği iyileştirdiğini ve ayrıntıların korunmasına katkı sağladığını göstermektedir.

Genel bir değerlendirme yapıldığında, GB hata ve bozulma temelli metriklerde (MAE, MSE, PSNR) öne çıkarken, CS, SSIM değerinde daha başarılı olmuştur. Bu sonuç, farklı ön işleme tekniklerinin farklı metriklerde avantajlar sunduğunu ve yöntem seçiminde metrik bazlı bir yaklaşım benimsenmesi gerektiğini ortaya koymaktadır.

Elde edilen veriler, diř radyografisi segmentasyon alıřmalarında n iřleme ařamasının bařarısı zerinde dođrudan etkili olduđunu gstermektedir. zellikle GB ve CS tekniklerinin, modelin đrenme srecine zarar verebilecek grlt ve kontrast dengesizliklerini azaltmada etkili olduđu, aynı zamanda diř yapısına ait kritik detayların korunmasında nemli bir rol stlendiđi grlmřtr. Bu bađlamda, GB ve CS yntemlerinin segmentasyon hatalarını azaltmada ve yapısal bilgiyi muhafaza etmede umut verici adaylar olduđu sonucuna varılabilir.

Literatrde sıklıkla tercih edilen CLAHE yntemi, yerel kontrastı artırma kabiliyeti sayesinde geniř bir uygulama alanına sahiptir. Ancak yalnızca literatrdeki genel eđilimlere dayanarak yntem semek, her veri seti iin en iyi sonuların elde edilmesini garanti etmemektedir. Bu tez kapsamında elde edilen bulgular, veri setinin zel karakteristiklerinin dikkate alınmasının kritik nem tařıdıđını aıka gstermektedir. Nitekim, bu alıřmada kullanılan dental radyografi verileri zerinde GB ve CS yntemleri, CLAHE'ye kıyasla daha yksek performans sergilemiřtir. Dolayısıyla, n iřleme yntemlerinin etkinliđi; kullanılan veri setinin yapısı, grntlerdeki grlt miktarı, kontrast seviyesi ve uygulama bađlamına gre farklılık gsterebilmektedir. Bu nedenle, segmentasyon bařarısını artırmak amacıyla tek tip bir n iřleme stratejisi benimsemek yerine, veri setine zg deđerlendirmeler yapılması gerektiđi anlařılmaktadır. Ayrıca, bu bulgular klinik uygulamalar ve otomatik teřhis sistemleri aısından da byk nem tařımaktadır; zira seilen n iřleme ynteminin bařarısı, dođrudan modelin klinik gvenilirlik ve dođruluđunu etkilemektedir. Sonu olarak, bu tez, n iřleme yntemlerinin seiminde literatrde yaygın olarak kullanılan tekniklere ek olarak veri setine zg ayrıntılı analizlerin yapılmasının gerekliliđini vurgulamaktadır. Byle bir yaklařım, yalnızca segmentasyon dođruluđunu artırmakla kalmayıp, aynı zamanda klinik karar destek sistemlerinin daha gvenilir ve etkili biimde kullanılmasına da katkı sađlamaktadır.

7. SEGMENTASYON ANALİZİ

Segmentasyon aşamasında, modelin oluşturduğu tahminlerin güvenilirliğini ve doğruluğunu belirlemek için sayısal incelemeler yapılmıştır. Bu bölümde, kullanılan ölçüm kriterleri detaylandırılmakta ve elde edilen bulgular performans değerlendirmesi ile bir arada sunulmaktadır.

7.1 Değerlendirme Metrikleri

Segmentasyon sonuçlarının kalitesini değerlendirmek amacıyla kaynaklarda sıkça başvurulan farklı ölçütlerden faydalanılmıştır. Dice katsayısı, IoU ve piksel doğruluğu gibi ölçümleri, modelin genel performansını ve bölgesel hassasiyetini göstermek için tercih edilmiştir.

7.1.1 Dice katsayısı

Dice katsayısı, görüntü segmentasyonu konusunda en sık başvurulan ölçütlerden biridir ve özellikle tıbbi görüntü analizinde oldukça kritik bir rol oynamaktadır. Bu ölçüt, tahmin edilen maske (P) ile gerçekteki maske (G) arasındaki örtüşme oranını değerlendirmektedir. Yani, iki grubun ne kadar benzer olduğunu belirleyen bir karşılaştırma katsayısıdır. Dice değeri 0 ile 1 arasında bir aralıkta yer alır; 1 değeri, tahmin edilen maskenin gerçek maske ile tam uyumlu olduğunu temsil ederken, 0 değeri ise hiçbir örtüşme olmadığını gösterir. Denklem 7.11'de formalize edilmiştir.

$$Dice = \frac{2 |P \cap G|}{|P| + |G|} \quad (7.11)$$

Burada $|P|$ tahmin edilen maske piksellerinin toplamını, $|G|$ ise gerçek maske piksellerinin toplamını ifade etmektedir. $|P \cap G|$ ise bu iki grup arasındaki ortak piksel sayısını göstermektedir. Dice katsayısı, özellikle dengesiz veri setleri ile küçük yapıları içeren görüntülerin (örneğin, dış radyografilerindeki kök kanalları, ufak lezyonlar vb.) değerlendirilmesinde önemli bir ölçüttür. Çünkü genel doğruluk ölçümleri küçük alanları göz ardı edebilecekken, Dice Katsayısı bu bölgelerin varlığını ve doğruluğunu doğrudan değerlendirmektedir.

7.1.2 Kesişim bölü birleşim

Kesişim Bölü Birleşim (Intersection over Union, IoU), Jaccard oranı olarak da adlandırılan bir ölçüdür; bu ölçü, tahmin edilen maske ile gerçek maske arasında

bulunan kesişim alanının, bu iki maskenin birleşim alanına olan oranı olarak tanımlanır. Matematiksel olarak, Denklem 7.12’de ifade edilmektedir:

$$IoU = \frac{|P \cap G|}{|P \cup G|} \quad (7.12)$$

Burada P modeliyle öngörülen piksel grubu, G ise gerçek piksel grubunu ifade etmektedir. Dice katsayısına benzer bir şekilde segmentasyon başarısını değerlendiren bir metrik olan IoU, daha katı bir inceleme sağlar. Bunun en önemli nedeni, yalnızca örtüşen alanları değil, tahmin edilen ve gerçek maskelerin kapsadığı toplam alanı da dikkate almasıdır. (Milletari vd., 2016) Bu yönüyle IoU, yanlış pozitif (False Positive, FP) ve yanlış negatif (False Negative, FN) bölgelerine karşı daha duyarlıdır ve özellikle segmentasyon sınırlarının doğruluğunu değerlendirmekte önemli bir kriterdir.

Tıbbi görüntüleme alanında IoU’nun tercih edilmesinin diğer bir sebebi, düşük örtüşme durumları olduğunda bile modelin ne kadar fazla "yanlış kapsama" gerçekleştirdiğini net bir şekilde göstermesidir. Örneğin, Dice yüksek olabilir ancak IoU değeri düşükse bu, modelin tahmin ettiği alanın gerçek yapıyı gereğinden fazla kapsadığı ya da eksik bıraktığı anlamına gelebilir. Böylelikle, IoU, Dice’a göre daha detaylı bir hata analizi yapma imkânı sunar ve segmentasyon modellerinin hassasiyetini değerlendirirken tamamlayıcı bir metrik işlevi görmektedir.

7.1.3 Piksel doğruluğu

Piksel doğruluğu (Pixel accuracy, PA), tahmin edilen maske ile gerçek maske arasında örtüşen piksel sayısının toplam piksel sayısına oranını belirten önemli bir performans ölçüsüdür. Yani, tüm piksel alanında doğru bir şekilde sınıflandırılan piksellerin yüzdesini hesaplamaktadır. Bu durum, Denklem 7.13’te matematiksel olarak ifade edilmektedir. (Long vd., 2015).

$$PA = \frac{|P \cap G| + |\bar{P} \cap \bar{G}|}{|U|} \quad (7.13)$$

Burada P , modelin öngördüğü maske alanını; G , gerçeği ifade eden maske alanını; \bar{P} , tahmin edilen maske alanının tamamlayıcısını (arka plan); \bar{G} , gerçek maske alanının tamamlayıcısını; U ise toplam piksel sayısını ifade etmektedir.

Piksel Doğruluğu, hesaplaması oldukça kolay ve anlaşılır bir ölçüt olduğundan, segmentasyon problemlerinde sıklıkla tercih edilmektedir. Ancak bu ölçüt, özellikle sınıf dengesizliği barındıran veri setlerinde yanıltıcı sonuçlar verebilmektedir. Örneğin, tıbbi görüntüleme alanı genellikle görüntünün küçük bir bölümü ile sınırlı kalırken arka plan oldukça geniştir. Bu tür bir durumda model yalnızca arka planı doğru tahmin ettiğinde, yüksek bir PA değeri elde edilebilir. Bu sebeple, PA tek başına segmentasyonun başarısını değerlendirmek için yeterli değildir; Dice katsayısı ve IoU gibi örtüşmeye dayalı metriklerle birlikte kullanıldığında daha anlamlı bulgular ortaya koymaktadır.

7.2 Performans Analizi

Diş radyografileri için otomatik segmentasyonun başarısı, sadece model tasarımına değil, aynı zamanda görüntülerin işleme yöntemlerine de büyük ölçüde bağlıdır. Görüntülerin ön işlenmesi, örneğin kontrast artırma veya gürültüyü azaltma gibi tekniklerle, görüntü kalitesini yükselterek derin öğrenme tabanlı sistemlerin etkinliğini önemli ölçüde artırabilir. Bu durum, özellikle farklı segmentasyon analizlerinde hassas görevlerin gerçekleştirilmesinde ihtiyaç duyulmuştur (Soomro vd., 2021). Ayrıca, yenilikçi ön işleme yöntemlerinin, çeşitli görüntülerde U-Net temelli yapılandırmalarla birlikte kullanıldığında segmentasyon performansını kayda değer ölçüde iyileştirdiği gözlemlenmiştir (J. Wang vd., 2021).

Aynı şekilde, segmentasyon başarısını değerlendirmek için kullanılan metriklerin seçimi de son derece önemlidir. Dice ve IoU, segmentasyon alanında sıkça tercih edilen metriklerdir; bu metriklerin değeri, aşırı segmentasyon ve segmentlenmeme durumlarını etkili bir şekilde değerlendirebilme yeteneklerinden kaynaklanmaktadır. Ancak, PA, hastane görüntülerinde sınıf dengesizliği nedeniyle yanıltıcı yüksek değerler verebilir, bu yüzden dikkatli bir şekilde incelenmelidir (Müller vd., t.y.).

Bu bağlamda, farklı ön işleme tekniklerinin ve ağ yapılandırmalarının segmentasyon başarısı üzerindeki etkilerini kapsamlı bir şekilde incelemek hayati bir adım olmuştur. Bu bölümde, önerilen çerçevenin başarısı, çeşitli U-Net varyantları ve omurga tabanlı modeller üzerinde sistematik olarak değerlendirilmiştir. Tezin amacı yalnızca nihai sonuçları sunmak değil; aynı zamanda hangi ön işleme tekniğinin hangi mimariyle en etkili şekilde çalıştığını ortaya koyarak, diş radyografilerinde segmentasyonun optimize edilmesine dair rehberlik sağlayacak bir değerlendirme sunmaktır. Bu doğrultuda, toplamda 14 farklı ön işleme yöntemi, dört farklı U-Net mimarisi (ResNet50, EfficientNetB4, VGG19 ve özelleştirilmiş U-Net) üzerinde test edilmiştir. Modelin başarısı, tıbbi görüntü segmentasyonunda yaygın olarak

kullanılan Dice, IoU ve Piksel doğruluğu gibi metrikler aracılığıyla değerlendirilmiştir. Böylece, hem piksel bazında doğruluk hem de bölgesel örtüşme oranları dikkate alınarak kapsamlı bir analiz gerçekleştirilmiştir. Elde edilen veriler, yalnızca modelin genel başarısını sergilemekle kalmamış, aynı zamanda ön işleme aşamasının segmentasyon sürecine olan katkısını nicel verilerle destekleyerek literatürdeki bir boşluğu doldurmuştur. Elde edilen deneysel sonuçlar, özellikle GB ve CS tekniklerinin segmentasyon başarısını önemli ölçüde artırdığını ortaya koymaktadır. ResNet50 tabanlı U-Net modeli için GB, 0,9215 Dice ile en yüksek başarıyı gösterirken, EfficientNetB4 tabanlı U-Net modelinde CS tekniği 0,9227 Dice ile dikkat çekmiştir. Bu değerler, her iki tekniğin yalnızca belirli bir mimariyle sınırlı kalmayıp, farklı ağ yapılarını da başarılı bir şekilde desteklediğini göstermektedir. Özellikle Tablo 7.4'de yer alan karşılaştırmalı sonuçlar incelendiğinde, GB ve CS yöntemlerinin diğer modellerde de daha yüksek Dice ve IoU puanları elde ederek genel performans açısından öne çıktığı net bir şekilde görülmektedir.

Tablo 7.3 Dört U-Net varyantında 14 farklı ön işleme yönteminin segmentasyon performansı karşılaştırması

ÖN İŞLEME YÖNTEMLERİ	U-NET (ResNet50)			U-NET (EfficientNetB4)			U-NET (VGG19)			U-NET (Özelleştirilmiş)		
	Dice	IoU	PA	Dice	IoU	PA	Dice	IoU	PA	Dice	IoU	PA
CS	0,9202	0,8523	0,8748	0,9227	0,8566	0,8753	0,9218	0,8549	0,8749	0,9212	0,8540	0,8749
CLAHE	0,9196	0,8513	0,8747	0,9207	0,8532	0,8747	0,9209	0,8749	0,8749	0,9202	0,8522	0,8749
SPN	0,9171	0,8470	0,8741	0,9169	0,8466	0,8741	0,9183	0,8490	0,8743	0,9161	0,8453	0,8740
GN	0,9146	0,8427	0,8736	0,9156	0,8444	0,8737	0,9151	0,8436	0,8737	0,9156	0,8444	0,8736
HE	0,9194	0,8509	0,8747	0,9202	0,8523	0,8748	0,9197	0,8515	0,8747	0,9183	0,8491	0,8745
GB	0,9215	0,8544	0,8752	0,9226	0,8563	0,8751	0,9220	0,8554	0,8752	0,9206	0,8530	0,8748
De + GB	0,9143	0,8422	0,8735	0,9153	0,8439	0,8737	0,9149	0,8432	0,8736	0,9139	0,8415	0,8734
CLAHE + HE	0,9190	0,8503	0,8745	0,9192	0,8506	0,8747	0,9177	0,8480	0,8743	0,9188	0,8498	0,8744
CLAHE + GC	0,9191	0,8504	0,8743	0,9208	0,8532	0,8747	0,9194	0,8509	0,8744	0,9184	0,8491	0,8742
CLAHE + MF	0,9194	0,8508	0,8745	0,9210	0,8537	0,8749	0,9203	0,8523	0,8748	0,9203	0,8524	0,8749

CLAHE + GB	0,9206	0,8529	0,8746	0,9214	0,8542	0,8750	0,9216	0,8547	0,8750	0,9197	0,8514	0,8746
CS + GB	0,9210	0,8537	0,8748	0,9223	0,8558	0,8749	0,9215	0,8545	0,8750	0,9218	0,8550	0,8751
CLAHE + MF + GC	0,9192	0,8506	0,8744	0,9202	0,8522	0,8748	0,9195	0,8511	0,8747	0,9184	0,8491	0,8744
CLAHE + MF + CS	0,9203	0,8525	0,8747	0,9212	0,8540	0,8749	0,9202	0,8522	0,8748	0,9205	0,8527	0,8750

Elde edilen sonuçlar, çalışmanın ilk aşamasında gerçekleştirilen görüntü kalitesi analizleri ile doğrudan örtüşmektedir. Özellikle GB yönteminin gürültüyü azaltma ve dokusal bütünlüğü koruma konusundaki etkisi, modelin segmentasyon başarısına anlamlı katkılar sağlamıştır. Benzer şekilde, CS yöntemi kontrastı artırarak dışlerin sınırlarını daha keskin biçimde görünür hale getirmiş ve bu sayede kenar bölgelerinin ayrıştırılmasını kolaylaştırmıştır. Bu gözlemler, yalnızca sayısal metriklerle değil, aynı zamanda görsel incelemelerle de doğrulanmış; her iki yöntemin de segmentasyon kalitesini artırdığı net bir biçimde ortaya konmuştur.

Bu kısımda hesaplanan PA değerlerinin, literatürde raporlanan bazı verilerden daha düşük seviyede olduğu dikkati çekmektedir. Ancak bu farklılık modelin yetersizliğine işaret etmemekte, daha çok değerlendirme yöntemindeki farklılıklardan kaynaklanmaktadır. Çalışmamızda, panoramik görüntüler doğrudan tüm alanlarıyla değil, yalnızca tanısal açıdan kritik bilgileri içeren ilgi alanı bölgeleri kırılarak eğitim ve test aşamalarına dâhil edilmiştir. Bu kırma işlemi sırasında görüntülerin büyük bir kısmını oluşturan arka plan bölgeleri hariç tutulmuştur. Oysa bu arka plan alanları, genellikle gerçek negatif pikseller içerdiğinden, piksel doğruluğu oranına yapay olarak olumlu katkı sağlamaktadır. Dolayısıyla, ilgi alanı bölgeleri kırması yapıldığında PA değerleri görece daha düşük görünse de, orijinal boyutlardaki görüntüler üzerinde yapılan değerlendirmeler literatürdeki bulgularla genel bir uyum göstermektedir. Bu nedenle, gözlenen PA düşüşü, modelin başarımındaki bir eksiklikten çok, veri seti organizasyonu ve girdi yapısındaki farklılıklardan kaynaklanmaktadır.

Performans karşılaştırmaları sonucunda, her bir model için öne çıkan üç ön işleme yöntemi CS, GB ve CS+GB olarak belirlenmiştir. Bu yöntemler yalnızca genel eğilim açısından değil, aynı zamanda farklı omurga mimarileri üzerinde de benzer şekilde yüksek başarı göstermeleriyle dikkat çekmiştir. Belirlenen bu yöntemler kullanılarak önerilen model, dört farklı temel yapı (ResNet50, EfficientNetB4, VGG19 ve özel tasarlanmış klasik U-Net) üzerinde yeniden test edilmiş ve ayrıntılı bir performans analizi gerçekleştirilmiştir. Böylece,


yalnızca tek bir modelin değil, farklı ağ mimarilerinin de bu ön işleme stratejilerinden nasıl fayda sağladığı kapsamlı biçimde ortaya konmuştur.

Elde edilen bulgular ayrıca, omurga mimarileri arasında EfficientNetB4'ün daha üstün ve kararlı bir performans sunduğunu göstermektedir. EfficientNet ailesinin temel avantajı, parametre sayısını ve hesaplama maliyetini artırmadan modelin derinliğini, genişliğini ve giriş çözünürlüğünü bileşik ölçeklendirme (compound scaling) yöntemiyle dengelemesidir. Bu yaklaşım sayesinde EfficientNetB4, diğer mimarilere kıyasla daha zengin özellik temsilleri elde edebilmekte, özellikle yüksek çözünürlüklü panoramik diş radyografilerinde hem küresel bağlamı hem de ince anatomik detayları aynı anda yakalayabilmektedir. Ayrıca bu omurga'nın önceden ImageNet üzerinde eğitilmiş olması, sınırlı boyuttaki dental veri setlerinde transfer öğrenmenin getirdiği avantajlarla daha hızlı yakınsama sağlamıştır. Sonuç olarak EfficientNetB4, yalnızca ortalama Dice değerlerinde en yüksek performansı göstermekle kalmamış, aynı zamanda düşük varyans ile daha istikrarlı bir dağılım sergileyerek farklı ön işleme yöntemleri karşısında da güvenilir sonuçlar üretmiştir. Tablo 7.5'de sunulan önerilen modelin sonuçları incelendiğinde, en yüksek Dice'in 0,9266 ile EfficientNetB4 tabanlı U-Net modelinde, GB yöntemi kullanılarak elde edildiği gözlemlenmektedir. Bu değer, sadece mevcut literatürde bildirilen sonuçları geçmekle kalmamış, ayrıca önerilen çerçevenin diş radyografisi segmentasyonu için etkili ve güvenilir bir yaklaşım olduğunu da göstermiştir. Bunun yanı sıra, CS ve GB kombinasyonlarının performansının diğer temel mimarilerde benzer şekilde öne çıktığı görülmüştür. Bu durum, CLAHE yönteminin kaynaklarda sıkça tercih edilmesine rağmen, her veri setinde aynı başarıyı sağlayamayacağını ve bu nedenle veri setine özel analizlerin büyük önem taşıdığını, ayrıca farklı yöntemlerin belirli durumlarda daha avantajlı olabileceğini açık bir şekilde ortaya koymaktadır.

Tablo 7.4 Önerilen modelin seçilen ön işleme yöntemleriyle segmentasyon performansı


ÖN İŞLEME YÖNTEMLERİ	U-NET (ResNet50)			U-NET (EfficientNetB4)			U-NET (VGG19)			Özelleştirilmiş U-NET		
	Dice	IoU	PA	Dice	IoU	PA	Dice	IoU	PA	Dice	IoU	PA
	Ön İşlemesiz	0,9230	0,8572	0,8793	0,9264	0,8632	0,8803	0,9216	0,8549	0,8789	0,9168	0,8467
CS	0,9228	0,8570	0,8793	0,9261	0,8626	0,8802	0,9218	0,8551	0,8790	0,9194	0,8511	0,8785
GB	0,9231	0,8574	0,8795	0,9266	0,8735	0,8804	0,9215	0,8548	0,8789	0,9152	0,8441	0,8774

Ayrıca, önerilen modelin başarılı sonuçlarına bir örnek, Şekil 7.24'te orijinal panoramik radyografik görüntü ile buna karşılık gelen gerçek (ground truth) maske ve modelin tahmin ettiği maske ile birlikte gösterilmiştir. Bu görsel analiz, modelin yalnızca genel yapıları doğru bir şekilde ayırt etmenin ötesinde, dişlerin sınırları, periodontal dokular ve ince anatomik detaylar gibi kritik alanları da yüksek bir doğrulukla segmentlere ayırabildiğini gözler önüne sermektedir. Özellikle diş sınırlarının net bir şekilde tanımlanması ve küçük yapısal özelliklerin korunması, modelin klinik uygulama potansiyelini artıran önemli bulgular arasındadır.




Şekil 7.25 Önerilen Modelin Örnek Segmentasyon Çıktısı: (a) Orijinal Panoramik Diş Röntgeni, (b) Gerçek Maske, (c) Tahmin Edilen Maske


Elde edilen bulguların daha anlaşılır ve karşılaştırılabilir hale gelmesi amacıyla, Tablo 7.4'te yer alan önerilen model sonuçları ayrıca grafiksel olarak görselleştirilmiştir. Şekil 7.25–7.28'te sunulan bu grafikler, farklı omurga mimarilerinde doğrulama Dice değerlerinin eğitim süreci boyunca nasıl değişim gösterdiğini ayrıntılı biçimde ortaya koymaktadır.




Şekil 7.26 ResNet50 Omurga ile Doğrulama Dice Katsayısı- Eğitim Döngüsü Değişimi



Şekil 7.27 EfficientNetB4 Omurga ile Doğrulama Dice Katsayısı - Eğitim Döngüsü Değişimi



Şekil 7.28 VGG19 Omurga ile Doğrulama Dice Katsayısı- Eğitim Döngüsü Değişimi




Şekil 7.29 Özelleştirilmiş U-Net ile Doğrulama Dice Katsayısı - Eğitim Döngüsü Değişimi

Sonuçların bütüncül değerlendirilmesi sonucunda, tüm modeller için en etkili üç veri ön işleme yöntemi CS, GB ve bu iki tekniğin birleşimi olan CS+GB olarak belirlenmiştir. Bu tekniklerin etkinliği yalnızca sayısal metriklerle sınırlı kalmamış, aynı zamanda görsel analizlerle de doğrulanmıştır. Elde edilen bulgular, bu yöntemlerin segmentasyon başarısını artırmada belirgin bir katkı sağladığını ve farklı ağ yapıları üzerinde de tutarlı şekilde olumlu sonuçlar verdiğini ortaya koymuştur.

Ön işleme uygulanmamış görüntülerle gerçekleştirilen ek deneyler, seçili tekniklerin katkısını daha net biçimde ortaya koymak amacıyla karşılaştırmalı olarak incelenmiştir. Bu analizlerde, özellikle EfficientNetB4 tabanlı U-Net modeli öne çıkmış ve 0,9266 Dice ile en yüksek başarıya GB yöntemiyle ulaşmıştır. Bu değer, yalnızca test edilen yöntemler arasında değil, aynı zamanda literatürde rapor edilen benzer çalışmalarla kıyaslandığında da dikkat çekici bir üstünlük sergilemektedir.

Analizi desteklemek ve modeller arasındaki karşılaştırmayı daha anlaşılır kılmak için, omurga mimarileri arasında elde edilen Dice dağılımını gösteren kutu grafikler hazırlanmıştır. Şekil 7.29'da sunulan bu görselleştirme, farklı model varyantlarının ortalama performans düzeylerini ve varyanslarını net biçimde ortaya koymaktadır. Grafikler, EfficientNetB4'ün yalnızca yüksek ortalama skorları ile değil, aynı zamanda düşük varyansıyla da kararlı ve güvenilir bir mimari olduğunu göstermektedir. Böylelikle, hem seçilen ön işleme tekniklerinin etkisi hem de farklı omurgaların segmentasyon süreçlerindeki genel stabilite düzeyleri kapsamlı bir şekilde değerlendirilmiştir.



Şekil 7.30 Önerilen Yöntemin Varyantları Arasında Dice Değerlerinin Dağılımı

Önerilen modelin etkinliğini değerlendirmek için, TDD kullanılarak yapılan üç güncel çalışma ile kapsamlı bir kıyaslama gerçekleştirilmiştir. Bu veri tabanı, tüm incelemeler için ortak bir referans noktası sağladığından, sonuçların nesnel, doğrudan ve adil bir şekilde incelenmesine imkan tanımaktadır. Böylelikle farklı yaklaşımların performans seviyeleri eşit koşullar altında değerlendirilebilmekte ve önerilen yöntem daha belirgin bir şekilde etkili

olduğunu göstermektedir. Tablo 7.6'teki verilere göre, Bhat ve ekibi (Bhat vd., 2025b) geleneksel U-Net yapısını kullanarak %92,53'lük bir Dice benzerlik oranı bildirmiştir. Benzer şekilde, (Panetta vd., 2022) numaralı araştırmada orijinal U-Net yapısıyla %92,49 oranında bir Dice puanı elde edilmiştir. Daha özelleştirilmiş bir model geliştiren (Mărginean vd., 2024b) CariSeg adındaki segmentasyon yapısıyla %88,90 oranında bir Dice sonucu elde etmiş, fakat bu oran U-Net tabanlı yöntemlerden daha düşük kalmıştır.

Bu tez çerçevesinde geliştirilen model, %92,66'lık Dice puanı ile sadece temeldeki U-Net yapısına dayanan yaklaşımları değil, aynı zamanda özel olarak tasarlanmış ileri segmentasyon modüllerini de geride bırakarak literatürde kayda değer bir üstünlük sağlamıştır. Özellikle performans değerleri arasında dahi küçük farklılıkların, hata toleransının düşük olduğu tıbbi görüntüleme alanında büyük önem taşıdığı göz önünde bulundurulduğunda, önerilen yöntemin sağladığı başarımın anlamlı olduğu görülmektedir. Bununla birlikte, önerilen yöntemin sergilenen yüksek performansı, ön işleme adımları ve yama tabanlı segmentasyon stratejisinin modelin başarısına olan katkısını net bir şekilde ortaya koymaktadır. Diş radyografilerinde sıkça karşılaşılan kontrast eksikliği, gürültü ve yapısal karmaşıklık gibi sorunlar düşünülünce, önerilen modelin bu zorlukların üstesinden gelerek yüksek doğrulukta sonuçlar üretebilmesi, yöntemin klinik açıdan uygulanabilirliğini ve güvenilirliğini artırmaktadır.

Tablo 7.5 Önerilen yöntem ile aynı veri seti üzerine mevcut çalışmaların karşılaştırılması

Yazar	Ön İşleme Süreci	Model	Dice	IoU
(Bhat vd., 2025b)	512×512 yeniden boyutlandırma	U-Net	0,9253	0,8613
(Panetta vd., 2022)	CLAHE	U-Net	0,9249	0,8662
(Mărginean vd., 2024b)	Kırpma + Gamma Düzeltme	U-Net	0,889	0,798
Bu Çalışma	ROI + GB + Sıfır Dolgulama + Yama Bölme	U-Net	0,9266	0,8735

8. SONUÇ VE TARTIŞMA

Bu tezde, görüntü iyileştirme süreçlerinin segmentasyon aşamasına sistematik bir şekilde dahil edilmesi hedeflenmiş ve bu süreçlerin modelin performansına olan etkisi detaylı bir şekilde incelenmiştir. Bu çerçevede, dış radyografi görüntülerinin segmentasyon verimliliğini artırmak için yeni bir bölge kılavuzlu ön işleme çerçevesi oluşturulmuştur. Sunulan yöntem, beş ana modülden oluşmaktadır: (i) ön işleme yönteminin belirlenmesi, (ii) ilgi alanı elde edilmesi, (iii) görüntülerin bölünmesi, (iv) U-Net varyasyonları ile segmentasyon ve (v) nihai işlem aşamaları. CS, GB ve bu iki yöntemin birleşimi olan CS+GB olarak belirlenmiştir. Bu aşamanın ardından, geliştirilmiş görüntülerin ilgi alanı bölgeleri alanları maske yardımıyla çıkarılmıştır. İlk adımda, radyografi görüntülerine on dört farklı geleneksel ve hibrit ön işleme yöntemi ayrı ayrı uygulanmış ve sonuçlar karşılaştırılmıştır. Yapılan analiz sonucunda en iyi performansı gösteren üç yöntem, kontrast çıkarılmış ve bu ilgi alanı bölgeleri görüntüleri, daha ayrıntılı bilgi edinme amacıyla dört eşit parçaya ayrılmıştır.

Segmentasyon modülünde her bir parça, hem klasik U-Net yapısı hem de ResNet50, VGG19 ve EfficientNetB4 gibi değişik kodlayıcı mimarileri ile özelleştirilmiş U-Net modelleri üzerinden işlenmiştir. Böylece, farklı mimarilerin özellik çıkarımındaki avantajları test edilmiştir. Son adımda parçalar bir araya getirilerek entegre bir segmentasyon çıktısı elde edilmiştir. Özellikle EfficientNetB4 tabanlı modellerin, dış radyografilerindeki karmaşık yapısal ilişkileri daha etkin bir şekilde temsil ettiği ve diğer modellerle kıyaslandığında daha yüksek doğruluk sağladığı tespit edilmiştir.

Önerilen çerçevenin başarısı, dış sağlığı alanındaki çalışmalarda yaygın olarak kullanılan güvenilir bir referans veri seti olan TDD üzerinden değerlendirilmiştir. Bulgular, bölge tabanlı yaklaşımın ilgi alanı bölgeleri görüntülerini yamalar halinde işleyerek daha ayrıntılı özelliklere odaklanmayı sağladığını ve bunun segmentasyon doğruluğunu önemli ölçüde artırdığını ortaya koymuştur. Ayrıca, düşük kaliteli dış radyografilerinde de ön işleme tekniklerinin segmentasyon verimliliğini belirgin bir şekilde artırdığı gösterilmiştir.

Elde edilen bulgular, sadece derin öğrenme tabanlı mimarilerin değil, aynı zamanda ön işleme tekniklerinin de dış radyografi segmentasyonunda kritik bir öneme sahip olduğunu net bir şekilde ortaya koymaktadır. Özellikle kontrast artırma ve gürültü azaltma gibi iyileştirme yöntemlerinin segmentasyon modellerinin doğruluğuna doğrudan katkı sağladığı gözlemlenmiştir.

Gelecekteki projeler dođrultusunda, önerilen yapının daha fazla ileriye götürülmesi amacıyla dikkat mekanizmalarının, dönüştürücü (transformer) temelli yapılar ile gelişmiş düzenleme yöntemlerinin birleştirilmesi öngörülmektedir. Bu sayede hem segmentasyonun doğruluđu hem de klinik açıdan uygulanabilirlik daha üst bir noktaya ulaştırılması amaçlanmaktadır.

KAYNAKÇA

- Adnan, N., Umer, F., Malik, S., & Hussain, O. A. (2024). Multi-model deep learning approach for segmentation of teeth and periapical lesions on pantomographs. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, 138(1), 196-204. <https://doi.org/10.1016/J.OOOO.2023.11.006>
- Alharbi, S. S. ;, Alrugaibah, A. A. ;, Alhasson, H. F. ;, Khan, R. U (2023). Detection of Cavities from Dental Panoramic X-ray Images Using Nested U-Net Models. <https://doi.org/10.3390/APP132312771>
- 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*. <https://arxiv.org/pdf/1802.06955>
- Aung, M. T. Z., Lim, S. H., Han, J., Yang, S., Kang, J. H., Kim, J. E., Huh, K. H., Yi, W. J., Heo, M. S., & Lee, S. S. (2024). Deep learning-based automatic segmentation of the mandibular canal on panoramic radiographs: A multi-device study. *Imaging Science in Dentistry*, 54(1), 81. <https://doi.org/10.5624/ISD.20230245>
- Awari, H., Subramani, N., Janagaraj, A., Balasubramaniapillai Thanammal, G., Thangarasu, J., & Kohar, R. (2024). Three-dimensional dental image segmentation and classification using deep learning with tunicate swarm algorithm. *Expert Systems*, 41(6), e13198. <https://doi.org/10.1111/EXSY.13198>
- Bakurov, I., Buzzelli, M., Schettini, R., Castelli, M., & Vanneschi, L. (2022). Structural similarity index (SSIM) revisited: A data-driven approach. *Expert Systems with Applications*, 189, 1-19. <https://doi.org/10.1016/j.eswa.2021.116087>
- Bezryadin, S., Bourov, P., & Ilinih, D. (2007). Brightness Calculation in Digital Image Processing. *International Symposium on Technologies for Digital Photo Fulfillment*, 1(1), 10-15. <https://doi.org/10.2352/ISSN.2169-4672.2007.1.0.10>
- Bhat, S., Birajdar, G. K., & Patil, M. D. (2025b). Tooth segmentation in panoramic dental radiographs using deep convolution neural network -Insights from subjective analysis. *Discover Applied Sciences*, 7(4), 1-18. <https://doi.org/10.1007/S42452-025-06606-0>

- Buades, A., Coll, B., & Morel, J. M. (2005). A non-local algorithm for image denoising. *Proceedings - 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, CVPR 2005, II*, 60-65. <https://doi.org/10.1109/CVPR.2005.38>
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? *Geosci. Model Dev. Discuss*, 7, 1525-1534. <https://doi.org/10.5194/gmdd-7-1525-2014>
- Chang, Y., Jung, C., Ke, P., Song, H., & Hwang, J. (2018). Automatic Contrast-Limited Adaptive Histogram Equalization with Dual Gamma Correction. *IEEE Access*, 6, 11782-11792. <https://doi.org/10.1109/ACCESS.2018.2797872>
- Chen, C., Qin, C., Qiu, H., Tarroni, G., Duan, J., Bai, W., & Rueckert, D. (2020). Deep Learning for Cardiac Image Segmentation: A Review. *Frontiers in Cardiovascular Medicine*, 7, 508599. <https://doi.org/10.3389/FCVM.2020.00025/XML>
- Chen, X., Zhang, Q., Lin, M., Yang, G., & He, C. (2018). No-Reference Color Image Quality Assessment: From Entropy to Perceptual Quality. *Eurasip Journal on Image and Video Processing*, 2019(1). <https://doi.org/10.1186/s13640-019-0479-7>
- Çallı, E., Sogancioglu, E., van Ginneken, B., van Leeuwen, K. G., & Murphy, K. (2021). Deep learning for chest X-ray analysis: A survey. *Medical Image Analysis*, 72, 102125. <https://doi.org/10.1016/J.MEDIA.2021.102125>
- Çiçek, Ö., Abdulkadir, A., Lienkamp, S. S., Brox, T., & Ronneberger, O. (2016). 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9901 LNCS, 424-432. https://doi.org/10.1007/978-3-319-46723-8_49
- Datta, S., Chaki, N., & Modak, B. (2023). A novel technique for dental radiographic image segmentation based on neutrosophic logic. *Decision Analytics Journal*, 7, 100223. <https://doi.org/10.1016/J.DAJOUR.2023.100223>
- Din, S., Shoaib, M., & Serpedin, E. (2025). CXR-Seg: A Novel Deep Learning Network for Lung Segmentation from Chest X-Ray Images. *Bioengineering 2025, Vol. 12, Page 167*, 12(2), 167. <https://doi.org/10.3390/BIOENGINEERING12020167>
- Ezzell, G. A., Galvin, J. M., Low, D., Palta, J. R., Rosen, I., Sharpe, M. B., Xia, P., Xiao, Y., Xing, L., & Yu, C. X. (2003). Guidance document on delivery, treatment planning, and clinical

- implementation of IMRT: Report of the IMRT subcommittee of the AAPM radiation therapy committee. *Medical Physics*, 30(8), 2089-2115. <https://doi.org/10.1118/1.1591194>
- Ferzli, R., & Karam, L. J. (2009). A no-reference objective image sharpness metric based on the notion of Just Noticeable Blur (JNB). *IEEE Transactions on Image Processing*, 18(4), 717-728. <https://doi.org/10.1109/TIP.2008.2011760>
- Fok, W. Y. R., Fieselmann, A., Huemmer, C., Biniazan, R., Beister, M., Geiger, B., Kappler, S., & Saalfeld, S. (2024). Adversarial robustness improvement for X-ray bone segmentation using synthetic data created from computed tomography scans. *Scientific Reports*, 14(1), 1-11. <https://doi.org/10.1038/S41598-024-73363-2>
- Ghadimi, D. J., Vahdani, A. M., Karimi, H., Ebrahimi, P., Fathi, M., Moodi, F., Habibzadeh, A., Khodadadi Shoushtari, F., Valizadeh, G., Mobarak Salari, H., & Saligheh Rad, H. (2025). Deep Learning-Based Techniques in Glioma Brain Tumor Segmentation Using Multi-Parametric MRI: A Review on Clinical Applications and Future Outlooks. *Journal of Magnetic Resonance Imaging*, 61(3), 1094-1109. <https://doi.org/10.1002/JMRI.29543>,
- Harsh, P., Chakraborty, R., Tripathi, S., & Sharma, K. (2021). Attention U-Net Architecture for Dental Image Segmentation. *2021 International Conference on Intelligent Technologies, CONIT 2021*. <https://doi.org/10.1109/CONIT51480.2021.9498422>
- Horé, A., & Ziou, D. (2010). Image quality metrics: PSNR vs. SSIM. *Proceedings - International Conference on Pattern Recognition*, 2366-2369. <https://doi.org/10.1109/ICPR.2010.579>
- Houssein, E. H., Mohamed, G. M., Djenouri, Y., Wazery, Y. M., & Ibrahim, I. A. (2024). Nature inspired optimization algorithms for medical image segmentation: a comprehensive review. *Cluster Computing*, 27(10), 14745-14766. <https://doi.org/10.1007/S10586-024-04601-5>
- Isensee, F., Jaeger, P. F., Kohl, S. A. A., Petersen, J., & Maier-Hein, K. H. (2021). nnU-Net: A selfconfiguring method for deep learning-based biomedical image segmentation. *Nature Methods*, 18(2), 203-211. <https://doi.org/10.1038/s41592-020-01008-z>
- Kumar, A., Bhadauria, H. S., & Singh, A. (2021). Descriptive analysis of dental X-ray images using various practical methods: A review. *PeerJ Computer Science*, 7, e620. <https://doi.org/10.7717/PEERJ-CS.620/TABLE-8>

- Kumari, A. R., Rao, S. N., & Reddy, P. R. (2022). Composite Feature Set Based Dental Image Segmentation Framework through Unsupervised Learning. *International Journal of Intelligent Engineering and Systems*, 15(5), 2022. <https://doi.org/10.22266/ijies2022.1031.55>
- Leo, L., Reddy, T., Intelligence, A. S.-J. of A., & 2023, undefined. (2023). Original Research Article Impact of Selective median filter on dental caries classification system using deep learning models. *jai.front-sci.com*, 6(2). <https://doi.org/10.32629/jai.v6i2.560>
- Li, M., Jiang, Y., Zhang, Y., & Zhu, H. (2023). Medical image analysis using deep learning algorithms. *Frontiers in Public Health*, 11, 1273253. <https://doi.org/10.3389/FPUBH.2023.1273253/REFERENCE>
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88. <https://doi.org/10.1016/J.MEDIA.2017.07.005>
- Ma, H., & Nie, Y. (2018). A two-stage filter for removing salt-and-pepper noise using noise detector based on characteristic difference parameter and adaptive directional mean filter. *PLOS ONE*, 13(10), e0205736. <https://doi.org/10.1371/JOURNAL.PONE.0205736>
- Ma, T., Dang, Z., Yang, Y., Yang, J., & Li, J. (2024). Dental panoramic X-ray image segmentation for multi-feature coordinate position learning. *Digital Health*, 10, 20552076241277150. <https://doi.org/10.1177/20552076241277154>
- Manzari, O. N., Bayrami, F., Khaloo, H., Khodakaramimaghsoud, Z., & Shokouhi, S. B. (2024). DenUnet: enhancing dental image segmentation through edge and body fusion. *Multimedia Tools and Applications*, 1-21. <https://doi.org/10.1007/S11042-024-19513-0/FIGURES/8>
- Marconato Stringhini, R., Welfer, D., Tello Gamarra, D. F., & Nogara Dotto, G. (2021). Noise Reduction with Detail Preservation in Low-Dose Dental CT Images by Morphological Operators and BM3D. *Advances in Intelligent Systems and Computing*, 1181 AISC, 309-317. https://doi.org/10.1007/978-3-030-49342-4_30
- Mărginean, A. C., Mureșanu, S., Hedeșiu, M., & Dioșan, L. (2024a). Teeth segmentation and carious lesions segmentation in panoramic X-ray images using CariSeg, a networks' ensemble. *Heliyon*, 10(10), e30836. <https://doi.org/10.1016/J.HELIYON.2024.E30836>

- Mehdizadeh, M., Tavakoli Tafti, K., & Soltani, P. (2023). Evaluation of histogram equalization and contrast limited adaptive histogram equalization effect on image quality and fractal dimensions of digital periapical radiographs. *Oral Radiology*, 39(2), 418-424. <https://doi.org/10.1007/s11282-022-00654-7>
- Mello Román, J. C., Fretes, V. R., Adorno, C. G., Gariba Silva, R., Vázquez Noguera, J. L., Legal-Ayala, H., Mello-Román, J. D., Escobar Torres, R. D., & Facon, J. (2021). Panoramic Dental Radiography Image Enhancement Using Multiscale Mathematical Morphology. *Sensors 2021, Vol. 21, Page 3110, 21(9)*, 3110. <https://doi.org/10.3390/S21093110>
- Milletari, F., Navab, N., & Ahmadi, S. A. (2016). V-Net: Fully convolutional neural networks for volumetric medical image segmentation. *Proceedings - 2016 4th International Conference on 3D Vision, 3DV 2016*, 565-571. <https://doi.org/10.1109/3DV.2016.79>
- Mishra, A. (2021). *Contrast Limited Adaptive Histogram Equalization (CLAHE) Approach for Enhancement of the Microstructures of Friction Stir Welded Joints*. <https://arxiv.org/pdf/2109.00886>
- Müller, D., Soto-Rey, I., & Kramer, F. (t.y.). *TOWARDS A GUIDELINE FOR EVALUATION METRICS IN MEDICAL IMAGE SEGMENTATION*.
- Nafi'iyah, N., Fatichah, C., Renwi Astuti, E., & Herumurti, D. (2020). The use of pre and post processing to enhance mandible segmentation using active contours on dental panoramic radiography images. In *2020 3rd International Seminar on Research of Information Technology and Intelligent Systems (ISRITI 2020)*, pp. 661-666. <https://doi.org/10.1109/isriti51436.2020.9315438>
- Nurmaini, S., Rachmatullah, M. N., Sapitri, A. I., Darmawahyuni, A., Tutuko, B., Firdaus, F., Partan, R. U., & Bernolian, N. (2021). Deep Learning-Based Computer-Aided Fetal Echocardiography: Application to Heart Standard View Segmentation for Congenital Heart Defects Detection. *Sensors 2021, Vol. 21, Page 8007, 21(23)*, 8007. <https://doi.org/10.3390/S21238007>
- Oktay, O., Schlemper, J., Folgoc, L. Le, Lee, M., Heinrich, M., Misawa, K., Mori, K., McDonagh, S., Hammerla, N. Y., Kainz, B., Glocker, B., & Rueckert, D. (2018a). *Attention U-Net: Learning Where to Look for the Pancreas*. <https://arxiv.org/pdf/1804.03999>
- Panetta, K., Rajendran, R., Ramesh, A., Rao, S., & Agaian, S. (2022). Tufts Dental Database: A Multimodal Panoramic X-Ray Dataset for Benchmarking Diagnostic Systems. *IEEE Journal*

of Biomedical and Health Informatics, 26(4), 1650-1659.
<https://doi.org/10.1109/JBHI.2021.3117575>

Park, K. J., & Kwak, K. C. (2019). A trends analysis of dental image processing. *International Conference on ICT and Knowledge Engineering*, 2019-November.
<https://doi.org/10.1109/ICTKE47035.2019.8966853>

Pham, D. L., Xu, C., & Prince, J. L. (2000). Current methods in medical image segmentation. *Annual Review of Biomedical Engineering*, 2(2000), 315-337.
<https://doi.org/10.1146/ANNUREV.BIOENG.2.1.315/CITE/REFWORKS>

Pizer, S. M., Amburn, E. P., Austin, J. D., Cromartie, R., Geselowitz, A., Greer, T., ter Haar Romeny, B., Zimmerman, J. B., & Zuiderveld, K. (1987). Adaptive histogram equalization and its variations. *Computer Vision, Graphics, and Image Processing*, 39(3), 355-368.
[https://doi.org/10.1016/S0734-189X\(87\)80186-X](https://doi.org/10.1016/S0734-189X(87)80186-X)

Rafael C. Gonzalez, R. E. W. (t.y.). *Digital Image Processing*. Geliş tarihi 17 Temmuz 2025, gönderen <https://www.cl72.org/090imagePLib/books/Gonzales%2CWoods-Digital.Image.Processing.4th.Edition.pdf>

Rajee, M. V., & Mythili, C. (2023). Dental Image Segmentation and Classification Using Inception Resnetv2. *IETE Journal of Research*, 69(8), 4972-4988.
<https://doi.org/10.1080/03772063.2021.1967793>

Reza, A. M., (2004). Realization of the Contrast Limited Adaptive Histogram Equalization (CLAHE) for Real-Time Image Enhancement. *JSPSy*, 38(1), 35-44.
<https://doi.org/10.1023/B:VLSI.0000028532.53893.82>

Robert Krutsh, & David Tenorio. (2011). *Histogram Equalization*.

Rocha, É. da S., & Endo, P. T. (2022). A Comparative Study of Deep Learning Models for Dental Segmentation in Panoramic Radiograph. *Applied Sciences (Switzerland)*, 12(6).
<https://doi.org/10.3390/app12063103>

Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9351, 234-241.
https://doi.org/10.1007/978-3-319-24574-4_28

- Salih, O., & Duffy, K. J. (2022). The local ternary pattern encoder–decoder neural network for dental image segmentation. *IET Image Processing*, 16(6), 1520-1530. <https://doi.org/10.1049/IPR2.12416;JOURNAL:JOURNAL:17519667;WGROU:STRING:PUBLICATI>
- Scarfe, W. C., & Farman, A. G. (2008). What is Cone-Beam CT and How Does it Work? *Dental Clinics of North America*, 52(4), 707-730. <https://doi.org/10.1016/J.CDEN.2008.05.005>
- Setianingrum, A. H., Rini, A. S., & Hakiem, N. (2017). Image segmentation using the Otsu method in Dental X-rays. *Proceedings of the 2nd International Conference on Informatics and Computing, ICIC 2017, 2018-January*, 1-6. <https://doi.org/10.1109/IAC.2017.8280611>
- Shen, D., Wu, G., & Suk, H.-I. (2017). *Deep Learning in Medical Image Analysis*. <https://doi.org/10.1146/annurev-bioeng-071516>
- Soomro, T. A., Ali, A., Jandan, N. A., Afifi, A. J., Irfan, M., Alqhtani, S., Glowacz, A., Alqahtani, A., Tadeusiewicz, R., Kantoch, E., & Zheng, L. (2021). Impact of Novel Image Preprocessing Techniques on Retinal Vessel Segmentation. *Electronics 2021, Vol. 10, Page 2297, 10(18)*, 2297. <https://doi.org/10.3390/ELECTRONICS10182297>
- Sparavigna, A. C. (2019). Entropy in image analysis. *Entropy*, 21(5). <https://doi.org/10.3390/E21050502>
- Szeliski R. (2010) *Computer vision: Algorithms and applications*. Springer
- Tan, M., & Le, Q. V. (2019). *EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks* (ss. 6105-6114). PMLR. <https://proceedings.mlr.press/v97/tan19a.html>
- Vigil, M. S. A., & Bharathi, V. S. (2021). Detection of periodontal bone loss in mandibular area from dental panoramic radiograph using image processing techniques. *Concurrency and Computation: Practice and Experience*, 33(17), e6323. <https://doi.org/10.1002/CPE.6323>
- Wang, J., Zhang, X., Lv, P., Zhou, L., & Wang, H. (2021). EAR-U-Net: EfficientNet and attention-based residual U-Net for automatic liver segmentation in CT. *Proceedings of the 36 th International Conference on Machine Learning, Long Beach, California, PMLR 97*. <https://arxiv.org/pdf/2110.01014>
- Wang, X., Alqahtani, K. A., Van den Bogaert, T., Shujaat, S., Jacobs, R., & Shaheen, E. (2024). Convolutional neural network for automated tooth segmentation on intraoral scans. *BMC Oral Health*, 24(1), 1-9. <https://doi.org/10.1186/S12903-024-04582-2/FIGURES/3>

- Wei, Y., Yang, M., Zhang, M., Gao, F., Zhang, N., Hu, F., Zhang, X., Zhang, S., Huang, Z., Xu, L., Zhang, F., Liu, M., Deng, J., Cheng, X., Xie, T., Wang, X., Liu, N., Gong, H., Zhu, S., ... Liu, M. (2024). Focal liver lesion diagnosis with deep learning and multistage CT imaging. *Nature Communications* 2024 15:1, 15(1), 1-14. <https://doi.org/10.1038/s41467-024-51260-6>
- Yakut, C., Ulukaya, S., & ... (2022). Görüntü filtreleme ile denetimsiz retina damar bölütlenmesi için parametre eniyileştirilmesi. *Mühendislik Bilimleri ve Tasarım Dergisi*, 10(3), 844-855. <https://doi.org/10.21923/jesd.1033339>
- Yoshimi, Y., Mine, Y., Ito, S., Takeda, S., Okazaki, S., Nakamoto, T., Nagasaki, T., Kakimoto, N., Murayama, T., & Tanimoto, K. (2024). Image preprocessing with contrast-limited adaptive histogram equalization improves the segmentation performance of deep learning for the articular disk of the temporomandibular joint on magnetic resonance images. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, 138(1), 128-141. <https://doi.org/10.1016/j.oooo.2023.01.016>
- Zhang, Z., Liu, Q., & Wang, Y. (2018). Road Extraction by Deep Residual U-Net. *IEEE Geoscience and Remote Sensing Letters*, 15(5), 749-753. <https://doi.org/10.1109/LGRS.2018.2802944>
- Zhou, Z., Rahman Siddiquee, M. M., Tajbakhsh, N., & Liang, J. (2018a). Unet++: A nested u-net architecture for medical image segmentation. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11045 LNCS, 3-11. https://doi.org/10.1007/978-3-030-00889-5_1,