



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



PANAROMİK RADYOGRAFİLERDE
VERİ ÖN İŞLEME VE DERİN ÖĞRENME
KULLANARAK DİŞ SEGMENTASYONU
Mehmet KOCAKUŞ

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Eylül-2025
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Mehmet KOCAKUŞ tarafından hazırlanan “Panaromik radyografilerde veri ön işleme ve derin öğrenme kullanarak diş segmentasyonu” adlı tez çalışması 09/09/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Ömer Kaan BAYKAN
(Konya Teknik Üniversitesi)

Danışman

Dr. Öğr. Üyesi Betül UZBAŞ
(Konya Teknik Üniversitesi)

Üye

Dr. Öğr. Üyesi Ayşe Merve ACILAR
(Necmettin Erbakan Üniversitesi)

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Mehmet KOCAKUŞ

Tarih:

ÖZET

YÜKSEK LİSANS TEZİ

PANAROMİK RADYOGRAFİLERDE VERİ ÖN İŞLEME VE DERİN ÖĞRENME KULLANARAK DİŞ SEGMENTASYONU Mehmet KOCAKUŞ

Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Betül UZBAŞ

Yıl, 2025 Sayfa 52

Jüri

Doç. Dr. Ömer Kaan BAYKAN
Dr. Öğr. Üyesi Ayşe Merve ACILAR

Dental segmentasyon, dental radyografik görüntülerde dişlerin ve çevresindeki anatomik yapıların sınırlarının belirlenmesi sürecidir. Bu süreç, dental yapıları dijital görüntüler üzerinde ayrı sınırlara ayırarak analiz edilebilir hale getirir. Özellikle Yapay Zekâ (YZ) destekli sistemlerde, dental segmentasyon; diş tespiti, çürük analizi, periodontal hastalıkların belirlenmesi ve ortodontik planlamalar gibi birçok klinik uygulamanın temelini oluşturmaktadır. Segmentasyonun amacı, tanı ve tedavi süreçlerinde doğru, hızlı ve tekrarlanabilir analizler sunarak klinik karar verme süreçlerini desteklemektir. Bu bağlamda, özellikle uzman eksikliği yaşanan bölgelerde otomatik dental segmentasyon sistemlerinin geliştirilmesi önemli bir ihtiyaç haline gelmiştir. Bu çalışma, U-Net Derin Öğrenme (DÖ) modeli kullanılarak dental radyografilerde segmentasyon performansı üzerinde veri artırımı, ön işleme teknikleri ve dikkat bloklarının etkisini araştırmaktadır. Araştırmanın amacı, otomatik diş segmentasyonu için en etkili görüntü işleme filtreleri, veri artırımı stratejileri ve derin öğrenme mimarileri kombinasyonunu belirlemektir. Çalışmada, Tufts Üniversitesi tarafından sağlanan 1.000 dental radyografiden oluşan bir veri seti kullanılmıştır. Veri seti, %85 eğitim ve %15 test olmak üzere ikiye ayrılmıştır. Görüntü kontrastını artırmak ve gürültüyü azaltmak amacıyla Kontrast Sınırlamalı Uyarlanabilir Histogram Eşitleme (Contrast-Limited Adaptive Histogram Equalization, CLAHE) Otsu eşikleme gibi ön işleme teknikleri ve, segmentasyon odak bölgelerini yorumlamak için Grad-CAM tabanlı ısı haritaları uygulanmıştır. Ayrıca, modelin genelleme yeteneğini artırmak için aynalama, 5° ve 10° derecelik döndürmeler ve öteleme gibi veri artırımı yöntemleri kullanılmıştır. Önerilen U-Net modeli, Adam optimizasyon algoritması kullanılarak 100 epok boyunca eğitilmiştir. Model performansını değerlendirmek amacıyla Dice skoru, Birleşim Üzerinden Kesişim (Intersection over Union, IoU) ve Piksel Doğruluğu (Pixel Accuracy, PA) ölçütleri kullanılmıştır. Veri artırma uygulanmadan gerçekleştirilen deneylerde, CLAHE ön işleme ve dikkat blokları içeren Attention U-Net modeli ile %91,01 Dice, %83,51 IoU ve %97,86 PA en yüksek başarı elde edilmiştir. CLAHE ön işleme ile veri artırma uygulandığında ise, aynalama yöntemi ile artırılmış veriler kullanılarak eğitilen klasik U-Net modeli %91,02 Dice, %83,51 IoU ve %97,86 PA değerleri ile en yüksek başarıyı göstermiştir. Elde edilen bulgular, uygun veri artırımı, ön işleme teknikleri ve dikkat bloklarının uygulanmasının, özellikle veri setinin sınırlı olduğu durumlarda, modelin güvenilirliğini ve doğruluğunu anlamlı düzeyde artırdığını göstermektedir. Çalışmada, veri ön işleme yöntemleri ve dikkat bloklarıyla desteklenen derin öğrenme modellerinin, diş segmentasyonu ve tanısının otomatikleştirilmesi yoluyla sağlık profesyonellerine destek olması amaçlanmaktadır. Bu yaklaşım, özellikle uzman radyologlara erişimin kısıtlı olduğu uzak bölgelerdeki sağlık kuruluşları için önemli bir değer taşımaktadır.

Anahtar Kelimeler: Dikkat Blokları, Derin Öğrenme, Isı Haritaları, U-Net Mimarisi, Veri Artırma, Veri Ön İşleme

ABSTRACT

MS THESIS

TOOTH SEGMENTATION IN PANORAMIC RADIOGRAPHS USING PREPROCESSING AND DEEP LEARNING

Mehmet KOCAKUŞ

**Konya Technical University
Institute of Graduate Studies Department of Computer Engineering**

Advisor: Asst. Prof. Dr. Betül UZBAŞ

Year, 2025 Pages 52

**Jury
Assoc. Prof. Dr. Ömer Kaan BAYKAN
Asst. Prof. Dr. Ayşe Merve ACILAR**

Dental segmentation is the process of defining the boundaries of teeth and the anatomical structures that surround them in dental radiographic images. This process separates dental structures into distinct boundaries on digital images, making them suitable for analysis. In particular, dental segmentation forms the basis of numerous clinical applications in artificial intelligence (AI)-assisted systems, such as tooth detection, caries analysis, identification of periodontal diseases, and orthodontic planning. Segmentation supports clinical decision-making processes by providing accurate, rapid, and repeatable analyses for diagnosis and treatment planning. In this context, developing automated dental segmentation systems has become essential, particularly in regions with a shortage of specialists. This study examines how data augmentation, preprocessing techniques, and attention blocks affect the performance of the U-Net deep learning model for segmentation in dental radiographs. The study aims to determine the most effective combination of image processing filters, data augmentation strategies, and deep learning architectures for automated tooth segmentation. The study uses a dataset of 1,000 dental radiographs from Tufts University. The dataset is divided into 85% for training and 15% for testing. Preprocessing techniques such as contrast-limited adaptive histogram equalization (CLAHE) and Otsu thresholding were applied to enhance image contrast and reduce noise. Grad-CAM-based heatmaps were employed to interpret the segmentation focus regions. Additionally, data augmentation methods, including mirroring and rotations of 5° and 10°, as well as translations, were employed to enhance the model's generalization capability. The proposed U-Net model was trained for 100 epochs using the Adam optimization algorithm. Model performance was evaluated using the Dice score, Intersection over Union (IoU), and Pixel Accuracy (PA) metrics. Without data augmentation, the Attention U-Net model incorporating CLAHE preprocessing and attention blocks achieved the highest performance with Dice, IoU, and PA scores of 91.01%, 83.51%, and 97.86%, respectively. When data augmentation with CLAHE preprocessing was applied, the classical U-Net model trained with augmented data using the mirroring method achieved the highest performance, with 91.02% Dice, 83.51% IoU, and 97.86% PA values. The findings demonstrate that applying appropriate data augmentation and preprocessing techniques, as well as attention blocks, significantly improves model reliability and accuracy, especially when the dataset is limited. This study aims to support healthcare professionals by automating tooth segmentation and diagnosis using deep learning models enhanced with preprocessing methods and attention blocks. This approach is valuable for healthcare facilities in remote areas with limited access to specialist radiologists.

Keywords: Attention Blocks, Data Augmentation, Data Preprocessing, Deep Learning, Heat Maps, U-Net Architecture,

ÖNSÖZ

Tez çalışmam boyunca bilgi, deneyim ve kıymetli yönlendirmeleriyle bana yol gösteren, her aşamada desteğini hissettiren değerli danışmanım Dr. Öğretim Üyesi Betül UZBAŞ'a en içten saygılarımı sunar, kendisine sonsuz teşekkürlerimi iletirim.

Bu süreçte sabırları, sevgileri ve destekleriyle daima yanımda olan kıymetli aileme de minnettar olduğumu belirtir, şükranlarımı sunarım.

Mehmet KOCAKUŞ
KONYA-2025



İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER.....	vii
SİMGELER VE KISALTMALAR.....	ix
1. GİRİŞ.....	1
2. KAYNAK ARAŞTIRMASI	4
2.1. Veri Ön İşleme Ve Veri Artırma Yöntemleri	4
2.2. Panoramik Radyografiler Üzerinden DÖ Uygulamaları	4
2.3. Dikkat Blokları Ve Isı Haritaları	5
3. MATERYAL VE YÖNTEM.....	8
3.1. Veri Seti	8
3.2. Çalışma Ortamı	9
3.3. Veri Ön İşleme.....	10
3.3.1. CLAHE	10
3.3.2. Otsu Filtreleme	11
3.3.3. Adaptif Otsu Filtreleme	13
3.4. Veri Artırma.....	13
3.5. Derin Öğrenme	14
3.6. ESA.....	15
3.6.1. Evrişim (Konvolüsyon) Katmanı.....	15
3.6.2. Adım (Stride)	16
3.6.3. Dolgu (Padding).....	16
3.6.4. Havuzlama Katmanı	18
3.6.5. Aktivasyon Fonksiyonları.....	18
3.6.6. Tam Bağlantı Katmanlar ve Çıktı	19
3.7. U-Net Mimarisi.....	19
3.7.1. Kodlama Aşaması (Encoder / Downsampling Path)	20
3.7.2. Dar Boğaz (Bottleneck)	20
3.7.3. Kod Çözme Aşaması (Decoder / Upsampling Path)	20
3.7.4. Çıkış Katmanı	21
3.8. Dikkat Blokları İle U-Net Model Geliştirmesi	21
3.9. Isı Haritalarının Kullanılması	21
3.10. Değerlendirme Metrikleri	22
3.10.1. Dice Skor	22
3.10.2. PA Skor.....	22

3.10.3. IoU Skor (Jaccard İndeksi)	23
4. DENEYSEL ÇALIŞMALAR.....	24
5. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	40
6. SONUÇLAR VE ÖNERİLER	46
KAYNAKLAR	48



SİMGELER VE KISALTMALAR

Kısaltmalar

AI :Artificial Intelligence

BB :Blok Boyutu

CBCT :Cone Beam Computed Tomography (Konik Işınlı Bilgisayarlı Tomografi)

CBAM : Convolutional Block Attention Module (Evrişimsel Blok Dikkat Modülü)

CGAN :Conditional Generative Adversarial Network (Koşullu Üretici Çekişmeli Ağ)

CLAHE :Contrast-Limited Adaptive Histogram Equalization (Kontrast Sınırlamalı Adaptif Histogram Eşitleme)

CL :Clip Limit (Kırpma Limiti)

DÖ :Derin Öğrenme

ESA :Evrişimsel Sinir Ağları

Faster R-CNN :Faster Region Based Convolutional Networks (Hızlandırılmış Bölge Tabanlı Evrişimsel Sinir Ağları)

GAN :Generative Adversarial Network (Üretici Çekişmeli Ağ)

GRAD-CAM :Gradient-Weighted Class Activation Mapping (Gradyan Tabanlı Sınıf Aktivasyon Haritası)

IOU :Intersection over Union (Kesişim Üzerine Birleşim Oranı)

LR :Düşük Çözünürlüklü

PA :Piksel Doğruluğu

SCGAN : Semi-Coupled Generative Adversarial Network

TGS :Tile Grid Size (Döşeme Izgara Boyutu)

ViT :Vision Transformer (Görüntü Dönüştürücü)

YSA : Yapay Sinir Ağları

YZ :Yapay Zeka

1. GİRİŞ

Dijital görüntüleme teknolojilerinin gelişmesiyle birlikte, sağlık alanında kullanılan tanı araçlarının çeşitliliği ve doğruluk düzeyi önemli ölçüde artmıştır. Bu araçlar arasında radyografik görüntüler, tıbbi tanı süreçlerinde sıklıkla başvuru alan ve birçok uzmanlık alanında standart olarak kullanılan temel görüntüleme yöntemlerinden biri hâline gelmiştir. Diş hekimliğinde ise panoramik radyografiler, hastanın tüm ağız yapısının tek bir görüntüde elde edilebilmesine olanak sağlaması sebebiyle hem ekonomik hem de tanı açısından oldukça verimli bir görüntüleme yöntemidir. Ancak görüntü kalitesi, kullanılan cihazın marka ve modeli, hastanın pozisyonu, ışığın geliş açısı, görüntüleme sırasında oluşan hareket gibi dışsal faktörlerden büyük ölçüde etkilenmektedir. Bu durum, görüntüdeki anatomik yapıların sınırlarının belirsizleşmesine neden olarak hekimin yorumuna dayalı teşhis sürecini zorlaştırmakta ve hata payını artırmaktadır (Litjens ve diğ., 2017).

Dijital görüntü işleme ve YZ tekniklerinin tıbbi görüntü analizinde devreye girmesi, insan gözünün sınırlarını aşan daha hassas ve tekrarlanabilir analizlerin yapılabilmesini mümkün kılmıştır. Son yıllarda özellikle DÖ tabanlı modellerin tıbbi görüntüler üzerindeki başarısı, bu alandaki araştırmaların hızla artmasına neden olmuştur (Litjens ve diğ., 2017). DÖ, büyük miktarda veriden karmaşık özellikleri öğrenebilme kabiliyeti sayesinde görüntü sınıflandırma, segmentasyon, obje tanıma ve benzeri birçok görevde geleneksel yöntemlerden daha yüksek performans göstermektedir. Özellikle Evrişimsel Sinir Ağları (ESA), görsel verilerin analizi konusunda ön plana çıkmaktadır. Bu çerçevede geliştirilen U-Net mimarisi, medikal görüntü segmentasyonu için özel olarak tasarlanmış ve sınırlı sayıda etiketli veriye sahip durumlarda dahi yüksek doğrulukla segmentasyon yapabilen bir yapıdadır (Ronneberger, ve diğ., 2015).

U-Net, encoder-decoder mimarisi ile hem düşük seviye hem de yüksek seviye öznetelikleri birleştirerek segmentasyon başarısını artırmakta, bu yönüyle özellikle medikal görüntülerin detaylı analizinde öne çıkmaktadır (Ronneberger ve diğ., 2015). Literatürde yapılan birçok çalışmada, U-Net ve türevlerinin beyin tümörlerinin belirlenmesi, akciğer nodüllerinin saptanması, cilt lezyonlarının segmentasyonu gibi çeşitli medikal görüntüleme problemlerinde yüksek başarı sağladığı gösterilmiştir. Bununla birlikte, diş hekimliği özelinde yapılan çalışmalar daha sınırlıdır. Dental

radyografik görüntüler hem düşük kontrast içermesi hem de benzer anatomik yapıların yoğunluğu nedeniyle segmentasyon işlemi açısından ayrı bir zorluk barındırmaktadır. Dişlerin sınırlarının net olmaması, üst üste binmiş anatomik yapılar ve görüntü gürültüsü gibi nedenlerle manuel segmentasyon süreci zahmetli ve zaman alıcıdır. Bu sebeple, otomatik segmentasyon çözümleri bu alanda büyük önem taşımaktadır.

Diş segmentasyonu, dental görüntüler üzerinde her bir dişin konumunun ve sınırlarının belirlenmesi işlemidir. Bu işlem, yalnızca tanı süreçlerinde değil; ortodontik tedavi planlaması, implant yerleştirme, cerrahi müdahaleler ve ağız-diş sağlığı takibinde de kritik rol oynamaktadır. Ancak bu segmentasyonun doğru bir şekilde yapılabilmesi için yeterli kalitede veri ve uygun modelleme yöntemleri gereklidir. Sağlık alanında veriye erişim, etik ve yasal sınırlılıklar nedeniyle oldukça kısıtlıdır. Özellikle kişisel sağlık verilerinin korunmasına yönelik düzenlemeler, araştırmacıların geniş ve nitelikli veri setlerine ulaşmasını engelleyebilmektedir (Litjens ve diğ., 2017). Bu bağlamda, sınırlı veri ile çalışan modellerin performansını artırmak için veri ön işleme ve veri artırma gibi yöntemlerin uygulanması kaçınılmaz hâle gelmiştir.

Görüntü ön işleme, modelin daha sağlıklı öğrenmesini sağlamak amacıyla görüntülerin yapay olarak iyileştirilmesini kapsar. Bu kapsamda uygulanan yöntemler arasında CLAHE gibi kontrast iyileştirme algoritmaları, gürültü azaltma için Gauss filtresi, histogram eşitleme gibi teknikler sayılabilir. Ayrıca veri artırma yöntemleri, özellikle DÖ modellerinin aşırı öğrenmesini (overfitting) önlemek adına sıkça başvurulan bir stratejidir. Aynalama (flipping), döndürme (rotation), yakınlaştırma (zooming) gibi geometrik işlemler sayesinde sınırlı sayıdaki veri çok sayıda varyasyon hâline getirilebilmekte, böylece modelin genelleme gücü artırılmaktadır (Litjens ve diğ., 2017).

Bu yüksek lisans tezinde, veri ön işleme, veri artırma, ısı haritaları ve dikkat bloklarının etkinliği Tufts Üniversitesi tarafından oluşturulan dental panoramik görüntülerden oluşan Tufts Dental Image Database kullanılarak test edilmiştir. Veri seti, 1000 adet farklı panoramik diş radyografisi ve bu görüntülere ait uzmanlar tarafından etiketlenmiş diş maskelerini içermektedir. Bu görüntüler eğitim (%85) ve test (%15) olmak üzere ikiye ayrılarak U-Net mimarisiyle eğitim gerçekleştirilmiştir. Eğitim aşamasında, veri ön işleme ve veri artırma teknikleri klasik U-Net ve dikkat blokları kullanılarak oluşturulan Attention U-Net ile farklı kombinasyonlar hâlinde

uygulanmıştır. Modelin başarısı Dice skoru, IoU skoru ve PA skoru gibi yaygın değerlendirme metrikleriyle ölçülmüştür. Elde edilen test sonuçlarına göre, klasik U-Net mimarisi kullanılarak CLAHE ön işleme ve aynalama veri artırma yöntemiyle 1700 eğitim veri sayısına ulaştıktan sonra Dice skor %91.02, IoU skor %83.51 ve PA skor %97.86 olarak gözlemlenmiştir. Diğer yöntemde ise Attention U-Net ile dikkat blokları kullanılarak CLAHE ön işleme ve veri artırma yapılmadan 850 eğitim görüntüsü üzerinden model eğitilmiş Dice skoru %91.01, IoU skoru %83.51 ve PA skoru %97.86 olarak gözlemlenmiştir. Gradyan Tabanlı Sınıf Aktivasyon Haritası (Gradient-weighted Class Activation Mapping, Grad-CAM) kullanılarak Attention U-Net ile eğitilen modellerin eğitim sırasında odaklandığı bölgeler incelenmiştir. Bu durum, uygun ön işleme ve veri artırma stratejilerinin, U-Net ve Attention U-Net gibi güçlü bir derin öğrenme mimarisiyle birlikte kullanıldığında dental segmentasyon performansını anlamlı ölçüde artırabileceğini ortaya koymaktadır.

Literatürde, benzer çalışmalar çoğunlukla tek bir ön işleme veya segmentasyon tekniği üzerine odaklanmış olup, yöntemlerin bir arada değerlendirilmesine dair karşılaştırmalı analizler sınırlıdır. Ayrıca, dental görüntüler üzerine yapılan çalışmaların büyük kısmı küçük veri setleriyle sınırlı kalmış, bu da sonuçların genellenebilirliğini kısıtlamıştır. Bu tez, dental radyografiler üzerinde yüksek doğrulukta segmentasyon elde edilebilmesi amacıyla, veri ön işleme teknikleri (örneğin CLAHE, Otsu ve adaptif Otsu), veri artırma yöntemleri (örneğin aynalama ve döndürme) ile dikkat bloklarının bir arada kullanılarak U-Net mimarisinin optimize edilmesini hedeflemektedir. Böylece hem akademik literatüre katkı sağlanmakta hem de diş hekimliği alanında kullanılabilecek pratik ve güvenilir bir yapay zekâ tabanlı analiz sunmaktadır.

2. KAYNAK ARAŞTIRMASI

2.1. Veri Ön İşleme ve Veri Artırma Yöntemleri

Literatürde DÖ tabanlı segmentasyon çalışmalarından önce uygulanan görüntü ön işleme tekniklerinin, segmentasyon başarısını artırmada etkili olduğunu gösteren çok sayıda sağlık temelli çalışma mevcuttur. Panetta ve diğ. (2022), tıbbi görüntülerin iyileştirilmesi amacıyla farklı kontrast artırma yöntemlerini karşılaştırmış, CLAHE yönteminin diğerlerine kıyasla daha iyi performans gösterdiğini ortaya koymuşlardır. Benzer şekilde, Zannah ve diğ. (2024) diş numaralandırma üzerine yaptıkları çalışmada, CLAHE uygulanmasının ardından histogramın dengeli bir şekilde eşitlenmesinin segmentasyon kalitesini artırdığını bildirmişlerdir. Helli ve Hamamcı (2022) ise 116 panoramik diş görüntüsü ile Adam optimizasyonu kullandıkları U-Net modelini 250 epok boyunca eğitmiştir. Yatay ve dikey çevirme, rastgele tuz ve biber gürültüsü ekleme gibi veri artırma teknikleri uygulanmış ve ön işlem olarak Lanczos filtresi kullanılmıştır. Morfolojik işlemler ve Otsu yöntemi ile maskeler optimize edilmiştir. Bu çalışmada %99 hassasiyet oranı ile önemli bir başarı göstermiş, veri sayısının az olmasına rağmen veri artırma ile %96 hassasiyet elde edilmiştir.

2.2. Panoramik Radyografiler Üzerinden DÖ Uygulamaları

Literatürde DÖ modelleri kullanılarak sağlık alanında radyografiler üzerinden birçok segmentasyon çalışması gerçekleştirilmiştir. Mertoğlu ve diğ. (2023) 200 panoramik radyografi içeren veri setinde Faster R-CNN tabanlı yöntemle %98 F1 skor başarısına ulaşmışlar; Kılıç ve diğ. (2021) çocuklarda süt dişlerinin otomatik algılanması için geliştirdikleri DÖ modelini 421 panoramik görüntü üzerinde eğitmişler ve %96 F1 skor elde etmişlerdir. Chen ve diğ. (2021) bulanık sınır sorunlarını aşmak için çok ölçekli konum algılama ağını kullanmış ve %93 Dice skoruna ulaşmışlardır. Almalki ve diğ. (2022) dört farklı diş probleminin tespiti için veri artırma teknikleriyle 1200 yapay görüntü oluşturmuş ve YOLOv3 modeliyle %99 doğruluk elde etmişlerdir. Kabir ve diğ. (2022) ise 1240 periapikal ısıрма radyografisi üzerinde U-Net ile eksik diş içeren görüntülerde %94 doğruluk elde etmişlerdir.

Panoramik radyografik görüntüler üzerinde Karaoğlu ve diğ. (2023) tarafından yapılan çalışma 2702 görüntüyü eğitim, doğrulama ve test olarak bölümlendirmiş; Mask R-CNN tabanlı yöntemlerini üç aşamalı sezgisel algoritma ile geliştirmişlerdir. Bu yaklaşım %95 F1 skora ulaşarak geleneksel yöntemlere kıyasla anlamlı bir ilerleme sağlamıştır. Chen ve diğ. (2019) ise 1250 diş röntgenini üç veri setine ayırarak Faster R-

CNN modeli ile ortalama %91 IoU skor elde etmişlerdir. Luo ve diğ. (2021) tarafından yapılan derlemede DÖ tabanlı yöntemlerin stomatolojik görüntü segmentasyonunda büyük potansiyele sahip olduğunu vurgulamışlardır. Benzer şekilde, Bilgir ve diğ. (2021) 2482 panoramik radyografik görüntü üzerinde Faster R-CNN Inception V2 modelini 200.000 epok boyunca eğitmiş ve %96 F1 skor elde etmişlerdir. Görürgöz ve diğ. (2021) retrospektif olarak topladıkları 1686 periapikal diş radyografisi üzerinde önceden eğitilmiş GoogLeNet Inception v3 ESA modeli ve transfer öğrenme tekniklerini kullanmışlardır. Jaw sınıflandırma, bölge tespiti ve genel model olmak üzere üç aşamalı yöntemlerle %98 hassasiyet ve %87 F1 skor elde etmişlerdir. Privado ve diğ. (2020) ise DÖ tabanlı YZ yöntemlerinin diş hekimliğinde diş tespiti alanındaki başarılarını derlemişlerdir.

Farajollahi ve diğ. (2023) DÖ tabanlı ağız içi diş görüntülerinde kemik değişikliklerini tespit eden modelleri incelemiş ve destek vektör makinelerinin diğer yöntemlere göre üstün başarı gösterdiğini belirtmişlerdir. Kaya ve diğ. (2022) çocuklardan alınan 4545 diş radyografisinde YOLOv4 modeliyle %91 Dice skoru sağlamışlar; Ayhan ve diğ. (2023) ise YOLOv7 ESA modeliyle 1170 dijital bitewing görüntüsü üzerinde %99 F1 skor elde etmişlerdir. Verma ve diğ. (2020) protein görüntülerinde GAN tabanlı veri artırmanın makro ve mikro f1 skorlarında %2.7 ve %2.64 artış sağladığını göstermişlerdir.

Son yıllarda, özellikle 2024 ve 2025 yıllarında gerçekleştirilen araştırmalar, dental radyografilerde segmentasyonun doğruluğunu artırmaya yönelik derin öğrenme modellerinde kayda değer gelişmeler olduğunu göstermektedir. Özçelik ve diğ. (2024), yapılan çalışmada önerilen U-Net modeli ile %93.74 Dice skor başarısına ulaşmışlardır. Öcal ve Altundağ'ın (2025) panoramik diş görüntüleri üzerinden yaptıkları segmentasyon çalışmasında literatürde üreteç olarak kullanılan farklı U-Net modelleri karşılaştırılmış %98'e ulaşan yüksek doğruluk oranları elde etmişlerdir. Ayrıca, Sun ve diğ. (2024), klasik U-Net yapısını CBAM ve ViT bileşenleriyle entegre ederek segmentasyon kalitesini artırmışlar; bu, dikkat tabanlı ve transformer mimarilerinin medikal görüntü işleme alanındaki potansiyelini gözler önüne sermişlerdir.

2.3. Dikkat Blokları Ve Isı Haritaları

Son yıllarda DÖ mimarilerinde dikkat (attention) temelli yapılar, özellikle medikal görüntü segmentasyonu alanında model başarısını artırmada etkili bir yöntem olarak öne çıkmaktadır. Dikkat blokları, modelin sadece anlamlı bölgelere odaklanmasını sağlayarak, hem segmentasyon doğruluğunu hem de modelin genelleme

kabiliyetini artırmaktadır. Özellikle panoramik radyografik görüntüler gibi düşük kontrastlı, sınırlı veri içeren ve yapısal olarak karmaşık dental görüntülerde bu tür yapılar önemli avantajlar sunmaktadır. Kayaoğlu ve diğ. (2025) yapılan çalışmada lateral sefalometrik radyografilerde C2, C3 ve C4 servikal vertebralarının tespiti ve semantik segmentasyon için Attention-Res U-Net kullanılarak %95.06 IoU skoru ile diğer yöntemlere göre daha yüksek doğruluk elde etmişlerdir. Benzer biçimde, Sun ve diğ. (2024) tarafından yapılan çalışmada U-Net kodlayıcı mimarisi ile birlikte Evrişimsel Blok Dikkat Modülü (Convolutional Block Attention Module, CBAM) ve Görüntü Dönüştürücü, (Vision Transformer, ViT) kullanılarak, dikkat modüllerinin özellikle sınırlı veri senaryolarında model başarısını istatistiksel olarak anlamlı düzeyde artırdığını belirtmişlerdir. Dikkat modüllerinin U-Net'in özellikle decoder katmanlarında kullanılması, segmentasyon çıktılarında kenar netliğini ve küçük yapıların belirginliğini artırmakta etkili olmaktadır. Zhong ve diğ. (2025), U-Net mimarisine entegre ettikleri Grouped Attention modülü ile %93'ün üzerinde Dice skoru elde etmişler ve dikkat mekanizmalarının özellikle küçük diş yapılarının segmentasyonunda belirgin katkı sağladığını ortaya koymuşlardır. Bununla birlikte, modelin karar mekanizmasını görselleştirmeye yönelik olarak kullanılan Sınıf Aktivasyon Haritalama (Class Activation Mapping, CAM) ve Gradyan Ağırlıklı Sınıf Aktivasyon Haritaları (Gradient-weighted Class Activation Mapping, Grad-CAM) gibi ısı haritaları da literatürde önemli bir yer tutmaktadır. Grad-CAM, modelin segmentasyon kararını hangi uzamsal bölgelere dayandığını görsel olarak sunarak hem model çıktılarının yorumlanabilirliğini artırmakta hem de hatalı sınıflandırma alanlarının analizinde etkili olmaktadır (Suara ve diğ. 2024). Bu sayede, mimaride yapılacak iyileştirmeler ve veri işleme stratejileri daha sağlıklı bir şekilde planlanabilmektedir.

Genel olarak, güncel araştırmalar, DÖ temelli segmentasyon modellerinin performansını artırmada veri ön işleme, veri artırma ve gelişmiş mimarilerin etkisini vurgulamaktadır. Literatür incelendiğinde, son yıllarda diş segmentasyonu alanında önemli ilerlemeler kaydedilmesine rağmen, alanda hâlen bazı boşlukların mevcut olduğunu göstermektedir. Mevcut çalışmalarda veri ön işleme ve veri artırma yöntemleri genellikle sınırlı ölçekte ele alınmış olup, bu tekniklere yönelik kapsamlı karşılaştırmalı analizlere yeterince yer verilmemiştir. Kullanılan veri setlerinin çoğu, nispeten düşük sayıda görüntü içermektedir. Ayrıca, model açıklanabilirliği, dikkat

blokları ve segmentasyon kararlarının görselleştirilmesi (örneğin ısı haritaları aracılığıyla) üzerine yapılan araştırmalar, alanın gelişimi açısından önemli bir yere sahiptir.

Bu çalışmanın literatürdeki mevcut çalışmalardan ayıran temel özellik, veri ön işleme ve veri artırma tekniklerinin, dikkat blokları ve ısı haritaları ile birlikte U-Net tabanlı segmentasyon modeli ile sistematik bir şekilde entegre edilmesidir. Özellikle veri artırma yöntemleri, sınırlı sayıda ve dengesiz diş radyografisi verisi bulunan medikal görüntüleme alanında modelin genelleme kabiliyetini artırarak daha yüksek doğruluk elde edilmesini sağlamaktadır. Bununla birlikte, önerilen yöntemle veri ön işleme adımlarının optimizasyonu, modelin gürültüye karşı dayanıklılığını ve segmentasyon hassasiyetini artırarak sonuçların tutarlılığını güçlendirmektedir. Ayrıca dikkat blokları modelin anatomik olarak anlamlı bölgelere odaklanmasına olanak tanırken; ısı haritaları, modelin öğrenme sürecinin görsel olarak yorumlanmasına ve karar mekanizmasının şeffaflığının artırılmasına katkı sağlamaktadır. Bu bütünleşik yaklaşım, diş radyografilerinde otomatik segmentasyonun hem doğruluğunu hem de uygulanabilirliğini artırarak, klinik kullanım potansiyelini geliştirmektedir.

Genel olarak, bu güncel araştırmalar ve önerilen yöntem, DÖ tabanlı segmentasyon modellerinde veri işleme tekniklerinin performans iyileştirmesindeki kritik rolünü vurgulamaktadır.

3. MATERYAL VE YÖNTEM

3.1. Veri Seti

Bu çalışmada kullanılan veri seti, Tufts Üniversitesi Diş Hekimliği Fakültesi Hasta Kayıt Sistemi'nden temin edilen Tufts Dental Database (TDD) veri kümesine dayanmaktadır (Tufts,2017). TDD, tanı sistemlerinin doğruluğunu değerlendirmek ve karşılaştırmak amacıyla oluşturulmuş, multimodal yapıya sahip panoramik diş radyografisi veri setidir.


Veri toplama protokolü, Tufts Üniversitesi Kurumsal Araştırma Kurulu (Institutional Research Board) tarafından onaylanmıştır (IRB ID: MODCR-01-12631, onay tarihi: 14 Temmuz 2017). Çalışma kapsamında 1 Ocak 2014 ile 31 Aralık 2016 tarihleri arasında alınan panoramik radyografiler değerlendirilmiştir. Toplamda 1000 adet dijital panoramik radyografi, Tufts Üniversitesi Diş Hekimliği Fakültesi'nin elektronik hasta kayıt sistemi olan *axiUm* üzerinden rastgele seçilmiştir. Rastgele seçim, bu tarih aralığında alınmış radyografilerin işlem kodlarına dayalı olarak yapılmıştır. Radyografilerin seçiminde dâhil etme kriteri, tanısal açıdan optimal görüntü kalitesine sahip olmaları ve teknik hata içermemeleridir. Seçilen görüntüler kimlik bilgileri gizlenmiş (de-identified) şekilde ve TIFF/JPEG formatında, kaydedilmiştir. Görüntüler, bir radyoloji uzmanı ve bir son sınıf diş hekimliği öğrencisi tarafından Labelbox yazılımı kullanılarak etiketlenmiştir. Etiketleme sürecine ek olarak göz takip verileri ve ses kayıtları da toplanmıştır. Panoramik radyografiler Instrumentarium Imaging OP100 Orthopantomograph ve Planmeca Promax 2D (Henry Schein) adlı iki farklı dijital panoramik görüntüleme cihazı ile elde edilmiştir. Her iki cihaz da klinik standartlara uygun şekilde dijital radyografi çekimi sağlamaktadır. Görüntülerin kalite ve kontrast düzeyinin yeterli olması için otomatik pozlama kontrolü (automatic exposure control) kullanılmıştır (Panetta ve diğ., 2022). Tufts üniversitesinden talepte bulunularak gönderilen linkten veri seti temin edilmiştir (Anonim, 2025).

Veri setinde yer alan panoramik radyografiler, Tufts Üniversitesi Diş Hekimliği Fakültesi'nde tedavi görmüş hastalara aittir. Radyografiler, klinik gereksinimler doğrultusunda hekimler tarafından tanısal amaçla çekilmiştir. Katılımcıların kimlikleri gizlenmiş olup, yaş veya cinsiyet gibi demografik bilgiler veri setinde açıkça yer

almamaktadır. Ancak veriler, çeşitli yaş ve cinsiyet gruplarından gelen hastalara ait olup, rastgele seçilen 1000 radyografiden oluşmaktadır. Bu çalışma için veri seti %85 eğitim ve %15 test olarak bölümlenmiştir.

Şekil 3.1.'de verilen görselde veri seti 6 ana bileşenden oluşmaktadır.

- a) Radyografi
- b) Anormalliği özetleyen parçalı maske
- c) Gri tonlama göz izleme bakış grafiği
- d) Renkli nicelenmiş göz izleme bakış grafiği
- e) Diş maskesi
- f) Maksillomandibular bölge



Şekil 3.1. Veri setine ait görseller (Panetta ve diğ., 2022)

3.2. Çalışma Ortamı

Çalışma kapsamında Intel Core I7 işlemcili 16GB RAM ve 256GB SSD bulunan bir bilgisayarda YZ modelleri eğitilip sonuçlar kontrol edilmiştir. IntelliJ DataSpell derleyici üzerinde Python programlama dilinde eğitim ve raporlama sürecinde Keras, TensorFlow ve Sklearn gibi kütüphanelerden destek alınarak model oluşturulmuştur.

Eğitim ve raporlama sürecinde IntelliJ DataSpell ide üzerinde python programlama dili ile kod geliştirmesi yapılmıştır. Çalışmada, model geliştirme ve analiz süreçlerinde Keras, TensorFlow ve Scikit-learn gibi yaygın olarak kullanılan açık kaynak kütüphanelerden yararlanılmıştır.

3.3. Veri Ön İşleme

Veri ön işleme, veri analizi ve makine öğrenimi uygulamalarında kritik bir aşamadır (Alwin ve Jayaraman, 2023). Bu süreç, ham verilerin daha anlamlı ve analiz edilebilir hale getirilmesi için çeşitli tekniklerin uygulanmasını içerir. Veri ön işleme, özellikle tıbbi görüntüleme ve elektronik sağlık kayıtları gibi alanlarda, verilerin kalitesini artırmak ve analiz süreçlerini optimize etmek amacıyla büyük önem taşır. Veri seti üzerinden yapılan birtakım işlemler verileri DÖ modelimize hazır hale getirir.

3.3.1. CLAHE

Histogram eşitleme, bir görüntünün parlaklık değerlerini kullanarak dinamik aralığını genişletir ve böylece kontrastını iyileştirir. Özellikle radyografik görüntülerde, bu yöntem detayları daha net hale getirmek için kullanılır. CLAHE görüntüleri alt görüntülere bölerek, histogram eşitleme yaparak geliştirilen ön işleme yöntemidir (Kayadibi ve diğ., 2024). Radyografik görüntülerde parlaklık değerlerini eşitleyerek, görüntülerin aydınlatma koşullarına göre değişiklik gösteren kontrast seviyelerini düzenlemek için kullanılır. Kırpma eşikleri kullanılarak kırılan bölümler eşit histogramlara bölünerek her bir parçanın histogramları iyileştirilir (Sezgin ve diğ., 2023). Radyografik görüntülerin arka planlarını da ön plan olarak geliştirerek yüksek kontrastlı görüntüler elde edilir. Özellikle medikal görüntülerde CLAHE gürültüyü engelleyerek, görüntünün kontrastını önemli oranda iyileştirir ve görüntünün kenar özelliklerinin keskinliklerini korur (Kayadibi ve diğ., 2024).

CLAHE uygulanırken görüntü genellikle $M \times N$ boyutlarında küçük alt bloklara bölünür. Bölünen her bloğa tile adı verilir. Her tile için temel histogram eşitleme uygulanır. Histogram eşitlemede kullanılan denklem 3.1.'de verilmiştir. Burada:

s_k : eşitlenmiş gri seviyeleri

L : toplam gri seviye sayısı

$h(j)$: gri seviye frekansı

MN : tile bölgesindeki toplam piksel sayısı

$$sk = \text{round}\left(\frac{(L-1)}{MN}\right) \sum_{j=0}^k h(j) \quad (3.1)$$

Transfer fonksiyonuyla histogram eşitlendikten sonra her histogram için bir clip limit (CL) belirlenir. Bu limitin üzerindeki histogram değerleri kırpılır ve kırpılan toplam değer, diğer gri tonlara eşit şekilde dağıtılır. Bu işlem gürültüyü azaltmak için gereklidir.

Eğer clip limit T_c olarak belirlenmişse:

$$h_{clipped}(i) = \min(h(i), T_c) \quad (3.2)$$

Aşan değerler:

$$E = \sum_{i=0}^{L-1} \max(0, h(i) - T_c) \quad (3.3)$$

Bu fazla değer L gri seviyeye eşit olarak dağıtılır. CLAHE'nin bir diğer önemli parametresi ise Tile Grid Size (TGS)'dir. Bu parametre görüntünün kaç alt parçaya bölüneceğini belirler. Küçük tile grid boyutları (ör. 8×8) daha lokal kontrast iyileştirmesi yaparken, bu durum aynı zamanda gürültünün artmasına neden olabilir. Daha büyük tile grid boyutları (ör. 16×16) ise global kontrast iyileştirmesi sağlar fakat lokal detaylarda kayıplar yaşanabilir (Pisano ve diğ., 1998).

3.3.2. Otsu Filtreleme

Otsu eşikleme yöntemi, Nobuyuki Otsu tarafından 1979 yılında geliştirilmiş bir görüntü işleme tekniğidir ve özellikle gri seviye görüntülerde nesne ve arka plan ayrımını otomatikleştirmek için kullanılır (Otsu, 1979). Bu yöntem, görüntüdeki piksel yoğunluklarına dayalı olarak optimum eşik değerini hesaplayarak görüntüyü iki sınıfa; ön plan ve arka plan ayırır. Özellikle tıbbi radyografik görüntülerde, detaylı yapıların arka plandan ayrıştırılmasında yaygın biçimde kullanılmaktadır.

Otsu yöntemi, kümeleme tabanlı bir eşikleme tekniği olup, histogram analizine dayanır. Her olası eşik değeri t için sınıflar arası varyansı (inter-class variance) hesaplanır ve bu varyansı maksimize eden eşik değeri seçilir. Bu değeri, sınıflar arası ayrımın en yüksek olduğu eşik noktasıdır.

Eşik değeri t olarak tanımlandığında, görüntüdeki pikseller arka plan (sınıf 1: $[0, t]$) ve ön plan (sınıf 2: $[t+1, L-1]$) olacak şekilde iki sınıfa ayrılır. Her eşik değeri için sınıf olasılıkları $w_0(t)$ ve $w_1(t)$, sınıf ortalamaları $u_0(t)$ ve $u_1(t)$, toplam ortalama gri seviye u_T , ve sınıflar arası varyans denklem 3.4.'den itibaren verilen denklemlerle tanımlanır. (Otsu, 1979):

t : Eşik değeri (0 ile $L-1$ arasında)

L : Gri seviye aralığı (genellikle 256)

$p(i)$: i . gri seviye değerinin normalize histogram değeri (Olasılık olarak yorumlanır)

$w_0(t)$: Eşik t 'ye kadar olan piksellerin (sınıf 0 / arka plan) toplam olasılığı

$w_1(t)$: Eşik t 'den sonraki piksellerin (sınıf 1 / ön plan) toplam olasılığı

$$w_0(t) = \sum_{i=0}^t p(i), \quad w_1(t) = \sum_{i=t+1}^{L-1} p(i) \quad (3.4)$$

Denklem 3.5.'de sınıf ortalama yoğunlukları verilmiştir.

$u_0(t)$: Arka plan sınıfının (sınıf 0) ortalama gri seviye değeri

$u_1(t)$: Ön plan sınıfının (sınıf 1) ortalama gri seviye değeri

$$u_0(t) = \frac{1}{w_0(t)} \sum_{i=0}^t i.p(i), \quad u_1(t) = \frac{1}{w_1(t)} \sum_{i=t+1}^{L-1} i.p(i) \quad (3.5)$$

Denklem 3.6.'da u_T ile görüntünün tüm piksellerinin ortalama gri seviye değeri hesaplanmaktadır.

$$u_T = \sum_{i=0}^{L-1} i.p(i) \quad (3.6)$$

Denklem 3.7.'de sınıflar arası varyans hesaplanarak eşikleme başarısı bulunur. Varyans ne kadar büyükse sınıflar o kadar ayrılmıştır. Bu değer maksimum olduğunda en uygun eşik değeri bulunmuş olur.

$$\sigma_b^2(t) = w_0(t).w_1(t).[u_0(t) - u_1(t)]^2 \quad (3.7)$$

Denklem 3.8.'de en uygun eşik değeri sınıflar arası varyansı maksimum yapan t değeri bulunur.

$$t^* = \operatorname{argmax}_t a_b^2(t) \quad (3.8)$$

3.3.3. Adaptif Otsu Filtreleme

Otsu eşikleme yöntemi, bir görüntüyü arka plan ve ön plan olmak üzere iki sınıfa ayırmak için otomatik olarak optimal bir eşik değeri belirler. Bu yöntem, görüntüdeki piksel yoğunluk histogramını analiz ederek sınıf içi varyansı (intra-class variance) minimize edecek şekilde eşik değeri seçer. Ancak klasik Otsu yöntemi, görüntünün tümüne tek bir eşik değeri uyguladığı için düşük aydınlatmalı ve değişken kontrastlı bölgelerde yetersiz kalabilir.

Adaptif Otsu yöntemi, görüntüyü küçük pencerelere (örneğin 64×64 veya 128×128 piksellik blok boyutlarına (BB)) ayırarak her bölgeye lokal otsu eşikleme uygular. Böylece, değişken aydınlatma koşullarında bile etkili segmentasyon sonuçları elde edilir.

Adaptif Otsu yöntemiyle lokal histogram analizleri sayesinde, kontrastı düşük dış yapılarının daha net biçimde segmentasyonu mümkün hale gelir.

Bu yöntemin avantajı şunlardır:

- Global aydınlatma değişimlerinden etkilenmez.
- Dışların parlaklık farklılıkları olan bölgelerde detayları korur.
- Segmentasyon sonrası etiket kalitesi artar.

3.4. Veri Artırma

Veri artırma (data augmentation), sınırlı sayıda etiketli veriye sahip DÖ uygulamalarında modelin genelleme yeteneğini geliştirmek amacıyla kullanılan yaygın bir tekniktir. Bu yaklaşım, mevcut görüntüler üzerinde çeşitli geometrik ve fotometrik dönüşümler uygulanarak sentetik örnekler üretir ve böylece modelin overfitting (aşırı öğrenme) eğilimi azaltılır. Ayrıca, farklı varyasyonlara sahip görüntülerle eğitim yapılması, modelin gerçek dünya verilerindeki çeşitliliğe karşı daha dayanıklı hale gelmesini sağlar (Shorten ve Khoshgoftaar, 2019).

Bu çalışmada, panoramik dental radyografilerde diş segmentasyonu amacıyla eğitilen U-Net modelinin başarısını artırmak için çeşitli veri artırma stratejileri uygulanmıştır. Özellikle görüntüler üzerinde aynalama (flipping), farklı açılarda döndürme (5° ve 10° derece sağ-sol dönüş) ve x eksenini üzerinde negatif-pozitif yönlü kaydırmalar (translation) gerçekleştirilmiştir. Bu dönüşümler, özellikle dental panoramik görüntülerde simetrik yapının bulunması ve dişlerin farklı konumlarda ortaya çıkabilmesi nedeniyle anatomik anlamlılığını koruyarak veri çeşitliliğini artırmaktadır. Örneğin, aynalama işlemi, çene yapısının simetrik doğasından ötürü modelin sol ve sağ bölgelere aynı şekilde duyarlı hale gelmesini sağlar. Rotasyon ve kaydırma işlemleri ise, radyografilerde dişlerin farklı açılarda ya da pozisyonlarda görüntülenmesi durumlarını simüle ederek modelin konumsal varyasyonlara karşı daha dayanıklı olmasını destekler.

3.5. Derin Öğrenme

DÖ, Yapay Sinir Ağları'nın (YSA) çok katmanlı yapılarla genişletilmesi fikrinden doğmuş, özellikle büyük veri kümeleri ile karmaşık ilişkileri otomatik olarak öğrenebilme potansiyeli nedeniyle son yıllarda dikkat çekmiştir. Kavramsal olarak ilk kez Dechter (1986) tarafından tanımlanan bu yaklaşım, 1980'li yıllarda sınırlı donanım kapasitesi nedeniyle geniş çapta uygulama bulamamıştır (Detcher, 1986). Ancak 2000'li yılların sonlarına doğru, Hinton ve arkadaşlarının derin sinir ağlarını katman katman ön-eğitim (pre-training) yöntemiyle optimize etmeleri, bu yöntemin yeniden bilimsel ilgi odağı olmasına yol açmıştır (Cengil ve Çınar, 2016).

DÖ'nün temel avantajı, veriden anlamlı özelliklerin çıkarımını manuel olarak yapmak yerine bu süreci katmanlar aracılığıyla otomatikleştirmesidir. Geleneksel makine öğrenmesinde uzman bilgisi gerektiren öznitelik mühendisliği süreci, DÖ sayesinde doğrudan verinin kendisinden öğrenilebilmektedir. Örneğin bir görüntü işleme problemi kapsamında, ham piksel değerlerinden kenar, şekil ve nesne gibi üst düzey soyut temsiller kademeli olarak öğrenilebilir (Şeker ve diğ., 2017). Bu özellik, özellikle tıbbi görüntüleme gibi karmaşık veri yapılarına sahip alanlarda büyük bir avantaj sağlamaktadır.

DÖ mimarileri, dental görüntülerde nesne tespiti ve sınıflandırma görevlerinde yüksek doğruluk sağlamaktadır (Jader ve diğ., 2022). Özellikle ESA, panoramik ve

Burada:

- I: giriş görüntüsü
- K: filtre (kernel)
- S: özellik haritası
- m,n: filtre boyutları

Evrişim işlemi, görüntünün lokal örüntülerini yakalamayı sağlar ve böylece model, dış gibi belirli morfolojik yapılara karşı duyarlı hale gelir. Bu işlem sırasında evrişim katmanının davranışını belirleyen iki temel parametre öne çıkar: adım (stride) ve dolgu (padding).

3.6.2. Adım (Stride)

Adım, filtrenin giriş görüntüsü üzerinde her adımda ne kadar ilerleyeceğini belirleyen bir parametredir. Stride değeri 1 olduğunda, filtre her pikseli hesaba katarak maksimum ayrıntıyı yakalamaya çalışır. Stride değeri artırıldığında ise, filtre daha büyük adımlarla ilerler ve böylece çıktı boyutu küçülür. Bu durum, modelin işlem yükünü azaltırken uzamsal çözünürlükte bilgi kaybına neden olabilir. U-Net gibi semantik segmentasyon mimarilerinde genellikle stride değeri 1 seçilerek, özellikle düşük seviye konumsal detayların kaybolmaması sağlanır (Ronneberger ve diğ., 2015; Dumoulin ve Visin, 2016).

3.6.3. Dolgu (Padding)


Dolgu, evrişim işlemi sırasında kenar piksellerin işlem dışı kalmaması ve çıktı boyutunun kontrol edilebilmesi için giriş görüntüsünün çevresine eklenen piksel dolgularıdır. İki yaygın dolgu türü mevcuttur:

- **Valid padding:** Girişin etrafına dolgu yapılmaz; bu durumda her evrişim işlemi çıktının boyutunu azaltır.
- **Same padding:** Girişin etrafına uygun miktarda sıfır eklenerek, çıktı boyutunun girişle aynı kalması sağlanır.

U-Net gibi encoder-decoder mimarilerinde same padding, çıktı boyutlarının giriş ile uyumlu olmasını sağlayarak, özellikle "skip connection" (atlama bağlantısı) yoluyla bilgi aktarımının simetrik şekilde yürütülmesine katkı sunar (Çiçek ve diğ., 2016). Bu


sayede kenar bölgelerindeki önemli anatomik yapılar korunur ve modelin segmentasyon başarımı artar.

Örneğin, 256×256 boyutlarında gri seviyeli bir panoramik diş görüntüsü ele alındığında ve bu görüntüye 3×3 boyutunda bir filtre uygulandığında, uygun padding ve stride değeri ile çıktı boyutu korunabilir. "Sıfır dolgusu" (zero-padding) kullanılarak orijinal boyutun korunması mümkündür. Şayet dolgu = 1 ve adım = 1 olarak seçilirse, 3×3 'lük bir filtre uygulandığında çıktı boyutu da 256×256 olarak kalır. Şekil 3.3.'de evrişim uygulanmış bir diş görüntüsü görülmektedir.



Şekil 3.3. Dolgu ve adım 1 ayarlanarak uygulanan evrişim işlemi


Evrişim katmanları, özelliklerin yerel olarak öğrenilmesini sağlar ve bu sayede özellikle panoramik diş röntgenlerinde lokal yapıların (örneğin, diş konturları, çürük bölgeleri veya kök uzantıları) yakalanmasında son derece etkilidir (Linlin ve Liu, 2022). Evrişimsel işlemlerin ardışık olarak derinleştirilmesiyle, ağ daha soyut ve semantik olarak anlamlı temsiller elde edebilir. Şekil 3.4.'de evrişim katmanında gerçekleşen süreç görülmektedir.



Şekil 3.4. Evrişim katmanı (Amidi ve Amidi, 2019)

3.6.4. Havuzlama Katmanı

Ortalama değer ya da maksimum değer hesaplamasına göre bu katmanda filtreleme yapılmaktadır. Filtre boyutunun alanına giren piksel değerlerin toplamının filtre pencere boyutuna bölünmesiyle ortalama havuzlama işlemi çalışır. Maksimum havuzlamada filtre boyutunun bulunduğu alandaki piksel değerlerinin en büyüğüdür. Özellikle maksimum havuzlama, keskin geçişlerin olduğu (ör. dış sınırları) alanları koruyarak segmentasyon modellerinde tercih edilir (Arı ve Hanbay, 2019). Şekil 3.5.'de havuzlama katmanında işlemlerin nasıl uygulandığına dair bir görsel verilmiştir. (Arı ve Hanbay, 2019)



Şekil 3.5. Ortalama havuzlama ve maksimum havuzlama (Arı ve Hanbay, 2019)

3.6.5. Aktivasyon Fonksiyonları

Evrişimden sonra gelen aktivasyon fonksiyonları, öğrenilen özellikleri doğrusal olmayan yapıya dönüştürerek modelin karmaşık örüntüleri öğrenmesini sağlar. Denklem 3.10.'da en sık kullanılan aktivasyon fonksiyonu ReLU (Rectified Linear Unit) verilmiştir.

$$f(x) = \max(0, x) \quad (3.10)$$


ReLU, hem hesaplama açısından verimli hem de gradyan kaybı (vanishing gradient) problemini azaltıcı özelliktedir. U-Net ve türevlerinde evrişim katmanlarından sonra genellikle ReLU kullanılır (Ronneberger ve diğ., 2015).

3.6.6. Tam Bağlantı Katmanlar ve Çıktı

Tam bağlantılı katmanlar (fully connected), genellikle sınıflandırma görevlerinde kullanılırken; segmentasyon görevlerinde çıktı katmanı olarak sigmoid (binary sınıflar için) veya softmax (çoklu sınıflar için) aktivasyonları tercih edilir.

3.7. U-Net Mimarisi

Tıbbi görüntü segmentasyonu alanında yüksek doğruluklu ve piksel düzeyinde ayrıntılı çıktı elde etmeyi hedefleyen U-Net mimarisi, ilk olarak Ronneberger ve diğ. (2015) tarafından biyomedikal görüntüler için geliştirilmiştir. Mimari, sınırlı sayıda etiketli veriyle dahi güçlü performans sergilemesi nedeniyle, dış segmentasyonu da dahil olmak üzere pek çok medikal alanda yaygın olarak tercih edilmektedir (Falk ve diğ., 2019). Bu mimari, giriş görüntüsünü derin özellik temsillerine dönüştürerek ve bu temsilleri konumsal bilgi ile birlikte yeniden yapılandırarak segmentasyon çıktısı üretir. U-Net temel olarak üç ana bileşenden oluşur: kodlayıcı yol (encoder/downsampling path), dar boğaz (bottleneck) ve çözücü yol (decoder/upsampling path). Bu yapı, hem uzamsal hem de anlamsal bilgilerin birleştirilmesine olanak tanır. Özellikle simetrik yapısı ve atlama bağlantıları (skip connections) sayesinde hem düşük seviye detayları hem de yüksek seviyeli soyut temsilleri etkili bir şekilde işler. Şekil 3.6.'da temel U-Net mimarisi verilmiştir (Ronneberger ve diğ., 2015).



Şekil 3.6. U-Net Mimarisi (Ronneberger ve diğ., 2015)

3.7.1. Kodlama Aşaması (Encoder / Downsampling Path)

Kodlama kısmı, konvolüsyonel katmanlar ve maksimum havuzlama (max pooling) katmanlarından oluşur. Her kodlama bloğunda genellikle iki adet 3×3 evrişim katmanı ve ardından 2×2 boyutunda maksimum havuzlama işlemi uygulanır. Bu yapı, her adımda görüntü boyutunu yarıya indirirken, filtre sayısını genellikle iki katına çıkararak modelin derinliğini artırır. Evrişim katmanları, ReLU aktivasyon fonksiyonu ile çalışır ve derinleştikçe görüntüden daha soyut ve yüksek seviyeli özellikler çıkarılır. Maksimum havuzlama işlemi ise konumsal çözünürlüğü azaltırken, semantik anlamı yoğunlaştırır. Bu yapı, modelin çeşitli ölçeklerdeki yapıları tanımasını sağlar (Ronneberger ve diğ., 2015).

Örneğin, giriş görüntüsü 256×256 piksel çözünürlüğe sahipse, her havuzlama adımı ile bu boyutlar sırasıyla 128×128 , 64×64 , 32×32 ve 16×16 olarak düşer. Aynı anda katman derinliği artar; filtre sayısı genellikle 64'ten başlayıp 128, 256, 512 gibi katlanarak artar. Bu durum, düşük çözünürlükte daha karmaşık desenlerin öğrenilmesini mümkün kılar (Çiçek ve diğ., 2016).

3.7.2. Dar Boğaz (Bottleneck)

Kodlama ve çözme aşamaları arasında yer alan dar boğaz kısmı, ağın en derin katmanını oluşturur. Bu kısımda, en düşük çözünürlükte en soyut özellikler çıkarılır. Filtre sayısı en yüksek düzeye ulaşır (genellikle 1024), uzamsal boyut ise en düşük düzeydedir (örneğin 16×16). Yine iki adet 3×3 evrişim katmanı ve bir ReLU aktivasyonu kullanılır. Bu katmanlar, segmentasyon için gerekli olan temel yapısal bilgileri yoğunlaştırır ve ağın geri kalanında kullanılacak temel temsilin oluşturulmasını sağlar (Isensee ve diğ., 2021).

3.7.3. Kod Çözme Aşaması (Decoder / Upsampling Path)

Çözücü kısmı, kodlayıcıda kaybedilen uzamsal bilgileri yeniden yapılandırmak için tasarlanmıştır. Her çözümleme bloğu, ters evrişim (transposed convolution / up-convolution) katmanı ile başlar. Bu katman, özelliğin boyutunu iki katına çıkarır ve ardından iki adet 3×3 evrişim ve ReLU aktivasyonu takip eder. Bu işlemler ile detaylar yeniden kazanılır.

Çözücü kısmının en özgün özelliği, skip connection (atlama bağlantısı) yapısıdır. Kodlayıcıdaki karşılık gelen katmanlardan gelen yüksek çözünürlüklü özellik haritaları, çözücüdeki ilgili katmanlara doğrudan kopyalanarak birleştirilir. Bu sayede, düşük seviyeli konumsal bilgiler ve yüksek seviyeli semantik bilgiler aynı anda kullanılarak daha doğru segmentasyon sonuçları elde edilir (Ronneberger ve diğ., 2015). Bu yapı, özellikle dental panoramik görüntülerde kesişen kemik, diş ve doku sınırlarının belirgin kalmasını sağlar.

3.7.4. Çıkış Katmanı

Son aşamada, genellikle 1×1 boyutunda bir evrişim katmanı kullanılarak elde edilen çok kanallı özellik haritaları, sınıf sayısı kadar kanala indirgenir. Bu kanallar softmax veya sigmoid aktivasyon fonksiyonları ile normalize edilir ve her piksel için ait olduğu sınıf tahmin edilir. Bu yapı sayesinde, segmentasyon haritası piksel düzeyinde elde edilir. Diş segmentasyonu genellikle ikili sınıflandırma (diş / diş değil) olduğundan bu katmanda sigmoid aktivasyon fonksiyonu tercih edilir.

3.8. Dikkat Blokları İle U-Net Model Geliştirmesi

Her decoder katmanına yerleştirilen dikkat blokları, ilgili encoder katmanından gelen özellik haritaları ile birleştirilmeden önce bir dikkat haritası (attention map) oluşturarak daha seçici bilgi akışı sağlar. Bu yapı, özellikle panoramik radyografilerdeki düşük kontrastlı diş sınırlarının daha keskin şekilde segmentasyonuna olanak tanır. Dikkat blokları, kodlayıcıdan gelen uzamsal bilgilerin çözümleyici bölümde daha anlamlı yorumlanmasını sağlar; böylece sınır ayrımlarının iyileştirilmesini, segmentasyon maskelerinin kenar hassasiyetinin artırılmasını ve küçük anatomik yapıların daha yüksek doğrulukla tespitini mümkün kılar (Schlemper ve diğ., 2019). Dikkat blokları, modelin yalnızca anlamlı ve önemli piksel bölgelerine odaklanmasını sağlayarak gereksiz bilgi akışını sınırlar ve sınırlı sayıda görüntü içeren veri setlerinde modelin genelleme kabiliyetini artırır (Oktay ve diğ., 2018).

3.9. Isı Haritalarının Kullanılması

Grad-CAM yöntemi, segmentasyon modelinin karar verirken hangi görüntü bölgelerine odaklandığını görsel olarak ortaya koymakta ve modelin içsel öğrenme süreçleri hakkında değerli bilgiler sağlamaktadır (Selvaraju ve diğ., 2017). Bu yöntem

sayesinde modelin sınıflandırma ya da segmentasyon kararlarında hangi bölgesel özellikleri dikkate aldığı anlaşılabilmekte, böylece modelin yorumlanabilirliği artırılmaktadır. Özellikle tıbbi görüntüleme alanında, modelin yalnızca doğruluk düzeyi değil, aynı zamanda karar alma sürecinin şeffaflığı da klinik açıdan büyük önem taşımaktadır (Samek ve diğ., 2017). Ayrıca, Grad-CAM görselleştirmeleri modelin hatalı sınıflandırma veya eksik segmentasyon yaptığı durumlarda hata kaynaklarının analizine olanak tanımakta ve model iyileştirme süreçlerinde rehberlik etmektedir (Selvaraju ve diğ., 2017). Bu sayede, modelin hangi sınırlarda tutarsızlık yaşadığı veya hangi bölgeleri yanlış yorumladığı belirlenerek, eğitim verisinin veya model mimarisinin daha bilinçli bir şekilde yeniden yapılandırılması mümkün hale gelmektedir (Zhou ve diğ., 2016).

3.10. Değerlendirme Metrikleri

3.10.1. Dice Skor

Dice skor tahmin edilen ve etiketlenen bölgeler arasındaki birleşmeyi hesaplar. Tam bir birleşimde, birleşme alanının ne kadar doğru olduğunu bulur. Tahmin edilen bölge ile kesin referans arasındaki örtüşme tabanlı bir değer olup 0-1 arasında değerler alır. Eğer her iki alan birbirine eşitse 1'e eşittir ve mükemmel bir bölütlemenin olduğu söylenebilir (Baştuğ Koç ve Akgün, 2021). Radyografik görüntüler üzerinden özellikle tümör, lezyon gibi küçük alanların değerlendirmesinin yapılırken dice skor yöntemi ile çalışma yapmak daha net sonuçlar verecektir.

Denklem 3.11.'de verilen formülde

P: Modelin tahmin ettiği pozitif piksel sayısını

T: Gerçek pozitif piksel sayısını

$|P \cap T|$: Doğru tahmin edilen pozitif piksel sayısını $|P|$: Tahmin edilen pozitif piksel sayısını

$|T|$: Gerçek pozitif piksel sayısını ifade eder.

$$F1 = \frac{2 * |P \cap T|}{|P| + |T|} \quad (3.11)$$

3.10.2. PA Skor

PA skor karışıklık matrisinden hesaplanarak bulunan metriklerden biridir. Doğru sınıflandırılan verilerin tüm veri setine oranıdır. Doğru olarak sınıflandırılan görüntüdeki piksellerin oranını veren değerdir. Her sınıf için ayrı ayrı olarak hesaplanır.

Karışıklık matrisinde gerçek pozitif, hedef sınıfa (gerçek etikete göre) ait olan ve doğru şekilde tahmin edilen bir pikseldir. Gerçek negatifse hedef sınıfa ait olmayan ve doğru bir şekilde tahmin edilen pikseldir. Özellikle segmentasyon işlemlerinde kullanılan PA skor segmentasyonun ne kadar doğru olduğunu hesaplar. Bu yöntem kullanılırken dengesiz veri setlerine ve tümör, lezyon gibi küçük alanların sonuçlarına odaklanmak yanıltıcı olabilir.

Denklem 3.12.'de verilen formülde;

TP: Doğru pozitif tahmin edilen pikseller

TN: Doğru negatif tahmin edilen pikseller

FP: Modelin pozitif tahmin ettiği ama gerçekte negatif olan pikseller

FN: Modelin negatif tahmin ettiği ama gerçekte pozitif olan pikselleri ifade eder.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.12)$$

3.10.3. IoU Skor (Jaccard İndeksi)

IoU (Birleşim Üzerinden Kesişim) değeri Jaccard indeksi olarak da tanınır. Tahmin edilen maskelerin gerçek maskelerle birleşme yüzdesidir. Tahmin edilen maskeyle gerçek maske arasında kesişimin tüm birleşim alanına bölünmesiyle IoU hesaplanır. Bu metrik semantik bölütlemelerde sıklıkla kullanılır. Modelin tahmin ettiği bölge ile gerçek bölgenin ne kadar örtüştüğünü hesaplayarak sonuç üretir. Skor %50 üzerine çıkarsa başarılı kabul edilir. Özellikle diş çürükleri ya da tümör tespitleri yapılan bölgelerin doğruluğunu değerlendirmek için kullanılır.

Denklem 3.13.'de verilen formülde;

TP: Gerçek pozitif piksellerin model tarafından doğru tahmin edilmesi


FP: Modelin pozitif tahmin ettiği ancak gerçekte negatif olan pikseller

FN: Gerçekte pozitif olup modelin tahmin edemediği pikselleri ifade eder.

$$IoU = \frac{TP}{TP + FN + FP} \quad (3.13)$$


4. DENEYSEL ÇALIŞMALAR

Tez çalışması kapsamında radyografik diş görüntüleri üzerinden eğitilen U-Net modeli ile veri ön işleme, veri artırma tekniklerinin ve dikkat bloklarının model başarısına etkisi incelenmiştir. Yapılan çalışmanın grafiksel özeti Şekil 4.1.'de verilmiştir. Attention U-Net ile model eğitimi tamamlandıktan sonra Grad-CAM ve ısı haritaları kullanılarak modelin eğitim sırasında odaklandığı bölgeler incelenmiştir.




Şekil 4.1. Yapılan çalışmanın grafiksel özeti

Yapılan çalışmada önerilen yöntemde her bir dişin tespiti için çok katmanlı bir U-Net model kullanılmıştır. Model eğitime başlanmadan önce alınan görüntüler min-max normalizasyon, CLAHE, otsu, adaptif otsu v.b. ön işlemlerden geçirilmiştir. Şekil 4.2.'de örnek bir görsel üzerinden veri ön işleme aşamasından geçen görseller görülmektedir.



Şekil 4.2. Model eğitimi öncesi ön işlemeden geçirilen diş görüntüleri a) Orijinal görüntü, b) Min-max normalizasyon, c) CLAHE, d) Otsu, e) Adaptif Otsu,

Modelin başarısını artırmak için aynalama, pozitif ve negatif yönde 5,10 derece döndürme, kaydırma olmak üzere 3 farklı veri artırma yöntemi kullanılmıştır. Veri artırma işlemi model eğitiminden ayrı olarak yapılmıştır. Şekil 4.3.'de veri artırma sonrası örnek görseller verilmiştir.



Şekil 4.3. Veri artırmadan geçirilmiş diş görüntüleri a) Orijinal b) Veri artırma sonrası aynalanmış c) Veri artırma sonrası 5 derece sola döndürülmüş d) Veri artırma sonrası 5 derece sağa döndürülmüş e) Veri artırma sonrası 10 derece sola döndürülmüş f) Veri artırma sonrası 10 derece sağa döndürülmüş, g) Veri artırma sonrası x ekseninde 10 piksel sağa kaydırılmış h) Veri artırma sonrası x ekseninde 10 piksel sola kaydırılmış

1000 farklı görüntü %85 - %15 eğitim ve test olarak ayrılarak 850 orijinal eğitim görüntüsünden aynalama ile veri artırma yapıldıktan sonra 1700 dış görüntüsü ve etiketi, sol ve sağ yönde 5 ve 10'ar derecelik döndürme işlemlerinden sonra 2550 dış görüntüsü ve etiketi, x ekseninde pozitif ve negatif yönde 10 derece kaydırma sonrası 2550 dış görüntüsü ve etiketi elde edilmiştir.

Model başarısına veri ön işleme ve veri artırma parametrelerinin etkisini incelemek üzere hibrit bir eğitim çalışması da yapılmıştır. Hibrit eğitim çalışmasında ilk olarak orijinal görüntüler üzerinden veri artırma işlemi yapılan görüntüler dosyaya kaydedilmiştir. Daha sonra sentetik görüntüler ve orijinal görüntülerle birlikte ön işleme adımı uygulanan görüntülerin U-Net ve Attention U-Net model ile eğitim süreci başlatılmıştır.

Eğitim sürecinde konvolüsyon bloklarında aktivasyon fonksiyonu olarak ReLU output konvolüsyon bloğunda Sigmoid aktivasyon fonksiyonu kullanılmıştır. Model 100 epok boyunca eğitilip Adam optimizasyonu kullanılmıştır. Eğitilen model .h5 formatında dosyaya kaydedilip eğitim süreleri .txt dosyasına kaydedilmiştir.

U-Net modeli ile eğitilen her bir model raporlama fonksiyonlarına verilerek dice skor, IoU skor ve PA skorları hesaplanmıştır. Eğitilmiş modelin yaptığı her bir tahmin .jpg formatında dosyaya kaydedilmiştir.


Farklı katman sayıları ile 256x256 olarak U-Net modeline verilen görüntüler evrişim aşamalarından geçirilerek model eğitilmiştir. Çizelgelerde verilen başarı sonuçları tüm test seti üzerinden hesaplanan genel başarı sonuçlarıdır. Eğitim sonucuna göre çıkarımlar yapıp test görüntüleri üzerinde Dice skor, PA skor ve IoU skor değerleri hesaplanmıştır. Çizelge 4.1.'de katman sayılarına göre model başarı sonuçları sunulmuştur.

Çizelge 4.1. Katman sayılarına göre model başarı sonuçları

Min Max	Ön İşleme Tekniği	Ön İşleme Parametreleri	Veri Artırma	Eğitim Veri Sayısı	Katman Sayısı	Validasyon	Batch Size	Dice Skor	IoU Skor	PA Skor
VAR	YOK	YOK	YOK	850	3	0.1	16	00.21	00.10	88.12
VAR	YOK	YOK	YOK	850	4	0.1	16	88.96	80.11	97.45
VAR	YOK	YOK	YOK	850	5	0.1	16	65.25	48.42	90.03

Herhangi bir ön işleme ve veri artırma tekniği kullanılmadan 850 veri ile model orijinal veri seti üzerinden eğitildiğinde farklı derinliklerdeki U-Net modelleri karşılaştırıldığında 4 katmanlı model en yüksek %88,96 Dice ve %80.11 IoU skorlarına ulaşarak dış segmentasyonunda en başarılı performansı göstermiştir. 5 katmanlı model

daha derin yapısına rağmen IoU değerinde (%48.42) ciddi bir düşüş yaşamış ve segmentasyon kalitesi zayıflamıştır. 3 katmanlı modelde ise hiç segmentasyon yapılamamıştır. Dice ve IoU skorları sıfıra yakın çıkmıştır. Bu sonuçlar diş segmentasyonu gibi sınıf dengesizliğine sahip medikal görüntülerde model derinliğinin dikaktli optimize edilmesi gerektiğini ve aşırı derin ağların genelleme kapasitesini bozabileceğini göstermektedir. Şekil 4.5.'te 3 4 ve 5 katmanlı U-Net modelleri için örnek bir görsel üzerinde yaptığı tahminler görülmektedir.



Şekil 4.5. 3 4 ve 5 katmanlı U-Net modelin yaptığı tahminler a) Orjinal test görüntüsü, b) Uzman etiketi c) 3 katmanlı model, d) 4 katmanlı model, e) 5 katmanlı model


Çizelge 4.2.'de CLAHE ön işleme tekniği kullanılarak farklı batch size değerleri altında model başarısı incelenmiştir.

Çizelge 4.2. Batch size parametresine göre model başarı sonuçları

Min Max	Ön İşleme Tekniği	Ön İşleme Parametreleri	Veri Artırma	Eğitim Veri Sayısı	Katman Sayısı	Validasyon	Batch Size	Dice Skor	IoU Skor	PA Skor
VAR	CLAHE	CL:2.0 TGS:8x8	YOK	850	4	0.1	8	89.70	81.32	97.63
VAR	CLAHE	CL:2.0 TGS:8x8	YOK	850	4	0.1	16	90.79	81.34	97.80
VAR	CLAHE	CL:2.0 TGS:8x8	YOK	850	4	0.1	32	89.60	81.11	97.60

CLAHE ön işleme tekniği kullanılarak farklı batch size'lar ile model başarısı incelendiğinde 16'lık batch size ile eğitilen model %90.79 Dice, %81.34 IoU ve %97.80

PA değerleriyle hem IoU hemde PA açısından en yüksek skorları sağlamıştır. 8'lik batch size %89.70 Dice ve %81.32 IoU ile oldukça başarılı olsa da bazı sınıflandırma detaylarında küçük eksiklikler gözlemlenmiştir. 32'lik batch size modelinde ise tüm metrikler daha düşük çıkmıştır. Bu durum büyük batch size değerlerinin bazı lokal detayları belirlemede yetersiz kalabileceğini göstermektedir. Elde edilen sonuçlar dental sınıflandırma gibi hassas uygulamalarda orta büyüklükte batch size değerlerinin daha dengeli ve etkili olduğunu ortaya koymaktadır. Şekil 4.6.'da örnek bir görsel üzerinde CLAHE ön işleme tekniği ve farklı batch size değerleri altında modelin yaptığı tahminler görülmektedir.




Şekil 4.6. CLAHE ön işleme ve farklı batch size değerleri altında modelin yaptığı tahminler a) Orjinal test görüntüsü, b) Uzman etiketi c) Batch size : 8, d) Batch size : 16, e) Batch size : 32

Çizelge 4.3.'de CLAHE ön işleme tekniği kullanılarak farklı validasyon değerleri altında model başarısı incelenmiştir.

Çizelge 4.3. Validasyon parametresine göre model başarı sonuçları

Min Max	Ön İşleme Tekniği	Ön İşleme Parametreleri	Veri Artırma	Eğitim Veri Sayısı	Katman Sayısı	Validasyon	Batch Size	Dice Skor	IoU Skor	PA Skor
VAR	CLAHE	CL:2.0 TGS:8x8	YOK	850	4	0.1	16	90.79	81.34	97.80
VAR	CLAHE	CL:2.0 TGS:8x8	YOK	850	4	0.2	16	89.87	81.61	97.65
VAR	CLAHE	CL:2.0 TGS:8x8	YOK	850	4	0.3	16	87.69	78.07	97.25

CLAHE ön işleme tekniği altında eğitim-veri ayırma oranının model başarısına etkisi incelendiğinde, validasyon oranı 0.1 olarak ayrıldığında model en yüksek %90.79 Dice ve %97.80 PA skorlarına ulaşmıştır. 0.2 validasyon oranında IoU skorunun %81.61 ile en yüksek olması, modelin genel segmentasyon alanlarını doğru belirleyebildiğini gösterse de dice skorunun düşmesi (%89.87), sınıf sınırlarında doğruluğun azaldığını işaret etmektedir. 0.3 validasyon oranında ise tüm metriklerde düşüş gözlenmiştir; bu durum, eğitim verisi miktarındaki azalmanın modelin öğrenme kapasitesini sınırladığını ortaya koymaktadır. Bu bağlamda veri seti büyüklüğü göz önünde bulundurularak daha düşük validasyon oranlarının tercih edilmesi segmentasyon başarısını artırmaktadır. Şekil 4.7.'de farklı validasyon değerleri altında örnek bir görsel üzerinde CLAHE ön işleme ile modelin yaptığı tahminler görülmektedir.




Şekil 4.7. CLAHE ön işleme ve farklı validasyon değerleri altında modelin yaptığı tahminler a) Orjinal test görüntüsü, b) Uzman etiketi c) Validasyon : 0.1, d) Validasyon : 0.2, e) Validasyon : 0.3

Çizelge 4.4.'de min-max normalizasyonun model başarısına etkisi incelenmiştir.

Çizelge 4.4. Min-max normalizasyon ile model başarı test sonuçları

Min Max	Ön İşleme Tekniği	Ön İşleme Parametreleri	Veri Artırma	Eğitim Veri Sayısı	Katman Sayısı	Validasyon	Batch Size	Dice Skor	IoU Skor	PA Skor
VAR	CLAHE	CL:2.0 TGS:8x8	YOK	850	4	0.1	16	90.79	81.34	97.80
YOK	CLAHE	CL:2.0 TGS:8x8	YOK	850	4	0.1	16	90.08	81.95	97.69
YOK	YOK	YOK	YOK	850	4	0.1	16	89.76	81.42	97.64
VAR	YOK	YOK	YOK	850	4	0.1	16	88.96	80.11	97.45

Min-Max normalizasyonun model başarısına etkisi incelendiğinde, İlk olarak, Min-Max normalizasyon uygulanmadan eğitilen model, %89.76 Dice skoru, %81.40 IoU ve %97.64 PA değerlerini elde etmiştir. Normalizasyon uygulandığında ise %88.96 Dice skoru, %80.11 IoU ve %97.45 PA olarak gözlemlenmiştir. Bu bulgular, normalizasyonun uygulandığı modelde başarının düştüğünü göstermektedir. CLAHE uygulamasının ardından elde edilen sonuçlarda ise Min-Max normalizasyonun etkisi kısmen değişmiştir. Normalizasyon uygulanmış modellerde %90.79 Dice skoru, %81.34 IoU ve %97.80 PA olarak ölçülürken, normalizasyon uygulanmamış modellerde %90.08 Dice skoru, %81.95 IoU ve %97.69 PA olmuştur. CLAHE sonrası değerlere bakıldığında, her iki modelin performansının birbirine çok yakın olduğu; ancak normalizasyonun Dice skorunu artırdığı, öte yandan IoU ve PA değerlerinde minimal farklılıklar olduğu görülmektedir. Genel olarak, Min-Max normalizasyonun tek başına uygulandığı durumda model performansında çok sınırlı veya hafif olumsuz etkiler gözlemlenirken, CLAHE gibi gelişmiş kontrast artırma teknikleri ile kombinasyonunda bu etkinin minimize olduğu ve model başarısının genel olarak arttığı sonucuna varılmıştır. Bu durum, CLAHE ön işleme adımının modelin genelleme yeteneğini destekleyerek normalizasyonun etkisini dengelediğini düşündürmektedir. Şekil 4.8.'de örnek bir görsel üzerinde min max normalizasyon ile eğitilen ve eğitilmeyen modellerin yaptığı tahminler görülmektedir.



Şekil 4.8. Min-max normalizasyon ile modelin yaptığı tahminler a) Orjinal test görüntüsü, b) Uzman etiketi c) Ön işleme : CLAHE Min-Max normalizasyon : Var, d) Ön işleme : CLAHE Min-Max normalizasyon : Yok, e) Ön işleme : Yok Min-Max normalizasyon : Yok, f) Ön işleme : Yok Min-Max normalizasyon : Var


Çizelge 4.5.’de CLAHE ön işleme tekniği kullanılarak TGS 4x4 ve farklı CL değerleri altında model başarısı incelenmiştir.

Çizelge 4.5. TGS 4x4 ve farklı CL parametresine göre model başarı sonuçları

Min Max	Ön İşleme Tekniği	Ön İşleme Parametreleri	Veri Artırma	Eğitim Veri Sayısı	Katman Sayısı	Validasyon	Batch Size	Dice Skor	IoU Skor	PA Skor
VAR	CLAHE	CL:1.0 TGS:4x4	YOK	850	4	0.1	16	88.12	78.76	97.30
VAR	CLAHE	CL:2.0 TGS:4x4	YOK	850	4	0.1	16	88.56	79.46	97.42

CLAHE ön işleme tekniği kullanılarak TGS parametresi 4x4 ve farklı CL değerleri altında model başarısı incelendiğinde CL parametresi 1.0 olarak belirlendiğinde %88.12 Dice skoru ve %78.76 IoU skoru elde edilirken, CL’nin 2.0’a yükseltilmesiyle bu değerler sırasıyla %88.56 ve %79.46’ya yükselmiştir. PA skoru da %97.30’dan %97.42’ye çıkmıştır. Bu artış daha belirgin kontrast sayesinde modelin dış konturlarını daha etkili ayırt edebildiğini göstermektedir. Bu doğrultuda CL 2.0 değeri

diş segmentasyonu için daha uygun bir kontrast sınırı sunmuştur. Şekil 4.9.'da örnek bir görsel üzerinde farklı CL değerleri altında modelin yaptığı tahminler görülmektedir.




Şekil 4.9. CLAHE ön işleme ve farklı CL değerleri altında modelin yaptığı tahminler a) Orjinal test görüntüsü, b) Uzman etiketi c) CL : 1.0, d) CL : 2.0

Çizelge 4.6.'da CLAHE ön işleme tekniği kullanılarak TGS 8x8 ve farklı CL değerleri altında model başarısı incelenmiştir.

Çizelge 4.6. TGS 8x8 ve farklı CL parametresine göre model başarı sonuçları

Min Max	Ön İşleme Tekniği	Ön İşleme Parametreleri	Veri Artırma	Eğitim Veri Sayısı	Katman Sayısı	Validasyon	Batch Size	Dice Skor	IoU Skor	PA Skor
VAR	CLAHE	CL:2.0 TGS:8x8	YOK	850	4	0.1	16	90.79	81.34	97.80
VAR	CLAHE	CL:3.0 TGS:8x8	YOK	850	4	0.1	16	37.15	22.81	90.74

CLAHE ön işleme tekniği kullanılarak TGS parametresi 8x8 ve farklı CL değerleri altında model başarısı incelendiğinde CL parametresi 2.0 iken %90.79 Dice, %81.34 IoU ve %97.80 PA skoruyla yüksek bir başarı elde edilmiştir. Ancak CL parametresi 3.0 ile model eğitildiğinde yapısal bütünlük büyük ölçüde kaybolmuş, diş konturları bozulmuş ve diş bölgelerinin bir kısmı sınıflandırılmamıştır. Bu bulgular, CL değerinin aşırı artırılmasının model performansını ciddi derecede olumsuz etkileyebileceğini ve optimum değer seçiminin kritik olduğunu göstermektedir. Şekil 4.10.'da örnek bir görsel üzerinde farklı CL değerleri altında modelin yaptığı tahminler görülmektedir.



Şekil 4.10. CLAHE ön işleme ve farklı CL değerleri altında modelin yaptığı tahminler a) Orjinal test görüntüsü, b) Uzman etiketi c) CL : 2.0, d) CL : 3.0


Çizelge 4.7.'de CLAHE ön işleme tekniği altında CL 2.0, TGS 8x8 olarak ayarlanıp, veri seti sayısının farklı veri artırma yöntemleri ile model başarısı incelenmiştir.

Çizelge 4.7. Veri artırma yöntemlerine göre model başarı sonuçları

Min Max	Ön İşleme Tekniği	Ön İşleme Parametreleri	Veri Artırma	Eğitim Veri Sayısı	Katman Sayısı	Validasyon	Batch Size	Dice Skor	IoU Skor	PA Skor
VAR	CLAHE	CL:2.0 TGS:8x8	Aynalama	1700	4	0.1	16	91.02	83.51	97.86
VAR	CLAHE	CL:2.0 TGS:8x8	10 derece döndürme	2550	4	0.1	16	90.08	81.95	97.73
VAR	CLAHE	CL:2.0 TGS:8x8	Kaydırma	2550	4	0.1	16	90.04	81.88	97.63
VAR	CLAHE	CL:2.0 TGS:8x8	5 derece döndürme	2550	4	0.1	16	87.94	78.48	97.27

CLAHE ön işleme tekniği altında CL 2.0, TGS 8x8 olarak ayarlanıp, veri seti sayısının farklı veri artırma yöntemleri ile eğitim veri sayısı artırılarak model eğitilmiştir. Aynalama yöntemiyle artırılmış 1700 veri ile elde edilen %91.02 Dice ve %83.51 IoU skorları, bu yöntemin sınıflandırma başarısını artırmada en etkili yöntem olduğunu göstermektedir. 10 derece döndürme ve X eksen kaydırma gibi geometrik dönüşümlerle elde edilen veri setlerinde de yüksek skorlar elde edilmiş (%90.08-%90.04 Dice), ancak bu yöntemler aynalama kadar etkili olmamıştır. 5 derece döndürme ile elde edilen sonuçlar ise en düşük değerlere sahiptir (%87.94 Dice). Bu

durum küçük açılı dönüşümlerin model öğrenmesine katkısının sınırlı olduğunu göstermektedir. Elde edilen sonuçlar diş sınıflandırma gibi yapısal simetri içeren tıbbi görüntü analizlerinde aynalama gibi simetri tabanlı veri artırma yöntemlerinin sınıflandırma başarısını artıracağını göstermektedir. Şekil 4.11.'de örnek bir görsel üzerinde farklı veri artırma teknikleri ile CLAHE ön işleme kullanılarak eğitilen modellerin yaptığı tahminler görülmektedir.




Şekil 4.11. CLAHE ön işleme ve farklı veri artırma yöntemleri altında eğitilen modellerin yaptığı tahminler a) Orjinal test görüntüsü, b) Uzman etiketi c) Aynalama, d) 10 derece döndürme, e) Kaydırma, f) 5 derece döndürme

Çizelge 4.8.'de Adaptif otsu ön işleme tekniği ile farklı BB değerleri altında model başarısı incelenmiştir.

Çizelge 4.8. Farklı BB değerleri için Adaptif Otsu ön işleme tekniği ile model başarı sonuçları


Min Max	Ön İşleme Tekniği	Ön İşleme Parametreleri	Veri Artırma	Eğitim Veri Sayısı	Katman Sayısı	Validasyon	Batch Size	Dice Skor	IoU Skor	PA Skor
VAR	Adaptif otsu	BB:7x7	YOK	850	4	0.1	16	89.18	80.48	97.47
VAR	Adaptif otsu	BB:9x9	YOK	850	4	0.1	16	89.26	80.61	97.46
VAR	Adaptif otsu	BB:11x11	YOK	850	4	0.1	16	87.68	78.06	96.96

Adaptif otsu ön işleme tekniği ile yapılan eşikleme işlemlerinde blok boyutunun sınıflandırma başarısına etkisi incenmiş BB : 9x9 olarak ayarlandığında %89.26 Dice, %80.61 IoU ve %97.46 PA skorlarına ulaşarak en yüksek başarıyı göstermiştir. Daha küçük blok boyutu olan 7x7 olarak ayarlandığında başarı %89.18 Dice ve %80.48 IoU ile benzer seviyede kalırken, blok boyutunun 11x11'e çıkarılmasıyla sınıflandırma doğruluğu düşmüş ve dice skoru %87.68'e gerilemiştir. Görseller üzerinden bakıldığında BB 9x9 ile eğitilen modelde yapılan tahminlerin uzman etiketleriyle örtüşme düzeyinin daha yüksek olduğu görülürken, BB 11x11 ile bazı dış konturlarının yeterince belirgin olmadığı gözlemlenmiştir. Bu sonuçlar adaptif otsu ön işleme yönteminin parametrelerinin dikkatli seçilmesinin sınıflandırma başarısı açısından kritik olduğunu göstermektedir. Şekil 4.12.'de adaptif otsu ön işleme yöntemi ve farklı BB değerleri altında eğitilen modellerin yaptığı tahminler görüntülenmektedir.




Şekil 4.12. Farklı BB değerleri için Adaptif otsu ön işleme tekniği altında eğitilen modellerin yaptığı tahminler a) Orjinal test görüntüsü, b) Uzman etiketi c) BB : 7x7, d) BB : 9x9, e) BB : 11x11

Otsu ön işleme yöntemi kullanılarak model eğitildiğinde PA skor altında model başarısı %96.06, Dice skor %83.31 ve IoU skor %71.40 olarak görülmüştür. Bu değerler, CLAHE, adaptif otsu yada veri artırma gibi tekniklerle eğitilen modelin altında kalmaktadır. Otsu yönteminin global bir eşikleme tekniği olması, görüntüdeki lokal kontrast farklılıklarını dikkate almaması nedeniyle sınıf doğruluğunu olumsuz etkileyebilmektedir. Bu durum dental panoramik görüntülerin analizinde lokal kontrasta duyarlı ön işleme yöntemlerinin tercih edilmesinin model başarısını artıracakını göstermektedir. Şekil 4.13.'de örnek bir görsel üzerinde otsu ön işleme yapılarak eğitilen modelin yaptığı tahminler gösterilmektedir.



Şekil 4.13. OTSU ön işleme yapılarak eğitilen modelin yaptığı tahmin

Hibrit olarak önce CLAHE sonra adaptif otsu filtreleme uygulanarak model eğitilmiş, CLAHE için CL 2.0 ve TGS 8x8 ayarlanmış, adaptif otsu için BB 9x9 ED 2.0 olarak ayarlanmış %97.38 PA skor, %89.05 Dice skor ve %80.26 IoU skor olarak ölçülmüştür. Bu skorlar adaptif otsunun tek başına kullanıldığı durumla benzer olup, CLAHE'nin kontrast artırıcı etkisinin sınırlı katkı sağladığını göstermektedir. Hibrit yaklaşım, özellikle düşük kontrastlı bölgelerde eşikleme hassasiyetini artırsada, sınıflandırma başarısında belirgin bir artış sağlamamıştır. Bu durum adaptif otsunun lokal yapıları zaten yeterince dikkate aldığını ve CLAHE ile elde edilecek iyileştirmelerin model başarısını çok etkilemediğini göstermektedir. Şekil 4.14.'de örnek bir görsel üzerinde hibrit önce CLAHE sonra adaptif otsu ön işleme yapılarak eğitilen modelin yaptığı tahmin görülmektedir.



Şekil 4.14. Hibrit önce CLAHE sonra adaptif OTSU ön işleme yapılarak eğitilen modelin yaptığı tahmin


Çizelge 4.9.'da dikkat blokları kullanılarak eğitilen Attention U-Net model başarısı incelenmiştir.

Çizelge 4.9. Dikkat blokları ile eğitilen model test seti başarı sonuçları

Min Max	Ön İşleme Tekniği	Ön İşleme Parametreleri	Veri Artırma	Eğitim Veri Sayısı	Katman Sayısı	Validasyon	Batch Size	Dice Skor	IoU Skor	PA Skor
VAR	CLAHE	CL:2.0 TGS:8x8	YOK	850	4	0.1	16	91.01	83.51	97.86
VAR	CLAHE	CL:2.0 TGS:8x8	Aynalama	1700	4	0.1	16	89.97	81.77	97.65

CLAHE ön işleme yöntemi kullanılarak veri artırma yapılmadan eğitilen modelde Dice skor %91.01, IoU skor %83.51 ve PA skor %97.86 oranında başarı


göstermiştir. Bu durum CLAHE ön işleme ile modelin dış sınırlarını daha belirgin olarak algılamasına olanak tanıdığına ve dikkat bloklarının bu iyleştirilmiş kontrast bilgisine odaklanarak etkin bir biçimde sınıflandırma gerçekleştirdiğini göstermektedir. CLAHE ön işlemeye ek olarak aynalama ile veri artırma uygulanan modelde ise %89.97 Dice skor, %81.77 IoU skor ve %97.65 PA skor olarak gözlemlenmiştir. Bu durum özellikle veri artırma yönteminin sınıflandırma başarısı açısından bir düşüğe neden olduğunu göstermektedir. Panoramik diş görüntülerinin yapısal simetrisine rağmen bazı anatomik çeşitliliklerin model tarafından öğrenilmesini zorlaştırabileceğini veya artırılan örneklerin modele ek gürültü kazandırdığını göstermektedir. Bununla birlikte, her iki durumdada dikkat blokları, modelin sınırlı kontrast farklarına rağmen anlamlı bölgelere odaklanmasına yardımcı olarak genel performans açısından olumlu sonuçlar üretmiştir. Özellikle PA skorun her iki durumda da %97'nin üzerinde olması, modelin tüm görüntü üzerinde yüksek doğrulukla tahmin yapabildiğini ancak sınıf bazlı hassasiyetin (dice ve IoU) veri artırma ile kısmen etkilendiğini göstermektedir. Şekil 4.15.'te örnek bir görsel üzerinde dikkat blokları kullanılarak eğitilen U-Net modelin yaptığı tahmin görülmektedir.



Şekil 4.15. Dikkat blokları ile eğitilen modelin yaptığı tahmin a) Orjinal test görüntüsü, b) Uzman etiketi
c) Veri artırma : Yok, d) Veri artırma : Aynalama

Şekil 4.16.'da Attention U-Net model ile dikkat blokları kullanıldıktan sonra eğitime giren örnek bir görüntünün eğitim sırasında sınıflandırma için odaklandığı bölge görülmektedir. Isı haritasında görüldüğü üzere model segmentasyon sırasında ağırlıklı olarak alt ve üst çene bölgesinde bulunan işlere yoğunlaştığı görülmektedir. Bu durum modelin eğitim sırasında dikkat blokları ile anlamlı ve amaca uygun şekilde doğru bölgelere odaklanıldığını göstermiştir. Alt çene bölgesindeki belirgin kırmızı ve


turuncu tonlar segmentasyon kararının bu bölgedeki aktivasyonlara dayandığını göstermektedir. Bununla birlikte modelin karar verdiği bölgeler ile tahmin edilen maske arasında güçlü bir örtüşme bulunmaktadır. Bu örtüşme modelin segmentasyon çıktılarının sadece sayısal metriklerle değil, aynı zamanda açıklanabilirlik açısından da tutarlı olduğunu göstermektedir.



Şekil 4.16. Modelin eğitim sırasında odaklandığı bölgeler


5. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu tez çalışmasında veri ön işleme veri artırma dikkat blokları, ısı haritaları ve U-Net modelinin farklı kombinasyonlarıyla panoramik radyografilerde diş segmentasyonu gerçekleştirmiştir. Şekil 5.1.'de farklı ön işleme tekniklerinin model sınıflandırma başarısı üzerindeki etkileri karşılaştırılmıştır.



Şekil 5.1 incelendiğinde sadece otsu yöntemi ile ön işleme düşük performans sergilemiş (%83.31 Dice, %71.40 IoU ve 96.06 PA), bu durum global eşikleme yöntemlerinin lokal detayları yakalamakta yetersiz kaldığını göstermiştir. CLAHE yöntemiyle kontrast artırıldığında sınıflandırma başarısı önemli derecede artmıştır (%90.79 Dice, %81.34 IoU ve %97,8 PA). Adaptif otsu yöntemi de benzer şekilde yüksek başarı göstermiş (%89.26 Dice, %80.61 IoU ve %97.46 PA), lokal eşikleme yaklaşımının etkili olduğunu ortaya koymuştur. Bu iki yöntemin birlikte kullanıldığı hibrit yapıda (%89.05 Dice, %80.26 IoU ve %97.38 PA), başarı adaptif otsu ile benzer seviyelerde kalmıştır. Sonuçlar dental panoramik görüntülerde lokal yapıların belirginleştirilmesine yönelik ön işleme tekniklerinin (özellikle CLAHE ve adaptif otsu) model doğruluğunu artırdığını, ancak hibrit yaklaşımların her zaman ek fayda sağlamadığını göstermektedir.

Şekil 5.2.'de farklı veri artırma yöntemlerinin CLAHE ön işleme ile model sınıflandırma başarısı üzerindeki etkileri karşılaştırılmıştır.



Veri artırma yöntemleri arasında aynalama, en az veriyle en iyi başarıyı sağlamıştır. Bu durum, modelin dental panoramik görüntülerdeki yapısal simetri den güçlü bir şekilde faydalanabildiğini göstermektedir. Döndürme ve kaydırma gibi geometrik dönüşümlerde başarıyı artırmakta etkili olmuştur. Fakat aynalama kadar büyük bir etki sağlamamıştır. Özellikle 5 derece döndürme gibi küçük açılarla döndürme, yeterince çeşitlilik sağlayamamış ve başarıda düşüşe yol açmıştır. Bu nedenle veri artırma stratejisi planlanırken, sadece miktar değil anlamsal çeşitlilikte göz önünde bulundurulmalıdır.

Orijinal veri seti ile herhangi bir veri ön işleme ve veri artırma yöntemi kullanılmadan katman sayılarının model başarısına etkisi incelendiğinde katman sayısı 4 olarak ayarlandığında ise en optimum katman sayısına ulaşan model %97.45 PA skor başarısı ile en yüksek model başarısına ulaşmıştır.

CLAHE ön işleme tekniği CL : 2.0 TGS 8x8 ayarlanarak farklı batch size parametreleri altında model eğitildiğinde 16 batch size için en optimum sonuç %97.80 PA skor başarısı ile elde edilirken, batch size'ın 8'e düşürülüp yada 32'ye yükseltildiği durumlar için model başarısının düştüğü görülmektedir. CL : 2.0 TGS 8x8 ayarlanarak farklı validasyon değerleri altında model eğitildiğinde, validasyon için veri sayısı artırıldığında model başarısının düştüğü görülmüştür. TGS : 4x4 olarak ayarlanıp farklı CL değerleri altından model eğitildiğinde CL değerinin 1.0'dan 2.0'a yükseltildiğinde model başarısının arttığı görülmüştür. TGS : 8x8 olarak ayarlandığında CL değeri 2.0'dan 3.0'a yükseltildiğinde model başarısının düştüğü gözlemlenmiştir. CL değerleri ve TGS değerlerinin gözlemlendiği 4 farklı model eğitimi için yapılan çalışmada

CLAHE ön işleme tekniği için en başarılı CL değeri 2.0 TGS değeri 8x8 olarak gözlemlenmiştir. CL : 2.0 ve TGS :8x8 olarak ayarlanıp farklı veri artırma teknikleri kullanılarak model eğitildiğinde en başarılı yöntem aynalama olarak gözlemlenirken aynalama veri artırma yöntemini sırasıyla, 10 derece döndürme, kaydırma ve 5 derece döndürme takip etmektedir.


OTSU ön işleme tekniği kullanılarak model eğitildiğinde %96.06, Dice skor %83.31 ve IoU skor %71.40 model başarısı elde etmesine karşın adaptif otsu ön işleme tekniğinin daha başarılı sonuçlar elde ettiği görüldüğü için adaptif otsu ön işleme yöntemine odaklanılmıştır. Adaptif otsu ön işleme tekniği kullanılarak farklı BB değerleri altında model eğitildiğinde BB değeri arttıkça model başarısının düştüğü gözlemlenmiştir.

Hibrit olarak önce CLAHE ön işleme ve sonra adaptif otsu ön işleme tekniği kullanılarak model eğitildiğinde model başarısı düştüğü için hibrit yöntem yerine en başarılı CLAHE ön işleme ile model başarısını artırmak için çalışmalar yapılmıştır.

Dikkat blokları kullanılarak model eğitimleri incelendiğinde doğru veri ön işleme yaklaşımı seçilip model eğitildiğinde veri artırmaya ihtiyaç kalmadan daha kısa sürede daha az veri ile model başarısının arttığı gözlemlenmiştir. Çizelge 5.1.'de de görüldüğü üzere farklı veri artırma teknikleri CLAHE, adaptif OTSU gibi ön işleme en başarılı sonuca dikkat blokları kullanılarak eğitilen attention U-Net modelde CLAHE ön işleme CL : 2.0 TGS : 8x8 eğitilen modelde %91.01 Dice skor, %83.51 IoU skor ve %97.86 PA skor ile ulaşıldığı gözlemlenmiştir. Dikkat blokları kullanılmadan eğitilen U-Net modelde ise aynalama yöntemi ile veri artırma yapılarak ve CLAHE ön işleme kullanılarak eğitilen modelde %91.02 Dice skor, %83.51 IoU skor ve %97.86 Pa skor ile ulaşıldığı gözlemlenmiştir.


Çizelge 5.1. Test seti başarı sonuçları

Model	Min Max	Ön İşleme Tekniği	Ön İşleme Parametreleri	Veri Artırma	Eğitim Veri Sayısı	Katman Sayısı	Validasyon	Batch Size	Dice Skor	IoU Skor	PA Skor
U-Net	VAR	CLAHE	CL:2.0 TGS:8x8	Aynalama	1700	4	0.1	16	91.02	83.51	97.86
Attention U-Net	VAR	CLAHE	CL:2.0 TGS:8x8	YOK	850	4	0.1	16	91.01	83.51	97.86
U-Net	VAR	CLAHE	CL:2.0 TGS:8x8	YOK	850	4	0.1	16	90.79	81.34	97.80
U-Net	YOK	CLAHE	CL:2.0 TGS:8x8	YOK	850	4	0.1	16	90.08	81.95	97.69
U-Net	VAR	CLAHE	CL:2.0 TGS:8x8	10 derece döndürme	2550	4	0.1	16	90.08	81.95	97.73
Attention U-Net	VAR	CLAHE	CL:2.0 TGS:8x8	Aynalama	1700	4	0.1	16	89.97	81.77	97.65
U-Net	VAR	CLAHE	CL:2.0 TGS:8x8	YOK	850	4	0.2	16	89.87	81.61	97.65
U-Net	VAR	CLAHE	CL:2.0 TGS:8x8	Kaydırma	2550	4	0.1	16	90.04	81.88	97.63
U-Net	VAR	CLAHE	CL:2.0 TGS:8x8	YOK	850	4	0.1	8	89.70	81.32	97.63
U-Net	VAR	CLAHE	CL:2.0 TGS:8x8	YOK	850	4	0.1	32	89.60	81.11	97.60
U-Net	VAR	Adaptif otsu	BB:7x7	YOK	850	4	0.1	16	89.18	80.48	97.47
U-Net	VAR	Adaptif otsu	BB:9x9	YOK	850	4	0.1	16	89.26	80.61	97.46
U-Net	VAR	YOK	YOK	YOK	850	4	0.1	16	88.96	80.11	97.45
U-Net	YOK	YOK	YOK	YOK	850	4	0.1	16	89.76	81.42	97.64
U-Net	VAR	CLAHE	CL:2.0 TGS:4x4	YOK	850	4	0.1	16	88.56	79.46	97.42
U-Net	VAR	CLAHE + Adaptif otsu	CL:2.0 TGS:8x8 BB:9x9	YOK	850	4	0.1	16	89.05	80.26	97.38
U-Net	VAR	CLAHE	CL:1.0 TGS:4x4	YOK	850	4	0.1	16	88.12	78.76	97.30
U-Net	VAR	CLAHE	CL:2.0 TGS:8x8	YOK	850	4	0.3	16	87.69	78.07	97.25
U-Net	VAR	CLAHE	CL:2.0 TGS:8x8	5 derece döndürme	2550	4	0.1	16	87.94	78.48	97.27
U-Net	VAR	Adaptif otsu	BB:11x11	YOK	850	4	0.1	16	87.68	78.06	96.96
U-Net	VAR	OTSU	YOK	YOK	850	4	0.1	16	83.31	71.40	96.06
U-Net	VAR	CLAHE	CL:3.0 TGS:8x8	YOK	850	4	0.1	16	37.15	22.81	90.74
U-Net	VAR	YOK	YOK	YOK	850	5	0.1	16	65.25	48.42	90.03
U-Net	VAR	YOK	YOK	YOK	850	3	0.1	16	00.21	00.10	88.12



Şekil 5.3. Test seti üzerinden yapılan tahminler a)Veri ön işleme CLAHE CL : 2.0 TGS : 8x8, dikkat blokları ile eğitilen modelin yaptığı tahmin, b)Veri ön işleme CLAHE CL : 2.0 TGS : 8x8, veri artırma aynalama ile eğitilen modelin yaptığı tahmin, c)Veri ön işleme CLAHE CL : 2.0 TGS : 8x8, veri artırma olmadan eğitilen modelin yaptığı tahmin

Şekil 5.3'te eğitilmiş model ile yapılan tahminlere dair en başarılı ilk 3 sonuç görülmektedir.



Şekil 5.4. En başarılı modelin eğitim doğruluğu ve eğitim kaybı grafikleri

Şekil 5.4.'de en başarılı modelin eğitim kaybı ve eğitim doğruluğu grafikleri verilmiştir. Eğitim kaybı (training loss) eğrisi, ilk epok'lardan itibaren hızlı bir azalış göstermiş ve 100. epok sonunda oldukça düşük değerlere ulaşmıştır. Bu durum, modelin eğitim verisi üzerinde başarılı bir öğrenme gerçekleştirdiğini göstermektedir. Eğitim doğruluğu (training accuracy) grafiğinde ise eğitim eğrisi %93 seviyelerine ulaşarak düzenli ve istikrarlı biçimde arttığı görülmüştür. Genel olarak, modelde ani küçük dalgalanmalar olsada modelin genel başarısına etki etmediği görülmüştür. Eğitim kaybı düzenli olarak azalmış ve eğitim doğruluğu hızlı şekilde yükselerek modelin başarılı bir şekilde öğrenme gerçekleştirdiği görülmüştür.

6. SONUÇLAR VE ÖNERİLER

Radyografik diş görüntüleri kullanılarak diş tespiti için yapılan bu çalışmada literatür taramalarında yüksek başarı elde edilmiş veri ön işleme yöntemleri ve U-Net DÖ modeli kullanılmıştır. Farklı veri ön işleme ve veri artırma işlemleri yapılarak veri seti hazır hale getirilmiştir. Bu işlemlerin ardından model eğitimleri farklı yöntemler kullanılarak (dikkat blokları, klasik U-Net) yapılmış ve eğitilen model ve görüntüler bilgisayar ortamına kaydedilmiştir. Model eğitimleri tamamlandıktan sonra performans değerlendirme metrikleriyle modelin güvenilirlik sonuçları hesaplanmıştır. Isı haritaları kullanarak modelin odaklandığı bölgeler yorumlanmıştır.

Diş tespiti için yapılan bu çalışmada farklı veri ön işleme ve veri artırma teknikleri kullanarak veri setine uygun optimizasyon parametreleri verildiğinde CLAHE ve adaptif OTSU gibi ön işleme tekniklerinin ve farklı sentetik veri artırma tekniklerinin model başarısını artırdığı görülmüştür. Dikkat blokları kullanılarak eğitilen U-Net modelde, model eğitimi sürecinde modelin daha doğru noktalara odaklanarak model başarısının arttığı gözlemlenmiştir. Gelecekte yürütülecek çalışmalarda, görüntülerin yönlü (oriyantasyon) duyarlılığını koruyacak şekilde tasarlanmış, daha gelişmiş ve optimize edilmiş veri artırma yöntemlerinin uygulanmasının faydalı olacağı düşünülmektedir. Bu bağlamda, özellikle elastik deformasyon (elastic deformation), mixup tekniği ve rastgele kırpmaya (random cropping) gibi yöntemlerin kullanılması planlanmaktadır. Söz konusu tekniklerin, modelin eğitim verisi üzerindeki çeşitliliği artırarak aşırı uyum (overfitting) riskini azaltması, farklı pozisyon, ölçek ve biçim varyasyonlarına karşı daha yüksek bir genelleme kabiliyeti kazandırması beklenmektedir. Ayrıca, bu veri artırma yaklaşımlarının, segmentasyon görevlerinde sınır çizgilerinin daha doğru belirlenmesine ve dolayısıyla modelin piksel düzeyinde hassasiyetinin artırılmasına katkı sağlayacağı düşünülmektedir. Tufts veri seti üzerinden yapılan bu çalışmada en yüksek başarı CLAHE ön işleme, aynalama ile veri artırma ve U-Net yöntemlerinin kombinasyonu ile %91.02 Dice, %83.51 IoU ve %97.86 PA skor olarak elde edilmiştir.

Çalışmada, kişisel verilere erişimin kısıtlı olduğu küçük ölçekli veri setlerinde, kapsamlı veri ön işleme ve sentetik veri artırma yaklaşımlarıyla desteklenen DÖ modellerinin kullanılmasının, elde edilen sonuçların doğruluğu ve güvenilirliğine önemli ölçüde katkı sağladığı görülmüştür. Özellikle veri kalitesinin ve

erişilebilirliğinin düşük olduğu ortamlarda, segmentasyon tabanlı bu tür sistemlerin geliştirilmesi, sağlık çalışanlarının iş yükünü azaltarak daha tutarlı karar süreçlerine yönelmelerine imkân tanıyabilir. Bununla birlikte, bu katkının düzeyi, büyük ölçüde uygulanan önışleme adımlarının etkinliği, elde edilen segmentasyon çıktılarının doğruluğu ve bu çıktıların klinik süreçlere entegrasyon başarısı ile ilişkilidir. Bu çerçevede, güçlü önışleme stratejileriyle desteklenen DÖ tabanlı yapay zekâ yaklaşımlarının, gelecekte daha güvenilir ve sürdürülebilir çözümler sunma potansiyeli taşıdığı değerlendirilmektedir.



KAYNAKLAR

- Almalki, Y., Din, A., Ramzan, M., Irfan, M., Aamir, K., Almalki, A., Alotaibi, S., Alaglan, G., Alshamrani, H., & Rahman, S. (2022). Deep learning models for classification of dental diseases using orthopantomography X-ray OPG images. *Sensors*, 22(19), 7370. <https://doi.org/10.3390/s22197370>
- Alwin, J., & Jayaraman, C. (2024). Preprocessing Techniques for Neuroimaging Modalities: An In-Depth Analysis. IntechOpen. doi: 10.5772/intechopen.109803
- Amidi, A., & Amidi, S. (2019). *Evrişimsel Sinir Ağları El Kitabı*. Stanford Üniversitesi Yayını. Erişim adresi: <https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-convolutional-neural-networks>
- Anonim, 2025 https://tdd.ece.tufts.edu/Tufts_Dental_Database/ Erişim Tarihi: 04.08.2025
- Arı, A., & Hanbay, D. (2019). Tumor detection in MR images of regional convolutional neural networks. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34(3), 1396-1409
- Ayhan, B., Ayan, E., & Bayraktar, Y. (2024). A novel deep learning-based perspective for tooth numbering and caries detection. *Clinical Oral Investigations*, 28(3), Article 178. Springer. <https://doi.org/10.1007/s00784-024-05566-w>
- Baştuğ Koç, A., & Akgün, D. (2021). U-net Mimarileri ile Glioma Tümör Segmentasyonu Üzerine Bir Literatür Çalışması. *Avrupa Bilim ve Teknoloji Dergisi*, Özel Sayı 26, 407-414. <https://doi.org/10.31590/ejosat.959590>
- Bhat, R., Birajdar, G., & Patil, R. (2023). A comprehensive survey of deep learning algorithms and applications in dental radiographs analysis. *Healthcare Analytics*, 4, 100282. <https://doi.org/10.1016/j.health.2023.100282>
- Bilgir, E., Bayrakdar, İ. Ş., Çelik, Ö., Orhan, K., Akkoca, F., Sağlam, H., Odabaş, A., Aslan, A. F., Ozcetin, C., Kılılı, M., & Rozylo-Kalinowska, I. (2021). An artificial intelligence approach to automatic tooth detection and numbering in panoramic radiographs. *BMC Medical Imaging*, 21(1), Article 124. Springer. <https://doi.org/10.1186/s12880-021-00656-7>
- Cejudo, J. E., Chaurasia, A., Feldberg, B., Krois, J., & Schwendicke, F. (2021). Classification of dental radiographs using deep learning. *Journal of Clinical Medicine*, 10(7), 1496. <https://doi.org/10.3390/jcm10071496>
- Cengil, Emine & Çınar, Ahmet (2016). A New Approach For Image Classification: Convolutional Neural Network. *European Journal of Technique (EJT)*, 6(2), 96-103.
- Chen, H., Zhang, K., Lyu, P., Li, H., Zhang, L., Wu, J., & Lee, C.-H. (2019). A deep learning approach to automatic teeth detection and numbering based on object

- detection in dental periapical films. *Scientific Reports*, 9(1), 3840. Springer Nature. <https://doi.org/10.1038/s41598-019-40414-y>
- Chen, Qiaoyi; Zhao, Yue; Liu, Yang; Sun, Yongqing; Yang, Chongshi; Li, Pengcheng; Zhang, Lingming; Gao, Chenqiang (2021). MSLPNet: multi -scale location perception network for dental panoramic X-ray images. *Neural Computing and Applications*, Cilt 33, Sayı 16, s. 10277-10291. Springer. DOI: 10.1007/s00521-021-05790-5
- Çiçek, Ö., Abdulkadir, A., Lienkamp, S.S., Brox, T., & Ronneberger, O. (2016). 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation. *In Medical Image Computing and Computer-Assisted Intervention (MICCAI)*.
- Dechter, R. (1986). Learning while searching in constraint-satisfaction problems. *Proceedings of the Fifth National Conference on Artificial Intelligence (AAAI'86)*, 178-183. AAAI Press.
- Dumoulin, V., & Visin, F. (2016). *A guide to convolution arithmetic for deep learning*. arXiv:1603.07285.
- Farajollahi, M., Safarian, M. S., Hatami, M., Esmaeil Nejad, A., & Peters, O. A. (2023). Applying artificial intelligence to detect and analyse oral and maxillofacial bone loss-A scoping review. *Australian endodontic journal : the journal of the Australian Society of Endodontology Inc*, 49(3), 720–734. <https://doi.org/10.1111/aej.12775>
- Görürgöz C., Orhan K., Bayrakdar I., Çelik Ö., Bilgir E., Odabaş A., Aslan A., Jagtap R., (2021) Performance of a convolutional neural network algorithm for tooth detection and numbering on periapical radiographs, *Dentomaxillofacial Radiology*, Cilt 51, Sayı 3, Makale no. 20210246. Oxford University Press. DOI: 10.1259/dmfr.20210246
- Helli, S., & Hamamcı, A. (2022). Tooth Instance Segmentation on Panoramic Dental Radiographs Using U-Nets and Morphological Processing. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 10(1), 39-50. <https://doi.org/10.29130/dubited.950568>
- Isensee, F., Jaeger, P.F., Kohl, S.A.A., Petersen, J., & Maier-Hein, K.H. (2021). nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. *Nature Methods*, 18, 203–211
- Jader, G., Fontineli, J., Ruiz, M., Abdalla, K., Pithon, M.M., & Oliveira, L. (2018). Deep Instance Segmentation of Teeth in Panoramic X-Ray Images. *2018 31st SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*, 400-407.
- Kabir, T., Lee, C. T., Chen, L., Jiang, X., & Shams, S. (2022). A comprehensive artificial intelligence framework for dental diagnosis and charting. *BMC Oral Health*, 22(1), Article 480. Springer Nature. <https://doi.org/10.1186/s12903-022-02514-6>
- Karaoğlu, A., Ozcan, C., Pekince, A., & Yasa, Y. (2023). Numbering teeth in panoramic images: A novel method based on deep learning and heuristic

- algorithm. *Engineering Science and Technology, an International Journal*, 37, Article 101316. Elsevier. <https://doi.org/10.1016/j.jestch.2022.101316>
- Kaya, E., Güneç, H. G., Gökyay, S. S., Kutal, S., Gülüm, S., & Ateş, H. F. (2022). Proposing a CNN Method for Primary and Permanent Tooth Detection and Enumeration on Pediatric Dental Radiographs. *Journal of Clinical Pediatric Dentistry*, 46(4), 293-298. <https://doi.org/10.22514/1053-4625-46.4.6>
- Kayadibi, İ., Köse, U., & Güraksın, G. E. (2024). Görüntü işleme teknikleri ve evrimsel sinir ağı kullanılarak bilgisayar destekli diş segmentasyonu. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 30(7), 924-933. <https://doi.org/10.5505/pajes.2024.22237>
- Kayaoğlu, M., Şengür, A., Çiğirim, S. Ç., & Bor, S. (2025). Detection of Cervical Vertebrae Using Object Detection and Semantic Segmentation Methods in Lateral Cephalometric Radiographs. *Türk Doğa ve Fen Dergisi*, 14(2), 26-36.
- Kılıç, M. C., Bayrakdar, İ. Ş., Çelik, Ö., Bilgir, E., Orhan, K., Aydın, O. B., Kaplan, F. A., Sağlam, H., Odabaş, A., Aslan, A. F., & Yılmaz, A. B. (2021). Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs. *Dento Maxillo Facial Radiology*, 50(6), Article 20200172. <https://doi.org/10.1259/dmfr.20200172>
- Linlin, Y., & Liu, Y. (2022). Sports Target Tracking Based on Discriminant Correlation Filter and Convolutional Residual Network. *Wireless Communications and Mobile Computing*, 2022(1), 2981513.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60–88.
- Luo, D., Zeng, W., Chen, J., & Tang, W. (2021). Deep learning for automatic image segmentation in stomatology and its clinical application. *Frontiers in Medical Technology*, 3, Article 767836. doi:10.3389/fmedt.2021.767836
- Mertoğlu, D., Keser, G., Namdar Pekiner, F. M., Bayrakdar, İ. Ş., Çelik, Ö., & Orhan, K. (2023). A deep learning approach to automatic tooth detection and numbering in panoramic radiographs: An artificial intelligence study. *Clinical and Experimental Health Sciences*, 13(4), 883-888. doi:10.33808/clinexphealthsci.1219160
- Oktay, O., Schlemper, J., Le Folgoc, L., Lee, M., Heinrich, M., Misawa, K., Mori, K., McDonagh, S., Hammerla, N. Y., Kainz, B., Glocker, B., & Rueckert, D. (2018). Attention U-Net: Learning Where to Look for the Pancreas. *arXiv preprint arXiv:1804.03999*.
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62–66. <https://doi.org/10.1109/TSMC.1979.4310076>

- Özçelik, S. T. A., Üzen, H., Şengür, A., & Çelebi, A. (2024). Derin öğrenme ile panoramik radyografi görüntülerinden diş segmentasyonu: UNet, FPN ve PSPNet karşılaştırması. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 13(4), 1347-1354.
- Öcal, H., & Altundağ, G. (2025). Comparative Analysis of GAN-based Segmentation Models on Dental Panoramic Radiography Dataset. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 37(1), 523-532. <https://doi.org/10.35234/fumbd.1642238>
- Panetta, K., Rajendran, R., Ramesh, A., Rao, S. P., & 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>
- Prados-Privado, M., Villalón, J. G., Martínez-Martínez, C. H., & Ivorra, C. (2020). *Dental Images Recognition Technology and Applications: A Literature Review*. *Applied Sciences*, 10(8), 2856. <https://doi.org/10.3390/app10082856>
- Pisano, E. D., Zong, S., Hemminger, B. M., DeLuca, M., Johnston, R. E., Muller, K. E., ... & Braeuning, M. P. (1998). Contrast limited adaptive histogram equalization image processing to improve the detection of simulated spiculations in dense mammograms. *Journal of Digital Imaging*, 11(4), 193-200. <https://doi.org/10.1007/BF03178082>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In N. Navab, J. Hornegger, W. M. Wells, & A. F. Frangi (Eds.), *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015* (pp. 234-241). Springer, Cham. https://doi.org/10.1007/978-3-319-24574-4_28
- Samek, W., Wiegand, T., & Müller, K. R. (2017). Explainable artificial intelligence: Understanding, visualizing and interpreting deep learning models. *arXiv preprint arXiv:1708.08296*.
- Schlemper, J., Oktay, O., Schaap, M., Heinrich, M., Kainz, B., Glocker, B., & Rueckert, D. (2019). Attention gated networks: Learning to leverage salient regions in medical images. *Medical Image Analysis*, 53, 197-207.
- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017). Grad-CAM: Visual explanations from deep networks via gradient-based localization. In *Proceedings of the IEEE International Conference on Computer Vision (ICCV)* (pp. 618-626).
- Sezgin, E., Üncü, Y. A., & Yardımcı, A. (2023). Prematüre retina kan damarlarının tespitinde farklı görüntü işleme yöntemlerinin performanslarının karşılaştırılması. *Süleyman Demirel University Faculty of Arts and Science Journal of Science*, 18(2), 62-75. <https://doi.org/10.29233/sdufeffd.1220516>

- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1), 1–48.
- Suara, S., Jha, A., Sinha, P., Sekh, A.A. (2024). Is Grad-CAM Explainable in Medical Images?. In: Kaur, H., Jakhetiya, V., Goyal, P., Khanna, P., Raman, B., Kumar, S. (eds) Computer Vision and Image Processing. CVIP 2023. *Communications in Computer and Information Science*, vol 2009. Springer, Cham. https://doi.org/10.1007/978-3-031-58181-6_11
- Sun, D., Wang, J., Zuo, Z., Jia, Y., & Wang, Y. (2024). STS-TransUNet: Semi-supervised tooth segmentation transformer U-Net for dental panoramic image. *Mathematical Biosciences and Engineering*, 21(2), 2366–2384. <https://doi.org/10.3934/mbe.2024104>
- Şeker, A., DİRİ, B., & BALIK, H. H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. *Gazi Mühendislik Bilimleri Dergisi* , vol.3, no.3, 47-564.
- Tufts University School of Dental Medicine. (2017). Tufts Dental Database (TDD). Institutional Research Board Approval ID: MODCR-01-12631.
- Verma R., Mehrota R., Rane C., Tiwari R., Agariya AK., (2020) Synthetic image augmentation with generative adversarial network for enhanced performance in protein classification. *Biomed Eng Lett.* 2020 Jul 13;10(3):443-452. doi: 10.1007/s13534-020-00162-9. PMID: 32850179; PMCID: PMC7438425.
- Zannah, R., Bashar, M., Mushfiq, R.B., Chakrabarty, A., Hossain, S., & Jung, Y.J. (2024). Semantic Segmentation on Panoramic Dental X-Ray Images Using U-Net Architectures. *IEEE Access*, 12, 44598-44612.
- Zhong, W., Ren, X., & Zhang, H. (2025). Automatic X-ray teeth segmentation with grouped attention. *Scientific reports*, 15(1), 64. <https://doi.org/10.1038/s41598-024-84629-0>
- Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., & Torralba, A. (2016). *Learning deepfeatures for discriminative localization*. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 2921–2929).