



T.C.

**ÇANAKKALE ONSEKİZ MART ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**PANORAMİK RADYOGRAFİK GÖRÜNTÜLERİ KULLANAN
DERİN ÖĞRENME TABANLI OTOMATİK DİŞ BÖLÜTLEME
YAKLAŞIMI**

YÜKSEK LİSANS TEZİ

CEREN SÖZERİ

Tez Danışmanı

PROF. DR. BAHADIR KARASULU

ÇANAKKALE – 2025



T.C.

ÇANAKKALE ONSEKİZ MART ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**PANORAMİK RADYOGRAFİK GÖRÜNTÜLERİ KULLANAN DERİN
ÖĞRENME TABANLI OTOMATİK DİŞ BÖLÜTLEME YAKLAŞIMI**

YÜKSEK LİSANS TEZİ

CEREN SÖZERİ

Tez Danışmanı

PROF. DR. BAHADIR KARASULU

ÇANAKKALE – 2025



T.C.
ÇANAKKALE ONSEKİZ MART ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



Ceren SÖZERİ tarafından Prof. Dr. Bahadır KARASULU yönetiminde hazırlanan ve **15/01/2025** tarihinde aşağıdaki jüri karşısında sunulan “**Panoramik Radyografik Görüntüleri Kullanan Derin Öğrenme Tabanlı Otomatik Diş Bölütleme Yaklaşımı**” başlıklı çalışma, Çanakkale Onsekiz Mart Üniversitesi Lisansüstü Eğitim Enstitüsü **Bilgisayar Mühendisliği Anabilim Dalı**’nda **YÜKSEK LİSANS TEZİ** olarak oy birliği ile kabul edilmiştir.

Jüri Üyeleri

İmza

Prof. Dr. Bahadır KARASULU

(Danışman)

Doç. Dr. Emrullah SONUÇ

Dr. Öğr. Üyesi Bora UĞURLU

.....

.....

.....

Tez No : 10603190

Tez Savunma Tarihi : 15/01/2025

.....
Doç. Dr. MELİS ULU DOĞRU

Enstitü Müdürü

.././2025

ETİK BEYAN

Çanakkale Onsekiz Mart Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kuralları'na uygun olarak hazırladığım bu tez çalışmada; tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi, tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu, tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi, kullanılan verilerde herhangi bir değişiklik yapmadığımı, bu tezde sunduğum çalışmanın özgün olduğunu, bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi taahhüt ve beyan ederim.

Ceren SÖZERİ

15/01/2025

TEŞEKKÜR

Bu tez çalışmasının tamamlanması, yalnızca kişisel çabalarımın değil, aynı zamanda beni yönlendiren, destekleyen ve yol gösteren pek çok değerli kişinin katkılarıyla mümkün olmuştur. Bu vesileyle, akademik ve kişisel hayatımda emeği geçen herkese teşekkürlerimi sunarım.

İlk olarak, akademik yolculuğum boyunca bana rehberlik eden danışman hocam Prof. Dr. Bahadır Karasulu'ya sonsuz teşekkürlerimi sunarım. Kendisi, bilimsel düşünce yapımı geliştirmemde, eleştirel bakış açısı kazanmamda ve bu tezi başarıyla tamamlamamda büyük katkı sağlamıştır. Her zaman sabırlı yaklaşımı, yapıcı eleştirileri ve teşvik edici desteği, bu sürecin tamamlanmasında büyük rol oynamıştır.

Eğitim hayatım boyunca maddi ve manevi olarak her zaman yanımda olan sevgili babam Sinan Sözeri'ye ve annem Nebibe Sözeri'ye en derin minnetlerimi sunarım. Onların fedakârlıkları, sevgileri ve inançları olmasaydı, bu noktaya ulaşmam mümkün olmazdı. Verdikleri emek ve bana olan güvenleri, yaşamım boyunca bir rehber olmaya devam edecektir.

Akademik hayatımda ilham kaynağım olan sevgili ablam Didem Sözeri Atik'e gönülden teşekkür ederim. Bilime olan tutkumun yeşermesinde ve akademik hedeflerime bağlı kalmamda her zaman örnek teşkil etmiştir. Kendisinin rehberliği, bu yolculukta attığım her adımda derin bir etki bırakmış ve bugün ulaştığım başarıda önemli bir paya sahiptir. Ayrıca, her zaman desteğini hissettiğim eniştem Altay Atik'e de içten teşekkür ederim. Entelektüel katkıları ve manevi desteği bu süreci daha anlamlı kılmıştır.

Manevi anlamda bana destek olan kıymetli arkadaşlarım Mina Araç ve İrem Işıl Solmaz'a da teşekkür ederim. Zorlu anlarımı aşmamda ve motivasyonumu yüksek tutmamda katkıları büyük olmuştur. Son olarak, her aşamada bana değerli fikirleriyle katkı sağlayan, bu süreçte her zaman yanımda olan ve desteğini esirgemeyen, her türlü zorlukta beni cesaretlendiren Murat Tahtacı'ya en içten teşekkürlerimi sunarım.

Ceren SÖZERİ
Çanakkale, Ocak 2025

ÖZET

PANORAMİK RADYOGRAFİK GÖRÜNTÜLERİ KULLANAN DERİN ÖĞRENME TABANLI OTOMATİK DİŞ BÖLÜTLEME YAKLAŞIMI

Ceren SÖZERİ

Çanakkale Onsekiz Mart Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı Yüksek Lisans Tezi

Danışman: Prof. Dr. Bahadır KARASULU

15/01/2025, 58

Bu çalışma, diş hekimliğinde sıklıkla teşhis ve tedavi yöntemleri için kullanılan panoramik radyografi görüntülerini ile sınıflandırılmasını gerçekleştiren bir yöntem sunmaktadır. Sınıflandırma sonucunda, hastanın yaş grubuna uygun olarak özel olarak eğitilmiş modeller kullanılarak diş yapıları için otomatik bölütleme yapılmıştır. Bu sayede, yetişkin ve çocuk hastalar için farklı anatomik ve yapısal özellikler göz önünde bulundurularak daha hassas sonuçlar elde edilmiştir. Sınıflandırma modelinin başarımı Tufts veri kümesiyle değerlendirilmiş ve başarımları doğruluğu 0,80 olarak kaydedilmiştir. Çalışmada geliştirilen derin öğrenme modeli, dişlerin otomatik olarak tespit edilmesini ve bölütlenmesini sağlayarak diş hekimlerine tanı ve tedavi süreçlerinde önemli veriler sunmaktadır. Bölütleme görevi için yetişkin ve çocuk görüntüleriyle iki ayrı model eğitilmiştir. Yetişkin görüntüleriyle eğitilen model DeepLabV3+ResNet50 iken çocuk görüntüleri ile eğitilen model olarak UNet seçilmiştir. Yetişkin görüntülerinde Kesişimin Birleşim Üzerine Oranında 0,90, Dice Katsayısında 0,95 başarı elde edilirken, çocuk görüntülerin bölütlenmesinde başarı Kesişimin Birleşim Üzerine Oranında 0,90, Dice Katsayısında 0,94 olarak kaydedilmiştir. Bu modellerin diş hekimleri tarafından daha rahat kullanılabilir olması açısından Gradio kütüphanesi kullanılarak grafiksel kullanıcı arayüzü oluşturulmuştur. Sunulan yöntem ve oluşturulan arayüz sayesinde hem tanı sürecinin doğruluğu artırılmış hem de hekimlerin iş yükü azaltılmaktadır. Çalışmada, diş hekimliği alanındaki tıbbi bilginin teknoloji ile daha verimli kullanılması, hastaların ihtiyaçlarına daha hızlı ve etkili çözümler sunmayı hedeflemektedir.

Anahtar Kelimeler: Derin Öğrenme, Görüntü Bölütleme, Evrişimli Sinir Ağı,
Görüntü İşleme



ABSTRACT

DEEP LEARNING BASED AUTOMATED TEETH SEGMENTATION APPROACH USING PANORAMIC RADIOGRAPHIC IMAGES

Ceren SOZERI

Canakkale Onsekiz Mart University

School of Graduate Studies

Master of Science Thesis in Computer Engineering

Supervisor: Prof. Dr. Bahadır KARASULU

15/01/2025, 58

This study presents a method for classifying panoramic radiographic images, which are frequently used for diagnostic and treatment purposes in dentistry. Following the classification, automatic segmentation of dental structures was performed using models specifically trained according to the patient's age group. This approach allowed for more precise results by considering the distinct anatomical and structural features of adult and pediatric patients. The accuracy of the classification model was evaluated using the Tufts dataset and recorded as 0.80. The deep learning model developed in this study enables the automatic detection and segmentation of teeth, providing significant data for dentists in diagnosis and treatment processes. For the segmentation task, two separate models were trained with adult and pediatric images. The model trained with adult images was DeepLabV3+ResNet50, while UNet was selected as the model for pediatric images. The segmentation performance for adult images achieved an Intersection over Union of 0.90 and a Dice Coefficient of 0.95. For pediatric images, the Intersection over Union was 0.90, and the Dice Coefficient was recorded as 0.94. To enhance usability for dentists, a user interface was developed by using Gradio library for these models. The proposed method and the accompanying interface improve diagnosis accuracy while reducing the workload of practitioners. This study aims to enhance the efficiency of medical knowledge in dentistry through technological advancements, ultimately providing faster and more effective solutions to patient needs.

Keywords: Deep Learning, Image Segmentation, Convolutional Neural Network, Image Processing



İÇİNDEKİLER

Sayfa No

JÜRİ ONAY SAYFASI.....	i
ETİK BEYAN.....	ii
TEŞEKKÜR.....	iii
ÖZET	iv
ABSTRACT	vi
İÇİNDEKİLER	viii
SİMGELER ve KISALTMALAR.....	x
ŞEKİLLER DİZİNİ.....	xii
TABLolar DİZİNİ.....	xiii

BİRİNCİ BÖLÜM

GİRİŞ

1

İKİNCİ BÖLÜM

ÖNCEKİ ÇALIŞMALAR

5

2.1. Literatürdeki Başarım Ölçütleri	5
2.2. Literatürdeki Çalışmalar.....	7

ÜÇÜNCÜ BÖLÜM

MATERYAL VE METOT

12

3.1. Diş Anatomisi	12
3.2. Panoramik Radyografiler.....	13
3.3. Makine Öğrenmesi	14
3.3.1. Danışmanlı Öğrenme.....	15
3.3.2. Danışmansız Öğrenme.....	15
3.3.3. Pekiştirmeli Öğrenme.....	15
3.4. Derin Öğrenme	16
3.4.1. Evrişimli Sinir Ağı.....	16

3.4.2. DeepLabV3+ResNet50 Mimarisi.....	18
3.4.3. UNet Mimarisi.....	19
3.4.4. Inception ve Xception	21
3.5 Bölütleme Yöntemi.....	22
DÖRDÜNCÜ BÖLÜM	
ARAŞTIRMA BULGULARI	
4.1. Çalışmada Kullanılan Yazılım ve Donanım Altyapısı.....	23
4.2. Veri Kümeleri.....	24
4.3. Deneysel Sonuçlar.....	25
4.3.1. Sınıflandırma Sonuçları.....	26
4.3.2. Bölütleme Sonuçları.....	35
4.4 Genel Bulgular.....	43
4.5 Grafikselle Kullanıcı Arayüzü.....	44
BEŞİNCİ BÖLÜM	
SONUÇ ve ÖNERİLER	
5.1. Sonuçlar.....	47
KAYNAKÇA	49

SİMGELER VE KISALTMALAR

EAKA	Eğri Altında Kalan Alan (Area Under Curve)
AUC	Area Under Curve
AİK	Alicı İşletim Karakteristik (Receiver Operating Characteristics)
ROC	Receiver Operating Characteristics
ESA	Evrışimli Sinir Ağı (Convolutional Neural Network)
CNN	Convolutional Neural Network
LPCNN	Large Patch Convolutional Neural Network
KBÜO	Kesişimin Birleşim Üzerine Oranı (Intersection Over Union)
IoU	Intersection Over Union
ÜÇA	Üretken Çekişmeli Ağ (Generative Adversarial Network)
GAN	Generative Adversarial Network
KDEÜÇA	Koşullu Derin Evrişimli Üretken Çekişmeli Ağ
BTESA	Bölge Tabanlı Evrişimli Sinir Ağı (Region-based Convolutional Neural Network)
R-CNN	Region-based Convolutional Neural Network
HBTESA	Hızlı Bölge Tabanlı Evrişimli Sinir Ağı (Faster Region-based Convolutional Neural Network)
Faster R-CNN	Faster Region-based Convolutional Neural Network
Maske - BTESA	Maske Bölge Tabanlı Evrişimli Sinir Ağı (Mask Region-based Convolutional Neural Network)
Mask R-CNN	Mask Region-based Convolutional Neural Network
DEÜÇA	Derin Evrişimli Üretken Çekişmeli Ağ (Deep Convolutional Generative Adversarial Network)
DCGAN	Deep Convolutional Generative Adversarial Network
DESA	Derin Evrişimli Sinir Ağı (Deep Convolutional Neural Network)
kÜÇA	Koşullu ÜÇA (Conditional GAN)
KGÜÇA	Kademeli Gelişen Üretken Çekişmeli Ağ (Progressive Growing of Generative Adversarial Networks)
PGGAN	Progressive Growing of Generative Adversarial Networks
StilÜÇA	Stil Üretken Çekişmeli Ağ (Style Generative Adversarial Networks)
StyleGAN	Style Generative Adversarial Networks

VNet	Hacimsel Sinir Ađı (Volumetric Neural Network)
DRÖGESAS	Derin Rastgele Ölçekli Gerilmiş Evrişimli Sinir Ađına Dayalı Sahne Sınıflandırma (Scene Classification Based on a Deep Random-Scale Stretched Convolutional Neural Network)
BYESA	Büyük Yama Evrişimli Sinir Ađları (Large Patch Convolutional Neural Networks)
ReLU	Rectified Linear Unit (Doğrultulmuş Doğrusal Birim)
DDB	Doğrultulmuş Doğrusal Birim
GGG	Görsel Geometri Grubu (Visual Geometry Group)
CDPR Dataset	Children's Dental Panoramic Radiographs Dataset
A100 GPU	NVIDIA A100 Tensor Core GPU

ŞEKİLLER DİZİNİ

Şekil No	Şekil Adı	Sayfa No
Şekil 1	Bir Azı Dişinin Anatomisi	13
Şekil 2	Üst Düzey Genel ESA Mimarisi	17
Şekil 3	UNet Modeli	21
Şekil 4	Çocuk Panoramik Diş Radyografi Veri Kümesi İçeriği	24
Şekil 5	Tufts Veri Kümesi İçeriği	25
Şekil 6	İkinci Veri Grubuyla Eğitilen ResNet50 Sınıflandırma Modeli Doğruluk Grafiği	28
Şekil 7	Üçüncü Veri Grubuyla Eğitilen ResNet50 Sınıflandırma Modeli Doğruluk Grafiği	29
Şekil 8	İkinci Veri Grubuyla Eğitilen ResNet50 Sınıflandırma Modeli Kayıp Grafiği	30
Şekil 9	Üçüncü Veri Grubuyla Eğitilen ResNet50 Sınıflandırma Modeli Kayıp Grafiği	31
Şekil 10	Üçüncü Veri Grubuyla Eğitilen ResNet50 Sınıflandırma Modeli AİK Eğrisi Grafiği	32
Şekil 11	Yetişkin Verilerinde En Yüksek Başarım Gösteren Görüntü	37
Şekil 12	Yetişkin Verilerinde En Düşük Başarım Gösteren Görüntü	37
Şekil 13	Çocuk Verilerinde En Yüksek Başarım Gösteren Görüntü	39
Şekil 14	Çocuk Verilerinde En Düşük Başarım Gösteren Görüntü	39
Şekil 15	'cate2_00063' isimli Yetişkin Görüntüsünde Kullanıcı Arayüzünün Kullanım Örneği	45
Şekil 16	'cate2_011' isimli Çocuk Görüntüsünde Kullanıcı Arayüzünün Kullanım Örneği	46

TABLULAR DİZİNİ

Tablo No	Tablo Adı	Sayfa No
Tablo 1	Sınıflandırma Modellerinin Başarım Ölçütlerine Göre Değerleri	27
Tablo 2	Sınıflandırma Modellerinin Tufts Veri Kümesindeki Doğru Sınıflandırma Oranı	33
Tablo 3	Görüntü Sınıflandırma Çalışmaları Karşılaştırması	34
Tablo 4	Yetişkin Test Veri Kümesindeki Bölütleme Başarımı	35
Tablo 5	Yetişkin Test Veri Kümesindeki Bölütleme Başarımı Tablosu Devamı	36
Tablo 6	Çocuk Test Veri Kümesindeki Bölütleme Başarımı	38
Tablo 7	Diş Görüntülerinde Bölütleme Çalışmaları Karşılaştırılması	40
Tablo 8	Diş Görüntülerinde Bölütleme Çalışmaları Karşılaştırılması Tablosu Devamı	41
Tablo 9	Diş Görüntülerinde Bölütleme Çalışmaları Karşılaştırılması Tablosu Devamı	42
Tablo 10	Diş Görüntülerinde Bölütleme Çalışmaları Karşılaştırılması Tablosu Devamı	43
Tablo 11	Bölütleme Sonuçlarının Özeti	44

BİRİNCİ BÖLÜM

GİRİŞ

Diş bölütleme, tıbbi görüntüleme alanında, özellikle diş röntgenleri gibi görüntülerde, dişlerin çevre dokulardan ayrıştırılması ve yalnızca dişlere özgü bilgilerin elde edilmesi sürecidir (Ezirganlı vd., 2012). Bu süreç, diş hekimliğinde teşhis, tedavi planlaması ve bilimsel araştırmalar gibi çeşitli uygulamalarda önemli bir rol oynamaktadır (Ezirganlı vd., 2012).

İnsan dişleri, kemik, yumuşak doku ve metal gibi farklı dokuların karmaşık bir bileşiminden oluştuğu için insan gözü ile ayrıştırılması oldukça zordur. Ancak, bilgisayar teknolojilerindeki gelişmeler ve özellikle görüntü işleme algoritmalarındaki ilerlemeler, bu soruna etkili bir çözüm sunmaktadır. Diş hekimliğinde bilgisayar destekli cihazlar son kırk yıldır kullanılmaktadır (Çelik vd., 2013). Böylece, insan gözüyle yapılması güç olan ayrıntılı analizler gerçekleştirilebilir. Bilgisayar destekli sistemler özellikle zamanın kritik olduğu durumlarda, karar almayı hızlandırır. Ek olarak insan gözünün yaptığı değerlendirmeler, değerlendirme yapılan zamana, ortama veya kişilere bağlı olarak değişkenlik gösterebilirken, bilgisayar sistemleri daha tutarlı sonuçlar üreterek sonuçların güvenilirliğini artırır. Böylece diş hekimliği gibi detaylı ve hassas analiz gerektiren alanlarda hata payı minimuma indirgenir.

Bilgisayar tabanlı diş bölütleme sistemleri, diş hekimliğinde daha doğru, hızlı ve güvenilir sonuçlar elde etmek için önemli bir teknoloji haline gelmiştir. Bu sistemler, diş hekimlerinin daha doğru teşhisler koymasına, tedavi planlarını eniyilenmiş hale getirmesine ve hastalarına daha iyi hizmet vermesine olanak tanır (Uçuk, 2024)

Dünya Diş Hekimliği Federasyonu Genel Kurulu'nun 2016'da yayınladığı makaleye göre; ağız sağlığı, konuşma, gülme, yutma, çiğneme, tatma ve yüz ifadeleriyle duyguları ifade edebilme gibi aktivitelerin herhangi bir acı veya rahatsızlık hissedilmeden gerçekleştirilmesine denir (FID Dünya Diş Hekimliği Federasyonu, 2016) Bu nedenle, bilgisayar destekli teşhis yöntemlerinin gelişmesi, ağız sağlığının genel olarak iyileştirilmesine önemli bir katkı sağlamaktadır (Glick vd., 2016).

Her ne kadar bir sorun olarak görünmese de, dünya genelinde ağız sağlığı toplumları tehdit eden önemli bir sorundur (World Health Organization, 2022). Bu sebeple dünya

genelinde ağız problemleri neredeyse 3,5 milyon kişiyi etkilemektedir ve etkilenenlerin dörtte üçü orta gelirli ülkelerde yaşamaktadır (World Health Organization, 2022).

Ağız ve diş sağlığı, toplum sağlığında önemli bir yere sahip olduğundan, ülkenin veya toplumun sosyoekonomik durumuna uygun olarak planlanma yapılması gerektiği vurgulanmıştır (Özyavaş, 2018).

Ağız sağlığı sadece çürüklerden korunmakla değil ayrıca, uzun süre biberon, veya emzik kullanımı çene yapısını değiştirdiğinden özellikle 3 ila 14 yaş arasındaki çocuklarda ağız sağlığına dikkat edilmesi, ilerde ortaya çıkabilecek rahatsızlıkları önlemeye yardımcı olur (Aran, 1978).

Diş hekimliğinde kullanılan görüntüleme yöntemleri, dişlerin lokal durumu değerlendiren ağız içi (periapikal, oklüzal, ısırtma) ve çene yapısı, sinüsler, eklemler gibi daha geniş bölgelerin değerlendirilmesinde kullanılan ağız dışı (panoramik, sefalometrik, bilgisayarlı tomografi gibi) olmak üzere iki ana grupta incelenir (Göçer vd., 2010).

Her alanda olduğu gibi diş alanında da doğru teşhis için kullanılan elektronik cihazlara bağlı görüntülerde dayanarak yapılan çıkarımlarda hata payı vardır ve bu hata payı bu çıkarım yapan kişiye, ölçme cihazının model ve çalışma yöntemine hatta görüntülerin değerlendirildiği fiziksel ortama bile bağlıdır (Özata ve Altuncan, 2010). Buna bağlı olarak, diş hekimleri tarafından radyografik görüntülerin manuel olarak anlamlandırılması zaman alabilir, karmaşık olduğu için hata olabilir. Bu sebeple, bu hataları en aza indireyecek kararlı bir makine öğrenmesi modeli, ideal doğruluğu sağlarken zamandan kazanmaya da yardımcı olacaktır. Çünkü makine öğrenmesi sağlık alanında birçok radyografi görüntülerinde başarılı sonuçlar vermiştir.

Makine öğrenmesi ve onun alt dalı olan derin öğrenme karmaşık ve büyük veri kümelerinden oluşan çalışmalarda da başarıya ulaşabilmektedir. Bu sebeple farklı varyasyonlara ve aykırı değerlere sahip veri kümelerinde derin öğrenme başarılı sonuçlara ulaşabilir. Derin öğrenme, yapay sinir ağlarından oluşur ve Tespit Etme (Detection), Tanıma (Recognition), Tanımlama (Identification), Bölütleme (Segmentation), Sınıflandırma (Classification), Regresyon gibi görevlerde sına sonuçlarındaki başarımlarını doğruluğu yüksek modeller üretir.

Evrişimli Sinir Ağı - ESA (Convolutional Neural Network - CNN), Konuşma Tanımlama (Speech Identification), Görüntü Sınıflandırma, Tespit Etme, Tanıma gibi birçok görevde kullanılabilen özel bir sinir ağıdır.

Bazı durumlarda, büyük verilerle eğitilmiş bir yapay sinir ağı modeli daha sonra daha küçük veri kümeleriyle tekrar eğitilebilir. Bu durum eğitim süresini azaltırken hem de yüksek başarımların gösterilmesine yardımcı olur.

Derin öğrenme modellerinin etkinliğini artırmak ve yeni, başarılı modeller geliştirmek için kullanılan bu yöntem Eğitim Aktarımı (Transfer Learning) denir. Yüz verilerinin karmaşık yapısını daha iyi modellemek için tasarlanmış özel bir mimariye sahip Xception, görüntü sınıflandırma görevlerinde tercih edilen ve Görsel Geometri Grubu - GGG (Visual Geometry Group - VGG)'nun kısaltması olan VGG16 ile VGG19, öznelik elde etmede kullanılan DeepLabV3 gibi bir çok önceden eğitilmiş modeller bulunmaktadır.

Eğitim Aktarımı, özellikle tıbbi görüntüleme gibi veriye ulaşmanın zor olduğu alanlarda büyük avantaj sağlar. Önceden eğitilmiş modeller sayesinde, sınırlı tıbbi görüntü verisiyle bile yeni hastalıkların teşhisi için etkili modeller geliştirilebilir. Tıpta kullanılan derin öğrenme algoritmaları, tanı koyma hassasiyetinde insan uzmanlara yaklaşarak, tıbbi görüntüleme gibi alanlarda önemli bir yardımcı araç haline gelmiştir (Burt vd., 2018).

Diş hekimliği alanında, panoramik diş görüntülerinin otomatik olarak bölütlenmesi teşhis ve tedavi süreçlerini hızlandırıp, hekim hatasını azaltmada önemli bir rol oynamaktadır. Bu çalışmada, çocuk ve yetişkin bireylere ait görüntülerdeki anatomik farklılıkları göz önünde bulundurarak, bölütleme görevi için özel olarak tasarlanmış derin öğrenme modelleri geliştirilmiştir.

Sınıflandırma görevi ise, bölütleme modeline verilecek panoramik görüntünün sınıfsal olarak doğru bölgelere uygun oranda ayrıştırılmasına dair ilk adım olması yoluyla daha doğru sonuçlar elde etmek amacıyla gerçekleştirilmiştir. Bu çalışma sayesinde, daha doğru ve hızlı teşhis konulması hedeflenmektedir.

Panoramik diş radyografilerinde, dişlerin üst kısmını belirten kuron ve dişlerin ete gömülü kısmını belirten kök bölümünün diğer dokularla sınırlarının daha hassas bir şekilde belirlenmesi için derin öğrenme tabanlı bölütleme modelleri olan DeepLabv3 + ResNet50 ve UNet kullanılmıştır. DeepLabv3, bir Derin Evrişimli Sinir Ağı (DESA)'dır ve anlamsal bölütlemeye karşılaşılan düşük öznelik çözünürlüğünü sorununu Atrous evrişimi (Atrous

convolution) kullanarak, diğeri bir sorun olan birden çok nesnenin bulunduğu görüntülerde nesnelerin farklı boyutlarda olması sebebiyle ortaya çıkan ölçeklendirme sorununu, görüntü piramidi (image pyramid) yöntemine kodlayıcı (encoder) ve kod çözücü (decoder) katmanı, bağlam modülü (context module) ve uzamsal piramit havuzlaması (spatial pyramid pooling) yöntemlerini ekleyerek çözmüşlerdir (Chen vd., 2017).

ResNet ise, katmanlar arası bilgi aktarımı gerçekleştiren Derin Artık Ağ (Deep Residual Network)'dır ve artık kelimesi, bir katmanın girişinin sonraki katmanın çıkışına bağlanmasına denir ve bu sebeple öğrenmeyi kolaylaştırırken ve başarımın artırması sağlar. (Shafiq ve Gu, 2022). ResNet50 ise 50 katmana sahip bir ResNet ağı olduğunu belirtir (He vd., 2016).

DeepLabV3+ResNet50 modeli ise ResNet'in öznetelik elde etme yeteneğini DeepLabV3'ü DESA ile mimarisi ile birleştirir. UNet ise, mimarisi gereği az veriden bir bağlam çıkarabilir bu sebeple küçük veri kümelerinde yüksek başarım gösterir (Ronneberger vd., 2015).

DeepLabV3+ResNet50 büyük verilerde daha iyi çalıştığından çocuk verilerinde oldukça düşük başarım sonuçları üretmiştir, bu nedenle çocuk verileri daha küçük veri kümelerinde başarılı sonuçlar veren UNet ile kullanılmıştır.

Bu çalışmanın en önemli katkılarından biri, çocukların panoramik radyografik görüntülerinde diş yapılarının bölütlenmesi üzerine odaklanılarak bu alandaki literatüre yeni bir yaklaşım ve buna dair uygulama kazandırılmıştır. Özellikle çocuklarda diş gelişimi ve büyüme süreçlerinin incelenmesinde bu bölütleme sonuçlarının önemli bir rol oynaması beklenmektedir.

Bu çalışmanın giriş bölümünü takiben, ikinci bölümde ilgili alandaki mevcut literatür incelenmiştir. Önceki çalışmalarda kullanılan veri kümeleri ve veri toplama yöntemleri, kullanılan başarım ölçütleri ve çözüme yönelik sunulan yöntemler incelenmiştir. Üçüncü bölümde ise çalışmanın temelini oluşturan diş ve ağız anatomisi, ağız içi hastalıklar, makine öğrenmesi ve derin öğrenme konularına dair teorik bir çerçeve sunulmuştur. Dördüncü bölümde ise, deneysel süreç, kullanılan yazılım ve donanım altyapısı, veri kümelerinin özellikleri ve elde edilen sonuçlar sunulmuştur. Son bölümde ise elde edilen bulguların tartışılması ve gelecek çalışmalar için önerilerde bulunulmuştur.

İKİNCİ BÖLÜM

ÖNCEKİ ÇALIŞMALAR

Literatürde dişlerle ilgili birçok veri kümesi olmasına rağmen, görüntü verileri panoramik, periapikal veya ısırtma (bite-wing) gibi farklı görüntü türleri içerebilir. Diş görüntüleri kullanılarak kapsamlı araştırmalar yapılmış olmasına rağmen bu çalışmalarda kullanılan veri kümelerinin çoğu ya özeldir ya da kamu kullanımına kapalıdır.

Panetta ve arkadaşları literatüre 1000 görüntülük bir veri kümesi sunmuş olsalar da, bu veri kümesine erişmenin tek yolu, "Panoramik Radyografi Veri Kümelerinin Karşılaştırılması" tablosunda halka açık olarak duyurulmasına rağmen sadece akademik araştırma için kullanmayı kabul etmektir (Panetta vd., 2021)

Çoğu veri kümesinde ya çocuk verileri bulunmamakta ya da çocuk verilerinin diğer diş rahatsızlıklarından (kanal tedavisi, dolgu, diş eksikliği, takma diş vb.) biri gibi ayrı bir kategoride değerlendirildiği gözlemlenmektedir. Ancak doğru sonuçlara ulaşılması için çocuk verilerinin ayrı bir modelde eğitilmesi yoluyla daha iyi ve sağlıklı sonuçlar üretebilir. Son zamanlarda araştırmacılar, 193 çocuk ve 2692 yetişkin diş görüntüsünü içeren karma bir veri kümesi oluşturmuşlardır (Zhang vd., 2023)

2.1. Literatürdeki Başarım Ölçütleri

Literatürde, eğitim başarı sonuçlarını gözlemek için çeşitli başarı ölçütleri kullanılmıştır. Literatürde, Başarım Doğruluğu (Accuracy), *F1* Ölçütü (*F1* Score), Anma (Recall), Duyarlılık (Precision) ve Özgüllük (Specificity) gibi sınıflandırma başarı ölçütleri ile Alıcı İşletim Karakteristik – AİK (Receiver Operating Characteristics - ROC) eğrisi ve Eğrinin Altında Kalan Alan - EAKA (Area Under Curve - AUC) gibi daha hassas ölçüm yapabilen ölçütler yaygın olarak kullanılır (Metin ve Karasulu, 2021).

Karışıklık Matrisi (Confusion Matrix), bir modelin başarımını değerlendirmek için kullanılır ve modelin yaptığı doğru ve yanlışları olması gereken gerçek etiketler ile karşılaştırma yoluyla görselleştirilmesine denir. Karışıklık Matrisi dört kategoride incelenir bunlar; Doğru Pozitif (True Positive - TP), Doğru Negatif (True Negative- TN), Yanlış Pozitif (False Positive - FP) ve Yanlış Negatif (False Negative - FN)'tir. Başarım Doğruluğu,

Anma, Duyarlılık ve *F1* Ölçütü gibi ölçütler bu kategorilerin birbirlerine oranları ile ölçülür. Bölütleme görevlerinde sıkça kullanılan Kesişimin Birleşim Üzerine Oranı – KBÜO (Intersection over Union - IoU), iki kümenin ne kadar örtüşüğünü ölçer.

Başarım doğruluğu, Doğru Pozitif ve Doğru Negatif sonuçların toplamının tümüne oranı ile bulunur ve Eşitlik 2.1’de formülü verilmiştir (Metin ve Karasulu, 2021).

$$Başarım\ Doğruluğu = \frac{(Doğru\ Pozitif)+(Doğru\ Negatif)}{(Doğru\ Pozitif)+(Doğru\ Negatif)+(Yanlış\ Pozitif)+(Yanlış\ Negatif)} \quad (2.1)$$

Duyarlılık, Doğru Pozitiflerin, tüm pozitiflere oranı ile hesaplanır ve Eşitlik 2.2’de formülü verilmiştir (Silva vd., 2018).

$$Duyarlılık = \frac{Doğru\ Pozitif}{(Doğru\ Pozitif)+(Yanlış\ Pozitif)} \quad (2.2)$$

Anma, tüm pozitif değerlerin içinde, doğru sınıflandırılan pozitif değerlerinin oranını verir ve Eşitlik 2.3’te formülü verilmiştir (Silva vd., 2018).

$$Anma = \frac{(Doğru\ Pozitif)}{(Doğru\ Pozitif)+(Yanlış\ Negatif)} \quad (2.3)$$

F1 Ölçütü ise Duyarlılık ve Anma arasındaki harmonik ortalamayı temsil eder. Hesaplama formülü Eşitlik 2.4’te verilmiştir (Metin ve Karasulu, 2021). Harmonik ortalama ise aykırı değerlerin etkisini azaltma amacıyla kullanılan bir merkezi eğilim ölçüsüdür (Miran, 2021).

$$F1\ Ölçütü = \frac{2 \times (Duyarlılık) \times (Anma)}{(Duyarlılık) + (Anma)} \quad (2.4)$$

Özgüllük, Tüm negatif değerler içinde doğru şekilde tanımlanan negatif değerlerin yüzdesi ile hesaplanır ve Eşitlik 2.5'te formülü verilmiştir (Fawcett, 2006).

$$\text{Özgüllük} = \frac{\text{Doğru Negatif}}{(\text{Doğru Negatif}) + (\text{Yanlış Pozitif})} \quad (2.5)$$

KBÜO, tahmin edilen küme ile gerçek kümenin kesişimlerinin birleşimlerine oranıdır (Zhou vd., 2019). Eşitlik 2.6'da formülü verilmiştir.

$$\text{KBÜO} = \frac{(\text{Tahmin Edilen Alan}) \cap (\text{Referans Alan})}{(\text{Tahmin Edilen Alan}) \cup (\text{Referans Alan})} \quad (2.6)$$

Dice Katsayısı, tahmin edilen maske ile gerçek maskenin kesişimlerinin boyutunun birleşimlerinin boyutuna oranıdır (Shamir vd., 2019). Eşitlik 2.7'de formül verilmiştir.

$$\text{Dice Katsayısı} = \frac{2 \times |(\text{Tahmin Edilen Maske}) \cap (\text{Referans Maskesi})|}{|(\text{Tahmin Edilen Maske})| \cup |(\text{Referans Maskesi})|} \quad (2.7)$$

2.2. Literatürdeki Çalışmalar

Aşırı Bölütleme (Over segmentation) ve Zayıf Bölütleme (Under segmentation) problemleri, görüntü işleme alanında çalışılan herhangi bir görüntüdeki ayrıştırılabilen farklı bilgilerin sınırları belirlenirken bu sınırların ilgi bölgeyi tam olarak ifade edip etmediğine denir. Bu nedenle bölütleme sonucu başarıyı düşebilmektedir. Bu problemin çözümü için birçok çalışma yapılmıştır.

Literatürde aşırı bölütleme problemini çözmek amacıyla dışlar arasındaki ayrımı keskinleştirmek için erozyon yöntemi (erosion procedure) ve matematiksel morfoloji tekniği olan ve görüntünün belirli özneteliğini vurgulamaya yarayan top-hat ile bottom-hat dönüşümü yapılmıştır, bu dönüşüm kontrastı artırarak arkaplan ile önplanı birbirinden ayırmaya ve gürültülerin azaltmasına yardımcı olmuştur (Li vd., 2012). Sonuçlara göre

önerilen yöntem, dış X-ışını görüntülerini başarılı bir şekilde bölütleyebildiğini ve aşırı bölütleme sorunun üstesinden gelebildiği belirtilmiştir (Li vd., 2012).

Top-hat dönüşümü başka bir çalışmada panoramik dış görüntülerinin kalitesini artırmak amacıyla kontrast, detay ve kenar keskinliğini artırmak için sunulan bir algoritmadır ve öznelilik çıkarma ile detayları iyileştirme görevinde bölgesel iyileştirmeler yaparak çeşitli başarımlar ölçütlerine göre iyi sonuçlar elde ettiği vurgulanmaktadır. (Román vd., 2021).

Gil Silva ve arkadaşları tarafından yapılan derleme makalede ise, dış görüntülerinde yapılan çalışmalar yöntem türüne, görüntü türlerine ve veri kümesi özelliklerine göre ayrılarak inceleme yapılmış ek olarak çalışma yapıldığı zaman literatürde bulunan makalelerin çoğu 1 ila 100 görüntü ile çalıştığı ve 500'den fazla görüntüye sahip bir veri kümesi içeren tek çalışmanın kamuya açık olmadığı belirtilmektedir (Silva vd., 2018). Bu sebeple 1978 işaretlenmiş görüntüden oluşan bir veri kümesi sunulmuş ve bu veri kümesi dişlerde uygulanan birçok tedavi yöntemini içeren bilgileri sahip olduğu belirtilmiştir (Silva vd., 2018). Veri kümeleri incelendiğinde ise 25 çalışma, 1 ila 100 veriden oluşan veri kümesi kullanırken, 101 ila 200 veriden oluşan veri kümesine sahip çalışma sayısı dört, 201 ila 500 veriyle çalışan üç ve 500'den fazla veriye sahip tek bir çalışma vardır ve bu veriler halka açık değildir ek olarak, sekiz çalışmada veri kümesinin büyüklüğünden bahsedilmemektedir (Silva vd., 2018). Veri kümelerinde görüntü tiplerinde ise genellikle ağız içi (intraoral) görüntülerin tercih edildiği, seçilen makalelerde ısırtma görüntü türünü kullanan 13, periapikal görüntüleri kullanan 14, panoramik görüntüleri kullanan dokuz, hem ısırtma hem de periapikal görüntüleri kullanan iki, hem ısırtma hem de panoramik görüntüleri kullanan bir, hem periapikal hem de panoramik görüntüleri kullanan bir ve bu üç görüntü türünü de kullanan bir çalışma bulunmaktadır (Silva vd., 2018).

Yüksel ve arkadaşları tarafından yapılan bir çalışmada ise beş farklı diş tedavisi yaklaşımı tespit eden ve aynı zamanda dişleri numaralandıran bir derin öğrenme modeli sunulmuş ve numaralandırma görevi için ortalama duyarlılık başarımının 0,89, tedavi tanımı için ise ortalama duyarlılık başarımının 0,59 olduğu belirtilmiştir (Yüksel vd., 2021).

2020'de Çelik ve Talu tarafından yapılan derleme makalesinde, yazarlara göre en çok kullanılan yedi Üretken Çekişmeli Ağ (ÜÇA) modelinin başarımları detaylı incelenmiştir ve Koşullu ÜÇA (Conditional GAN) ile Derin Evrişimli ÜÇA (DEÜÇA)'dan oluşan hibrit bir Koşullu Derin Evrişimli Üretken Çekişmeli Ağ (KDEÜÇA) modeli önerilmiştir. Bu incelemeye göre, hata oranı en düşük ve başarımları 0,97 ile en yüksek başarıya sahip model

başka bir model olarak kaydedilirken önerilen yöntem 0,80’de kalmıştır bu başarıyı her sınıf için yapılan hatanın modelin tüm hatalarına bölünmesiyle ve bu sonucun 1’den çıkarılıp 100 ile çarpılması sonucu elde edilmiştir. (Çelik ve Talu, 2020).

Ağız içi görüntülerde ÜÇA kullanan bir diğer çalışmada, Kademeli Gelişen Üretken Çelişmeli Ağ (Progressive Growing of Generative Adversarial Networks - PGGAN) isimli üretici ağ ile başarılı örnekler üretildiğini belirtmişler (Kokomoto vd., 2021). Normal mimarilerden farklı olarak, girdi bilgilerini ağın girişine değil de ara bir kontrol alanında ince detayların yakalanmasını sağlayan StilÜÇA (StyleGAN) ile karşılaştırma yapılmıştır (Karras vd., 2020). StilÜÇA’nın PGGAN’dan daha iyi sonuçlar üretmesine rağmen PGGAN ağına göre çok daha hızlı çalışıp süreyi ve maliyeti düşürdüğü için daha uygun bir seçenek olduğu belirtilmiştir (Kokomoto vd., 2021).

Literatürde Abdal ve arkadaşları tarafından yapılan çalışmada, StilÜÇA tarafından üretilmiş nesnelere bölütleme yapılan bir çerçeve (framework) önerilmektedir (Abdal vd., 2021). Bu çerçeve arka plan ile ön planı birbirinden ayırmakta insan görüntülerinde saç, sakal ve gözlük ekleyebilmektedir (Abdal vd., 2021).

Yang ve arkadaşları tarafından yapılan bir derleme makalesinde iki boyutlu ve üç boyutlu dış görüntülerindeki gürültüyü azaltmak, çözünürlüğü artırmak, nesne tespiti ve sınıflandırma gibi görevlerde kullanılan birçok ÜÇA türünü detaylı incelemişler ve dış hekimliği alanında ÜÇA’ların uygulanabilirlik potansiyelinin yüksek olduğunu belirtmişlerdir (Yang vd., 2024).

Dış hastalıklarında çürüklerle ilgili yapılan bir çalışmada, panoramik görüntülerde çürüklerin derecelerini sınıflandırmak için bir derin öğrenme mimarisi geliştiren Zhu ve arkadaşları, boyutu 1159 olan veri kümesi ile eğitilen sinir ağına dikkat modülü ekleyerek bölütlemeye Dice Katsayısı (Dice Coefficient) göre elde edilen başarıyı 0,93 olarak belirtmişlerdir (Zhu vd., 2023).

Dış tespit etme ve numaralandırma görevi için Evrişimli Sinir Ağı (ESA) modeli sunulan bu çalışmada, 1352 yetişkin verisi ile eğitilen modelin dış tespit etme görevi için Hızlı Bölge Tabanlı Evrişimli Sinir Ağı (HBTESA) mimarisi kullanıldığı ve dış numaralandırma görevi için ise Görsel Geometri Grubu (VGG16) mimarisinden yararlanıldığı belirtilmiştir. Dış tespit etme ve dış numaralandırma görevleri için duyarlılık ölçüt değeri 0,99 olarak belirtilmiştir (Tuzoff vd., 2019).

Bölütleme görevi için, Bölge Tabanlı Evrişim Sinir Ağı'na dayanan biri mimariye sahip olan Maske Bölge Tabanlı Evrişim Sinir Ağı (Maske BTESA) ile tüm dişleri içeren, eksik dişleri olan, diş protezi olan ve diş protezi olmayan, restorasyonlu ve restorasyonsuz olmak üzere görüntüleri on farklı kategoride eğitilmiş ve bilimsel bulgulara göre modelin kategorileri sınıflandırma başarımları doğruluğu 0,98, ortalama duyarlılık 0,94 ve ortalama anma 0,84 olarak belirtilmiştir (Jader vd., 2018).

Tufts veri kümesini 760 eğitim, 190 geçerlilik ve 50 test verisi olarak kullanan başka bir çalışma da ise görüntü bölütleme için Maske - BTESA kullanarak eğittikleri modelde 0,98 değerinde bir başarımları doğruluğuna ulaştığı belirtilirken, Dice Katsayısının 0,87 olduğunu vurgulanmış ve en zorlu görevin birden fazla eksik diş olan görüntülerde olmasının nedeninin referans olarak alınacak çok fazla diş olmadığından varolan dişin doğru tanımlanmasının oldukça zor olduğu dile getirilmiştir (Rubiu vd., 2023).

2010 ile 2023 arasında yayımlanan makalelerin derlendiği bir çalışmada ise, en yaygın kullanılan diş görüntü tipleri panoramik ve periapikal radyografilerin olduğu belirtilirken, diş çürükleri ve lezyonların görüntü kategorilerinde en sık kullanılan kategorilerden olduğu vurgulanmış ve seçilen çalışmaların veri kümesi boyutları ile başarımları incelenmiş çalışmaların kısa özetleri ve görevleri sunulmuştur (Bhat vd., 2023). Bu çalışmanın sonuçlarına göre; diş görüntülerinin etiketlenmesi çok fazla insan çabası gerektirdiğinden otomatik olması gerektiği, diş radyografilerinde bölütleme ve sınıflandırma çalışmalarında genellikle görüntü iyileştirme yapıldığı, doğru yöntem seçimi ile diş bölütleme, tanımlama ve numaralandırmada başarımları artırılacağı ancak mevcut çalışmaların veri toplama, model doğrulama ve uygulanabilirlik açısından yetersiz olduğu belirtilmiştir (Bhat vd., 2023).

Bir başka çalışmada, panoramik diş radyografileri kullanarak diş tespiti ve diş rahatsızlıkları sınıflandırması için yeni bir yöntem geliştirilmiştir bu yöntemde üç farklı diş kliniğinden alınan görüntüler, 14 farklı diş rahatsızlıkları ile birlikte piksel düzeyinde etiketlenmiş ve anlamsal (semantic) bölütleme ESA ile eğitilmiştir (Muresan vd., 2020). Dişler, iki aşamalı etiketleme algoritmasıyla tespit edilip, diş rahatsızlıkları sınıflandırılmış, teşhis sürecine yardımcı olacak raporlar oluşturulmuş ve çalışma farklı başarımları ölçütleriyle değerlendirmiştir (Muresan vd., 2020). Bunun yanı sıra en zor görevlerden biri olan eksik dişlerin bulunduğu görüntülerde bile başarımları yakalamıştır (Muresan vd., 2020).

Derin Evrişimli Üretken Çekişmeli Ağ (DEÜÇA) kullanılarak sağlık verileriyle görüntü üretimi üzerine gerçekleştirilen ve literatüre yeni bir veri kümesi kazandıran çalışmada, üretilen çocuk diş görüntülerinin gerçekçiliği tatmin edici bulunmuş olmakla birlikte, görüntü çözünürlüklerinin bölütleme ve sınıflandırma gibi ileri düzey görevler için yetersiz olabileceği ifade edilmiştir (Sözeri ve Karasulu, 2024).

Bu tez çalışmasında literatürdeki çeşitli çalışmalarda çocuk verilerinin oldukça az kullanıldığı görülerek, buna dair bir sınıflandırma ve bölütlemenin başarımı ortaya koyacak deneyler üzerinde çalışılmıştır. Elde edilen deneysel sonuçlar ve bulgulara bu çalışmada yer verilmektedir.



ÜÇÜNCÜ BÖLÜM

MATERYAL VE METOT

Diş hekimliğinde makine öğrenmesi diş çürüğü, diş yapısındaki anormali, kemik yoğunluğu ve ağız kanseri tespiti, yaş bulma, kişi tanıma veya cinsiyet bulma, diş numaralandırma, diş bölütleme gibi alanlarda kullanılır (Bhat vd., 2023).

Bu bölümde, diş anatomisi ve panoramik radyografilerin açıklaması yapılmakla beraber bu görüntülerde sınıflandırma ve ilgili bölgelerde bölütlemesi yapılması için gereken makine öğrenmesi ve derin öğrenme yöntemleri detaylarına yer verilmektedir.


3.1 . Diş Anatomisi

Diş anatomisi, insan dahil olmak üzere farklı hayvan türlerinin dişlerini toplayıp sınıflandırarak ve sistematik bir yapı oluşturarak diş morfolojisinin temel ilkelerini anlamaya katkı sağlar (Kondo vd., 2022).

Dişler, besinleri ısırma ve öğütme işlevlerinde sindirime yardımcı olurlar, bunlardan kesici dişler yiyecekleri daha küçük parçalara bölmek için, büyük azı dişleri ise besinleri öğütmek için kullanılır (Arslan, 2022).

Normal bir dişin anatomik parçalarından biri olan kuron dişin görünen ve çiğneme görevinde rol olan kısmı iken, kök dişin gömülü olan ve dişi sabit tutan kısmıdır. Kök, her zaman kurondan daha uzundur. Kökün boyutu diş grubuna göre değişir (Campista vd., 2023).

Servikal çizgi, kuron ile kök arasında bulunan ara bölümdür ve dişin en dar kısmıdır (Campista vd., 2023). Kuron, kök ve servikal çizginin sembolik gösterimi Şekil 1'de verilmiştir. Şekil 1'de yetişkin bir insanda azı dişinin şematik görünümü verilerek burdaki bölümler Campista ve arkadaşlarının çalışmasında belirtildiği haliyle ifade edilmiştir (Campista vd., 2023).



Şekil 1: Bir Azı Dişinin Anatomisi (Campista vd., 2023).

İnsanlarda dişler diş şekillerine ve işlevlerine göre sınıflandırılır; bunlar toplam sekiz tane olan ve besinlerin kesilmesi veya kavranmasında görev alan kesici dişler, toplam dört tane olan ve besinleri küçük parçalara ayırma görevini üstlenen köpek dişleri, toplam yirmi tane olan azı dişleri ise besinlerin öğütülmesini sağlayarak sindirim sürecine katkı sağlar (Campista vd., 2023). Kesici dişler ve köpek dişleri tek köke sahipken azı dişleri genellikle iki ayrı köke sahiptir ancak bazı durumlarda üç köke sahip olan azı dişleri de bulunur (Campista vd., 2023).

3.2. Panoramik Radyografiler

Wilhelm Conrad Roentgen tarafından 1895 yılında X-ışınları keşfedildikten sonra ilk diş radyografisi Dr. Otto Walkhoff tarafından çekilmiştir (Williamson, 2006). Röntgen teknolojisi ise X-ışınları kullanılarak yapılan bir tıbbi görüntüleme tekniğidir. Röntgen teknolojisi, 1910'lara kadar X-ışını makinesi düşük verimli, gaz içeren soğuk katot iyon X-ışını tüpü kullanılmıştır ve röntgen makinesinin kapasitesi, düşük verimliliği, zayıf nüfuz etme gücü, zayıf görüntü netliği ve koruma eksikliği vardır.

1910'da Amerikalı fizikçi Coolidge, Tungsten filamentinin, tüp akımı için gereken elektronları sağlamak için akkor bir duruma ısıtılması ile tüp akımı, filamanın ısıtma sıcaklığı ayarlanarak kontrol edilebileceğini ve bu durumun görüntü kalitesini iyileştirilebileceğini keşfetmiştir.

Çift odaklı X-ışını tüpü, 1923'te icat edildi. Çift odaklı X-ışını tüpünün gücü birkaç kilovata ulaşabilir, dikdörtgen odak noktasının yan uzunluğu yalnızca birkaç milimetredir ve

X-ışını görüntü kalitesi büyük ölçüde iyileştirilmiştir. Aynı zamanda, kontrast etmenleri aşamalı olarak uygulanması, X-ışını teşhisinin kapsamını sürekli olarak genişletmiştir.

Yüksek enerjili ve düşük enerjili olmak üzere iki tür röntgen vardır. Tıbbi teşhislerde düşük enerjili röntgenler kullanılmaz çünkü vücut onları tamamen emer ve görüntüyü iyileştirmeden radyasyon miktarını artırır.

Dört farklı radyografi türü vardır ve kullanım amaçları değişkenlik göstermektedir. Oklüzal radyografi diş kemercinin geniş bir kısmını görüntülemektedir (Bhat vd., 2023). Genellikle çocuk hastaların diş yerleşimini ve gelişimini takip etmek için kullanılırken, ısırtma yöntemi ağzın belirli bir bölgesinde detaylı bilgi almak için ve periapikal radyografi bir dişin köke kadar sınırlar dahil olmak üzere tamamını görüntülemeye kullanılır (Bhat vd., 2023).

Panoramik radyografi, bir hastanın çene yapısı, diş ve dokuları tek bir görüntüde incelenmesini sağlayan iki boyutlu bir röntgen tipidir (van Nistelrooij vd., 2024). Bu röntgenler sadece diş sağlığı, şekli ve birbirine ile uyumu hakkında bilgi sağlamakla kalmaz, aynı zamanda dişleri çevreleyen doku ve çene kemiklerinde meydana gelebilecek herhangi bir boşluk, kemik kaybı veya diğer anormalliklerin fark edilmesine yardımcı olur (Ezirganlı vd., 2012).

Panoramik röntgen çekilirken, çene ve alın sabitlenir. Ağzı bir miktar açık tutmak gerektiğinden bir aparat ısırılır ve ardından röntgen makinası kişinin etrafında yarım daire olacak şekilde döner. Tüm ağız ile çenenin kapsamlı bir görüntüsü elde edilir.

3.3. Makine Öğrenmesi

Makine Öğrenmesi, bir modelin veri kümelerinden örüntüler ve ilişkiler öğrenmesini, anlam çıkarmasını sağlar. Başarılı bir eğitimden geçen model sadece öğrendiği değil öğrenmediği verileri de genellebilir ve eğitimine bağlı olarak bir çıktı üretir (Karasulu vd., 2022). Bu çıktı ses, görüntü ya da yazı veya rakam olabilir. Makine öğrenmeleri genellikle üç alt kategoriye ayrılır. Bunlar; danışmanlı, danışmansız ve pekiştirmeleri öğrenmedir (Karasulu vd., 2022).

3.3.1. Danışmanlı Öğrenme

Bu öğrenme yönteminde, model etiketlenmiş veriler ile eğitilir. Bu sebeple girdi verileri doğru sonuçlarla eşleştirilerek modele eğitimi gerçekleştirilir. Sınıflandırma ve regresyon olarak iki farklı görev tanımı vardır. Sınıflandırma, eğitimde kullanılan verinin etiketlerde belirtilen sınıflardan hangisi olduğuna karar verir. İki sınıfı bulunan görevlere ikili (binary) sınıflandırma denilir. Genellikle çok sınıflı görevlerde sınıf sayısı en az iki veya ikiden fazla olacak şekilde ayarlanabilir (Karasulu vd., 2022). Regresyon ise çıktı olarak bir sayı üretir. Bu sayı eğitim verilerinin özniteliklerinden elde ettiği anlama bağlı olur (Karasulu vd., 2022). Örneğin tecrübe ve meslek verilerine göre maaş tahmini yapılması regresyona örnektir (Karasulu vd., 2022).

3.3.2. Danışmansız Öğrenme

Danışmansız öğrenme yöntemi, etiketlenmemiş verilerle çalışır, model verilerde bir ortaklık veya desen (pattern) bulmaya çalışır. Kümeleme işlemi bu yöntemin kullanıldığı görevlerdendir. Kümeleme, benzer verileri belirlenen sınır değerlere kadar gruplar ve kümeler oluşturur (Metin ve Karasulu, 2021).

Tıp, pazarlama gibi alanlarda kullanılır, örnek olarak internet sitelerinde müşterilerin ürün tercihlerini ve harcama limitlerine göre müşterilerin kümeleneşmesi ya da hastalık teşhisin de semptomlara göre hastaların veya hastalıkların kümeleneşmesi örnek verilebilir (Karasulu vd., 2022).

3.3.3. Pekiştirmeli Öğrenme

Pekiştirmeli Öğrenme, mantık çerçevesi içinde seçilen durumlara göre ödül ve ceza almasına bağlı olarak şartlı bir şekilde öğrenme gerçekleştirilmesine denir (İmamoğlu vd., 2009). Pekiştirmeli Öğrenmede bir etmen vardır ve bu etmen karşılaştığı durumlara tepki gösterir ve tepkisine oranla bir cevap alır (Sarican ve Engin, 2024). Etmenin hedefi aldığı

ödülleri artırmaktır (Sarıcan ve Engin, 2024). Bunu da daha önce aldığı ödüllerdeki tepkilerini tekrar ederek gerçekleştirmeye çalışır (Sarıcan ve Engin, 2024). Otonom araçlarda, yol bulma uygulamalarında ve oyunlarda kullanılan bir eğitim modelidir (Metin ve Karasulu, 2021).

3.4. Derin Öğrenme

Yapay zekâ ve makine öğrenme yöntemlerinin alt dalı olan çalışma alanıdır. Otomatik öznitelik öğrenme olarak ifade edilebilen ve temel özniteliklerle elde edilen somut bilgilerin, anlamsal olarak zenginleştirilmesiyle daha karmaşık bir bilgi birikimine ulaşarak, problemde ele alınan varlıkların sınıflandırılması, tanınması veya tahminlemede çoklu katman yapısına sahip yapay sinir ağlarının kullanımına dayanır.

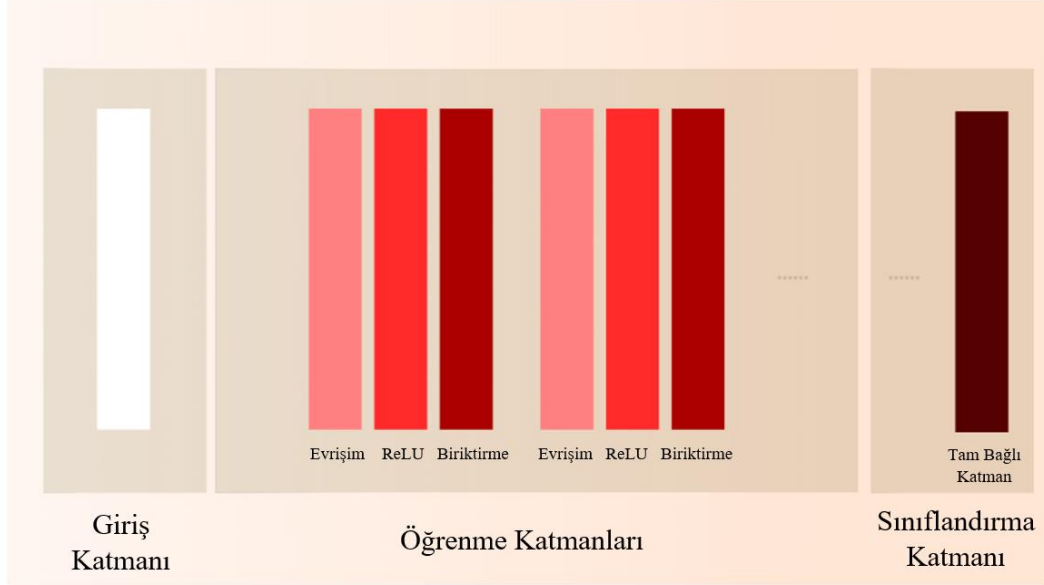
Temsili öğrenme, düşük seviyeli renk, doku ve biçim gibi özniteliklerin anlamsal olarak zenginleştirilmesi yoluyla daha yüksek seviyeden özniteliklere dönüştürülmesini sağlayan bir derin öğrenme tekniğidir (Karasulu vd., 2022).

Derin ağ modelinde temsili öğrenme soyutlama amacıyla uygulanır ve görüntü içerisindeki düşük ve yüksek seviyeli öznitelikler arasında bulunan anlamsal boşluğun (semantic gap) soyut özniteliklerin kullanımı sayesinde olabildiğince azalması, özniteliklerin zenginleştirilmesine katkı sağlarken, sınıflandırma başarımını artırmaktadır (Karasulu vd., 2022). Soyutlama derin öğrenmede sınıflandırma kalitesini artıracak gerekli özniteliklere odaklanmaktadır (Karasulu vd., 2022).

3.4.1. Evrişimli Sinir Ağı

ESA'nın amacı verilerdeki üst seviye öznitelikleri öğrenmektir. ESA giriş katmanından gelen verileri tam bağlı katmanlar aracılığıyla çıkış katmanı tarafından verilen bir dizi sınıf puanına dönüştürür. ESA mimarisinin birçok varyasyonu vardır. Bunlar Şekil 2'de gösterildiği gibi giriş katmanı, öğrenme katmanları ve sınıflandırma katmanı olmak üzere üç ana katman grubu ile tanımlanırlar. Şekil 2'de ESA mimarisinin şematik görünümü

verilerek bundaki bölümler Patterson ve Gibson çalışmasında belirtildiği haliyle ifade edilmiştir (Patterson ve Gibson, 2017).



Şekil 2. Üst Düzey Genel ESA Mimarisi (Patterson ve Gibson, 2017)

Giriş katmanı, genellikle görüntünün mevcut boyutunu uzamsal biçimindeki girdi olarak kabul eder (Patterson ve Gibson, 2017). Öğrenme katmanlarında evrişim, Doğrultulmuş Doğrusal Birim - DDB (Rectified Linear Unit - ReLU), biriktirme ve düzleştirme katmanları bulunur. Evrişim (Convolution) katmanında, görüntü üzerinde bir filtre gezer ve gezerken yapılmak istenen göreve göre filtre bulunduğu piksellerde çeşitli matematiksel hesaplamalar yapar (Patterson ve Gibson, 2017). Ulaşılan vektörel sonuca Öznitelik Haritası (Feature Map) denir (Patterson ve Gibson, 2017).

Öznitelik haritası katmanlardaki aktivasyon fonksiyonlarının öğrenme sonucunda nasıl tepki verdiğinin görsel bir sonucudur (Patterson ve Gibson, 2017). Bu sonuç üzerinden, öğrenmenin etkin olup olmadığını ve sınıf aktivasyonlarının sonucunda hata miktarlarının azalıp azalmadığı gözlemlenebilir (Karasulu vd., 2022).

Öğrenme katmanında DDB aktivasyon fonksiyonu genellikle evrişimden sonra gelir ve gelen veri eğer eksi değerse DDB o değeri sıfır yapar (Patterson ve Gibson, 2017).

Biriktirme (Pooling) katmanında ise gelen öznitelik haritalarına boyut küçültme yaparak, özniteliklerle ilgili önemli kısımları yakalamaya ve ezberleme riskini azaltmaya yardımcı olur (Karasulu vd., 2022).

Düzleştirme (Flattening) katmanı ise, katmanlardan gelen çıktıyı tek boyutlu bir vektöre dönüştürerek katmanların verileri işlemlerini kolaylaştırırken, sınıflandırma katmanı ise, genelde tam bağlı katmanlardan oluşur (Karasulu vd., 2022). Girdi verileri ile çıktı arasında bağlantı kurma yetenekleri sayesinde ESA görüntü işleme, sinyal işleme ve tavsiye sistemler gibi karmaşık görevleri çözmede başarılıdır (Karasulu vd., 2022).

Bölge Temelli Evrişimli Sinir Ağı - BTESA, 2014 yılında Girshick ve arkadaşları tarafından geliştirilen bir nesne algılama yöntemidir. Bir görüntüdeki nesnelerin bölgelerini ve sınıfını belirlemek için bir ESA mimarisini kullanır (Girshick vd., 2014). BTESA'da görüntü bölge önerilerine (region proposals) böler daha sonra her bölge için sırasıyla ESA uygulanır (Girshick vd., 2014). Elde edilen öznitelik haritaları kullanılarak sınıflandırma için destek vektör makineleri kullanılır (Girshick vd., 2014). Yöntemin, çok fazla parametreye sahip olması, yavaş olması ve belleği yorması gibi problemleri vardır (Girshick vd., 2014). Bu dezavantajları gidermek için DahaHızlı-BTESA (Faster R-CNN) ve Maske BTESA (Mask R-CNN) gibi yeni nesne algılama yöntemleri geliştirilmiştir (Girshick vd., 2014).

Maske BTESA, 2017 yılında aralarında Girshick'in de bulunduğu He ve arkadaşları tarafından geliştirilen bir nesne algılama yöntemidir (He vd., 2017). Maske BTESA, bir görüntüdeki nesnelerin bölütleme yapılırken her nesne için bir maske oluşturularak nesnelere birbirinden ayırt etmeyi ve daha ayrıntılı nesne analizleri yapmayı mümkün kılar (He vd., 2017). Maske BTESA, DahaHızlı-BTESA'in geliştirilmiş halidir. Maske BTESA, BTESA, Hızlı-BTESA ve DahaHızlı-BTESA'den daha iyi başarımlar gösterir (He vd., 2017).

3.4.2. DeepLabV3 + ResNet 50 Mimarisi

DeepLabv3, Derin Evrişimli Sinir Ağı (DESA) mimarisine sahiptir ve anlamsal bölütlemede karşılaşılan iki önemli problemlerde biri olan düşük öznitelik çözünürlüğünü sorununu Atrous evrişim (atrous convolution) kullanarak çözümlenmektedir (Chen vd., 2017).

Birden çok nesnenin bulunduğu görüntülerde ise bölütlenmesi gereken nesnelerin birbirlerinden farklı boyutlarda olması sebebiyle ortaya ölçeklendirme sorunu çıkar. Literatürdeki ilgili çalışmada DeepLabV3 ile bu sorun, görüntü piramidi (image pyramid) yöntemine kodlayıcı (encoder) ve kod çözücü (decoder) katmanı, bağlam modülü (context module) ve uzamsal piramit biriktirmesi (spatial pyramid pooling) yöntemlerini ekleyerek çözümlenmiştir (Chen vd., 2017).

ResNet ise, katmanlar arası bilgi aktarımı gerçekleştiren Derin Artık Ağlar (Deep Residual Network)'dan oluşur ve bu artık kelimesi, bir katmanın girişinin sonraki katmanın çıkışına bağlanmasına yoluyla detayları yakalamaya ve başarımın artırmasına sağlamaktadır (Shafiq ve Gu, 2022). ResNet50 ise 50 katmana sahip bir ResNet ağı olduğunu belirtir (He vd., 2016).

Görüntü bölütlemeye DeepLabV3 modelinin başarımını artırmak amacı ile ResNet ile birleştirilerek harita görüntülerinde deney yapan Heryadi ve arkadaşları, DeepLabV3 ağını üç farklı ResNet modeli olan ResNet34, ResNet50 ve ResNet101 ile bölütleme eğitim başarımlarını incelemişlerdir (Heryadi vd., 2020). Deney sonucunda, en iyi başarımlar doğruluk ölçütü DeepLabV3+ResNet34 için 0,87 olurken DeepLabV3+ResNet50 için 0,86 ve DeepLabV3+ResNet101 için 0,92 olarak ölçülmüştür (Heryadi vd., 2020).

Bu tez çalışmasında, DeepLabV3+ResNet101'in yüksek bellek ile daha verimli çalışmasından dolayı, DeepLabV3+ResNet50'in başarısı göz önüne alınarak yetişkin görüntülerinde bölütleme görevi için DeepLabV3+ResNet50 kullanılmıştır.

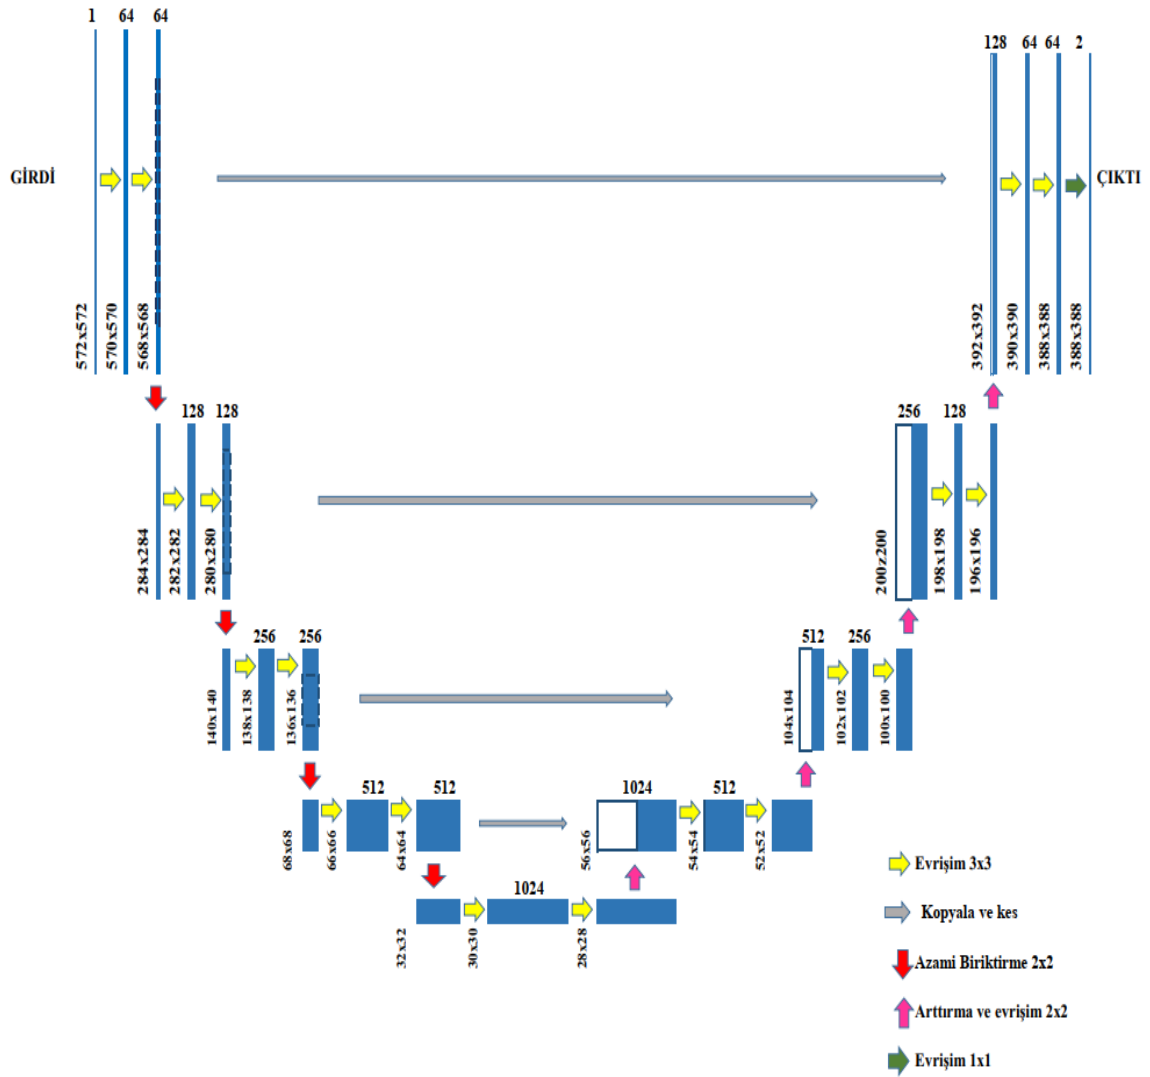
Çocuk görüntülerinde de aynı model denenmiş ancak veri kümesi az olduğundan oldukça düşük bir başarımlar sonucu elde etmiştir. Bu sebeple çocuk verilerinde, küçük boyut veri kümelerinde bile başarılı olan UNet tercih edilmiştir.

3.4.3. UNet Mimarisi

UNet, 2015 yılında Ronneberger ve arkadaşları tarafından geliştirilen bir evrişimli sinir ağıdır ve biyomedikal görüntülerde bölütleme görevi için deney yapılırsa da diğer alanlarda da başarılı olacağı öngörülmüştür (Ronneberger vd., 2015). UNet adını Şekil 3'te görüleceği gibi U harfine benzer mimarisinden almaktadır.

UNet, iki bölümden oluşur ilki klasik ESA'dır. Bilgi iletim hattı her katmanda daralırken ikinci kısmında ise öznitelik haritaları boyut artırarak örnekleme yapmaktadır (Ronneberger vd., 2015). Her katmanda bilgi iletim hattı kapasitesi genişler böylece bağlam yüksek seviyelere taşınmış olur (Ronneberger vd., 2015). Bu durum daha başarılı çıkarımlar yapmasını sağlamaktadır. Veri kümesi küçük olsa dahi, bu başarımını koruyarak sürdürmektedir (Ronneberger vd., 2015). Şekil 3'de UNet mimarisinin şematik görünümü verilerek, katmanlar Ronneberger ve arkadaşlarının yaptığı çalışmada belirtildiği haliyle ifade edilmiştir (Ronneberger vd., 2015).

UNet mimari modelinde ilk katmanlarda sinir düğümü sayısı 64 iken ikinci ve sonraki katmanlarda sırayla iki katına çıkmaktadır. Ortadaki beşinci katmana gelindiğinde ise bu artış sonucu 1024 düğüme ulaşılmakta ve bu katmanda Darboğaz (Bottleneck) oluşturulduğundan Kodlama ve Kod Çözücü (Encode and Decode) olarak öznitelik haritası (feature map) dönüşüm işlemi yapılır (Ronneberger vd., 2015). Bu sayede öznitelik yorumlama ve öğrenmeye dair bilgi elde etme yolu oluşturulmuş olur (Ronneberger vd., 2015). Takip eden sonraki, katmanlarda ise sınıflandırmaya dair işlemler için elde edilen öznitelikler filtrelenerek altıncı katmanda düğümler yarıya düşmekte ve 512 düğüme ulaşılmaktadır (Ronneberger vd., 2015). Son katman olan dokuzuncu katmana gelene kadar her katmanda düğüm sayısı yarıya düşürülerek en son katmana gelindiğinde 128 düğüm ve 64 düğümden oluşan yapı ile UNet modeli yapısı tamamlanarak sadece yüksek seviyeli özniteliklerin mevcut olduğu soyutlanmış bir bilgi akışı sağlanmış olur (Ronneberger vd., 2015).



Şekil 3. UNet Modeli (Ronneberger vd., 2015)

3.4.4. Inception ve Xception

2014 yılında yapılan bir yarışmada üretilen Inception, Hebbian prensibi ve Çok Ölçekli İşlem Sezgisine (The Intuition of Multi-Scale Processing) dayanan mimariye sahip bir DESA'dır (Szegedy vd., 2015). Öne çıkan özelliği hesaplama maliyetini belli bir aralıkta tutarken, sinir ağının derinliğinin artırılmış olmasıdır nesne algılama ve görüntü sınıflandırma gibi görevlerde başarılı olduğu vurgulanmıştır (Szegedy vd., 2015). Daha

sonra Inception modeli geliştirilerek InceptionV1, InceptionV2 ve InceptionV3 modelleri literatüre sunulmuştur.

Xception ise geliştirilmiş bir Inception modelidir ve adını eXtra Inception (eXtreme Inception)'dan alır (Chollet, 2017). Xception mimarisi, Inception V3 ile aynı sayıda parametreye sahip olmasına rağmen model parametreleri daha verimli kullanıldığından başarımları artırılmıştır (Chollet, 2017). Bu parametreler, aktivasyon fonksiyonları, katman sayıları, adım sayısı (epoch) ağırlıklar ve yanlılık (bias) olarak tanımlanır ve üstün (hyper) parametreler denir (Probst vd., 2019).

3.5 Bölütleme Yöntemi

Bölütleme, bir görüntüde bulunan ve belirli özellikleri olan etmenleri anlamlı bölümlere ayırmaya denir (Öztürk, ve Öztürk, 2021). Bölütlemelerden elde edilen sonuçlar, görüntülerden çıkarım yapma, öznitelik elde etme ve nesnelerin sınıflandırılması gibi süreçlerde kullanılmaktadır (Alasu, 2018).

Görüntü bölütleme yöntemleri birçok farklı tekniğe göre yapılabilir, bu teknikler eşikleme tabanlı bölütleme, kenar tabanlı bölütleme, aktif kontur tabanlı bölütleme, kümeleme ve bölge tabanlı bölütlemeler olarak adlandırılır (Öztürk, ve Öztürk, 2021).

Bazı çalışmalarda, birden fazla nesne için bölütleme yapılabilir, örneğin bir sokak görüntüsünde hem insanlar hem hayvanlar hem ağaçlar hem de arabalar ayrı ayrı bölütlenebilir (Minaee vd., 2021).

Aşırı Bölütleme ve Zayıf Bölütleme, bölütlemelerde karşılaşılan en önemli problemlerdendir. Aşırı Bölütleme tek bir nesnenin gereğinden fazla küçük parçalara ayrılmasına bağlı olarak birden fazla bölütlenmiş olarak kabul edilir (Sigut vd., 2015). Böylece model yeni görüntülerde genelleme yapamaz.

Zayıf Bölütleme ise tam tersi olarak, birden çok nesnenin tek bir nesne gibi bölütlenmesine denmektedir (Sigut vd., 2015). Nesnelerin özelleştirilmesi gerekirse, gereksiz genelleştirilmesine ve bu sebeple modelin nesneleri ayrıştırılamamasına neden olmaktadır (Sigut vd., 2015).

DÖRDÜNCÜ BÖLÜM

ARAŞTIRMA BULGULARI

Bu bölümde, çalışmada kullanılan yazılım ve donanım altyapıları ile yetişkin ve çocuklara ait panoramik diş görüntülerinden oluşan Children's Dental Panoramic ve Tufts veri kümelerinin ayrıntıları açıklanmıştır. Ayrıca, bu veri kümeleri üzerinde derin öğrenme mimarileri modelleri sayesinde gerçekleştirilen sınıflandırma ve bölütleme işlemlerinin deneysel sonuçları sunulmuştur.

4.1. Çalışmada Kullanılan Yazılım ve Donanım Altyapısı

Bu çalışmada Google Colab ("Google Colaboratory", 2024) geliştirme ortamında A100 GPU kaynağı üzerinde çalışacak şekilde, Python programlama dilinin 3.10.12 versiyonu kullanılarak deneyler gerçekleştirilmiştir. Modellerin geliştirilmesinde, Google tarafından geliştirilen makine öğrenmesi kütüphanesi olan Tensorflow 2.17.1 versiyonu ("Tensorflow", 2024), derin öğrenme kütüphanesi olan Keras 3.5.0 versiyonu ("Keras", 2024), Facebook tarafından geliştirilen açık kaynaklı bir makine öğrenmesi kütüphanesi olan PyTorch 2.5.1 ("PyTorch", 2024) ile torchvision kütüphanesinin 0.20.1 ("PyTorch", 2024) versiyonu kullanılmıştır.

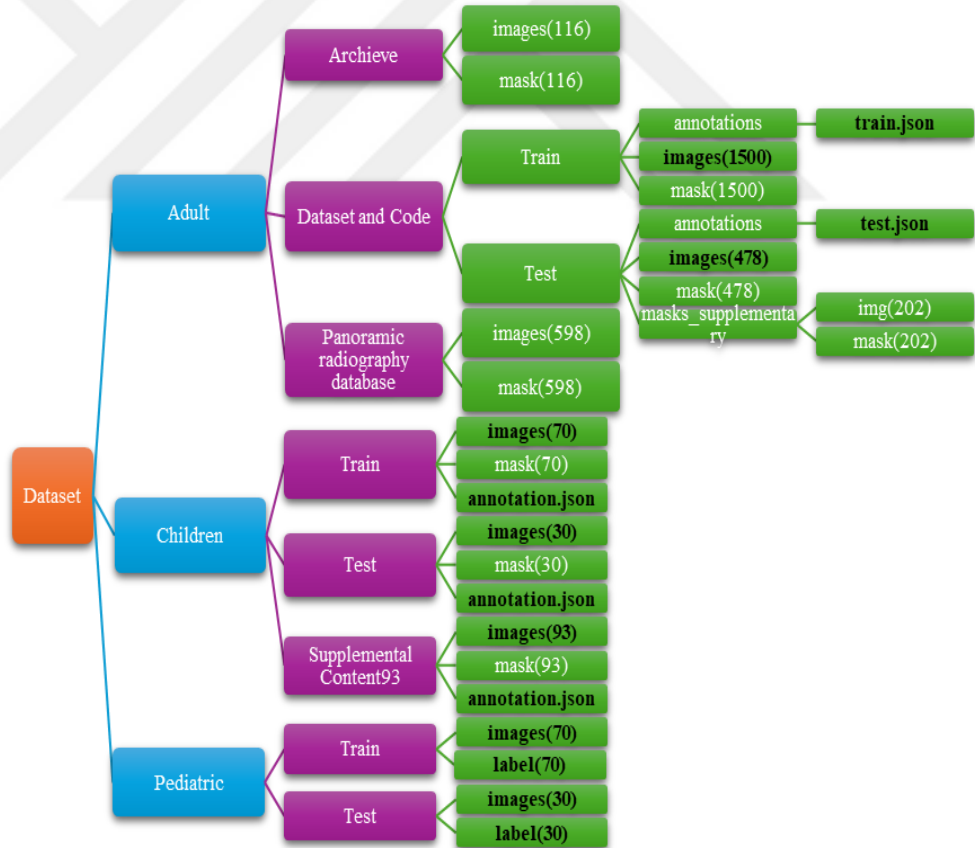
Görüntü işlemede, boyutlandırma filtreleme gibi veri ön işleme aşamasında kullanılan Pillow kütüphanesinin 11.0.0 ("Pillow", 2024) versiyonu, veri görselleştirmede kullanılan Matplotlib kütüphanesinin 3.8.0 versiyonu ("Matplotlib", 2024), bilimsel hesaplamalarda boyut ayarlamaları için numpy kütüphanesinin 1.26.4 versiyonu ("Numpy", 2024) kullanılmıştır.

Verileri ve kaydedilen modelleri google şirketinin veri deposu olan Google Drive'dan alabilmek ("Google Drive", 2024) ve Drive'a kaydedebilmek için google.colab kütüphanesinin 1.0.0 versiyonu ("Google Colaboratory", 2024), veri manipülasyonu için pandas kütüphanesinin 2.2.2 versiyonu ("Pandas", 2024), makine öğrenme algoritmalarını içeren scikit-learn kütüphanesinin 1.5.2 versiyonu ("Scikit-Learn", 2024), ve adım sayılarının ilerleyişini görselleştirmek adına tqdm kütüphanesinin 4.66.6 versiyonu ("Tqdm", 2024), kullanılmıştır.

4.2. Veri Kümeleri

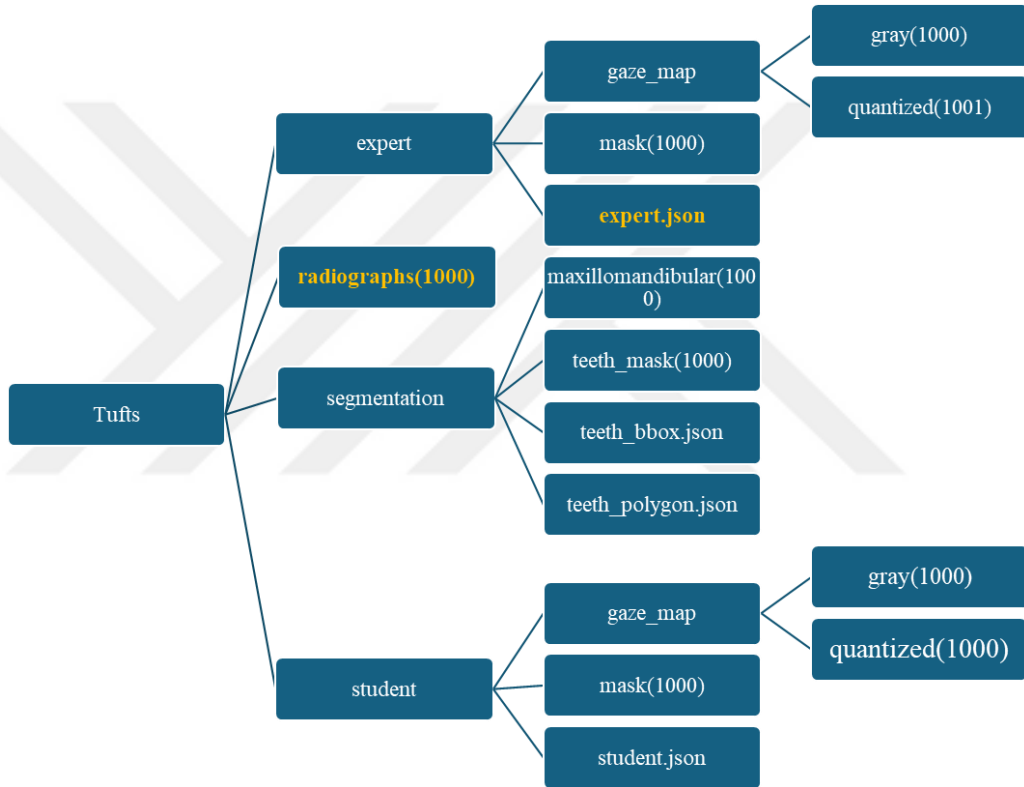
Bu çalışmada, Zhang ve arkadaşları tarafından “Children's Dental Panoramic Radiographs Dataset”(CDPR Dataset) isimle literatüre sunulan veri kümesi kullanılmıştır (Zhang vd., 2023). Şekil 4’te bu veri kümesinin içerdiği veriler ve sınıf etiketleri görülmektedir.

Yetişkin görüntü verilerinin % 64’ü eğitim, % 16’sı geçerleme ve % 20’si test olacak şekilde 1265 eğitim 317 geçerleme ve 396 test verisi olarak ayrılmıştır. Yetişkin veri kümesi toplam 1978 görüntüden oluşmaktadır. Çocuk görüntü verileri de % 64’ü eğitim, % 16’sı geçerleme ve % 20’si test olacak şekilde 123 eğitim, 31 geçerleme ve 39 test verisi olarak ayrılmıştır. Çocuk veri kümesi toplam 193 görüntüden oluşmaktadır.



Şekil 4. Çocuk Panoramik Diş Radyografi Veri Kümesi İçeriği

Literatürde bu alanda kullanılan diğer bir veri kümesi ise Tufts Dental Database isimli veri kümesidir (Panetta vd., 2021). Tufts Üniversitesi Diş Hekimliği Fakültesi'ndeki hastalara dair elektronik veritabanından rastgele radyografiler seçilerek oluşturulmuştur. Sadece eğitim amaçlı çalışmalarda kullanılmasına izin verilmektedir. Bu veri kümesinde çocuk ve yetişkin verileri karışık halde bulunur. Bu sebeple sınıflandırma işlemini test etmek için kullanılmıştır. Bu veri kümesinde dişlerin tip etiketleri, hasta cinsiyeti ve yaşı da bulunmaktadır. Şekil 5'te bu veri kümesinin içeriği görülmektedir.



Şekil 5. Tufts Veri Kümesi İçeriği

4.3. Deneysel Sonuçlar

Bu bölümde sınıflandırma ve bölütleme işlemleri hakkında bilgi ve elde edilen sonuçların detayları verilmiştir. Sınıflandırma, veri kümesinde bulunan verilerin hangi sınıfa ait olduğunu bulma işlemi iken, bölütleme ise bir görüntüde bulunan nesnelere

konumlarının, ince detaylarının veya farklı bölgelerinin diğer bölgelerden ayrıştırılmasına denilmektedir.

Kullanılan bu yöntemlere ait deneyler, analizler ve çeşitli ölçütlere göre başarımları ve elde edilen bulguların görselleştirmelerle birlikte detaylı sonuçları incelenmiştir.

4.3.1 Sınıflandırma Sonuçları

Bu çalışmada dış görüntülerinin çocuk ve yetişkin olarak sınıflandırılması için ResNet50, Xception, Inception ve VGG19 modelleri ile deney yapılmıştır. Normalde yetişkin verilerinde 1500, çocuk verilerinde 193 görüntü vardı ancak yetişkin verilerinde 170 adet çocuk verisi olduğu belirlendiğinden bu söz konusu 170 görüntü yetişkin veri kümesinden çocuk veri kümesine taşınmıştır.

İlk olarak 1330 yetişkin verisi ve 363 çocuk görüntüsü ile eğitim denenmiş ancak ağırlıkların ayarlanmasına rağmen düşük başarımlar elde edilmiştir. Verilerin %64'ü eğitim için, % 16'sı geçerlilik için % 20'si ise test için ayrılmıştır. Daha sonra yetişkin veri kümesi rastgele olacak şekilde üç gruba ayrılmıştır. Bu gruplar seçilen dört derin öğrenme mimari modelleri ile eğitilmiştir.

Bu deney A100 GPU üzerinde her model için 30 eğitim adım sayısı ile gerçekleştirilmiştir. Erken durdurma (early stopping) geçerlilik kaybına göre ve tahammül (patience) sayısı on olarak ayarlanmıştır. Aktivasyon fonksiyonu olarak DDB kullanılmıştır. Parçalanma büyüklüğü (batch size) değeri 32 olarak ayarlanmış ve toplam eğitim beş saat 17 dakika sürmüştür.

Tufts veri kümesi ile yapılan değerlendirme deneyi ise yaklaşık bir saat sürmüştür. Tablo 1'de bu modellerin üç farklı gruptaki Doğruluk, Duyarlılık, Anma, $F1$ ölçütü ve Özgüllük değerleri verilmiştir.

Tabloya göre, üçüncü grup verileri ile eğitilen ResNet50 modeli başarımlar doğruluğu olarak 0,78 değerini elde ederek en yüksek başarımları gösterirken en yüksek ikinci başarımları ikinci grup verileri ile eğitilen ResNet50 göstermiştir.

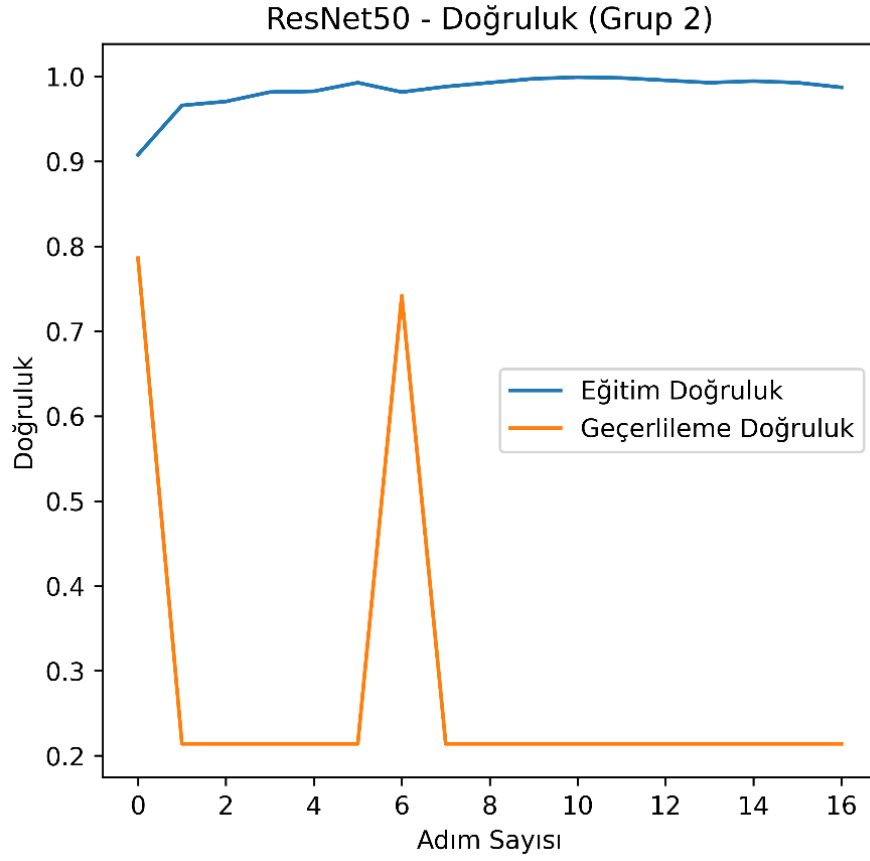
Duyarlılık ve $F1$ ölçütünde ikinci grup verileri ile eğitilen ResNet50 en yüksek başarımları elde ederken, Anma ve Özgüllük ölçütlerinde üçüncü grup verileriyle eğitilen

ResNet50 en yüksek başarıyı elde etmiştir. Şekil 6'da ResNet50 modelinin ikinci veri grubuyla olan eğitiminin başarımlarını doğruluğu verilmiştir.

Tablo 1.

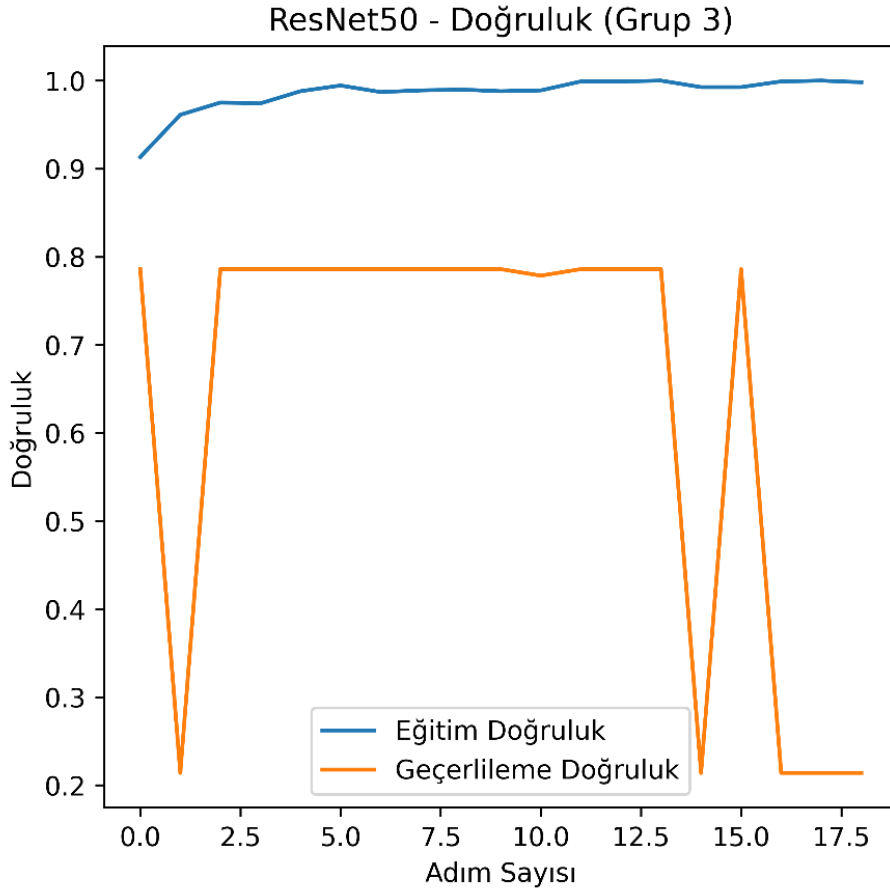
Sınıflandırma Modellerinin Başarımlar Ölçütlerine Göre Değerleri

Grup	Model	Doğruluk	Duyarlılık	Anma	F1 Ölçütü	Özgüllük
1	VGG19	0,6814	0,6782	0,6814	0,6798	0,8007
1	InceptionV3	0,6725	0,6741	0,6725	0,6733	0,7894
1	Xception	0,6637	0,6637	0,6637	0,6637	0,7857
1	ResNet50	0,2153	0,0463	0,2153	0,0763	0,0000
2	VGG19	0,6667	0,6779	0,6667	0,6720	0,7744
2	InceptionV3	0,6578	0,6644	0,6578	0,6610	0,7744
2	Xception	0,6578	0,6543	0,6578	0,6560	0,7857
2	ResNet50	0,7758	0,7038	0,7758	0,7089	0,9699
3	VGG19	0,6342	0,6342	0,6342	0,6342	0,7669
3	InceptionV3	0,6371	0,6424	0,6371	0,6397	0,7631
3	Xception	0,6106	0,6181	0,6106	0,6143	0,7443
3	ResNet50	0,7817	0,6151	0,7817	0,6885	0,9962



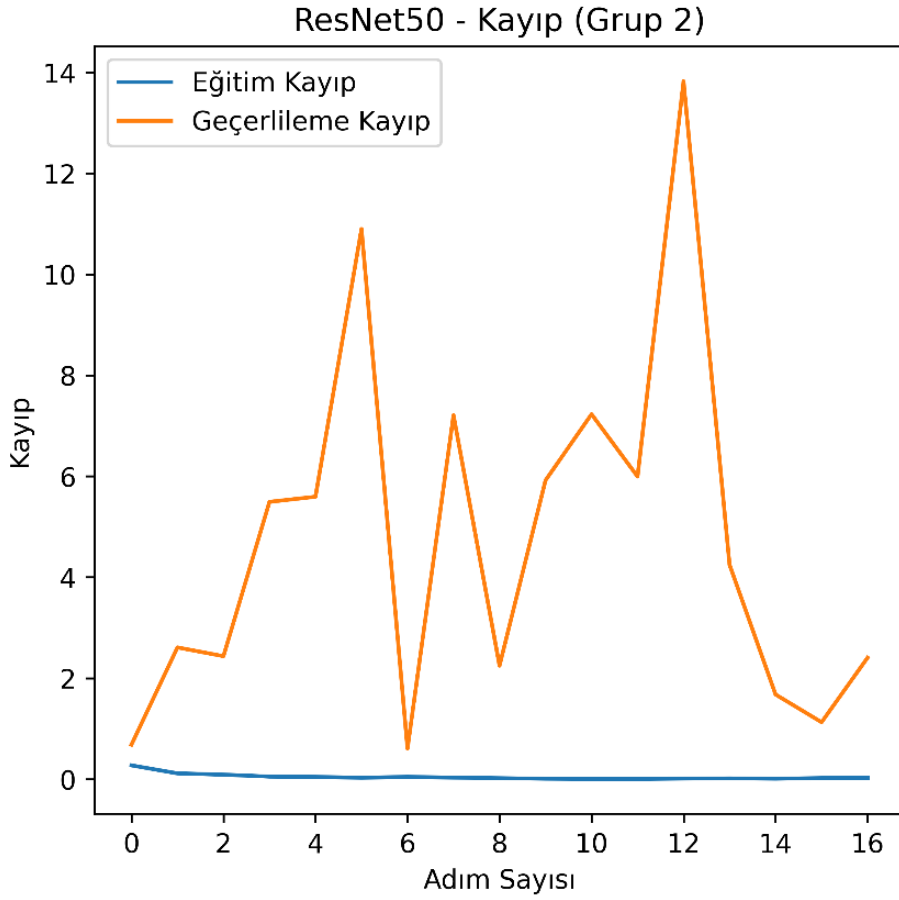
Şekil 6. İkinci Veri Grubuyla Eğitilen ResNet50 Sınıflandırma Modeli Doğruluk Grafiği

Şekil 6'daki grafikte görüldüğü gibi eğitim doğruluğunda yüksek başarı elde eden model, geçerileme doğruluğunda başarıyı yakalayamamıştır. Bunun nedenlerinden biri aşırı öğrenme (overfitting) olabilir. Aşırı öğrenme bir modelin eğitim veri kümesini çok iyi öğrenmesi ancak gördüğü yeni verilerde genelleme yapamadığı için doğru sonuç üretilmediği durumlara denir. Şekil 7'de üçüncü veri grubuyla eğitilen ResNet50'nin doğruluk grafiği verilmiştir.



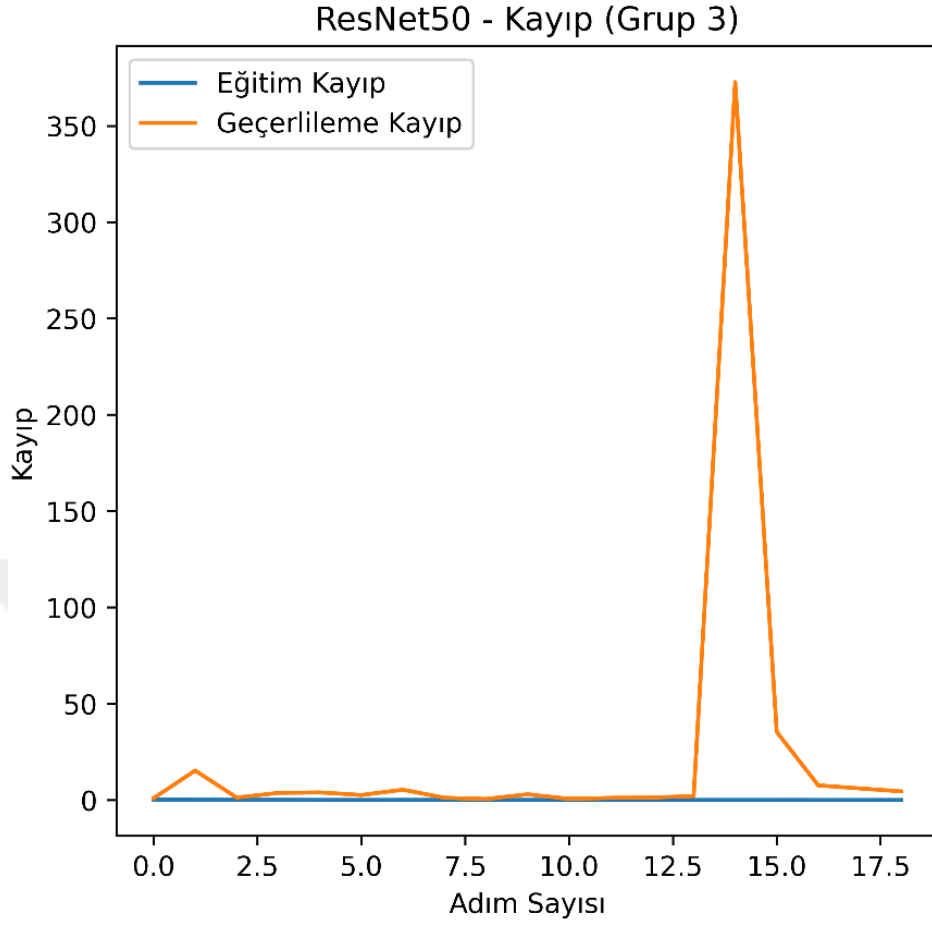
Şekil 7. Üçüncü Veri Grubuyla Eğitilen ResNet50 Sınıflandırma Modeli Doğruluk Grafiği

Şekil 7’de görüldüğü üzere, eğitim doğruluğu yüksek iken, geçerlileme doğruluğunda dalgalanmalar yaşanmaktadır bu da modelin kararsız olduğunu gösterir. Bu durumun nedeni modelin aşırı öğrenmeye bağlı ezberleme sorunu olabilmektedir. Şekil 8’den ikinci veri grubuyla eğitilen ResNet50 kayıp grafiği verilmiştir.



Şekil 8. İkinci Veri Grubuyla Eğitilen ResNet50 Sınıflandırma Modeli Kayıp Grafiği

Kayıp Fonksiyonlarının (Loss Function) görevi, model tahminleri ile gerçek değerlerin arasındaki farkı ölçmektir. Bu sebeple bu fark ne kadar düşük olursa model o kadar iyi eğitilmiş demektir. Şekil 8’de Geçerlileme Kaybının iniş çıkışlı olması kararsız olduğuna ve aşırı öğrenme olduğuna dair bir işaret olabileceği anlaşılmaktadır. Şekil 9’da üçüncü veri grubuyla eğitilen ResNet50 kayıp grafiği verilmiştir.

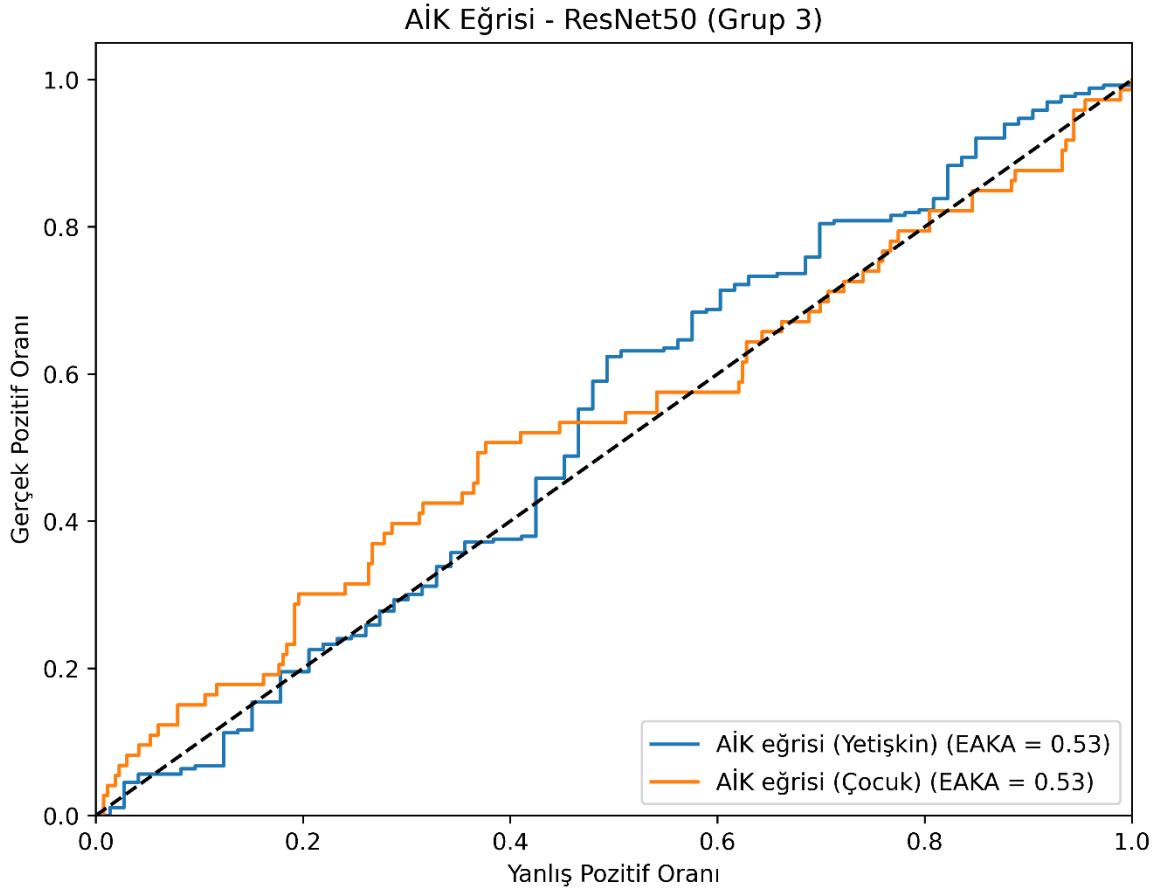


Şekil 9. Üçüncü Veri Grubuyla Eğitilen ResNet50 Sınıflandırma Modeli Kayıp Grafiği

Şekil 9’da ise Şekil 8’dekine göre daha tutarlı bir kayıp fonksiyonu görülmektedir. İki model de aşırı öğrenmiş olabilir ancak üçüncü veri grubuyla eğitilen modelin diğer modelden daha genelleştirilebilir bir model olduğu deneylerle kanıtlanmıştır.

İdeal bir modelde EAKA değeri 1,0’a yakın olmalıdır ancak ikinci gruba eğitilen ResNet50’de EAKA 0,47’de kalmış bu da 0,5 olan ve siyah kesikli çizgilerle gösterilmiş olan rastgele tahmin çizgisinin altında olduğundan sınıf ayrıştırıcılık başarımının düşük seviyede kaldığı anlaşılmaktadır. Şekil 10’da üçüncü veri grubuyla eğitilen modelin AİK eğrisi grafiği verilmiştir.

Şekil 10’a göre EAKA 0,53 olduğundan hem rastgele tahmin çizgisinin üstündedir hem de ikinci gruba eğitilen ResNet50 modelinden daha başarılıdır.



Şekil 10. Üçüncü Veri Grubuyla Eğitilen ResNet50 Sınıflandırma Modeli AİK Eğrisi Grafiği

Daha detaylı bir karşılaştırma yapmak adına modellerin hiç görmediği 1000 veriye sahip Tufts veri kümesi ile deney yapılmıştır. Doğruluk değerlerine göre sıralanmış modellerin Tufts veri kümesindeki başarımları Tablo 2’de verilmiştir. ResNet50 ile eğitilen Grup 2 ve Grup 3 modelleri diğerlerinden daha yüksek başarıma ulaşmıştır.

Tablo 2.

Sınıflandırma Modellerinin Tufts Veri Kümesindeki Doğru Sınıflandırma Oranı

Sıra	Grup	Model	Eğitim Veri Kümesindeki Başarım Doğruluğu	Tufts Veri Kümesindeki Başarım Doğruluğu
1	3	ResNet50	0,7817	0,658
2	2	ResNet50	0,7758	0,808
3	1	VGG19	0,6814	0,689
4	1	InceptionV3	0,6725	0,547
5	2	VGG19	0,6667	0,411
6	1	Xception	0,6637	0,189

Tablo 3'te görüldüğü üzere literatürde kullanılan modeller sayesinde ilgili çalışmalarla çeşitli deneyler gerçekleştirilmiştir. Ancak dengesiz veri kümesi (imbalanced dataset) ve yüksek hesaplama maliyeti nedeniyle eğitilen modelin başarımı ise literatürdeki diğer modellere göre daha düşük kalmıştır.

Literatürde bulunan diğer görüntü sınıflandırma çalışmalar ile modelin sınıflandırma başarıları karşılaştırılmak üzere Tablo 3'te gösterilmiştir. ResNet50 ile eğitilen başka bir model bir milyon görüntü ile eğitilerek 0,79 başarımlı doğruluğu sağlarken, çalışmada kullanılan modelimiz daha az görüntü sayısı ile 0,78 başarımlı doğruluğu sağlamıştır.

Tablo 3.

Görüntü Sınıflandırma Çalışmaları Karşılaştırması

Çalışma	Kullanılan Yöntem	Başarım	Veri Kümesi Boyutu
Jader vd., 2018	Maske - BTESA	Doğruluk: 0,98	1500
Xu vd., 2018	ESA	Doğruluk: 0,99	1200
Qian vd., 2021	MobileNetV3-Large	Doğruluk: 0,80	150
Qian vd., 2021	InceptionV3	Doğruluk: 0,67	150
Zhong vd., 2016	BYESA	Doğruluk: 0,89	2100
Blot vd., 2016	MaxMin-ESA	Doğruluk: 0,82	60000
Liu vd., 2018	DRÖGESAS	Doğruluk: 0,95	2100
Plested ve Gedeon, 2022	Xception	Doğruluk: 0,79	14197122
Plested ve Gedeon, 2022	InceptionV3	Doğruluk: 0,78	14197122
Plested ve Gedeon, 2022	ResNet50	Doğruluk: 0,79	14197122
Önerilen Model	ResNet50	Doğruluk: 0,78	1693

4.3.2. Bölütleme Sonuçları

Bu bölümde dış görüntülerinin çocuk ve yetişkin olarak ayrı modellerde bölütleme işlemi için yapılan deneyler ve detaylı analizlere yer verilmiştir. Literatürde DeepLabV3+ResNet101 en yüksek başarıya ulaşmıştır ancak bellek yetersizliği ve uzun çalışma zamanı gerektirmesi nedeniyle ona göre daha hızlı çalışan ve daha az belleğe ihtiyaç duyan DeepLabV3+ResNet50 seçilerek yetişkin veri kümesinde deneyler gerçekleştirilmiştir. Verilerin % 64'ü eğitim için, % 16'sı geçerleme için % 20'si ise test için ayrılmıştır. Bu modelin Dice Katsayısı ve KBÜO ölçütlerine göre en iyi ve en kötü başarımların değerleri Tablo 4'te ilk dokuz görüntü ve devamı şeklindeki diğer görüntülerin değerleri ise Tablo 5'te verilmiştir.

Tablo 4.

Yetişkin Test Veri Kümesindeki Bölütleme Başarımı

Başarı Sırası	Görüntü Adı	KBÜO (IoU)	Dice Katsayısı
1	cate4-00080.jpg	0,9054669074	0,9503884889
2	cate4-00094.jpg	0,9054631094	0,9503863968
3	cate2-00199.jpg	0,9044189262	0,949810899
4	cate4-00070.jpg	0,9007160545	0,9477649777
5	cate4-00071.jpg	0,8997466256	0,9472280287
6	cate2-00201.jpg	0,8979087567	0,9462085609
7	cate2-00219.jpg	0,8975756989	0,9460236021
8	cate4-00086.jpg	0,8973622964	0,9459050579
9	cate4-00100.jpg	0,8968536818	0,9456224172

Tablo 5.

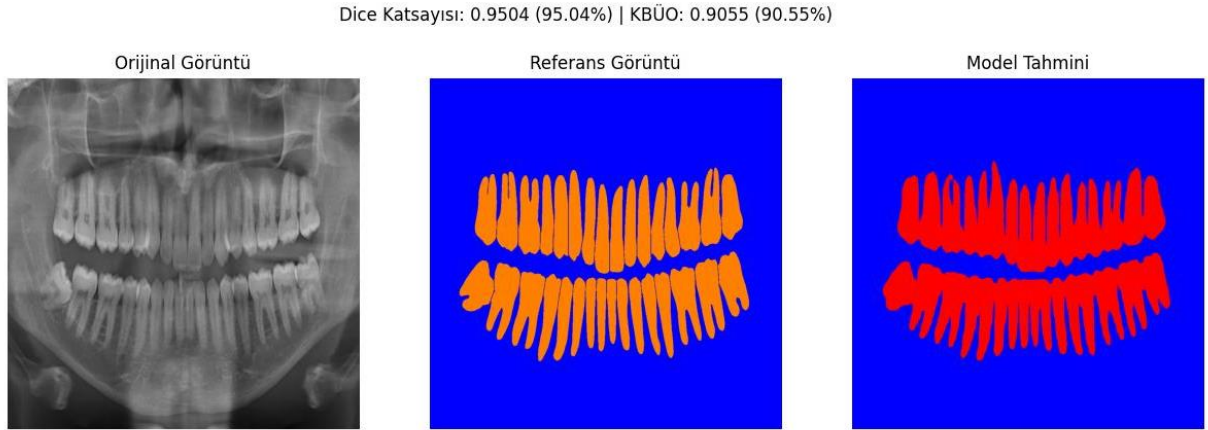
Yetişkin Test Veri Kümesindeki Bölütleme Başarımı Tablosu Devamı

Başarı Sırası	Görüntü Adı	KBÜO (IoU)	Dice Katsayısı
10	cate2-00175.jpg	0,8963275895	0,9453299045
387	cate1-00056.jpg	0,7155529872	0,8341951458
388	cate1-00049.jpg	0,7148324061	0,8337052689
389	cate1-00029.jpg	0,7147640936	0,8336588062
390	cate1-00050.jpg	0,7093198232	0,8299439503
391	cate1-00041.jpg	0,7060313671	0,827688612
392	cate1-00026.jpg	0,7046844776	0,8267623561
393	cate1-00037.jpg	0,6849658264	0,8130323069
394	cate1-00039.jpg	0,6848191299	0,8129289581
395	cate1-00051.jpg	0,6786868724	0,8085925774
396	cate4-00114.jpg	0,6397554234	0,7803059094
Toplam Görüntü Sayısı		Ortalama KBÜO	Ortalama Dice
396		0,84	0,91

Tablo 4 ve Tablo 5'e göre en iyi başarımlar, KBÜO için 0,90 olurken Dice Katsayısı için bu başarımlar 0,95'e çıkmıştır. Ortalama KBÜO başarımları ise 0,84 değerinde kalırken Dice Katsayısı değeri ise 0,91 olarak hesaplanmıştır.

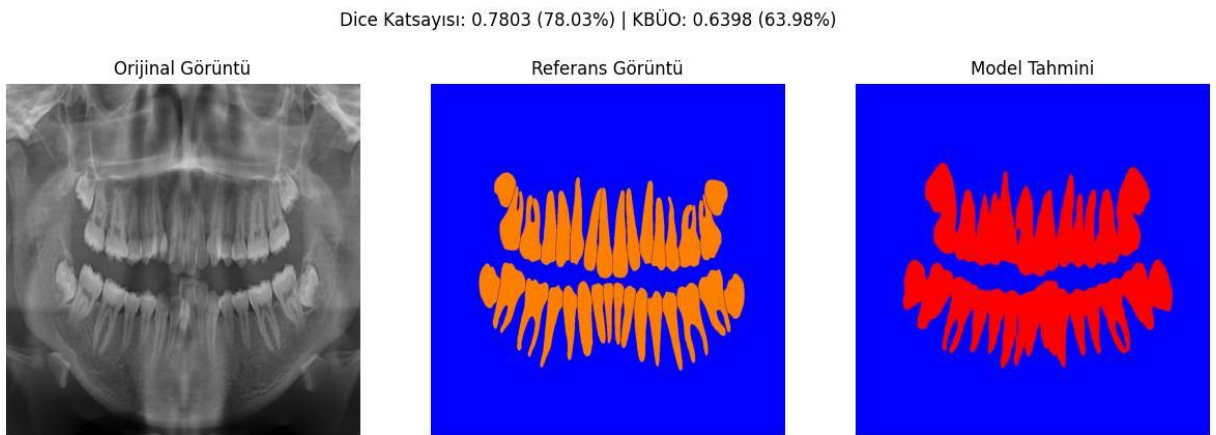
Tablo 4 ve Tablo 5'ten anlaşıldığı üzere kategori iki ve kategori dört için bölütleme başarımı yüksek iken, kategori bir için diğerlerine göre biraz daha düşük kalmıştır.

Şekil 11'de en yüksek başarımlı gösteren görüntü referans maske ve model tahmin maskesi ile karşılaştırmalı olarak verilmiştir.



Şekil 11. Yetişkin Verilerinde En Yüksek Başarımlı Gösteren Görüntü

Şekil 12'de ise tüm test veri kümesi içerisinde en düşük başarımlı gösteren görüntünün gerçek görüntü, referans maske ve model tahmini ile karşılaştırılması verilmiştir.



Şekil 12. Yetişkin Verilerinde En Düşük Başarımlı Gösteren Görüntü

Çocuk görüntülerinde yapılan deneylerde ise DeepLabV3+ResNet50 için başarımları değeri 0,14'te kalmıştır. Bunun başlıca sebebi, yetişkin veri kümesinin boyutunun çocuk veri kümesi boyutundan çok daha büyük olmasından kaynaklanmaktadır. Çözüm olarak UNet modeli 193 çocuk görüntüsü ile eğitilmiştir. Tablo 6'da KBÜO ve Dice Katsayısına göre en yüksek ve en düşük başarımları sağlayan on görüntüye ait deney sonuçlarına dair veriler gösterilmiştir.


Tablo 6.

Çocuk Test Veri Kümesindeki Bölütleme Başarımları

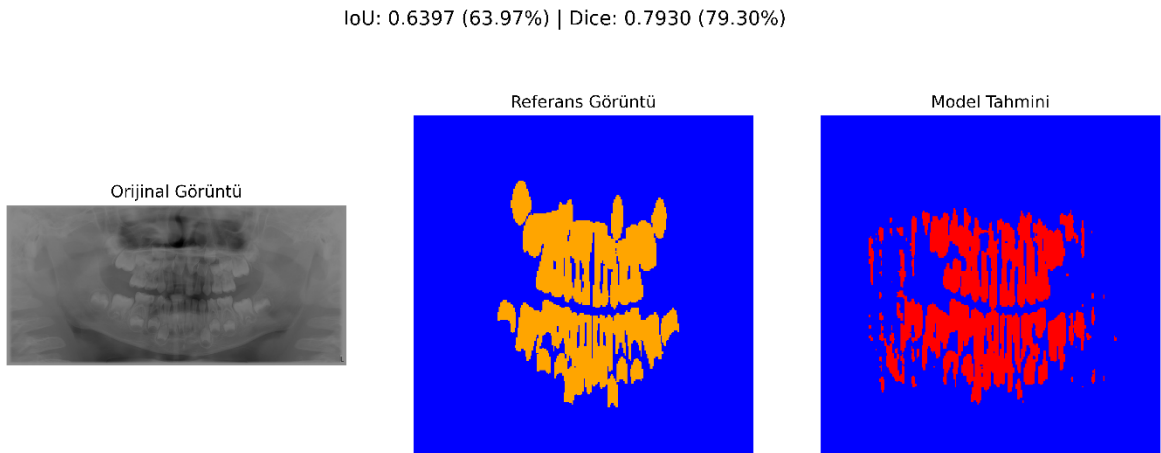
Başarı Sırası	Görüntü Adı	KBÜO (IoU)	Dice Katsayısı
1	cate2_005.png	0,904716372	0,940216422
2	cate5_0001.png	0,897273123	0,935832381
3	cate2_011.png	0,890997767	0,928064108
4	cate4_0000.png	0,890194118	0,927679062
5	cate2_009.png	0,887762249	0,927220702
35	cate2_003.png	0,832570612	0,891773403
36	cate1_013.png	0,830249012	0,891243577
37	cate2_002.png	0,824108422	0,883565187
38	cate3_0000.png	0,767800391	0,872802377
39	cate4_0001.png	0,639699817	0,793044925
Toplam Veri Sayısı: 39		Ortalama KBÜO: 0,85	Ortalama Dice:0,90

Tablo 6’da görüldüğü üzere 39 test görüntüsü için ortalama KBÜO değeri 0,85 ve ortalama Dice Katsayısı değeri 0,90 olarak hesaplanmıştır.

En yüksek Dice Katsayısı değeri 0,94 hesaplanırken en düşük Dice Katsayısı değeri ise 0,79 olarak kaydedilmiştir. En yüksek KBÜO değeri 0,90 hesaplanırken en düşük KBÜO değeri ise 0,63 olarak hesaplanmıştır. Şekil 13 ve Şekil 14’te en yüksek ve en düşük başarımları gösteren deney sonuçlarına dair veriler şematize edilmiştir.



Şekil 13. Çocuk Verilerinde En Yüksek Başarımları Gösteren Görüntü



Şekil 14. Çocuk Verilerinde En Düşük Başarımları Gösteren Görüntü

Şekil 13 ve Şekil 14’te görüldüğü üzere başarımların bu kadar yüksek olması görüntü kontrastı ile alakalı olması muhtemeldir. Bunun temel sebebi olarak Şekil 13’teki orijinal görüntüde siyah ve beyazlar daha net iken Şekil 14’teki orijinal görüntüde daha çok gri tonlarında siyah ve beyazlar net değildir. Bu duruma, çekim yapılan cihaz veya çekim yapılan ortam neden olabilmektedir. Bu yaklaşımla, model siyah ve beyazların daha keskin olduğu görüntülerde daha yüksek başarımlar gösterir denilebilir. Tablo 7, Tablo 8 ve Tablo 9’da, literatürde bulunan bölütleme çalışmalarının farklı veri kümeleri boyutlarına ve farklı başarımlarına göre başarımları verilmiştir.

Tablo 7.

Diş Görüntülerinde Bölütleme Çalışmaları Karşılaştırması

Çalışma	Kullanılan Yöntem	Başarımlar	Veri Kümesi Boyutu	Veri Kümesi Adı ve Kaynağı
Wirtz vd., 2018	UNet	Dice Katsayısı: 0,74	4000	Belirtilmemiştir
Lahoud vd., 2021	ESA	KBÜO: 0,87	314	Belirtilmemiştir
Yang vd., 2021	ESA	KBÜO: 0,97	10	Belirtilmemiştir
Li vd., 2020	UNet	KBÜO : 0,91	24	Sichuan Üniversitesi Batı Çin Stomatoloji Hastanesi. Chengdu, Çin

Tablo 8.

Diş Görüntülerinde Bölütleme Çalışmaları Karşılaştırması Tablosu Devamı

Çalışma	Kullanılan Yöntem	Başarım	Veri Kümesi Boyutu	Veri Kümesi Adı ve Kaynağı
Shaheen vd., 2021	UNet	KBÜO: 0,82	186	Belirtilmemiştir
Chen vd., 2020	VNet	KBÜO : 0,88	25	Güney Tıp Üniversitesi Stomatoloji Hastanesi, Guangzhou, Çin.
Cui vd., 2022	ESA+VNet	Dice Katsayısı: 0,94	4938	CQ-hospital, HZ-hospital ve SH-hospital
Zhu vd., 2023	ESA	Dice Katsayısı: 0,93	1159	Zhejiang Üniversitesi Tıp Fakültesi Hastanesi
Rubiu vd., 2023	Maske - BTESA	Dice Katsayısı: 0,87	1000	Tufts (Panetta, Rajendran, Ramesh, Rao ve Agaian, 2021).

Tablo 9.

Diş Görüntülerinde Bölütleme Çalışmaları Karşılaştırması Tablosu Devamı

Çalışma	Kullanılan Yöntem	Başarım	Veri Kümesi Boyutu	Veri Kümesi Adı ve Kaynağı
Kaki vd., 2023	DeepLabV3	Dice Katsayısı: 0,94	2075	UFBA_UESC_DENTAL_IMA_GES_DEEP (Kaggle web sitesi, ancak ulaşılamıyor)
Alhasson, 2024	DeepLabV3+	KBÜO: 0,8646	434	Intelligent Vision Research Lab (Silva, Pinheiro, Oliveira ve Pithon, 2020)
Zou vd., 2024	DeepLabV3+ ResNet18	KBÜO: 0,86 Dice Katsayısı: 0,91	2000	CDPR Dataset
Zou vd., 2024	Deformable Convolution and Mamba Integration Network	KBÜO: 0,87 Dice Katsayısı: 0,93	2000	CDPR Dataset
Zou vd., 2024	UNet	KBÜO: 0,86 Dice Katsayısı: 0,92	2000	CDPR Dataset

Tablo 10.

Diş Görüntülerinde Bölütleme Çalışmaları Karşılaştırması Tablosu Devamı

Çalışma	Kullanılan Yöntem	Başarım	Veri Kümesi Boyutu	Veri Kümesi Adı ve Kaynağı
Önerilen Yetişkin Modeli	DeepLabV3 +ResNet50	KBÜO: 0,90 Dice Katsayısı : 0,95	1978	CDPR Dataset
Önerilen Çocuk Modeli	UNet	KBÜO: 0,90 Dice Katsayısı : 0,94	193	CDPR Dataset

Tablo 7'ye göre, Li ve arkadaşları UNet kullanarak 24 görüntüde KBÜO için 0,91 değerini, Wirtz ve arkadaşları 4000 görüntüde Dice Katsayısı değerini 0,74 olarak ve Tablo 8'e göre Shaheen ve arkadaşları UNet kullanarak 186 görüntüde KBÜO değerini 0,82 elde etmişlerdir. Bu tez çalışmasında çocuk görüntülerinde 193 görüntüde KBÜO için 0,90 değeri, Dice Katsayısı değeri 0,94 olarak elde edilmiştir.

Tablo 9'a göre Alhasson, 13 yaş ve üstü hastaların görüntülerinde 434 görüntüde DeepLabV3 kullanarak KBÜO için 0,86 değerine ulaşırlarken, Tablo 10'da görülebileceği gibi ise bu tez çalışmasında yetişkin verilerinde DeepLabV3+ResNet50 kullanarak 1978 görüntüde Dice Katsayısında için 0,95 değerine ve KBÜO için 0,90 değerine ulaşılmıştır. Tablo 10'daki çocuk verilerinin sonucu literatürde sadece yetişkin görüntülerinde sonuçların mevcut olması nedeniyle, başkaca bir çalışma ile kıyaslanamamıştır.

4.4. Genel Bulgular

Çocuk ve Yetişkin veri kümelerinde gerçekleştirilen bölütleme deneyleri literatürde bulunan çalışmalarla karşılaştırıldığında yüksek başarımla elde ettiği, sınıflandırma modelinin

ise 0,78 ile veri kümesi boyutu da dikkate alınarak sınıflandırma ve bölütleme başarımının yeterince iyi olduğu sonucuna ulaşılmaktadır.

Sınıflandırmada üçüncü grupta eğitilen modelde başarım doğruluğu 0,78 iken Tufts veri kümesindeki doğru sınıflandırma başarım değeri 0,65 olarak kaydedilmiştir.

İkinci grup ile yapılan eğitimde ise başarım doğruluk değeri 0,77 iken Tufts veri kümesindeki doğru sınıflandırma başarım değeri 0,80 olarak kaydedilmiştir. Bölütlemeye ise KBÜO ve Dice Katsayısına göre en yüksek değerler, en düşük değerler ve değerlerin ortalaması Tablo 11’de tanımlayıcı istatistik yoluyla özetlenmiş olarak verilmiştir.

Tablo 11

Bölütleme Sonuçlarının Özeti

Veri Tipi	En Yüksek Değer	En Düşük Değer	Ortalama	Standart Sapma
Yetişkin	KBÜO: 0,90	KBÜO: 0,63	KBÜO: 0,84	KBÜO: 0,04245
	Dice Katsayısı: 0,95	Dice Katsayısı: 0,78	Dice Katsayısı: 0,91	Dice Katsayısı: 0,02355
Çocuk	KBÜO: 0,90	KBÜO: 0,63	KBÜO: 0,85	KBÜO: 0,04662
	Dice Katsayısı: 0,94	Dice Katsayısı: 0,79	Dice Katsayısı: 0,90	Dice Katsayısı: 0,02850

4.5. Grafikselle Kullanıcı Arayüzü

Eğitilen sınıflandırma ve bölütleme modellerinin kullanımını kolaylaştırmak amacıyla, grafik arayüzü tasarlanmıştır. Diş hekimlerinin, panoramik diş görüntülerinde dişler ve dişlere ait bölgelerin tanımlanması ve dişler hakkında fikir edinmesi hedeflenmiştir.



Şekil 15. 'cate2_00063' isimli Yetişkin Görüntüsünde Kullanıcı Arayüzünün Kullanım Örneği

Kullanıcı arayüzü, Hugging Face ("Hugging Face", 2024) isimli şirket tarafından geliştirilen Gradio (Abid vd., 2019) isimli arayüz oluşturma kütüphanesi ile tez çalışması kapsamında Python dili ve deneylerde de kullanılan derin öğrenme mimari modelleri kullanılarak oluşturulmuştur ("Gradio", 2024).

Arayüz kullanımı için, kullanıcı sisteme bir görüntü yükledikten sonra görüntü, derin öğrenme mimarisine dayanan sınıflandırma modeli ile sınıflandırılarak ilgili arayüz çerçevesine (yüklenen görüntünün sağ tarafında) hasta tipi bölümünde "Çocuk" veya "Yetişkin" etiketini sınıf tespit sonucu olarak yazdırmaktadır. Daha sonra bölütleme kısmında diş panoramik görüntüsünün maske görünümü denilen biçimde bölütlenmiş kısımlar olarak; kırmızı renkte ön plan ve mavi renkte ise arka plan olarak adlandırılan kısımları görülmektedir. Şekil 15 ve Şekil 16'da yetişkin ve çocuk verileri kullanılarak yapılan deneylerin sonuçlarından birer örnek verilmiştir.



Şekil 16. 'cate2_011' isimli Çocuk Görüntüsünde Kullanıcı Arayüzünün Kullanım Örneği

Şekil 16'da görüldüğü üzere "Giriş Görüntüsü" yazan kısma görüntü sürükleyip bırakıldığında o görüntüyü analiz etmek için turuncu renkle gösterilen "Analiz Et" butonuna basılması gerekmektedir. Görüntünün öge karmaşıklığı ve modelin işlemsel gereksinimleri dahilinde yaklaşık 5 ila 6 saniye içerisinde hasta tipi ve bölütleme sonucu ekranda görünür hale gelmektedir. Bu grafiksel arayüzün tıp alanında özellikle diş hekimliği alanında eğitim alan öğrencilerin ve mesleğe yeni başlamış hekimlerin, hastaların diş ve çene yapılarını otomatik olarak ayırt etmede kullanımının, hem verimlilik, hem tanıdaki etkinlik hem de çok sayıdaki hasta için görece hızlı tanı koymada kendilerine yararlı olacağı anlaşılmaktadır.

BEŞİNCİ BÖLÜM

TARTIŞMA VE SONUÇLAR

5.1. Sonuçlar

Bu çalışmada, diş görüntülerinin çocuk ve yetişkin olarak sınıflandırılması için ResNet50, yetişkin verilerinin bölütlenmesi için DeepLabV3+ResNet50 modeli ve çocuk görüntüleri için UNet modeli eğitilmiştir. Veri kümesi olarak 1978 yetişkin verisi, 193 çocuk verisi kullanılmıştır. Sınıflandırma görevi için çeşitli derin sinir ağı mimari modelleri denenmiş ancak iki sınıfın dengesiz veri sayısına sahip olması varolan modellerin yüksek başarımlar gösterememesine neden olmuştur. Bu sebeple yetişkin veri kümesi rastgele verilerden oluşan üç gruba bölünerek her bir grup Xception, Inception, VGG19 ve ResNet50 ile eğitilmiş en yüksek başarımlar üçüncü grup ResNet50 modelinde başarımlar doğruluk değeri 0,78, Tufts veri kümesinde yapılan değerlendirmeye göre ikinci grup ile eğitilen ResNet50 için başarımlar doğruluğu değeri 0,80 olarak elde edilmiştir.

Literatüre göre, başarılı bölütleme modellerinden biri olan DeepLabV3+ResNet50 bölütleme görevi için seçilmiştir. Yetişkinlerde en yüksek başarımlar Dice Katsayısında 0,95 iken KBÜO değeri 0,90'a ulaşılmıştır. DeepLabV3+ResNet50 yetişkin verilerinde başarımlar elde etmesine rağmen çocuk verilerinde KBÜO 0,14 değerinde kalmıştır bu sebeple küçük veri kümelerinde de başarımlar sağlayan UNet modeli denenmiş ve en yüksek başarımlar Dice Katsayısı için 0,94 değeri elde edilirken iken KBÜO değeri için 0,90'a ulaşılmıştır.

Çalışmanın asıl amacı, diş görüntülerinde literatürde ayrıca değerlendirilmeyen çocuk görüntülerinde başarımlar yakalamak ve en doğru bölütleme modelini sunmaktır. Bu model sayesinde, diş hekimliği alanında teşhis ve tedavi yöntemlerinde daha hızlı ve daha doğru karar verilmesine yardımcı olmak hedeflenmektedir.

Oluşturulan arayüz sayesinde tıp alanında ve diş hekimliği alanında okuyan öğrencilerin, mesleğe yeni başlayan hekimlerin, hasta sayısı oldukça fazla olan uzman hekimlerin kullanabileceği yapıda; diş anatomisi, diş ve çene yapısına dair tanı oluşturmalarında yardımcı olabilecek, verimli ve etkin sonuçlar içeren bir yazılımsal araç bu tez kapsamında üretilerek kendilerine sunulmuştur.

Çalışma belirli kısıtlamalara sahiptir ve bunlar gelecekteki arařtırmalarda ele alınabilir. Çocuk veri kümesi küçük ve sınırlı bir örneklem grubuna ait olduğundan sonuçların genelleştirilebilirliği kısıtlı olabilir. Eğitim sırasında kullanılan donanım sebebiyle kaynak ve zaman kısıtlamaları nedeni ile daha iyi modellerde eğitim gerçekleştirilememiştir.

Gelecekteki çalışmalar için, çocuk veri kümesi boyutlarını artırarak modele farklı veriler ile daha çok öznelik öğretilmesini sağlamak ve yetişkin verilerinde eksik dışlarda bölütleme örneklerinin artırılmasının büyük oranda başarıyı daha da iyileştireceği öngörülmektedir.



KAYNAKÇA

- Abdal, R., Zhu, P., Mitra, N. J., and Wonka, P. (2021). "Labels4free: Unsupervised segmentation using stylegan", *In Proceedings of the IEEE/CVF International Conference on Computer Vision*, October 11-17, Canada, 13970-13979.
- Abid, A., Abdalla, A., Abid, A., Khan, D., Alfozan, A. and Zou, J. (2019). "Gradio: Hassle-Free Sharing and Testing of ML Models in the Wild", *arXiv preprint arXiv:1906.02569*. <https://doi.org/10.48550/arXiv.1906.02569>.
- Alasu, S. (2018). Çizge Kesim Temelli İnteraktif Görüntü Bölütleme Yöntemlerinin Karşılaştırılması. Yüksek Lisans Tezi. İnönü Üniversitesi, Fen Bilimleri Enstitüsü, Malatya.
- Alhasson, H. F. (2024). "Automatic Segmentation of Teeth from Panoramic X-Ray Images Employing Deep Learning Models", *In 2024 4th Interdisciplinary Conference on Electrics and Computer (INTCEC)*, June 11-13, USA,1-6.
- Aran, İ. (1978). "Diş Ağız Sağlığı ve Beslenme", *Beslenme ve Diyet Dergisi*, 7(1), 78-85.
- Arslan, S. S. (2022). "Çiğneme fonksiyonu: anatomi, fizyoloji ve nörolojik kontrol", *Anatolian Clinic the Journal of Medical Sciences*, 27(1), 95-102. <https://doi.org/10.21673/anadoluklin.902646>.
- Bhat, S., Birajdar, G. K., and Patil, M. D. (2023). "A comprehensive survey of deep learning algorithms and applications in dental radiograph analysis", *Healthcare Analytics*, Volume 4, 100282. <https://doi.org/10.1016/j.health.2023.100282>.
- Blot, M., Cord, M., and Thome, N. (2016). "Max-min convolutional neural networks for image classification", *In 2016 IEEE International Conference on Image Processing (ICIP)*, September 25-28, USA, 3678-3682.
- Burt, J. R., Torosdagli, N., Khosravan, N., RaviPrakash, H., Mortazi, A., Tissavirasingham, F., and Bagci, U. (2018). "Deep learning beyond cats and dogs: recent advances in diagnosing breast cancer with deep neural networks", *The British journal of radiology*, Volume 91, Issue 1089, 20170545, <https://doi.org/10.1259/bjr.20170545>.

- Campista, H., Matos, J. D., Queiroz, D., Maciel, L., Massaroni, P. and Cristina, P. (2023). *Dental anatomy and morphology*. Atena Publishing: Brazil.
- Chen, L. C., Papandreou, G., Schroff, F. and Adam, H. (2017). "Rethinking atrous convolution for semantic image segmentation", *arXiv, preprint arXiv:1706.05587*.
- Chen, Y., Du, H., Yun, Z., Yang, S., Dai, Z., Zhong, L., and Yang, W. (2020). "Automatic segmentation of individual tooth in dental CBCT images from tooth surface map by a multi-task FCN", *IEEE Access*, vol. 8, 97296-97309, <https://doi.org/10.1109/ACCESS.2020.2991799>.
- Chollet, F. (2017). "Xception: Deep Learning with Depthwise Separable Convolutions", *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, July 21-26, USA, 1800-1807, <https://doi.org/10.1109/CVPR.2017.195>.
- Cui, Z., Fang, Y., Mei, L., Zhang, B., Yu, B., Liu, J., and Shen, D. (2022). "A fully automatic AI system for tooth and alveolar bone segmentation from cone-beam CT images", *Nature Communications*, 13(1), 2096. <https://doi.org/10.1038/s41467-022-29637-2>.
- Çelik, G., ve Talu, M. F. (2020). "Çekişmeli üretken ağ modellerinin görüntü üretme performanslarının incelenmesi.", *Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22(1), 181-192. <https://doi.org/10.25092/baunfbed.679608>.
- Çelik, G., Sarı, T., ve Üşümez, A. (2013). "Bilgisayar destekli diş hekimliği ve güncel CAD/CAM sistemleri", *Cumhuriyet Dental Journal*, 16(1), 74-82. <https://doi.org/10.7126/cdj.2012.1545>.
- Dou, W., Gao, S., Mao, D., Dai, H., Zhang, C., and Zhou, Y. (2022). "Tooth instance segmentation based on capturing dependencies and receptive field adjustment in cone beam computed tomography", *Computer Animation and Virtual Worlds*, 33(5), 2100. <https://doi.org/10.1002/cav.2100>.
- Ezirganlı, Ş., Kazancıoğlu, H. O., Mihmanlı, A., ve Demirtaş, N. (2012). "Çenelerdeki Patolojilerin Tanısı İçin Panoramik Radyografilerin Kullanılması Her Zaman Yeterli midir?", *ADO Klinik Bilimler Dergisi*, 6(1), 1105-1108.
- Fawcett, T. (2006). "An introduction to ROC analysis", *Pattern Recognition Letters*, 27(8), 861-874. <https://doi.org/10.1016/j.patrec.2005.10.010>.

- FDI Dünya Diş Hekimliği Federasyonu (2016). *FDI Dünya Diş Federasyonu Yıllık Raporu*.
Erişim: 10 Ocak 2025, <https://www.fdiworldental.org/resource/annual-report-2016>
- Glick, M., Williams, D. M., Kleinman, D. V., Vujicic, M., Watt, R. G., and Weyant, R. J. (2016). “A new definition for oral health developed by the FDI World Dental Federation opens the door to a universal definition of oral health”, *British Dental Journal*, 221(12), 792-793. <https://doi.org/10.1038/sj.bdj.2016.953>.
- Girshick, R., Donahue, J., Darrell, T., and Malik, J. (2014). “Rich feature hierarchies for accurate object detection and semantic segmentation”, *IEEE Conference on Computer Vision and Pattern Recognition*, June 23-28, USA, 580-587, <https://doi.org/10.1109/CVPR.2014.81>.
- Google Colabratory. (2025, 10 Ocak). Erişim Adresi: <https://colab.research.google.com>
- Google Drive. (2025, 10 Ocak). Erişim Adresi: <https://desktop.google.com.tr/drive/about.html>
- Gradio. (2024, 30 Ocak). Erişim Adresi: <https://www.gradio.dev>
- Göçer, Ö., Gülseçen, S., ve Erdem, T. (2010). “Diş hekimliği fakültesi hastanelerinde dijital radyografi uygulamasında karşılaşılan sorunların bilişim teknolojilerindeki gelişmeler ışığında değerlendirilmesi”, 1-3 Şubat 2010, Uşak Üniversitesi, Uşak, *XII. Akademik Bilişim Konferansı Bildirileri*, 561-568.
- He, K., Gkioxari, G., Dollár, P., and Girshick, R. (2017). “Mask r-cnn”, *In Proceedings Of The IEEE International Conference On Computer Vision (ICCV)*, October 22-29, Italy, 2961-2969.
- He, K., Zhang, X., Ren, S., and Sun, J. (2016). “Deep residual learning for image recognition”, *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, June 27-30, USA, 770-778. <https://doi.org/10.1109/CVPR.2016.90>
- Heryadi, Y., Irwansyah, E., Miranda, E., Soeparno, H., and Hashimoto, K. (2020). “The effect of resnet model as feature extractor network to performance of DeepLabV3 model for semantic satellite image segmentation.” *In 2020 IEEE Asia-Pacific Conference on Geoscience, Electronics and Remote Sensing Technology (AGERS)*, December 07-08, Indonesia, 74-77.

Hugging Face. (2025, 10 Ocak). Erişim Adresi: <https://huggingface.co>

İmamoğlu, N., Eresen, A., ve Efe, M. Ö. (2009). “Döner Ters Sarkaç Sisteminin Pekiştirmeli Öğrenme Algoritmaları ile Kontrolü”, *Otomatik Kontrol Türk Milli Komitesi, Otomatik Kontrol Ulusal Toplantısı TOK09*.13-16 Ekim 2009, İstanbul.

Jader, G., Fontineli, J., Ruiz, M., Abdalla, K., Pithon, M., and Oliveira, L. (2018). “Deep instance segmentation of teeth in panoramic X-ray images”, *In 2018 31st SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*, October 29 - November 1 2018, Brazil, 400-407.

Kaki, M., Gunnam, S., Dhanavath, S., Gorantla, P. K., and Saripineni, R. (2023). “Semantic Segmentation of Dental Caries using Improved Deeplab V3Network”, *In 2023 3rd International Conference on Intelligent Communication and Computational Techniques (ICCT)*, January 19-20, India, 1-5.

Karasulu, B., Yücalar, F., ve Borandag, E. (2022). “İnsan kulağı görüntüleri kullanarak cinsiyet tanıma için derin öğrenme tabanlı melez bir yaklaşım”, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 37(3), 1579-1594. <https://doi.org/10.17341/gazimmfd.945188>.

Karras, T., Laine, S., Aittala, M., Hellsten, J., Lehtinen, J., and Aila, T. (2020). “Analyzing and improving the image quality of stylegan”, *In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, June 13-19, USA, 8110-8119.

Keras. (2024, 10 Ocak). Erişim Adresi: <https://keras.io/>

Kokomoto, K., Okawa, R., Nakano, K., and Nozaki, K. (2021). “Intraoral image generation by progressive growing of generative adversarial network and evaluation of generated image quality by dentists”, *Scientific Reports*, 11(1), 18517. <https://doi.org/10.1038/s41598-021-98043-3>

Kondo, S., Morita, W., and Ohshima, H. (2022). “The biological significance of tooth identification based on developmental and evolutionary viewpoints”, *Journal of Oral Biosciences*, 64(3), 287-302. <https://doi.org/10.1016/j.job.2022.05.004>

Lahoud, P., EzEldeen, M., Beznik, T., Willems, H., Leite, A., Van Gerven, A., and Jacobs, R. (2021). “Artificial intelligence for fast and accurate 3-dimensional tooth

- segmentation on cone-beam computed tomography”, *Journal of Endodontics*, 47(5), 827-835. <https://doi.org/10.1016/j.joen.2020.12.020>.
- Li, H., Sun, G., Sun, H., and Liu, W. (2012). “Watershed algorithm based on morphology for dental X-ray images Segmentation”, *In 2012 IEEE 11th International Conference on Signal Processing vol. 2*, October 21-25, China, 877-880.
- Li, Q., Chen, K., Han, L., Zhuang, Y., Li, J., and Lin, J. (2020). “Automatic tooth roots segmentation of cone beam computed tomography image sequences using U-net and RNN” *Journal of X-ray Science and Technology*, 28(5), 905-922. <https://doi.org/10.3233/XST-200678>
- Liu, Y., Zhong, Y., Fei, F., Zhu, Q., and Qin, Q. (2018). “Scene Classification Based on a Deep Random-Scale Stretched Convolutional Neural Network”, *Remote Sensing*, 10(3), 444. <https://doi.org/10.3390/rs10030444>.
- Matplotlib. (2024, 10 Ocak). Erişim Adresi: <https://matplotlib.org>
- Metin, İ. A., ve Karasulu, B. (2021). “İnsanın günlük aktivitelerinin yeni bir veri kümesi: Derin öğrenme tekniklerini kullanarak sınıflandırma performansı için kıyaslama sonuçları”, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 36(2), 759-778. <https://doi.org/10.17341/gazimmfd.772849>
- Minaee, S., Boykov, Y., Porikli, F., Plaza, A., Kehtarnavaz, N., and Terzopoulos, D. (2021). “Image segmentation using deep learning: A survey”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 44, no. 7, 1 July 1, 3523-3542, <https://doi.org/10.1109/TPAMI.2021.3059968>
- Miran, B. (2021). *Temel İstatistik: Genişletilmiş Baskı* (Vol. 1). Ege Üniversitesi Basımevi: İzmir.
- Muresan, M. P., Barbura, A. R., and Nedevschi, S. (2020). “Teeth detection and dental problem classification in panoramic X-ray images using deep learning and image processing techniques”, *In 2020 IEEE 16th International Conference on Intelligent Computer Communication and Processing (ICCP)*, September 03-05, Romania, 457-463. <https://doi.org/10.1109/ICCP51029.2020.9266244>.
- Numpy (2024, 10 Ocak). Erişim Adresi: <https://numpy.org>

- Özata, M. ve Altuncan, H. (2010). “Hastanelerde tıbbi hata görülme sıklıkları, tıbbi hata türleri ve tıbbi hata nedenlerinin belirlenmesi: Konya örneği”, *Tip Araştırmaları Dergisi*, 8(2), 100-111.
- Öztürk, N., ve Öztürk, S. (2021). “Bölütlenme tabanlı yeni görüntü iyileştirme yöntemi.” *Avrupa Bilim ve Teknoloji Dergisi*, (32), 975-981.
<https://doi.org/10.31590/ejosat.1041197>
- Özyavaş, S. (2018). “Türkiye’de ağız diş sağlığı politikası: mevcut durum analizi.” *Hacettepe Sağlık İdaresi Dergisi*, 21(4), 789-805.
- Pandas. (2024, 10 Ocak). Erişim Adresi: <https://pandas.pydata.org>
- Panetta, K., Rajendran, R., Ramesh, A., Rao, S. P., and Agaian, S. (2021). “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>.
- Patterson, J., and Gibson, A. (2017). *Deep learning: A practitioner's approach*. O'Reilly Media, Inc: USA.
- Plested, J., and Gedeon, T. (2022). “Deep transfer learning for image classification: a survey”, *ArXiv*, *preprint* *arXiv:2205.09904*.
<https://doi.org/10.48550/arXiv.2205.09904>
- Pillow. (2024, 10 Ocak). Erişim Adresi <https://pillow.readthedocs.io/en/stable/>
- Probst, P., Boulesteix, A. L., and Bischl, B. (2019). “Tunability: Importance of hyperparameters of machine learning algorithms”, *Journal of Machine Learning Research*, 20(53), 1-32.
- PyTorch. (2024, 10 Ocak). Erişim Adresi: <https://pytorch.org>
- Qian, S., Ning, C., and Hu, Y. (2021). “MobileNetV3 for image classification.” *In 2021 IEEE 2nd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE)*, 490-497.
- Román, J. C. M., Fretes, V. R., Adorno, C. G., Silva, R. G., Noguera, J. L. V., Legal-Ayala, H., and Facon, J. (2021). “Panoramic dental radiography image enhancement using

multiscale mathematical morphology”, *Sensors*, 21(9), 3110.
<https://doi.org/10.3390/s21093110>.

Ronneberger, O., Fischer, P., and Brox, T. (2015). “U-net: Convolutional networks for biomedical image segmentation”, *In Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015: 18th International Conference*, October 5-9, Germany, 234-241.

Rubiu, G., Bologna, M., Cellina, M., Cè, M., Sala, D., Pagani, R., and Ali, M. (2023). “Teeth segmentation in panoramic dental X-ray using mask regional convolutional neural network”, *Applied Sciences*, 13(13), 7947. <https://doi.org/10.3390/app13137947>.

Scikit-Learn. (2024, 10 Ocak). Erişim Adresi: <https://scikit-learn.org>

Sarıcan, B., ve Engin, O. (2024). “Makine Çizelgeleme Problemlerinin Çözümünde Pekiştirmeli Öğrenme Etkisinin Analizi”, *ALKÜ Fen Bilimleri Dergisi*, 6(2), 116-140. <https://doi.org/10.46740/alku.1390397>.

Shafiq, M., and Gu, Z. (2022). “Deep residual learning for image recognition: A survey”, *Applied Sciences*, 12(18), 8972. <https://doi.org/10.3390/app12188972>.

Shaheen, E., Leite, A., Alqahtani, K. A., Smolders, A., Van Gerven, A., Willems, H., and Jacobs, R. (2021). “A novel deep learning system for multi-class tooth segmentation and classification on cone beam computed tomography”, *Journal of Dentistry*, 115, 103865. <https://doi.org/10.1016/j.jdent.2021.103865>

Shamir, R. R., Duchin, Y., Kim, J., Sapiro, G., and Harel, N. (2019). “Continuous dice coefficient: a method for evaluating probabilistic segmentations”, *arXiv preprint arXiv:1906.11031*. <https://doi.org/10.48550/arXiv.1906.11031>.

Sigut, J., Fumero, F., and Nuñez, O. (2015). “Over-and under-segmentation evaluation based on the segmentation covering measure”, *The 23rd International Conference in Central Europe on Computer Graphics, Visualization and Computer Vision EUROGRAPHICS*, June 8-12, University of West Bohemia, Plzen, Czech Republic, 83-89.

Silva, B., Pinheiro, L., Oliveira, L. and Pithon, M., (2020). “A study on tooth segmentation and numbering using end-to-end deep neural networks”, *Conference on Graphics Patterns and Images (SIBGRAPI)*, November 07-10, Brazil, 164-171.

- Silva, G., Oliveira, L., and Pithon, M. (2018). “Automatic segmenting teeth in X-ray images: Trends, a novel data set, benchmarking and future perspectives”, *Expert Systems with Applications*, 107, 15-31. <https://doi.org/10.1016/j.eswa.2018.04.001>.
- Sözeri, C. ve Karasulu, B., (2024). “An Approach for Data Augmentation of Dental X-Ray Images with the use of Deep Convolutional Generative Adversarial Network”, *ICONDATA'2024, 6th International Conference on Data Science and Applications 2024*, the Proceedings Book, Paper ID: 77, September 02-06, Kosovo, 118-123, e-ISBN: 978-605-72045-3-0.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., and Rabinovich, A. (2015). “Going deeper with convolutions”, *In Proceedings of The IEEE Conference on Computer Vision and Pattern Recognition*, June 07-12, USA, 1-9. <https://doi.org/10.1109/CVPR.2015.7298594>.
- Tensorflow. (2024, 10 Ocak). Erişim Adresi: <https://www.tensorflow.org/>
- Tqdm. (2024, 10 Ocak). Erişim Adresi: <https://pypi.org/project/tqdm/>
- Tuzoff, D. V., Tuzova, L. N., Bornstein, M. M., Krasnov, A. S., Kharchenko, M. A., Nikolenko, S. I., and Bednenko, G. B. (2019). “Tooth detection and numbering in panoramic radiographs using convolutional neural networks”, *Dentomaxillofacial Radiology*, 48(4), 20180051. <https://doi.org/10.1259/dmfr.20180051>.
- Uçuk, M. K. (2024) “Bilgisayar Destekli Restorasyonlar ve Diş Hekimliğinde Kullanımının Değerlendirilmesi”, *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 6(1), 1-4. <https://doi.org/10.47769/izufbed.1377884>
- van Nistelrooij, N., Ghoul, K. E., Xi, T., Saha, A., Kempers, S., Cenci, M., and Vinayahalingam, S. (2024). “Combining public datasets for automated tooth assessment in panoramic radiographs”, *BMC Oral Health*, 24(1), 387. <https://doi.org/10.1186/s12903-024-04129-5>
- Williamson, G. F. (2006). “Intraoral radiography: Positioning and radiation protection”, *RDH*, 26(12), 23.
- Wirtz, A., Mirashi, S. G., and Wesarg, S. (2018). “Automatic teeth segmentation in panoramic X-ray images using a coupled shape model in combination with a neural network”, *In Medical Image Computing and Computer Assisted Intervention–*

MICCAI 2018: 21st International Conference, Proceedings, Part IV 11, September 16-20, Spain, 712-719.

- World Health Organization. (2022). *Global oral health status report: towards universal health coverage for oral health by 2030*. Erişim: 5 Ocak 2025, <https://www.who.int/team/noncommunicable-diseases/global-status-report-on-oral-health-2022>
- Xu, X., Liu, C., and Zheng, Y. (2018). “3D Tooth Segmentation and Labeling Using Deep Convolutional Neural Networks”, *IEEE Transactions on Visualization and Computer Graphics*, 25(7), 2336-2348. <https://doi.org/10.1109/TVCG.2018.2839685>.
- Yang, S., Kim, K. D., Arijji, E., and Kise, Y. (2024). “Generative adversarial networks in dental imaging: a systematic review”, *Oral Radiology*, 40(2), 93-108. <https://doi.org/10.1007/s11282-023-00719-1>.
- Yang, Y., Xie, R., Jia, W., Chen, Z., Yang, Y., Xie, L., and Jiang, B. (2021). “Accurate and automatic tooth image segmentation model with deep convolutional neural networks and level set method”, *Neurocomputing*, 419, 108-125. <https://doi.org/10.1016/j.neucom.2020.07.110>.
- Yüksel, A. E., Gültekin, S., Simsar, E., Özdemir, Ş. D., Gündoğar, M., Tokgöz, S. B., ve Hamamcı, İ. E. (2021). “Dental enumeration and multiple treatment detection on panoramic X-rays using deep learning.” *Scientific reports*, 11(1), 12342. <https://doi.org/10.1038/s41598-021-90386-1>.
- Zhang, Y., Ye, F., Chen, L., Xu, F., Chen, X., Wu, H., and Huang, X. (2023). “Children’s dental panoramic radiographs dataset for caries segmentation and dental disease detection”, *Scientific Data*, 10(1), 380. <https://doi.org/10.1038/s41597-023-02237-5>.
- Zhong, Y., Fei, F., and Zhang, L. (2016). “Large patch convolutional neural networks for the scene classification of high spatial resolution imagery”, *Journal of Applied Remote Sensing*, 10(2), 025006-025006. <https://doi.org/10.1117/1.JRS.10.025006>.
- Zhou, D., Fang, J., Song, X., Guan, C., Yin, J., Dai, Y., and Yang, R. (2019). “IoU loss for 2d/3d object detection”, *In 2019 International Conference on 3D Vision (3DV)*, 16-19 September, Canada, 85-94. <https://doi.org/10.1109/3DV.2019.00019>.

Zhu, H., Cao, Z., Lian, L., Ye, G., Gao, H., and Wu, J. (2023). “CariesNet: a deep learning approach for segmentation of multi-stage caries lesion from oral panoramic X-ray image”. *Neural Computing and Applications*, 1-9. <https://doi.org/10.1007/s00521-021-06684-2>

Zou, B., Huang, X., Jiang, Y., Jin, K., and Sun, Y. (2024). “Demambanet: deformable convolution and mamba integration network for high-precision segmentation of ambiguously defined dental radicular boundaries”. *Sensors*, 24(14), 4748. <https://doi.org/10.3390/s24144748>.

