

**ANKARA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**DOKTORA TEZİ**

**RADYOLOJİK GÖRÜNTÜLERDE DIŞ ANOMALİLERİNİN DERİN  
ÖĞRENME İLE TESPİTİ**

**Esra SİVARİ RESUL**

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**ANKARA  
2025**

**Her hakkı saklıdır**

## ÖZET

Doktora Tezi

### RADYOLOJİK GÖRÜNTÜLERDE DİŞ ANOMALİLERİNİN DERİN ÖĞRENME İLE TESPİTİ

Esra SİVARİ RESUL

Ankara Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Gazi Erkan BOSTANCI  
Eş Danışman: Dr. Öğr. Üyesi Güler Burcu SENİRKENTLİ

Çocuklarda diş anomalilerinin erken ve doğru teşhisi, zamanında tedavilere rehberlik etmek ve gelecekteki ağız sağlığı sorunlarından kaçınmak için esastır. Ancak, panoramik radyografilerin yorumlanması klinisyenler arasında değişiklik gösterebilir ve genellikle deneyim seviyelerinden etkilenir. Bu çalışmada, radyolojik değerlendirme için kritik bir tanı rolü oynadığı germ eksikliği ve süpernumere dişler gibi pediatrik diş anomalilerini tespit etmek için tasarlanmış yeni bir derin öğrenme modeli olan Kompakt İnvolüsyonel Transformatör (CIT) tanıtılmıştır. Bir uzman pedodontist tarafından düzenlenen veri seti, 1.170 pediatrik panoramik radyografiden oluşmaktadır ve hem çoklu sınıflandırma (germ eksikliği, normal, süpernumere diş) hem de ikili sınıflandırma ayarlarında test edilmek üzere yapılandırılmıştır. Üç sınıflı görevde, CIT, %96,00 doğruluk, %95,29 F1 skoru, %95,76 AUC ve %93,28 Matthews korelasyon katsayısı elde ederek son teknoloji derin öğrenme modellerinden daha iyi performans göstermiştir. Modelin yorumlanabilirliği, kararlara katkıda bulunan bölgeleri vurgulayan Grad-CAM ısı haritalarıyla desteklenmiştir. Karşılaştırmalı bir değerlendirmede, McNemar testine göre CIT, pedodontistlere karşı anlamlı biçimde üstündür; genel diş hekimleriyle fark anlamlı değildir ve klinik örtüşme sürmektedir. Gerçekleştirdiğimiz literatür taramasından bildiğimiz kadarıyla, bu tez çalışmasında, otomatik germ eksikliği tespiti için tasarlanmış ilk yapay zeka yaklaşımı ve aynı zamanda tıbbi görüntü analizi için transformatör tabanlı bir model içinde involüsyonun ilk uygulaması sunulmaktadır.

**Kasım 2025, 89 sayfa**

**Anahtar Kelimeler:** Derin öğrenme, Germ eksikliği, Süpernumere diş, Pediatrik panoramik radyografiler, Kompakt involüsyonel transformatör

# ABSTRACT

PhD Thesis

## DETECTION OF DENTAL ANOMALIES ON RADIOLOGICAL IMAGES WITH DEEP LEARNING

Esra SIVARİ RESUL

Ankara University  
Graduate School of Natural and Applied Sciences  
Department of Computer Engineering

Supervisor: Prof. Dr. Gazi Erkan BOSTANCI  
Co-Supervisor: Assist. Prof. Dr. Güler Burcu SENİRKENTLİ

Early and accurate diagnosis of dental anomalies in children is essential for guiding timely treatments and preventing future oral health complications. However, the interpretation of panoramic radiographs can vary among clinicians and is often influenced by their level of experience. This study introduces a novel deep learning model called the Compact Involutional Transformer (CIT), which is specifically designed to detect pediatric dental anomalies including germ deficiency and supernumerary teeth, where radiological evaluation plays a critical role in diagnosis. A dataset of 1,170 pediatric panoramic radiographs was compiled and annotated by a specialist in pediatric dentistry. The model was evaluated in both multi-class classification (germ deficiency, normal, and supernumerary teeth) and binary classification tasks. In the multi-class scenario, the CIT model outperformed existing state-of-the-art deep learning architectures by achieving 96.00% accuracy, 95.29% F1 score, 95.76% AUC, and 93.28% Matthews correlation coefficient. Model interpretability was supported by Grad-CAM heatmaps that highlighted the image regions contributing to the decision-making process. In a comparative analysis, the According to McNemar's test, CIT demonstrates statistically significant superiority over the pediatric dentist group, whereas its difference from the general dentist group is not significant; clinical concordance is maintained. Based on our review of the existing literature, this thesis presents the first artificial intelligence approach developed for the automatic diagnosis of germ deficiency and provides the first known implementation of involution within a transformer-based architecture for medical image analysis.

**November 2025, 89 pages**

**Key Words:** Deep learning, Germ deficiency, Supernumerary teeth, Pediatric panoramic radiographs, Compact involutional transformer

## TEŐEKKÜR

Öncelikle, akademik yolculuđum boyunca her zaman yanımda olan, engin bilgi birikimi, titiz akademik yaklaşımı ve özellikle metodolojinin geliştirilmesinde sağladığı teknik rehberlikle bana ışık tutan danışmanım Prof. Dr. Gazi Erkan BOSTANCI'ya en derin şükranlarımı sunarım.

Eş danışmanım Dr. Öğr. Üyesi Güler Burcu SENİRKENTLİ'ye, sadece veri setinin oluşturulmasında değil, pedodonti alanındaki engin bilgisiyle diş terminolojisinin doğru şekilde anlaşılması, testlerin yorumlanması ve klinik doğruluğun sağlanması konularındaki eşsiz katkıları için gönülden teşekkür ederim.

Tez izleme komitemin değerli üyeleri Prof. Dr. Resmiye Ebru TİRALİ ve Prof. Dr. Mehmet Serdar GÜZEL'e, akademik vizyonumu geliştiren yol gösterici tavsiyeleri ve içten yönlendirmeleri için teşekkür ederim.

İnsan uzman-yapay zeka karşılaştırmalı değerlendirmelerde gönüllü olarak katkı sağlayan Başkent Üniversitesi Diş Hekimliği Fakültesi, Çankırı Devlet Diş Hastanesi ve Çankırı Karatekin Üniversitesi Diş Hekimliği Fakültesi'nde görev yapan kıymetli hekim hocalarıma içtenlikle teşekkür ederim.

Doktora sürecim boyunca bilgi ve deneyimlerini esirgmeden paylaşan, her zaman teşvik edici ve yol gösterici olan değerli arkadaşım Dr. Hüsamettin ŞERBETÇİ'ye teşekkür ederim.

Ve her şeyin ötesinde... En büyük teşekkürü aileme borçluyum. Her adımda dualarıyla yanımda olan sevgili annem Suna KARAAĞAÇ'a, desteğiyle bana hep güç veren canım kardeşim Gözde Nur ARSLAN'a ve sabrıyla, sevgisiyle, bana bu süreci mümkün kılan hayat arkadaşım Ahmet RESUL'a kalpten teşekkür ederim.

Esra SİVARİ RESUL  
Ankara, Kasım 2025

## İÇİNDEKİLER

<b>TEZ ONAYI</b>	
<b>ETİK.....</b>	<b>i</b>
<b>ÖZET.....</b>	<b>ii</b>
<b>ABSTRACT .....</b>	<b>iii</b>
<b>TEŞEKKÜR .....</b>	<b>iv</b>
<b>SİMGELER VE KISALTMALAR DİZİNİ .....</b>	<b>vii</b>
<b>ŞEKİLLER DİZİNİ .....</b>	<b>ix</b>
<b>ÇİZELGELER DİZİNİ .....</b>	<b>x</b>
<b>1. GİRİŞ.....</b>	<b>1</b>
<b>1.1 Tezin Gerekçeleri .....</b>	<b>3</b>
<b>1.2 Tezin Amacı ve Önemi.....</b>	<b>3</b>
<b>1.3 Tezin Kapsamı .....</b>	<b>4</b>
<b>1.4 Tezin Yapısı .....</b>	<b>5</b>
<b>2. KURAMSAL TEMELLER VE KAYNAK ÖZETLERİ.....</b>	<b>6</b>
<b>2.1 Kuramsal Temeller .....</b>	<b>6</b>
<b>2.1.1 Süpernumere dişler .....</b>	<b>6</b>
<b>2.1.2 Germ eksikliği ve dental agenezi.....</b>	<b>8</b>
<b>2.1.3 Derin öğrenme ve mimarileri .....</b>	<b>9</b>
<b>2.2 Kaynak Özetleri.....</b>	<b>11</b>
<b>2.2.1 Süpernumere dişlerin tespiti ve derin öğrenme.....</b>	<b>11</b>
<b>2.2.2 Kalıcı diş germlerinin tespiti ve derin öğrenme.....</b>	<b>17</b>
<b>2.2.3 Dental agenezi tespiti ve derin öğrenme .....</b>	<b>17</b>
<b>2.2.4 Diğer diş anomalilerinin tespiti ve derin öğrenme.....</b>	<b>18</b>
<b>2.2.5 Literatür boşlukları ve tezin bilimsel katkıları.....</b>	<b>19</b>
<b>3. MATERYAL VE YÖNTEMLER.....</b>	<b>22</b>
<b>3.1 Genel Bakış .....</b>	<b>22</b>
<b>3.2 Veri Seti.....</b>	<b>24</b>
<b>3.3 CNN .....</b>	<b>27</b>
<b>3.4 ViT .....</b>	<b>29</b>
<b>3.5 CCT .....</b>	<b>32</b>
<b>3.6 CIT.....</b>	<b>35</b>
<b>3.7 Eğitim ve Doğrulama Süreçleri.....</b>	<b>40</b>
<b>3.8 Performans Metrikleri.....</b>	<b>44</b>

<b>3.9 İstatistiksel Analiz Yöntemleri .....</b>	<b>48</b>
<b>3.10 Açıklanabilir Yapay Zeka Yöntemleri .....</b>	<b>49</b>
<b>4. BULGULAR .....</b>	<b>51</b>
<b>4.1 Eğitim ve Doğrulama Performansları .....</b>	<b>51</b>
<b>4.2 Test Performansları .....</b>	<b>55</b>
<b>4.3 Yapay Zeka Modellerinin İnsan Uzmanlarla Kıyaslanması .....</b>	<b>63</b>
<b>4.4 İstatistiksel Analiz Bulguları .....</b>	<b>65</b>
<b>4.5 Açıklanabilir Yapay Zeka Bulguları .....</b>	<b>67</b>
<b>5. TARTIŞMA .....</b>	<b>69</b>
<b>6. SONUÇ .....</b>	<b>78</b>
<b>KAYNAKLAR .....</b>	<b>82</b>
<b>ÖZGEÇMİŞ .....</b>	<b>88</b>

## SİMGELER VE KISALTMALAR DİZİNİ

$X, x$	Giriş görüntüsü
$Y, y$	Çıkış görüntüsü
$W$	Ağırlık matrisi
$b$	Bias terimi
$\sigma$	Aktivasyon Fonksiyonu
$d_k$	Anahtar vektör boyutu
$Q$	Sorgu matrisi (Query)
$K$	Anahtar matrisi (Key)
$V$	Değer matrisi (Value)
$A_k$	k. öznitelik haritası
$\eta$	Öğrenme oranı

### **Kısaltmalar**

ACC	Accuracy (Doğruluk)
ADAM	Adaptive Moment Estimation
AMNN	Associative Memory Neural Network
AP	Average Precision (Ortalama Kesinlik)
AUC	Area Under Curve
BPNN	Backpropagation Neural Network
CCT	Compact Convolutional Transformer
CIT	Compact Involutional Transformer
CLAHE	Contrast-limited Histogram Equalization
CNN	Convolutional Neural Network
DSC	Dice Similarity Coefficient
FN	False Negative (Yanlış Negatif)
FP	False Positive (Yanlış Pozitif)
FPR	False Positive Rate (Yanlış Pozitif Oranı)
GDG	Genel Diş Hekimi Grubu

GELU	Gaussian Error Linear Unit
GPU	Graphics Processing Unit
Grad-CAM	Gradient-weighted Class Activation Mapping
IoU	Intersection Over Union
JPEG	Joint Photographic Experts Group
JSC	Jaccard Similarity Coefficient
MCC	Matthews Correlation Coefficient
MHSA	Multi-Head Self-Attention
MLP	Multilayer Perceptron
PREC-REC	Precision-Recall
PREC	Precision (Kesinlik)
R-CNN	Regions with Convolutional Neural Network
RBNN	Radial Basis Neural Network
REC	Recall (Geri çağırma)
ReLU	Rectified Linear Unit
RGB	Red Green Blue
ROC	Receiver Operating Characteristic
ROI	Region of Interest
SHAP	SHapley Additive exPlanations
SOTA	State-of-the-Art
SPEC	Specificity (Özgüllük)
TN	True Negative (Gerçek Negatif)
TP	True Positive (Gerçek Pozitif)
TPR	True Positive Rate (Doğru Pozitif Oranı )
UPG	Uzman Pedodontist Grubu
ViT	Vision Transformer
VS	Veri Seti
WHO	World Health Organization
XAI	Explainable Artificial Intelligence
YOLO	You Only Look Once

## ŞEKİLLER DİZİNİ

Şekil 2.1 Panoramik radyografide mesiodens ve süpernümere diş örnekleri .....	7
Şekil 2.2 Panoramik radyografide kalıcı diş germi eksikliği örneği .....	9
Şekil 3.1 Tez çalışması için önerilen yöntemin genel iş akışı.....	23
Şekil 3.2 Veri setinden germ eksikliği, normal ve süpernümere diş sınıfları için panoramik radyografi örnekleri.....	25
Şekil 3.3 Veri setinin yapılandırılması ve deneysel tasarımın yapısı.....	27
Şekil 3.4 CNN mimarisinin genel yapısı.....	28
Şekil 3.5 ViT mimarisinin genel yapısı.....	30
Şekil 3.6 CCT mimarisinin genel yapısı .....	33
Şekil 3.7 CCT ve CIT mimarilerinin kıyaslanması.....	37
Şekil 3.8 CIT mimarisinin genel yapısı.....	37
Şekil 3.9 İkili sınıflandırma görevleri için karışıklık matrisi .....	45
Şekil 3.10 McNemar testinde kontenjans tablosu .....	48
Şekil 4.1 CIT modelinin VS1 üzerindeki eğitim ve doğrulama sürecine ait doğruluk ve kayıp eğrileri .....	52
Şekil 4.2 CIT modelinin VS2 üzerindeki eğitim ve doğrulama sürecine ait doğruluk ve kayıp eğrileri .....	53
Şekil 4.3 CIT modelinin VS3 üzerindeki eğitim ve doğrulama sürecine ait doğruluk ve kayıp eğrileri .....	54
Şekil 4.4 CIT modelinin üç farklı veri seti için karışıklık matrisleri .....	56
Şekil 4.5 CIT modelinin VS1 için ROC ve PREC-REC eğrileri .....	58
Şekil 4.6 CIT modelinin VS2 için ROC ve PREC-REC eğrileri .....	59
Şekil 4.7 CIT modelinin VS3 için ROC ve PREC-REC eğrileri .....	60
Şekil 4.8 Çeşitli test görüntüleri için Grad-CAM görselleri .....	68
Şekil 6.1 VS1'den elde edilen sonuçlara dayalı genel performans özeti .....	79

## ÇİZELGELER DİZİNİ

Çizelge 3.1 CIT modelinin konfigürasyonu, hiperparametreleri ve parametre özeti.....	44
Çizelge 3.2 Performans metriklerine genel bakış .....	47
Çizelge 4.1 CIT ve SOTA modellerinin üç farklı veri setindeki performansları.....	63
Çizelge 4.2 VS1 için CIT ve insan uzmanların sınıflandırma performansları.....	64
Çizelge 4.3 VS1 için McNemar testinin sonuçları.....	66
Çizelge 5.1 Literatürdeki ilgili sınıflandırma çalışmalarına genel bakış .....	77

## 1. GİRİŞ

Günümüzde ağız ve diş sağlığı alanındaki teknolojik gelişmelerle ağız ve diş hastalıklarının çoğu erken teşhis ve tedavi olanaklarına sahip olsa da küresel olarak artışı önlenememiştir. Dünya Sağlık Örgütü (World Health Organization, WHO) Küresel Ağız Sağlığı Durum Raporuna (2022) göre dünya çapında yaklaşık 3,5 milyar insan ağız ve diş hastalıklarından etkilenmiştir. Özellikle düşük ve orta gelirli ülkelerin çoğu, teşhis ve tedavi maliyetleri sebebiyle ağız ve diş sağlığı alanında yeterli hizmete sahip değildir. Bu durumun sonucu olarak düşük ve orta gelirli ülkelerde her 4 kişiden 3' ünün ağız ve diş hastalıklarından etkilendiği WHO (2022) tarafından tahmin edilmektedir. Başta diş çürükleri olmak üzere en yaygın görülen diş hastalıkları periodontal hastalıklar, dişsizlik (edentulism), oral kanser, diş anomalileri ve yarık dudak ve damak hastalıklarıdır. Bu hastalıklar için verimli teşhis ve tedavi sağlanmadığında hafif rahatsızlıktan ölüme kadar değişebilen çeşitli komplikasyonlara neden olabilir.

Dişlerin anormal boyutları, morfolojisi, sayıları ve dişlerin sürme paterni dahil olmak üzere dental anomaliler olarak tanımlanır (Sella Tunis vd. 2021). En yaygın görülen anomaliler diş eksikliği veya fazlalığından kaynaklanan sayı anomalileridir. Dental anomaliler her iki çenede de önemli estetik ve fonksiyonel problemlere yol açar. Maloklüzyon, dental agenezi veya süpernumere dişler çiğneme fonksiyonunu olumsuz etkileyerek yetersiz beslenme ve sindirim sorunlarına neden olabilir. Özellikle anterior bölgede yer alan diş anomalileri artikülasyon ve fonetik sorunlara neden olabilir. Ağız-diş estetiği sosyal kabul ve bireyin kendini ifade etme biçimini etkileyerek özellikle çocuk ve ergen bireylerde psikolojik strese neden olabilir. Agenezi ve süpernumere dişler gibi anomaliler, diş dizisinde çapraşıklık ve uygunsuz diş pozisyonları oluşturarak ortodontik planlamayı ve protez uygulamalarını zorlaştırabilir. Anomalili bölgelerde temizlenme zor olacağından periodontal hastalık ve çürük riski artar. Tüm bunlara ek olarak, diş koşulları gıdanın uygun şekilde sindirilmesi ile güçlü bir şekilde ilişkili olduğu için dental anomaliler genel sağlık durumunu etkileyebilir. Bu nedenle bu tür komplikasyonları önlemek için dental anomalilerin önceden saptanması ve uygun zamanda müdahale edilmesi gereklidir. Dental anomalilerin teşhisi, tedavi seçimini doğrudan etkiler. Doğru

teşhis, en uygun ve minimum tedaviyi sağlayarak komplikasyonları ve cerrahi veya ortodontik tedavinin kapsamını azaltır.

Ağız ve diş hastalıklarının teşhisinde klinik muayeneye ek olarak dental görüntüleme teknolojileri oldukça önemli bir rol oynamaktadır (Shah vd. 2014). İki boyutlu panoramik ve periapikal radyografiler başta olmak üzere konik ışınlı bilgisayarlı tomografi, manyetik rezonans görüntüleme ve ultrason gibi üç boyutlu dental görüntüleme teknolojilerinin ileri seviyeye ulaşması teşhiste başarı oranını arttırmıştır. Periapikal radyografiler, oklüzal radyografiler ve panoramik radyografiler dental anomalileri analiz etmek ve komplikasyonların varlığını değerlendirmek için yaygın olarak kullanılır. Bazı anomalilerin doğrulanması ve çıkarılması kolay olabilirken, gömülü mesiodens gibi bazılarının sadece radyolojik inceleme ile tespit edilebilmesi cerrahi zorluğu artırmaktadır (Kılınç & Çetin 2020). Radyolojik inceleme ve karar verme süreci uzman deneyimine ve gözlemciler arasındaki değişkenlere bağlıdır. Panoramik radyografilerde arka planın gürültülü olması ve anatomik yapıların üst üste binmesi (superimposition) görüntü tabanlı dental teşhisi zorlaştırmaktadır (Shah vd. 2014). Uzman, inceleme ve karar verme sürecinde dental anomalileri gözden kaçırabilir. Güvenilir ve objektif radyografik bilgi, klinik karar vermede son derece önemlidir.

Bilgisayar destekli teşhis, özellikle kritik, yaşamı tehdit eden bir durumun hızlı bir şekilde teşhis edilmesinin gerekli olduğu acil tanısal görüntülemelerde uygulanabilir hastalık teşhisi sağlamaktadır. Son zamanlarda, derin öğrenme algoritmaları kullanan yapay zekaya dayalı sistemler, insan gözlemciler tarafından soyutlanan karakteristik özellikleri kullanan geleneksel metodoloji tarafından oluşturulan bilgisayar destekli tespit ve teşhis sistemlerinin yerini hızla almıştır. Günümüzde derin öğrenme algoritmaları diş görüntüleme alanında aktif olarak uygulanmaktadır. Derin öğrenme algoritmalarının ağız ve çene-yüz bölgelerindeki çeşitli hastalıkları mükemmel bir şekilde tespit ettiği bildirilmiştir (Tandon vd. 2020, AbuSalim vd. 2022, Carrillo-Perez vd. 2022). Ağız ve diş sağlığı alanında çok sayıda görüntü elde edilmesi, bu görüntülerin analizinde diş hekimlerinin bilgisayar uygulamalarına bağımlı olması ve sınırlı sürede karar verme performansının yükseltilmesi gibi durumlar göz önüne alındığında derin öğrenme uygulamalarının gelecekteki yeri için büyük bir potansiyel görünmektedir. Dental

anomalilerin bir derin öğrenme modeli ile yüksek doğruluk ve hassas ölçümlerle tespit edilmesi, maliyet, zaman, iş yükü tasarrufu, erken tanı ve dental teşhiste objektiflik gibi uzmana ve hastalara yardımcı olabilecek birçok fırsat sunabilir.

Bu tez çalışması, dental radyolojik görüntüler üzerinde germ eksikliği ve süpernumere dişler gibi radyolojik incelemenin kritik olduğu dental anomalilerin yenilikçi ve açıklanabilir bir derin öğrenme mimarisi kullanılarak otomatik teşhisi ve sınıflandırılması problemini ele almaktadır.

## 1.1 Tezin Gerekçeleri

Tezin gerekçeleri aşağıdaki gibi sıralanabilir:

- Dental anomalilerin neden olduğu komplikasyonları önlemede erken tanı hayati öneme sahiptir.
- Uzman kısıtlı sürede teşhis ve tedavi kararları almalı ve uygulamalıdır.
- Gömülü mesiodens, süpernumere dişler ve germ eksikliği gibi anomaliler sadece radyolojik inceleme ile tespit edilebilir.
- Radyolojik inceleme ve karar verme süreci uzman deneyimine ve gözlemciler arasındaki değişkenlere bağlıdır.
- Uzman, inceleme ve karar verme sürecinde dental anomalileri gözden kaçırabilir.
- Diş sağlığı alanında teşhis ve tedavi maliyetlidir.

## 1.2 Tezin Amacı ve Önemi

Bu tez çalışması potansiyel dental agenezinin en erken belirtisi olan germ eksikliği ve gömülü mesiodensleri kapsayan süpernumere dişler gibi sadece radyolojik inceleme ile tespit edilebilen anomalilerin pediatrik panoramik radyografiler üzerinde otomatik tespiti için derin öğrenme tekniklerine dayalı yenilikçi bir sistem önermeyi amaçlamaktadır. Tezin gerekçelerine dayanarak süpernumere dişler ve germ eksikliği anomalilerinin bir

yapay zeka modeli ile yüksek doğruluk ve hassas ölçümlerle tespit edilmesi klinik uygulamada maliyet, zaman, iş yükü tasarrufu, erken tanı ve dental teşhiste objektiflik gibi uzmana ve hastalara yardımcı olabilecek kritik öneme sahiptir. Klinik öneminin yanı sıra uzman diş hekimleri tarafından oluşturulmuş yeni bir veri seti üzerinde performans üstünlüğü sunan açıklanabilir ve yenilikçi bir derin öğrenme modelinin literatüre sunulması ve istatistiksel analizlere dayalı insan ve yapay zeka performansını kıyaslayan bir çalışma olması gibi bilimsel katkılar yapay zekanın tıbbi uygulamaları ve multidisipliner bilimler için oldukça önemlidir.

Bu çalışma için önerilen sistemin hedefleri aşağıdaki gibi sıralanabilir:

- Yüksek doğruluk ve hassas ölçümlerle dental anomalileri tespit edebilmek
- Maliyet, zaman ve iş yükü tasarrufu sağlayabilmek
- Hızlı karar verebilen ve erken tanı olanağı sunan bir sistem geliştirebilmek
- Dental tanıda objektiflik sağlayabilmek
- Uzmanlara yardımcı olacak açıklanabilir bir sistem tasarlayabilmek

### **1.3 Tezin Kapsamı**

Bu tez çalışmasında, pediatrik panoramik radyografilerde süpernümere dişlerin ve germ eksikliğinin otomatik tespiti için özel olarak geliştirilen, Kompakt İnvolüsyonel Transformatör (Compact Involutional Transformer, CIT) adı verilen yenilikçi ve açıklanabilir bir derin öğrenme mimarisi tanıtılmaktadır. Bu kompakt tasarım hem yerel hem de bağlamsal diş yapılarını daha etkili bir şekilde yakalayarak geleneksel evrişimli veya yalnızca transformatörlü modellere göre önemli bir ilerleme sunmaktadır. Bu tez çalışması için 1.170 panoramik radyografiden oluşan özel bir veri seti toplanmış ve deneyimli bir pediatrik diş hekimi tarafından etiketlenmiştir. Önerilen modelin performansı hem çoklu (germ eksikliği, normal, süpernümere diş) hem de ikili sınıflandırma görevleri için değerlendirilmiştir. Aynı zamanda performansın kıyaslanması amacıyla veri seti Görüş Transformatörü (Vision Transformer, ViT), Kompakt Evrişimsel Transformatör (Compact Convolutional Transformer, CCT) ve

Evrişimli Sinir Ağı (Convolutional Neural Network, CNN) olmak üzere son teknoloji (State-of-the-Art, SOTA) modeller ile eğitilmiş sonuçlar ayrıntılı olarak analiz edilmiştir. Sınıflandırma sırasında modelin odak alanlarının görselleştirilmesine olanak tanıyarak klinik güveni arttırmak amacıyla açıklanabilir yapay zeka (Explainable AI, XAI) tekniklerinden Gradyan Ağırlıklı Sınıf Aktivasyon Haritası (Gradient-weighted Class Activation Mapping, Grad-CAM) uygulanmıştır. CIT modelinin tanısal performansı, McNemar testi kullanılarak uzman diş hekimleriyle istatistiksel olarak karşılaştırılmış ve sistemin pratik faydası ve rekabetçi doğruluğu kanıtlanmıştır.

#### 1.4 Tezin Yapısı

Bu tez çalışmasının ilerleyen bölümleri aşağıdaki gibi yapılandırılmıştır:

- Bölüm 2’de süpernumere dişler, germ eksikliği ve dental agenezi hakkında kuramsal temeller verilmiş, dental anomalilerin derin öğrenme ile teşhisi üzerine literatür çalışmaları sunulmuş ve literatürdeki boşluklar incelenerek tez çalışmasının bilimsel katkıları verilmiştir.
- Bölüm 3’te çalışmada kullanılan veri seti, önerilen ve SOTA modellerin mimarisi ve uygulama yöntemleri, değerlendirme metrikleri, Grad-CAM ile açıklanabilirlik ve istatistiksel analiz yöntemleri detaylı olarak açıklanmıştır.
- Bölüm 4’te eğitim ve doğrulama performansları, test sonuçları, SOTA modellerle performans karşılaştırmaları, Grad-CAM görselleştirmeleri, insan-yapay zeka karşılaştırmaları ve istatistiksel anlamlılık bulguları açıkça sunulmuştur.
- Bölüm 5’te bulguların klinik ve teknik açıdan yorumu, literatür karşılaştırması, önerilen yöntemin güçlü ve zayıf yönleri ve çalışmanın kısıtları gibi konular tartışılmıştır. Son olarak tez çalışmasından elde edilen ana sonuçlar verilerek tez çalışması sonuçlandırılmıştır.

## 2. KURAMSAL TEMELLER VE KAYNAK ÖZETLERİ

### 2.1 Kuramsal Temeller

#### 2.1.1 Süpernümere dişler

Normal dişlenme dizisinde olması gereken sayıya ek olarak bir veya birden fazla diş gelişmesi durumu hiperdonti veya süpernümere diş olarak tanımlanır (Maylid vd. 2024). Bu fazladan dişler morfolojik olarak normal bir diş benzeyebileceği gibi şekil bakımından atipik de olabilir. Normal forma sahip ekstra bir diş supplemental diş olarak adlandırılırken, küçük, konik ya da tüberkül şeklindeki atipik fazladan dişlere mesiodens denir. Mesiodens, genellikle üst çenenin ön bölgesinde, iki santral kesici dişin ortasında görülür ve en sık rastlanan süpernümere diş tipidir (Mallineni vd. 2025). Daha arka bölgelerde görülen fazladan küçük azı dişleri paramolar, üçüncü büyük azı dişlerinin arkasında yerleşen fazladan dişler ise distomolar olarak tanımlanır.


Süpernümere dişlerin oluşumunun etiyojisi henüz tam olarak bilinmemekle birlikte en yaygın kabul gören hipotez, dental laminaların hiperaktivitesi olarak kabul edilmektedir (Watted vd. 2025). Ek olarak ortaya çıkışında spesifik genetik faktörlerin önemli bir katkısı olduğu düşünülmektedir. Bazı sendromlar da bu duruma eşlik edebilir; örneğin Cleidocranial Dysplasia sendromu hem iskelet sistemi anomalileri hem de çok sayıda süpernümere diş oluşumu ile karakterizedir. Bu sendromda 50'den fazla diş oluşabileceği bildirilmiştir (Lu vd. 2024). Yine Gardner Sendromu gibi bazı genetik hastalıklar da süpernümere diş görülme sıklığını artırabilir (Antal vd. 2024).

Watted vd. (2025) tarafından yürütülmüş güncel bir derleme çalışmasında, pediatrik hastalarda süpernümere diş prevalansı süt dişlenme döneminde %0,4-0,8 daimi dişlenme döneminde ise %0,1-6,9 arasında değiştiği bildirilmiştir. Prevalans aralığının geniş olması dünya çapındaki farklı çalışmaların metodolojisi, ırk, yaş grubu gibi

farklılıklardan kaynaklanmaktadır. Erkeklerde kadınlara göre iki kat daha sık görüldüğü rapor edilmiştir.

Süpernumere dişler çoğunlukla üst çene (maksiller) bölgesinde, özellikle ön dişlerde ortaya çıkarak hem estetik hem de fonksiyonel açıdan çeşitli sorunlara yol açabilir. Sürme yolunu tıkayarak diğer dişlerin sürmesini engelleyebilir, dişlerin yer değiştirmesine, dönmesine, orta diş hattında kaymaya, diş sıkışıklığı veya diastema yani aralıklı dişlenmeye ve hatta kök rezorpsiyonlarına neden olabilir. Unerüpte kalan süpernumere dişler kist oluşumlarına da zemin hazırlayabilir. Bu yüzden erken tanı ve disiplinler arası müdahale gelişmekte olan diş dizisindeki sonuçları en aza indirmek için oldukça önemlidir.

Klinik muayenede diş hekimi, diş sürmesinde gecikme, sürme düzeninde düzensizlik, orta hat kayması veya diş arkında sıkışıklık gibi bulguları dikkate alarak; tanıyı doğrulamak amacıyla radyolojik görüntüleme yöntemlerinden yararlanarak süpernumere dişleri tespit edebilir. Tedavi gerekliliği ise dişin yerleşimine, estetik ya da fonksiyonel sorun yaratıp yaratmadığına göre belirlenir. Yer darlığı, kist gelişimi veya diş dizilimini bozması gibi durumlarda cerrahi olarak çıkarılması önerilir. Cerrahi sonrası ortodontik tedavi planlaması ile boşluk yönetimi ve dişlerin ideal pozisyonlara taşınması sağlanır. Çok sayıda süpernumere dişin görüldüğü sendromik olgularda ise multidisipliner bir yaklaşım gereklidir; çene cerrahisi, ortodonti, genetik danışmanlık ve pedodonti bir arada çalışmalıdır (Bacali vd. 2024).



Şekil 2.1 Panoramik radyografide mesiodens ve süpernumere diş örnekleri

### 2.1.2 Germ eksikliği ve dental agenezi


Dental laminadan köken alan, dişin mine organı ve dental papilla yapılarına farklılaşan bir hücre yığını diş germi olarak tanımlanmaktadır (Bei 2009). Bir dişin var olması, biyolojik olarak bu germin varlığına ve sağlıklı gelişmesine bağlıdır. Diş agenezisi, doğrudan bir dişin gelişimsel yetersizliğini ifade eder. Mevcut diş agenezisi türünü sınıflandırmada 1 ila 6 dişin olmaması durumu için Hipodonti terimi kullanılmaktadır. Oligodonti ve anodonti, diş eksikliğinin daha şiddetli formlarıdır ve oligodonti, 6'dan fazla dişin olmaması, anodonti ise tüm dişlerin tamamen yokluğu durumlarını tanımlamak için kullanılan terimlerdir.

Dental agenezi en sık görülen kraniyofasiyal anomalidir. Çoğunlukla genetik sendromlarla ilişkili olabilir veya etiolojisinde hem genetik hem de çevresel faktörler rol oynayabilir (Duke vd. 2023). Daha az yaygın olarak gebelikte radyasyon, enfeksiyon ya da annenin sigara kullanımı gibi etkenler geçici ya da yerel germ gelişim bozukluklarına neden olabilir (De Coster vd. 2009). Prevalansı, analiz edilen popülasyonun bölgesine, örneklem büyüklüğüne, etnik kökene ve cinsiyetine göre değişmekte olup, Shen vd. (2025) tarafından yürütülmüş güncel bir epidemiyolojik çalışmada, pediyatrik popülasyondaki prevalans %6,8 olarak bildirilmiştir. Yetişkin popülasyonda, kadınlarda 1,37 kat daha yaygındır (Al-Ani vd. 2017).

Diş agenezisinin dişlerin ektopik sürmesi, periodontal hasar ve alveolar kemiğin erken kaybı gibi etkilerin yanı sıra yüz gelişimini, konuşmayı, psikososyal durumu da etkileyerek hastaların yaşamlarını önemli ölçüde olumsuz etkiler. Dental agenezi erken teşhis edilmezse süt dişleri geç düşer ve yerinde boşluk oluşur. Bu boşluk, komşu dişlerin boşluğa kaymasına ve çene kemiğinde hacim kaybına ve dental dizilim bozukluklarının gelişmesine yol açar (Meade ve Dreyer 2023). Kalıcı diş germi, süt dişi döküldükten sonra gelecek olan kalıcı dişin tohumudur ve çoğu diş germinin varlığı ancak çocukluk döneminde kanıtlanabilir olduğu için özellikle erken yaş kalıcı diş germi eksikliği kesin dental agenezi varlığına işaret değildir. Ancak, bir dişin var olması, biyolojik olarak bu germin varlığına ve sağlıklı gelişmesine bağlı olduğu gerçeğiyle potansiyel dental

agenezinin erken teşhisi için germ eksikliğinin tespit edilerek takip edilmesi kritik öneme sahiptir (De Aguiar vd. 2025).

Klinik muayene sırasında pediatrik hastada süt dişlerinin zamanında düşmemesi veya belirli yaşta sürmesi beklenen kalıcı dişlerin hala görülmediği durumlarda diş hekimi şüphelenerek radyolojik görüntüleme yöntemlerine başvurur ve diş germine dair görüntüleme yapılır; böylece teşhis konulur. Tedavi planlamasında pedodonti ortodonti çene cerrahisi gibi branşların iş birliği gereklidir.



Şekil 2.2 Panoramik radyografide kalıcı diş germi eksikliği örneği

### 2.1.3 Derin öğrenme ve mimarileri

Makine öğrenmesinin bir alt alanı olan derin öğrenme, yüksek boyutlu verileri içeren karmaşık problemleri modellemek ve çözmek için yapay sinir ağlarının kullanımı etrafında döner. Özellikle, çoklu soyutlama katmanları aracılığıyla veri temsillerini öğrenme ve böylece otomatik özellik çıkarımına olanak tanıma yeteneğiyle bilinir. Derin öğrenmenin başlangıcı, sinir ağları üzerine yapılan ilk çalışmalarla 1950'lere dayanır, ancak hızlı gelişimi, büyük veri setlerinin, hesaplama gücünün ve gelişmiş algoritmaların kullanılabilirliğiyle 2000'lerde gerçekleşmiştir (Hinton vd. 2006). Derin öğrenme modellerinin, özellikle de CNN'lerin başarısı, bilgisayarlı görü, konuşma tanıma ve doğal dil işleme gibi çeşitli alanları önemli ölçüde geliştirmiştir.

CNN'ler, görsel verilerdeki örüntüleri tanımak için tasarlanmış bir derin öğrenme mimarisi sınıfıdır. Gelişimleri, nöronların özelliklerin uzamsal hiyerarşilerini tespit edecek şekilde düzenlendiği insan görsel sisteminden ilham almıştır. LeCun vd. (1989), 1980'lerde LeNet mimarisinin geliştirilmesiyle başlattığı temel çalışma, CNN'lerin rakam tanıma gibi görevlerdeki ilk başarısını işaret etmiştir. Ancak CNN'ler, ImageNet yarışmasında (Krizhevsky vd. 2012) dikkate değer sonuçlar elde eden AlexNet'in tanıtımıyla 2012 yılında yaygın bir tanınırlık kazanmıştır. O zamandan beri, VGG (Simonyan ve Zisserman 2015), ResNet (He vd. 2016) ve Inception (Szegedy vd. 2015) dahil olmak üzere çeşitli CNN mimarileri önerilmiş ve her biri kaybolan gradyanlar, hesaplama verimliliği ve model doğruluğu gibi farklı zorlukları ele almak için derinliği, bağlantıları ve yapıyı geliştirmiştir. Bu gelişmeler, CNN'leri birçok bilgisayarlı görme uygulamasının temel taşı haline getirmiştir.

İlk olarak Vaswani vd. (2017) tarafından doğal dil işleme görevleri için tanıtılan transformatörler, derin öğrenme alanında bir paradigma değişimini temsil etmektedir. CNN'lerin aksine, transformatörler evrimsel katmanlara dayanmaz, bunun yerine tüm girdi dizisi boyunca bağımlılıkları yakalamak için öz-dikkat (self-attention) mekanizmaları kullanır. Bu öz-dikkat, transformatörlerin girdinin uzak bölümleri arasındaki ilişkileri modellemesine olanak tanır ve bu da onları dizi tabanlı görevler için oldukça etkili hale getirir. Transformatör mimarisi o zamandan beri bilgisayarlı görme görevlerine uyarlanmış ve uzun menzilli bağımlılıkları verimli bir şekilde yakalayamama gibi CNN'lerin doğasında bulunan sınırlamaları ele almada umut vadeden bir mimari olmuştur. ViT, görüntülerin yama dizileri olarak ele alındığı ve küresel bağlamı öğrenmek için öz-dikkat mekanizmalarının uygulandığı ilk büyük uyarlamalardan birini temsil eder ve bu da görüntü sınıflandırma görevlerinde en son teknoloji performansına yol açar.

ViT, görüntü tanıma görevlerine yeni bir yaklaşım olarak Dosovitskiy vd. (2020) tarafından tanıtılmıştır. Pikselleri veya yerel yamaları girdi olarak ele alan geleneksel CNN'lerin aksine, ViT bir görüntüyü sabit boyutlu, örtüşmeyen yamalara böler ve bu yamaları metindeki kelimelere benzer bir dizi olarak ele alır. Dönüştürücülerin öz-dikkat mekanizmasını uygulayarak, ViT büyük veri setlerinde üstün performans göstermiş ve

kıyaslama görevlerinde CNN tabanlı modelleri geride bırakmıştır. ViT'nin başarısı, verimliliği artırmak için yama yerleştirme ve hiyerarşik öğrenme gibi tekniklerin dahil edilmesiyle daha da geliştirilmesine ve benimsenmesine yol açmıştır. ViT, dizi tabanlı verilerin ötesinde potansiyellerini sergileyerek, transformatör mimarilerinin çeşitli bilgisayarlı görme uygulamalarına uygulanmasına yönelik daha geniş bir ilgi uyandırmıştır.

Hassani vd. (2021) tarafından önerilen CCT mimarisi, derin öğrenme alanında hem performans hem de verimlilik açısından önemli yenilikler sunan bir yaklaşımdır. CCT, CNN ve transformatör mimarilerinin güçlü yönlerini birleştirmeyi amaçlayan umut verici yeni bir mimariyi temsil etmektedir. CCT, yerel özellik çıkarımı için evrimsel katmanlar ve küresel bağlam modellemesi için transformatörler kullanarak hem hesaplama verimliliği hem de gelişmiş performans sunmayı amaçlamaktadır. Bu hibrit yaklaşım, giriş verilerindeki uzun menzilli bağımlılıkları yakalarken uzamsal hiyerarşilerin daha etkili bir şekilde öğrenilmesini sağlar. Halen aktif geliştirme aşamasında olmasına rağmen, CCT, geleneksel CNN'lerin ve transformatörlerin tek başlarına sınırlılıklara sahip olabileceği görüntü sınıflandırma gibi görevlerde potansiyel göstermiştir. Sonuç olarak, CCT, özellikle bilgisayarlı görme ve tıbbi görüntüleme uygulamalarında derin öğrenme alanını daha da ileriye taşıyabilecek yenilikçi bir mimari olarak dikkat çekmektedir.

## **2.2 Kaynak Özetleri**

### **2.2.1 Süpernümere dişlerin tespiti ve derin öğrenme**

Al Kheraif vd. (2019), içinde süpernümere dişlerin de bulunduğu farklı dental hastalıkların tespiti için görüntü işleme, makine öğrenmesi ve derin öğrenme algoritmalarını hibrit şekilde kullanmıştır. Adaptif histogram eşitleme yöntemiyle panoramik radyografilerin (1.500 görüntü) kalitesi iyileştirilmiş ve gürültü azaltılmıştır. İyileştirilmiş görüntülere 11 farklı görüntü işleme algoritması (Bölge büyütme, Bölme ve birleştirme, Niblack yaklaşımı, Canny yöntemi gibi) ile segmentasyon uygulanmıştır.

Daha sonra segmente görüntüler Çok Katmanlı Algılayıcı (Multilayer Perceptron, MLP), Geri Yayılım Sinir Ağı (Backpropagation Neural Network, BPNN), İlişkilendirme Belleği Sinir Ağı (Associative Memory Neural Network, AMNN), Radyal Temel Sinir Ağı (Radial Basis Neural Network, RBNN) ve CNN kullanılarak sınıflandırılmıştır. En yüksek performans %97,07 doğruluk (accuracy, ACC) ile Hibrit graf kesim (Hybrid graph cut) segmentasyonu ve CNN birleşiminden elde edilmiştir.

Kuwada vd. (2020), 550 panoramik radyografi kullanarak maksiller kesici bölgede gömülü süpernümere dişlerin varlığını sınıflandırmak için AlexNet, VGG-16, ve DetectNet modellerini kullanmıştır. VGG16, DetectNet ve AlexNet ile karşılaştırıldığında önemli ölçüde daha düşük değerler vermiştir. DetectNet'in performans değerlendirilmesi için geri çağırma (recall, REC), kesinlik (precision, PREC) ve F1 skorun tamamının %100 olduğu bildirilmiştir.

Ahn vd. (2021) tarafından yürütülmüş bir çalışmada, 1.100 panoramik radyografi görüntüsü mesiodens ve mesiodens olmayan kategorilerine transfer öğrenme ve ön eğitilmiş CNN'ler kullanılarak sınıflandırılmıştır. Yazarlar ön eğitilmiş modeller olarak SqueezeNet, ResNet18, ResNet101 ve InceptionResNetV2 ağlarını seçmiş ve 5-kat çapraz doğrulama ile eğitmiştir. Bu çalışmada genel diş hekimleri ve pediatrik diş hekimlerinden oluşan insan denetçi grubunun ve derin öğrenme modellerinin 100 adet görüntü içeren test veri seti üzerindeki performansları kıyaslanmıştır. Genel diş hekimleri %95, pediatrik diş hekimleri %99, InceptionResNetV2 ağı ise %88 ACC performansı sergilemiştir. İnsan denetçi grubunun sınıflandırma performansı oldukça yüksek olsa da derin öğrenme modelleri test süresini 811,8 saniyeden (birim: s) 1,5 s'ye indirmiştir.

Ha vd. (2021), 612 hastanın panoramik radyografisi üzerinde mesiodensleri tespit etmek için YOLOv3'e (You Only Look Once) dayalı bir CNN modeli geliştirmiştir. Üç dişlenme grubuna (süt, karışık ve kalıcı dişlenme) göre model performansı hem dahili (130 görüntü) hem de harici (118 görüntü) test verilerine göre değerlendirilmiştir. Orijinal görüntülerde dahili test veri setinin doğruluğu %96,20 ve harici test veri setinin doğruluğu %89,80 olarak bildirilmiştir. Çalışmada, görüntü ön işleminin etkisini araştırmak için

orijinal görüntülere kontrastla sınırlı histogram eşitleme (Contrast-limited Histogram Equalization, CLAHE) uygulanmıştır ve model performansı üzerinde ihmal edilebilir bir etkisi olduğu tespit edilmiştir.

Mine vd. (2022) tarafından yürütülmüş bir çalışmada, süpernümere dişler (100 tek süpernümere diş ve 20 çift süpernümere diş) ve anormallik olmayan (n = 100) dahil olmak üzere toplam 220 pediatrik panoramik radyografinin sınıflandırılması için AlexNet, VGG16 ve InceptionV3 kullanılmıştır. VGG16 ağı tek süpernümere dişlerde %84 ACC, tek ve çift süpernümere dişlerde %82 ACC ile en yüksek performansı sergilemiştir.

Okazaki vd. (2022), tek süpernümere diş ve/veya odontomalı ile diş anomalisi olmayan panoramik radyografilerden oluşan 150 örnekle veri setini sınıflandırmak için AlexNet ağını kullanmıştır. Yazarlar, Veri seti 1: odontomalı ve diş anomalisi olmayan, Veri seti 2: tek süpernümere diş veya odontomalı ve diş anomalisi olmayan; Veri seti 3: tek süpernümere diş ve odontomalı ve diş anomalisi olmayan, olmak üzere 3 farklı veri seti oluşturmuştur. AlexNet, Veri seti 1, 2 ve 3 için sırasıyla %77,80, %87,50 ve %70 ACC performansı göstermiştir.

Ragodos vd. (2022) tarafından süpernümere diş dahil 10 farklı dental anomali sınıfı içeren 38.486 ağız içi fotoğrafının sınıflandırılması için transfer öğrenme önerilmiştir. Ön eğitilmiş ResNet18 modeli süpernümere diş sınıfını %57,10 alıcı işletim karakteristiği altında kalan alan (ROC-AUC) ile ayırt etmiştir. Üç anomali dışında tüm anomaliler için, F1 skorları, derin öğrenme modelinin 8 yıllık klinik deneyime sahip bir diş hekimiyle karşılaştırıldığında anomali tespitinde rekabetçi bir performans gösterdiği bildirilmiştir.

Lee vd. (2022) tarafından yürütülen bir çalışmada süpernümere diş dahil 17 farklı sınıftan oluşan dental anomali ve hastalıkların sınıflandırılması için Faster R-CNN önerilmiştir. Çalışma için 23.000 panoramik radyografiden oluşan dev bir veri seti kullanılmıştır. Süpernümere sınıfının duyarlılık (sensitivity, SEN) değeri %62,96 olarak bildirilmiştir.

Jeon vd. (2022), 3-13 yaş aralığında 600 pediatrik hastanın periapikal radyografileri üzerinde YOLOv3, RetinaNet ve EfficientDet-D3 algoritmalarını kullanarak gömülü mesiodenleri otomatik olarak saptamıştır. Her bir modelin performansı, 120 test görüntüsü (mesiodensli 60 periapikal radyograf ve mesiodenssiz 60 periapikal radyograf) kullanılarak ACC, SEN ve PREC metriklerine dayalı olarak değerlendirilmiştir. YOLOv3, RetinaNet'in ve EfficientDet-D3 modelleri için sırasıyla %97,50, %98,30 ve %99,20 ACC değerleri elde edilmiştir.

J. Kim vd. (2022), 988 panoramik radyografiden oluşan veri setini mesiodens ve mesiodens olmayan kategorilerine ayırmak için iki ağdan oluşan bir model önermiştir. Modelin ilk ağını oluşturan DeeplabV3+ maksiller ön bölgedeki ilgi bölgesini (Region of Interest, ROI) ayarlamak için posterior molar boşluğu kullanan bir model olarak segmentasyon görevini üstlenir. İkinci ağ olan InceptionResNetV2 ise mesiodenslerin varlığını belirlemek için kırılmış maksiller ön dişleri kullanarak sınıflandırma görevini üstlenir. InceptionResNetV2 ağı manuel segmente edilmiş görüntüleri %89,20 ACC ile sınıflandırırken DeeplabV3+ ağı ile segmente edilmiş görüntüleri %97,10 ACC ile sınıflandırmıştır.

Dai vd. (2023), bir çalışmada panoramik görüntülerdeki mesiodensleri bir aşamada lokalize etmek için tam otomatik, derin öğrenmeye dayalı bir yaklaşım önermiştir ve mesiodens tespitini yalnızca bir tanımlama görevi yerine bir regresyon problemi olarak ele almıştır. Önerilen model YOLOv5'e benzer şekilde omurga ağı, boyun ağı ve algılama kafası olmak üzere üç bölümden oluşmaktadır. YOLOv5'ten farklı olarak omurga ağında maliyeti düşüren hayalet darboğazlar (ghost bottlenecks) ve Sıkıştır-ve-Uyarma katmanları (Squeeze-and-Excitation layer) kullanılmıştır. Yazarların DMLnet ismini verdikleri bu yaklaşımla %94 ACC elde edilmiştir.

Chen vd. (2024), süpernümere dişlerin oklüzal radyografilerde tespit edilmesi için CNN tabanlı bir akıllı tıbbi yardımcı sistem önermiştir. Süpernümere dişlerin tanısal zorlukları göz önüne alınarak, modelde özellik artırma teknikleri ve renk eşleme yöntemi kullanılmıştır. Çalışmada, süpernümere dişlerin tespiti için temel CNN modeli ile

geliştirilmiş versiyon karşılaştırılmış ve renk eşleme yönteminin ACC oranını %63,16'dan %76,32'ye çıkardığı rapor edilmiştir. Modelin PREC oranı %78,95 olarak belirlenmiş ve bu oran, önceki yöntemlere kıyasla %18,43'lük bir iyileşme göstermiştir. Yapay zeka modelinin, süpernümere dişleri doğru şekilde tanımlamakta başarılı olduğu ancak klinik kullanımı için daha fazla veri ile doğrulanması gerektiği belirtilmiştir.

H. Kim vd. (2024), çalışmalarında çocuk hastalara ait panoramik radyografilerde gömülü mesiodenslerin segmentasyonu ve sınıflandırılması için derin öğrenme tabanlı bir yaklaşım önermiştir. Çalışmada, 3-9 yaş arası çocuklara ait 850 panoramik radyografi kullanılmış olup, bu görüntülerden 750'si model eğitimi için, 100'ü ise test verisi olarak ayrılmıştır. Görüntülerin işlenmesi aşamasında, ön işleme olarak ROI belirlenmiş ve bu bölge, uzman bir diş hekimi tarafından kesilerek modelin daha verimli öğrenmesi sağlanmıştır. Derin öğrenme modeli olarak, U-Net tabanlı bir semantik segmentasyon yöntemi uygulanmış ve modelin omurga katmanında önceden eğitilmiş ResNet ağı kullanılmıştır. Modelin segmentasyon başarımı Jaccard ve Dice benzerlik katsayıları (Jaccard and Dice Similarity Coefficient, JSC and DSC) ile değerlendirilmiş olup, her iki metrikte de %90'ın üzerinde bir başarı sağlandığı rapor edilmiştir. Ayrıca, modelin mesiodens tanısındaki ACC oranı %91-92 arasında değişirken, F1 skoru %94-95 olarak hesaplanmıştır. Yapay zeka modelinin tanı süresi yalnızca 7,5 s olarak belirlenmiş olup, bu sürenin insan uzmanların tanı koyma süresinden anlamlı derecede daha düşük olduğu tespit edilmiştir. Model ve uzmanlar arasındaki uyum, Cohen'in Kappa istatistiği ile değerlendirilmiş ve orta düzeyde bir uyum ( $\kappa=0,767$ ) tespit edilmiştir. Sonuç olarak, önerilen derin öğrenme modeli, mesiodens segmentasyonunda yüksek bir doğruluk sağlamış ve insan uzmanlarla benzer tanısal performans sergilerken, belirgin şekilde daha hızlı sonuç üretmiştir.

Hayashi-Sakai vd. (2024), çalışmalarında panoramik radyografiler üzerinde mesiodens tespiti için dört farklı derin öğrenme modelini karşılaştırmıştır. Çalışmada, toplam 628 panoramik radyografi kullanılmış olup, bu görüntüler eğitim, doğrulama ve test setlerine ayrılmıştır. Eğitim setinde 218 mesiodens içeren ve 203 normal görüntü kullanılmışken, doğrulama setinde 51 mesiodensli ve 55 normal görüntü, test setinde ise 40 mesiodensli ve 61 normal görüntü yer almıştır. Çalışmada, binary connect mnist\_LeNet adlı hafif bir

CNN modeli en iyi performansı göstermiştir. Model ACC, PREC, REC ve F1 skoru gibi metriklerle değerlendirilmiş olup, en yüksek ACC oranı %97, REC oranı %99 olarak tespit edilmiştir. Model performansını görselleştirmek için SHapley Additive exPlanations (SHAP) (Lundberg ve Lee 2017) yöntemi kullanılmış ve modelin sınıflandırmada hangi özellikleri dikkate aldığı açıklanmıştır. Çalışmada ayrıca, radyografileri değerlendiren uzman diş hekimleri ile yapay zeka modellerinin performansı kıyaslanmış ve yapay zekanın, özellikle düşük kaliteli görüntülerde uzmanlardan daha iyi sonuçlar ürettiği rapor edilmiştir. Sonuç olarak, önerilen yapay zeka modelinin, mesiodens tespitinde ek radyografik inceleme ihtiyacını azaltabileceği ve tanısal süreci destekleyebileceği vurgulanmıştır

Korkmaz vd. (2025), panoramik radyografilerde distomolar dişlerin tespiti için farklı yapay zeka modellerini karşılaştırmıştır. Çalışmada, 117'si distomolar içeren ve 146'sı içermeyen toplam 263 panoramik radyografi kullanılmıştır. Verinin sınırlı olması nedeniyle transfer öğrenme yöntemi kullanılmış ve 5-kat çapraz doğrulama ile modelin genelleme yeteneği artırılmıştır. AlexNet, DarkNet, DenseNet, EfficientNet, GoogLeNet, ResNet, MobileNet, NasNet-Mobile, VGG ve Xception modelleri karşılaştırılmış ve en iyi ACC oranı %96,20 ile DarkNet, DenseNet ve ResNet modellerinin birleştirilmesi sonucu elde edilmiştir. Modelin klinik kullanıma uygun olduğu belirtilmiş ancak açıklanabilirlik konusunda ek çalışmalar gerektiği vurgulanmıştır.

Zheng vd. (2025), periapikal radyografilerde süpernümere dişlerin otomatik tespiti için Faster R-CNN ve YOLOv8 modellerini karşılaştırmıştır. 469 radyografiden oluşan bir veri seti kullanılmış olup, 419 görüntü eğitim için, 50 görüntü ise test için ayrılmıştır. Model performansları PREC, REC ve birleşim üzerindeki kesişim (Intersection Over Union, IoU) metrikleri ile değerlendirilmiştir. YOLOv8 modeli %99 PREC ve %97 ortalama ACC oranı ile Faster R-CNN modelinden anlamlı şekilde daha iyi performans göstermiştir. Yapay zeka modelleri, sekiz diş hekimi ile kıyaslanmış ve her iki modelin de insan uzmanları geçtiği rapor edilmiştir. Özellikle YOLOv8 modeli, yüksek doğruluğu ve hız avantajı ile periapikal radyografi analizinde umut verici bir aday olarak değerlendirilmiştir.

### **2.2.2 Kalıcı diř germlerinin tespiti ve derin öğrenme**

Kaya vd. (2022), 5-13 yař aralıęındaki pediatrik hastaların panoramik radyografileri üzerinde kalıcı diř germlerini tespit etmek için YOLOv4 kullanmıřtır. 50.096 kalıcı diř germi içeren 4518 görüntünün %10'u test verisi olarak kullanılmıř %94,16 ortalama kesinlik (average precision, AP) elde edilmiřtir.

### **2.2.3 Dental agenezi tespiti ve derin öğrenme**

E. Kim vd. (2024), pediatrik hastalara ait panoramik radyografiler üzerinde eksik diřlerin tespiti için derin öğrenme tabanlı bir model geliřtirmiřtir. Çalıřmada, 8-16 yař arası 806 hastaya ait panoramik radyografiler dört bölgeye ayrılarak 3.224 veri noktası oluřturulmuř, veri seti %80 eğitim ve %20 test olarak ayrılmıřtır. Modelin performansı %73,80 doęruluk oranı ile deęerlendirilmiř ve özellikle kanin ve premolar diřlerin eksiklięinin tespitinde daha bařarılı olduęu gözlemlenmiřtir. Görselleřtirme amacıyla Grad-CAM yöntemi kullanılarak modelin dikkate aldıęı bölgeler analiz edilmiřtir. Ancak, molar diřlerde tespit oranının daha düşük olduęu ve modelin klinik kullanımı için daha fazla doęrulama çalıřmasına ihtiyaç duyduęu belirtilmiřtir.

Kadi vd. (2024), nadir genetik hastalıklara baęlı olarak geliřen diř eksikliklerini tespit etmek amacıyla i-Dent adlı derin öğrenme tabanlı bir sanal asistan geliřtirmiřtir. Çalıřmada, panoramik radyografilerde eksik diřlerin tespit edilmesi için Mask R-CNN ve U-Net modelleri kullanılmıř, diř yařı tahmini yapılarak genetik faktörlerle iliřkilendirilmiřtir. Model, PAX9, WNT10A ve EDA genleri ile iliřkili diř eksikliklerini %72 ACC oranıyla tespit edebilmiřtir. Açıklanabilirlik açasından modelin karar mekanizmasını destekleyecek yöntemlerin geliřtirilmesi gerektięi belirtilmiř ve klinik kullanım için daha geniř veri setleriyle doęrulama yapılmasının önemi vurgulanmıřtır.

Uyar ve Uyar (2025), hipodonti teřhisi için transfer öğrenme yöntemiyle eğitilmiř çeřitli CNN modellerini ve makine öğrenimi sınıflandırıcılarını karřılařtırmıřtır. Çalıřmada, 6-

12 yaş arası 1.068 pediatrik hastaya ait panoramik radyografiler kullanılmıştır. Veriler, tek premolar agenezi, çoklu premolar agenezi ve sağlıklı olmak üzere üç sınıfa ayrılmıştır. VGG19 modeli ve çift katmanlı sinir ağı kombinasyonu en yüksek ACC değerini sağlamış (%95,63), modelin özellikle hipodonti tanısında etkili olduğu belirtilmiştir. Açıklanabilirlik metodolojisi kullanılmamış olsa da model çıktılarının uzman diş hekimleri tarafından yorumlanabilir olduğu ifade edilmiştir.

#### **2.2.4 Diğer diş anomalilerinin tespiti ve derin öğrenme**

Liu vd. (2022) tarafından yürütülen bir çalışmada, üst birinci azı dişlerinin ektojik sürmesinin tespiti için yaşları 4-9 arasında değişen 1.480 hastanın panoramik röntgen görüntüleri CNN tabanlı füzyon modeli ile %90 SEN değeri ile sınıflandırılmıştır.

Zhu vd. (2022), 438 üst birinci azı dişlerinin ektojik sürmesini içeren 285 panoramik radyografi için no-new-Net (nnU-Net) modeli ile segmentasyon sonucu %83,40 IoU ve %99 ACC elde etmiştir.

Celik (2022) tarafından yürütülen bir çalışmada, gömülü alt üçüncü azı dişleri tespiti için 300 hastanın 440 panoramik radyografisi üzerinde ResNet50, AlexNet ve VGG16'yı omurga olarak kullanan Faster R-CNN ve YOLOv3 kullanılmıştır. YOLOv3 %93 REC ve %88 PREC ile yüksek performans göstermiştir.

Ariji vd. (2022), mandibular kanalın gömülü üçüncü molar dişe yakınlığını panoramik radyografilerde görselleştirmek için segmentasyon ve transfer öğrenme yöntemlerini kullanarak bir derin öğrenme modeli önermiştir. Alt çene kanalını ve gömülü üçüncü azı dişini içeren panoramik radyografiler iki ayrı hastaneden toplanmıştır. Birinci hastaneden alınan veriler kullanılarak bir kaynak model oluşturulmuş, simülatif olarak ikinci hastaneye aktarılmış ve hedef modeller oluşturmak için ikinci hastaneden çeşitli miktarlarda veriler kullanılarak eğitilmiştir. Çalışma sonucunda U-Net modeli ile %83,10 DSC elde edilmiştir.

Duman vd. (2023), 434 panoramik radyografiden oluşan bir veri seti üzerinde taurodont dişlerin tespiti için U-Net modeli kullanmış ve %86,50 PREC sonucu bildirmiştir.

Yu vd. (2025), karma dişlenme döneminde ektopik diş sürmelerinin otomatik teşhisi için çok aşamalı bir derin öğrenme modeli geliştirmiştir. Çalışmada, 6-12 yaş arası 1.576 çocuğa ait panoramik radyografiler kullanılmış ve veriler %80 eğitim, %10 doğrulama ve %10 test olarak bölünmüştür. Model, diş segmentasyonu ve gelişim evrelerinin otomatik sınıflandırılması aşamalarını içermektedir. Segmentasyon başarımı IoU, PREC ve F1 skoru açısından değerlendirildiğinde sırasıyla %95,90, %96,60 ve %97,90 oranlarında yüksek performans göstermiştir. Yapay zeka modelinin ektopik diş sürmelerini teşhis etme başarımı, üç uzman diş hekiminin değerlendirmeleri ile karşılaştırılmış ve McNemar testi ile analiz edilmiştir. Sonuçlara göre model, bir uzman diş hekiminden anlamlı derecede daha iyi performans gösterirken ( $p < 0,05$ ), diğer iki uzmanla arasında istatistiksel olarak anlamlı bir fark bulunmamıştır. Bu bulgular, yapay zeka destekli sistemlerin pedodonti alanında erken teşhis süreçlerini destekleyebileceğini ve klinik kararları hızlandırabileceğini göstermektedir.

### **2.2.5 Literatür boşlukları ve tezin bilimsel katkıları**

Derin öğrenme tabanlı diş tanılamada kaydedilen önemli ilerlemeye rağmen, mevcut literatürde bazı sınırlamalar hala belirgindir. Mevcut çalışmaların çoğu ikili sınıflandırma görevlerine (örneğin, süpernumere dişlerin veya hipodontinin varlığı veya yokluğu) odaklanmakta ve genellikle önceden eğitilmiş CNN mimarilerine dayanmaktadır. Dahası, bazı modeller ümit verici performans gösterse de çoğu açıklanabilir yapay zeka gibi klinik yorumlanabilirlik yöntemlerini içermemekte ve uzman teşhisine kıyasla performansı istatistiksel olarak titizlikle değerlendirmemektedir. Daha da önemlisi, bugüne kadar, özellikle süt ve daimi dişlerin bir arada bulunması ve daha fazla anatomik değişkenlik nedeniyle ek zorluklar sunan pediatrik panoramik radyografilerde, germ eksikliğinin otomatik olarak ayrı bir tanı kategorisi olarak tespitini ele alan bildirilmiş bir çalışma bulunmamaktadır.

Bu çalışma, özellikle panoramik radyografilerde süpernümere dişlerin ve germ eksikliğinin otomatik tespiti için geliştirilen, CIT adı verilen derin öğrenme mimarisine dayalı yeni bir bilgisayar destekli tanı sistemini tanıtmaktadır. Önerilen çerçeve, yüksek tanısal performans sağlamayı, zaman ve klinik iş yükünü azaltmayı, erken teşhisi desteklemeyi ve diş teşhisinde nesnelliği artırmayı amaçlamaktadır. Bu kompakt tasarım hem yerel hem de bağlamsal diş yapılarını daha etkili bir şekilde yakalayıp geleneksel evrişimli veya yalnızca transformatörlü modellere göre önemli bir gelişme sunmaktadır. Bu çalışma, önceki çalışmaların kapsamının ötesine geçerek alandaki ilk otomatik germ eksikliği tespiti çalışmasıdır. Model, tanısal karmaşıklığın doğası gereği daha yüksek olduğu pediatrik panoramik radyografilerde geliştirilmiş ve doğrulanmıştır; bu da modelin sağlamlığını ve klinik önemini daha da vurgulamaktadır. Dahası, bu çalışma, sınıflandırma sırasında modelin odak alanlarının görselleştirilmesine olanak sağlayarak, açıklanabilir yapay zeka tekniklerinin uygulanmasıyla şeffaflığı ve klinik güveni artırmaktadır. CIT modelinin tanısal performansı, McNemar testi kullanılarak uzman diş hekimlerinin performansı ile istatistiksel olarak karşılaştırılmış ve sistemin pratik faydası ve rekabetçi doğruluğu vurgulanmıştır. Anomaliye özgü sınıflandırma, pediatrik uygulanabilirlik, yorumlanabilirlik ve istatistiksel doğrulama alanlarındaki kritik boşlukları doldurarak, bu çalışma yapay zeka destekli diş teşhisinin ilerlemesine önemli bir katkı sağlamaktadır.

Tezin bilimsel katkıları aşağıdaki gibi sıralanabilir:

- Bir pedodontist tarafından derlenip ek açıklamalarla desteklenen, diş anomalisi tespit araştırmaları için yüksek kaliteli bir kaynak sağlayan yeni bir pediatrik panoramik radyografi veri setinin tanıtımı.
- Tıbbi görüntü analizi için transformatör tabanlı bir modelde involüsyonun bilinen ilk uygulamasını temsil eden, adaptif involüsyon özelliklerini entegre eden yeni bir kompakt transformatör mimarisinin geliştirilmesi.
- Diş radyolojisi alanında önemli ancak daha önce keşfedilmemiş bir anomaliyi ele alan, germ eksikliğini tespit etmek için ilk yapay zeka tabanlı teşhis çerçevesi.

- Transfer öğrenme modellerine yeni bir alternatif sunan ve pediatrik diş görüntülemesinin benzersiz zorluklarına göre uyarlanmış, süpernümere diş tespiti için göreve özgü bir mimari.
- Model çıktılarını yorumlamak ve yorumlanabilirlik araçlarının diş görüntüleme arařtırmalarındaki sınırlı kullanımını ele almak için açıklanabilir yapay zeka tekniklerinin dahil edilmesi.
- Modelin performansını uzman diş hekimleriyle titizlikle karşılařtırmak için gelişmiş istatistiksel testlerin kullanılması ve klinik uygulanabilirlik için ampirik destek sağlanması.
- Önerilen mimarinin panoramik radyografik analizde mevcut SOTA yöntemlerine göre üstün performansının deneysel olarak gösterilmesi ve gerçek dünyada uygulanma potansiyelinin vurgulanması.

### 3. MATERYAL VE YÖNTEMLER

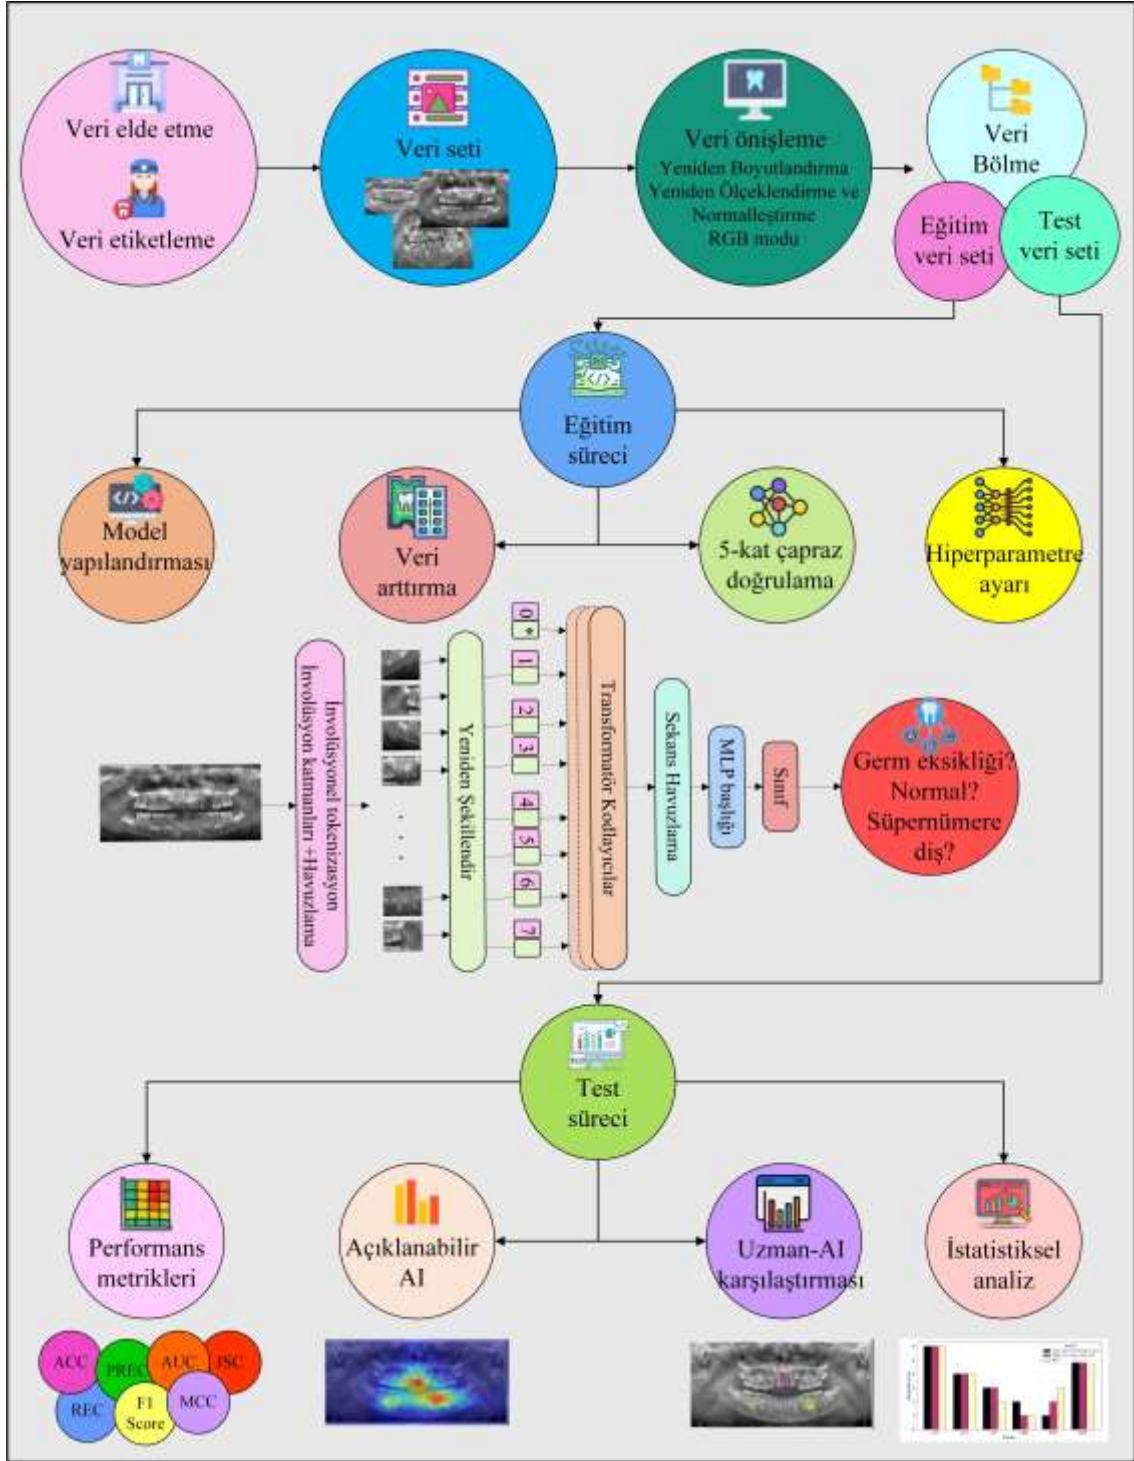
#### 3.1 Genel Bakış

Tez çalışması için önerilen yöntemin genel iş akışı Şekil 3.1’de sergilenmiştir. Metodoloji veri toplama, ön işleme, model eğitimi ve performans değerlendirmesi dahil olmak üzere birkaç temel aşamadan oluşmaktadır. Başlangıçta, etik kurulu ve izin belgeleri tamamlanmış, iş birliği yapan kurumlardan pediatrik panoramik radyografiler toplanmış ve her görüntü için germ eksikliği ve süpernümere diş gibi diş anomalilerinin varlığına göre etiketlenmek üzere uzman rehberliğinde açıklamalar yapılmıştır. Düzenlenen veri seti daha sonra görüntülerin RGB formatında yeniden boyutlandırılması, yeniden ölçeklendirilmesi ve normalleştirilmesiyle ön işleme tabi tutulmuştur. Ardından, veriler eğitim ve test alt setlerine ayrılmış ve doğrulama sağlayarak önyargıyı en aza indirmek için 5-kat çapraz doğrulama uygulanmıştır.

Eğitim aşamasında, panoramik görüntülerden uzamsal olarak uyarlanabilir yerel özellikleri çıkarmak için involüsyon tabanlı bir tokenizer kullanılmıştır. Bu involüsyonel özellikler, sekans dizilerine yeniden şekillendirilerek kodlayıcı katmanları (transformer encoders), sekans havuzlama (sequence pooling) ve MLP başlığından (MLP head) oluşan hafif bir transformatör mimarisine aktarılmıştır. Öğrenme sürecini optimize etmek için veri artırma (data augmentation) teknikleri ve hiperparametre ayarlaması uygulanmıştır. Model, germ eksikliği, normal veya süpernümere diş durumlarını tespit ederek hem ikili hem de çok sınıflı sınıflandırma görevlerini gerçekleştirecek şekilde yapılandırılmıştır.

Test aşamasında, eğitilen model, bir test seti kullanılarak değerlendirilmiştir. Sınıflandırma performansı, ACC, PREC, REC, F1 skoru, Matthews korelasyon katsayısı (Matthews Correlation Coefficient. MCC), Alıcı işletim karakteristiği (Receiver Operating Characteristic, ROC), AUC ve JSC dahil olmak üzere çeşitli standart metrikler kullanılarak ölçülmüştür. Ayrıca, belirginlik temelli görselleştirme teknikleri aracılığıyla açıklanabilirlik sağlanmış ve bu da model tahminlerinin klinik olarak yorumlanabilir olmasını sağlamıştır. Model çıktıları ile klinik yargılar arasındaki uyumu değerlendirmek

için uzman-yapay zeka karşılaştırmalı testleri gerçekleştirilmiştir. Son olarak, sonuçların istatistiksel anlamlılığı, uygun istatistiksel analizler yoluyla belirlenerek modelin tanısal güvenilirliği doğrulanmıştır.



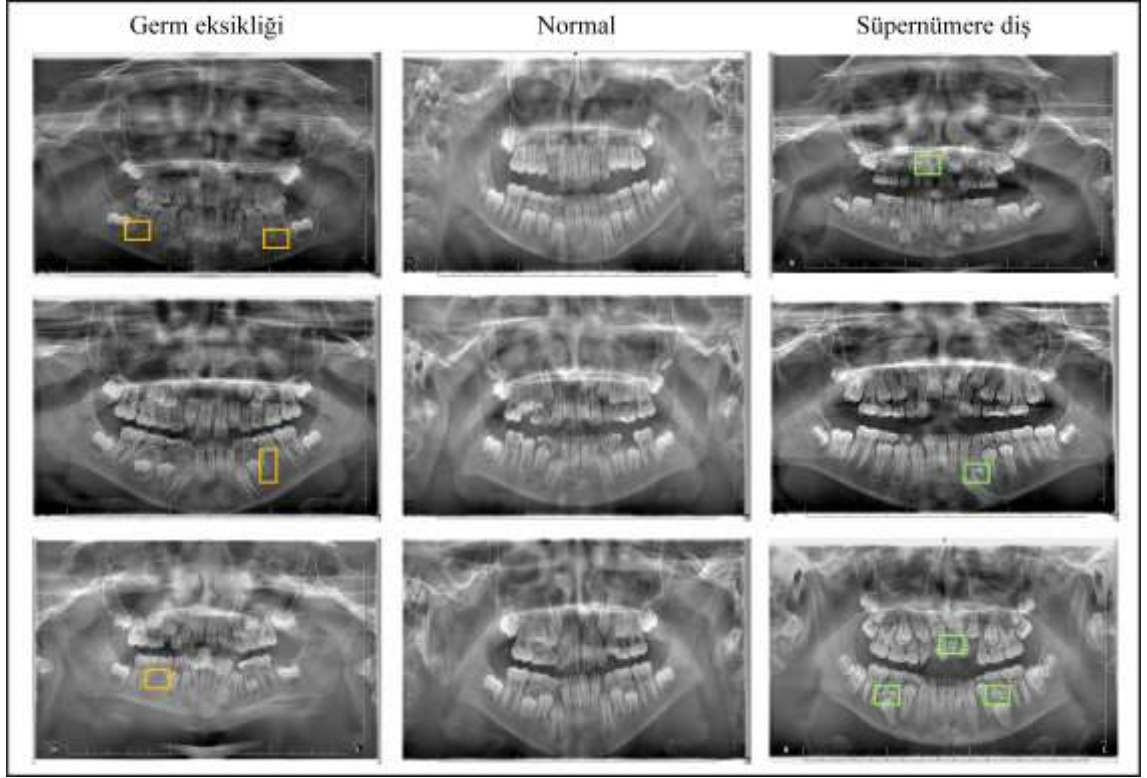
Şekil 3.1 Tez çalışması için önerilen yöntemin genel iş akışı

### 3.2 Veri Seti

Bu tez çalışmasının gerçekleştirilebilmesi için Ankara Üniversitesi Rektörlüğü Sağlık Bilimleri Alt Etik Kurulu Başkanlığından 20.06.2023 tarihli 11/91 sayılı etik açıdan uygundur kararı alınmıştır. Etik kurul kararı alındıktan hemen sonra görüntü elde etme ve etiketleme aşaması başlamış, bir seneyi aşkın bir süre sonunda nihai veri seti oluşturulmuştur.

Tez çalışmasında kullanılan panoramik diş radyografileri, Başkent Üniversitesi Ankara Hastanesi Diş Hekimliği Fakültesi'nin klinik veri tabanından retrospektif olarak elde edilmiştir. Tanısal doğruluk ve etiketleme güvenilirliğini sağlamak amacıyla, yalnızca tanısı kesinleşmiş ve tedavi süreci tamamlanmış olgular çalışmaya dahil edilmiştir. Bu doğrultuda, 2014–2019 yılları arasındaki hasta kayıtları sistematik olarak incelenmiştir. Veri seti, on yılı aşkın klinik deneyime sahip kıdemli bir pedodontist tarafından toplanmış, doğrulanmış ve etiketlenmiştir. Bu çok düzeyli doğrulama yaklaşımı, referans veri setinin kalitesini ve tutarlılığını artırmak amacıyla uygulanmıştır. Ham veriler, yeniden adlandırma ve yeniden boyutlandırma işlemlerine tabi tutularak, model eğitimi ve değerlendirmesi için uygun son haline getirilmiştir. Nihai veri seti, toplam 1.170 anonimleştirilmiş panoramik radyografiden oluşmaktadır. Bunların 605'i kalıcı diş germi eksikliği, 166'sı süpernumere diş, 399'u ise germ eksikliği ve süpernumere gibi dental anomali bulgusu içermeyen normal görüntü olarak etiketlenmiştir. Şekil 3.2, veri setinden çeşitli örnekler sunmaktadır.

Etik ve yasal gizlilik yükümlülükleri nedeniyle, klinisyen tarafından yaş, cinsiyet ya da tıbbi geçmiş gibi bireye özgü veriler sağlanmamıştır. Bu sebeple demografik analiz gerçekleştirilememiştir. Ancak, klinik kayıtlar ve kurumsal protokoller doğrultusunda, veri setinin yalnızca pediatrik hastalara ait olduğu ve yaş aralığının yaklaşık 3 ila 12 yıl arasında değiştiği bilinmektedir. Ay cinsinden kesin yaş bilgisi ya da doğum tarihi gibi ayrıntılı veriler mevcut değildir. Tüm görüntüler JPEG (Joint Photographic Experts Group) formatında sağlanmış olup, özgün çözünürlükleri değişkenlik göstermektedir; çünkü bu görüntüler doğrudan kurumsal görüntüleme sisteminden dışa aktarılmıştır.



Şekil 3.2 Veri setinden germ eksikliği, normal ve süpernümere diş sınıfları için panoramik radyografi örnekleri

Süpernümere diş sınıfı, mesiodens, distomolar ve paramolar gibi çeşitli morfolojik alt türleri içermektedir. Ancak, her bir alt türün örnek sayısının sınırlı olması nedeniyle, derin öğrenmenin çalışma doğası gereği ayrı alt sınıfların oluşturulması mümkün olmamıştır. Dengesiz veya az temsil edilen alt sınıflar üzerinde model eğitimi yapılmasının aşırı öğrenme (overfitting) ve düşük genelleme performansı gibi önemli riskler taşıdığı bilinmektedir. Bu nedenle, tüm varyasyonlar, istatistiksel yeterlilik ve eğitim kararlılığını sağlamak amacıyla tek bir süpernümere sınıfı altında birleştirilmiştir.

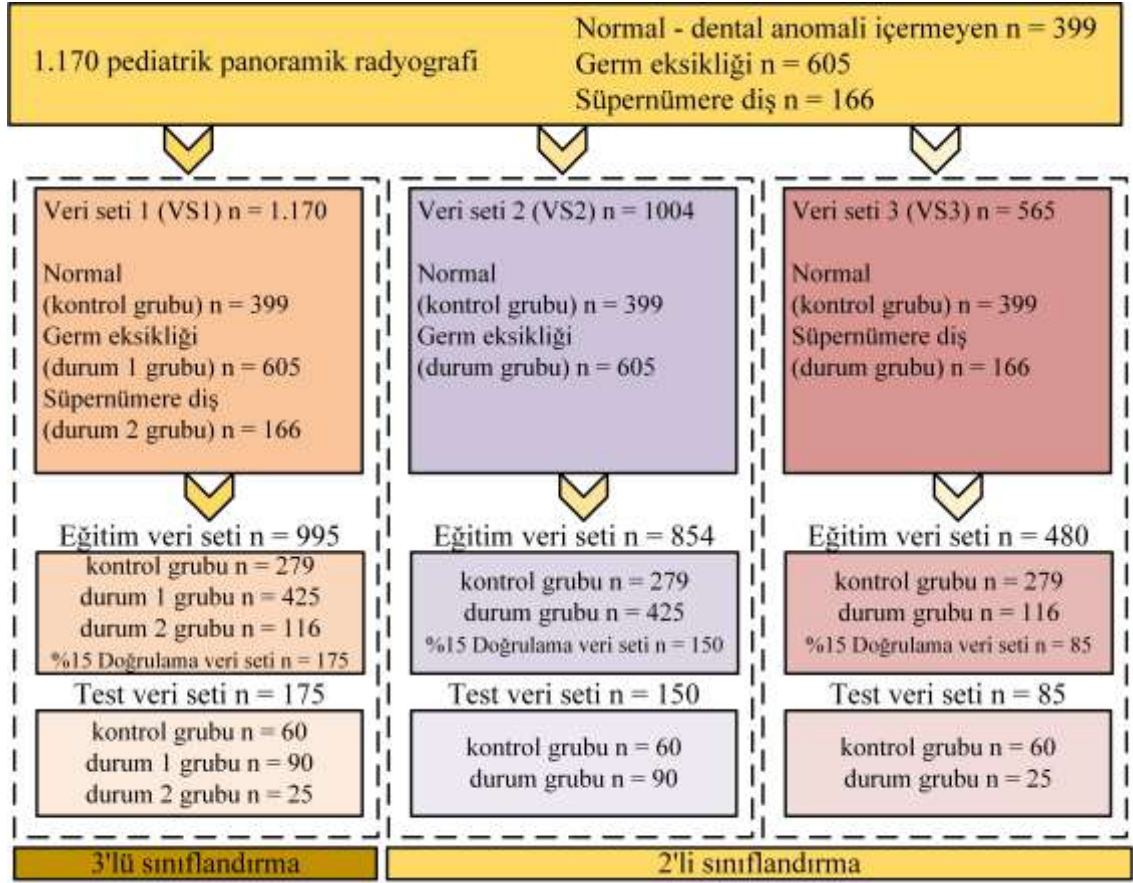
Dört yaş altı pediatrik hastalarda bir diş germinin (özellikle ikinci küçük azı dişi, 5 numaralı diş) radyografik olarak henüz görünür hale gelmemesi, normal diş gelişimi sınırları içerisinde değerlendirilebilir. Bu nedenle, erken çocukluk döneminde bir dental germin bulunmaması, kesin olarak ageneziyi göstermemektedir. Bununla birlikte, potansiyel germ eksikliğinin erken yaşta tespit edilmesi, dental agenezi açısından ön belirti oluşturabileceğinden klinik açıdan önemli kabul edilmekte ve agenezinin sonradan doğrulanması halinde erken müdahale olanağı sunmaktadır. Bu gerekçeye dayanarak,

dört yaş altındaki hastalarda germ eksikliği olarak tanımlanan olgular, erken tarama ve tanısal modelleme açısından potansiyel önem taşıdığı için veri setine dahil edilmiştir.

Sınıflandırma modelinin performansının kapsamlı bir şekilde değerlendirilebilmesi amacıyla, veri seti belirli görevleri hedefleyen üç ayrı yapılandırma halinde düzenlenmiştir: VS1 yapılandırması çok sınıflı sınıflandırma (normal, germ eksikliği, süpernümere dış) için kullanılırken; VS2 ve VS3 yapılandırmaları ikili sınıflandırma senaryoları için geliştirilmiştir. Bu kapsamda VS2, germ eksikliği ile normal olguların karşılaştırılmasında, VS3 ise süpernümere dış ile normal olguların ayırımında kullanılmıştır (Şekil 3.3). Sınıflandırma performanslarının karşılaştırılabilmesi için her bir veri seti yapılandırması, modelin eğitim ve test süreçlerinde bağımsız olarak kullanılmıştır.

Her bir veri seti, %70 eğitim, %15 doğrulama ve %15 test alt setlerine ayrılacak şekilde, tabakalı karıştırmalı bölme (stratified shuffling splitting) stratejisiyle bölünmüştür. Bu yöntem, sınıf dağılımlarının orijinal oranlarını koruyarak, rastgele örnekleme yöntemine kıyasla daha kararlı bir performans tahmini sağlamıştır. Modele girdi olarak verilmeden önce tüm görüntüler çift doğrusal enterpolasyon yöntemiyle  $224 \times 224$  piksel boyutuna yeniden boyutlandırılmış ve temel görüntü özelliklerinin korunması sağlanarak [0,1] aralığında normalize edilmiştir. Tüm görüntü işlemleri RGB formatında gerçekleştirilmiştir.

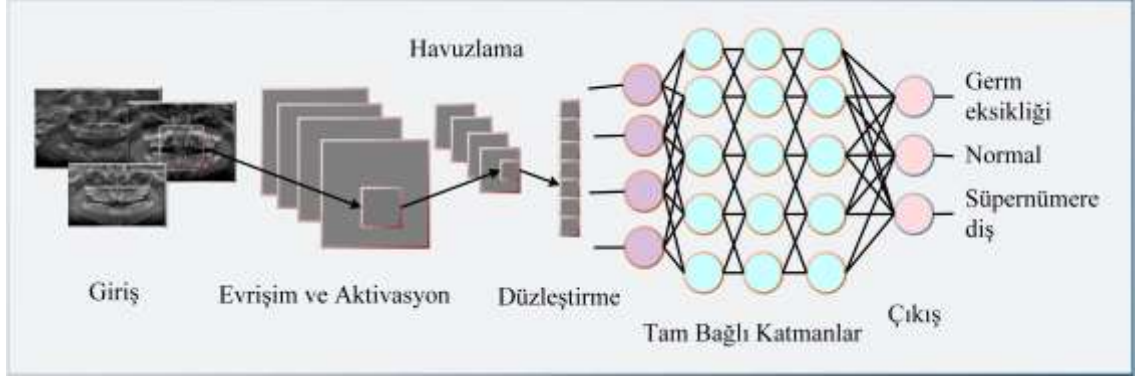
Modelin genellenebilirliğini artırmak ve aşırı öğrenme riskini azaltmak amacıyla, eğitim sırasında gerçek zamanlı veri artırma teknikleri uygulanmıştır. Bu teknikler,  $\pm 0,2$  oranında rastgele döndürme, her iki ekseninde  $\pm 0,2$  oranında yakınlaştırma-ayarlama işlemleri ve  $\pm 0,1$  oranında kontrast değişikliklerini içermektedir. Veri artırma sırasında görüntü sınırları dışına taşan bölgeler, dikey ve yatay kenar uzantısı (edge propagation) yöntemiyle doldurulmuştur.



Şekil 3.3 Veri setinin yapılandırılması ve deneysel tasarımın yapısı

### 3.3 CNN

Bir CNN'nin mimarisi genellikle, her biri ağın giriş verilerinden uzamsal özellik hiyerarşilerini öğrenmesini sağlayan belirli matematiksel işlemler gerçekleştiren birden fazla katmandan oluşur. Bu katmanlar, evrişim (konvolüsyon) katmanları, havuzlama katmanları, tam bağlantılı katmanlar ve normalizasyon katmanlarını içerir. CNN mimarisi Şekil 3.4'te sunulmuştur.



Şekil 3.4 CNN mimarisinin genel yapısı

Evrişim katmanı, evrişimin matematiksel işlemi aracılığıyla giriş verilerine bir dizi filtre (çekirdek, kernel) uygular.  $X$ : Giriş özellik haritası;  $W$ : filtre;  $b$ : önyargı (bias);  $*$ : evrişim işlemi temsil etmek üzere evrişim işlemi Denklem (3.1)'de verilmiştir. Bu katman, kenarlar, dokular ve basit şekiller gibi yerel uzamsal özellikleri çıkarır.

$$Y = X * W + b \quad (3.1)$$

Evrişimden sonra, ağın karmaşık desenleri öğrenmesi için çok önemli olan doğrusal olmayanlığı sağlamak amacıyla çıkışa eleman bazında Rektifiye Doğrusal Birim (Rectified Linear Unit, ReLU) gibi bir aktivasyon fonksiyonu uygulanır. Özellik haritalarının uzamsal boyutlarını azaltmak için bir havuzlama işlemi uygulanır. Yaygın havuzlama yöntemleri arasında, bir özellik haritası bölgesinden maksimum değer seçildiği maksimum havuzlama ve ortalama değer alındığı ortalama havuzlama bulunur. Bir CNN'nin son aşamasında, öğrenilen özellikler düzleştirilir ve her düğümün bir önceki katmandaki her düğüme bağlandığı bir veya daha fazla tam bağlantılı katmandan geçirilir. İşlem, bir aktivasyonun ardından doğrusal bir dönüşümdür.

Birçok mimari, performansı artırmak için yenilikçi fikirler sunarak derin öğrenme alanını ileriye taşımıştır:

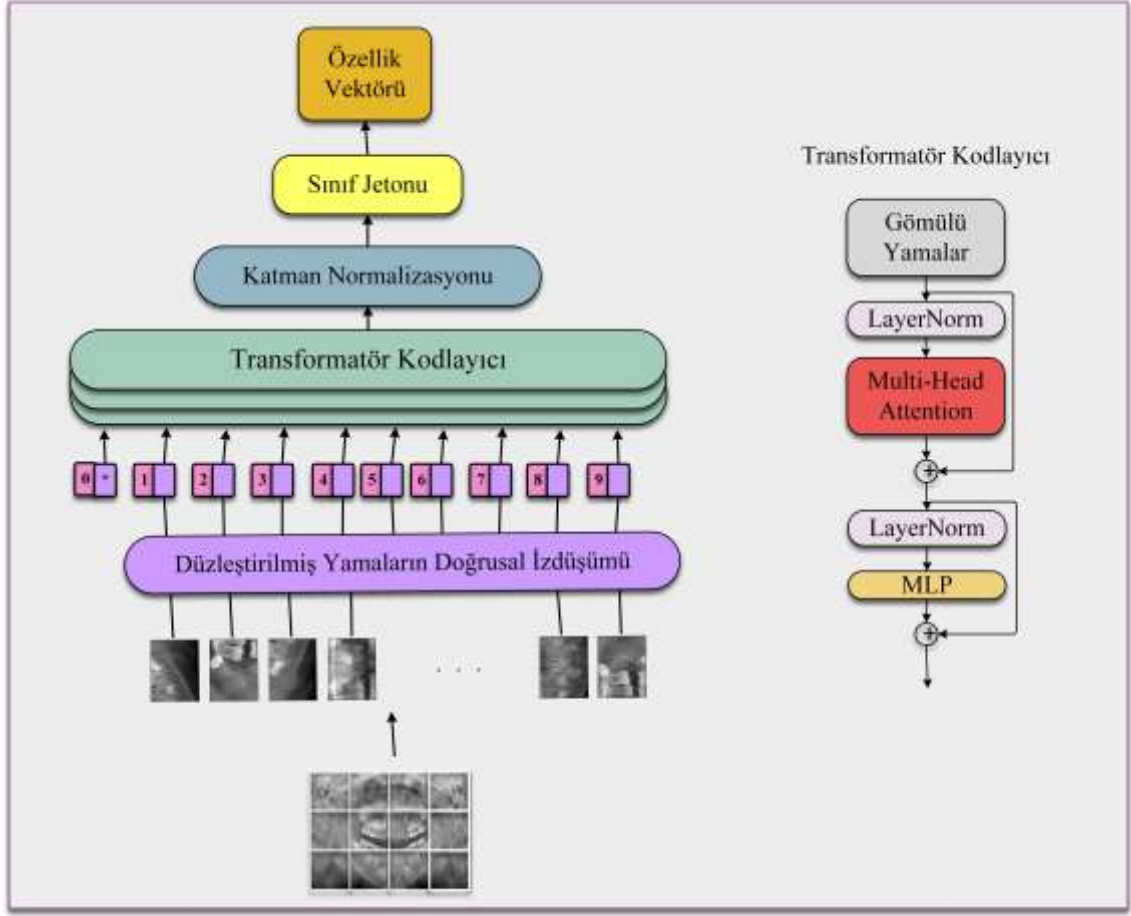
- VGG16/19: Bu modeller, evrişim katmanlarının derin yığınlarını ve bunları tamamen bağlı katmanların takip ettiği basit ama etkili bir mimari sunmuştur.

Temel yenilik, hiyerarşik özellikleri yakalamak için birçok katmanda küçük  $3 \times 3$  evrişim filtreleri kullanmalarında yatmaktadır.

- Inception: Inception ailesi, farklı ölçeklerdeki özellikleri yakalamak için farklı boyutlarda (örneğin,  $1 \times 1$ ,  $3 \times 3$ ,  $5 \times 5$ ) birden fazla filtreyi paralel olarak kullanan inception modülleri kavramını ortaya koymuştur. Bu modeller ayrıca  $1 \times 1$  evrişimler aracılığıyla boyut azaltmayı da içerir.
- Xception: Bu model, standart evrişimleri derinlik bazlı ayrılabilir evrişimlerle değiştirerek Inception mimarisini genişletir. Bu, büyük veri setlerinde daha verimli hesaplamalar ve daha iyi performans sağlar.
- InceptionResNet: Inception modüllerini artık (residual) bağlantılarla birleştiren InceptionResNet, gradyan akışını kolaylaştırarak eğitim verimliliğini ve model yakınsamasını iyileştirmeyi amaçlamaktadır.
- ResNet: ResNet'teki temel yenilik, kaybolan gradyan sorununu azaltarak çok derin ağların eğitimine olanak tanıyan artık bağlantıların kullanılmasıdır.
- DenseNet: DenseNet, katmanlar arasında yoğun bağlantılar sunar ve her katman önceki tüm katmanlardan girdi alır. Bu, özelliklerin daha iyi yeniden kullanımına ve daha verimli eğitime olanak tanır.

### 3.4 ViT

CNN'lerden farklı olarak ViT mimarisi, transformatör modülleri içindeki dikkat (attention) mekanizmalarını kullanan bir tür sinir ağıdır. Şekil 3.5'te ViT ve transformatör kodlayıcı mimarisi sunulmuştur.



Şekil 3.5 ViT mimarisinin genel yapısı

Bir giriş görüntüsü  $X \in \mathbb{R}^{H \times W \times C}$ , sabit boyutlu piksel bloklarına bölünerek  $N = \frac{WH}{p^2}$  adet yama (patch) elde edilir. Denklem (3.2)'de verildiği gibi her yama düzeltililip doğrusal projeksiyondan (Dense layer) geçirilir. Denkelem (3.2)'de verilen  $W_p$  ve  $b_p$ , sırasıyla projeksiyonun ağırlık ve önyargı parametreleridir.

$$z_i = x_i W_p + b_p \quad (3.2)$$

Tüm yamalar bir araya getirilerek  $Z_0 = [z_{cls}; z_1; z_2; \dots; z_N]$  formunda giriş dizisi oluşturulur. Giriş dizisi, her ögeye konumsal bilgi eklenmesiyle Denklem (3.3)'te verilen konumsal gömme (position embedding) işleminden geçer.

$$\tilde{z}_i = z_i + p_i \quad (3.3)$$

Konumsal gömme işleminden sonra elde edilen token dizisi transformatör kodlayıcı katmanına aktarılır. Transformatör kodlayıcı, katman normalizasyonu (LayerNorm), Çok Kafalı Kendine Dikkat (Multi-Head Self-Attention, MHSA) ve Gelu etkinleştirmeli MLP bloklarından oluşmaktadır. Dikkat mekanizması, vektörleri birbiriyle ilişkilendirerek her özellik vektörünün diğer özellik vektörlerinden dikkat çekmesine ve onlardan bilgi öğrenmesine olanak tanır. Bu, görsel içeriğin daha geniş bir bağlamda temsil edilmesini sağlar. Matematiksel olarak, dikkat mekanizması genellikle bir iç çarpım ve ardından bir softmax işlevi kullanılarak ifade edilir.  $Q$ ,  $K$  ve  $V$  sırasıyla sorguyu (giriş dizisindeki bir yama vektörü), anahtar ve değeri (giriş sırasındaki tüm yamaların değer vektörleri) temsil ediyorsa, dikkat ağırlıkları Denklem (3.4)'te gösterildiği gibi hesaplanır.

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (3.4)$$

Denklem (3.4)'te  $d_k$ , anahtar ve değer vektörlerinin boyutluluğunu temsil eder.  $Q = ZW^Q$ ,  $K = ZW^K$ ,  $V = ZW^V$  ile tanımlanır ve burada  $W^Q, W^K, W^V \in \mathbb{R}^{d \times d_k}$  şeklinde öğrenilebilir ağırlık matrisleridir. İç çarpım işlemi, sorgu vektörü ile her bir anahtar vektör arasındaki benzerliği ölçer. Daha sonra bu benzerlikler, ağırlıkları elde etmek için softmax fonksiyonu kullanılarak normalleştirilir. Son olarak, bu ağırlıklar, katılan değer vektörünü elde etmek için değer vektörleriyle çarpılır. Denklem (3.5)'te verilen MHSA, dikkat mekanizmasının birden fazla kafasını paralel olarak birleştirir ve  $W^O$  ağırlık matrisi, birleştirilmiş kafa çıktılarını nihai çıktıya dönüştürür. Her kafa, farklı dikkat ağırlıklarını hesaplamak için farklı öğrenilebilir ağırlık matrislerini ( $W_i^Q, W_i^K, W_i^V$ ) kullanır. Denklem (3.5)'teki " $head_i$ " terimi,  $i$ ' inci kafanın çıktısını belirtir. Tüm başlıkların birleştirilmesinden elde edilen çıktı,  $W^O \in \mathbb{R}^{hd_k \times d}$  boyutunda bir çıktı projeksiyonu ağırlığı ile işlenmektedir.

$$\begin{aligned} MHSA(Q, K, V) &= Concat(head_1, head_2, \dots, head_h)W^O, \\ head_i &= Attention(QW_i^Q, KW_i^K, VW_i^V) \end{aligned} \quad (3.5)$$

Elde edilen çıktı,  $MHSA(Q, K, V) = MHSA(Z)$  olmak üzere, artık bağlantı ve katman normalizasyonu işlemlerinden geçmektedir (Denklem (3.6)). Ardından Denklem (3.7)'de verildiği gibi, her bir tokene bağımsız olarak bir MLP uygulanarak Denklem (3.8)'de

verildiği gibi, yine bir artık bağlantı ve katman normalizasyonu işlemlerinden geçirilir. Denklem (3.7)'de verilen  $\sigma$ , genellikle  $GELU(x) = x \cdot \phi(x)$  olmak üzere doğrusal olmayan bir aktivasyon fonksiyonunu temsil etmektedir;  $W_1, W_2 \in \mathbb{R}^{d \times d_{ff}}$  ise MLP katmanına ait ağırlık matrisleridir.

$$Z' = LayerNorm(Z + MHSA(Z)) \quad (3.6)$$

$$MLP(Z) = \sigma(Z'W_1 + b_1)W_2 + b_2 \quad (3.7)$$

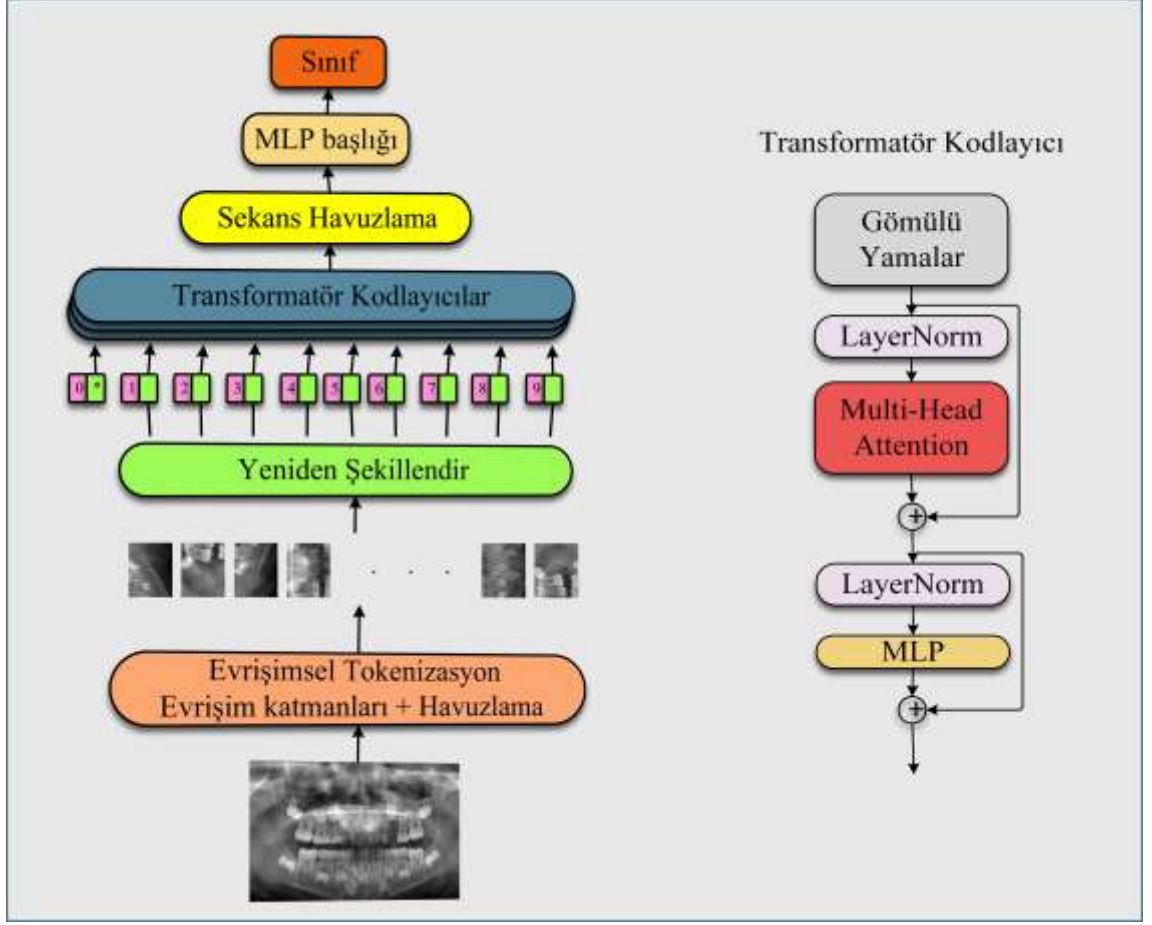
$$\tilde{Z} = LayerNorm(Z' + MLP(Z')) \quad (3.8)$$

Transformatör kodlayıcılardan elde edilen çıkış dizisi  $Z_L = [z_{cls}^{(L)}; z_1^{(L)}; z_2^{(L)}; \dots; z_N^{(L)}]$  olmak üzere; Burada  $L$ , son kodlayıcı katmanını ifade eder ve ViT modelinde, doğrudan sınıflandırma için yalnızca sınıf token'ı (class token,  $z_{cls}^{(L)}$ ) kullanılmaktadır. Sınıf token'ı, genellikle iki katmanlı bir MLP başlıktan geçirilir ve softmax aktivasyonu ağırlık çıktısını sınıf olasılıklarına dönüştürür.

### 3.5 CCT

CCT, klasik transformatör mimarilerinin büyük veri gereksinimlerini hafifletmek ve bu tür modellerin düşük veri senaryolarında dahi başarılı olmasını sağlamak amacıyla geliştirilmiştir. Geleneksel ViT mimarilerinin sınırlamalarını ele alan CCT, hesaplama maliyetlerini ve veri bağımlılığını azaltırken, aynı zamanda daha geniş bir uygulama alanı sunmayı hedeflemektedir.

CCT'nin temel yeniliği, görsel girdiler üzerinde çalışan bir tokenizer modülü ile başlar. Bu modül, görselleri sabit boyutlu yamalar yerine öğrenilebilir kompakt öznitelik haritalarına dönüştürür. Bu süreçte kullanılan kompakt evrişim katmanları, görsellerin uzamsal bilgilerini sıkıştırılmış bir formatta temsil ederek transformatör modeline giriş sağlar. Bu şekilde, görüntülerin düşük çözünürlükte dahi yüksek temsiliyetle işlenmesi mümkün olur. CCT mimarisi Şekil 3.6'da sunulmuştur.



Şekil 3.6 CCT mimarisinin genel yapısı

Evrişim katmanlarındaki her bir İki boyutlu evrişim işlemi,  $x_{ijm}$ : giriş görüntüsü üzerindeki bir pikselin  $m$ -inci kanal değeri;  $W_{klmc}$ :  $K \times L$  boyutlu filtrelerin  $m$ -inci kanalı için  $c$ -inci çıktıyı üreten ağırlıkları;  $b_c$ :  $c$ -inci çıktı kanalı için önyargı terimi;  $y_{ijc}$ : çıkış görüntüsünde  $i, j$  koordinatında  $c$ -inci kanalın değeri olmak üzere Denklem (3.9)'da verilen matematiksel tanıma dayanmaktadır.

$$y_{ijc} = \sum_{k=1}^K \sum_{l=1}^L \sum_{m=1}^M W_{klmc} x_{(i+k)(j+l)m} + b_c \quad (3.9)$$

Evrişimsel tokenizasyon işlemi için ilk evrişim,  $(H, W, C_{in})$  boyutundaki bir giriş görüntüsünü alır ve  $P$ : sıfır dolgusu (zero padding);  $K$ : filtre boyutu (kernel size);  $S$ : adım boyutu (stride) olmak üzere giriş filtresiyle dönüşüm sonrası çıktı boyutu Denklem (3.10)'da verildiği gibi ifade edilir.

$$H' = \left\lfloor \frac{H+2P-K}{S} + 1 \right\rfloor, W' = \left\lfloor \frac{W+2P-K}{S} + 1 \right\rfloor \quad (3.10)$$

Evrişim işleminin ardından uzamsal boyutlar maksimum havuzlama işlemi ile azaltılır. Havuzlama işlemi,  $K_p \times K_p$  boyutlu bir filtrenin maksimum değerini seçerek Denklem (3.11)'de verildiği gibi ifade edilir.

$$y_{ijc} = \max_{(k,l) \in K_p} x_{(i+k)(j+l)c} \quad (3.11)$$

$K_p$ : Havuzlama filtresinin boyutu (pooling kernel size);  $S_p$ : Havuzlama adım boyutu (pooling stride) olmak üzere maksimum havuzlama sonrası çıktı boyutu Denklem (3.12)'de verildiği gibidir ve havuzlama işlemi, çıktı boyutunu küçülterek uzamsal bilgiyi yoğunlaştırır.

$$H' = \left\lfloor \frac{H-K_p}{S_p} + 1 \right\rfloor, W' = \left\lfloor \frac{W-K_p}{S_p} + 1 \right\rfloor \quad (3.12)$$

Bu işlemin ardından elde edilen öznitelik haritası transformatör kodlayıcı mimarisine uygun olarak sekans adı verilen sıralı bir forma yeniden şekillendirilir ve evrişimsel öznitelik haritalarının sıralı temsile dönüştürülmesi ile transformatör bloklarına giriş sağlanır. Transformatör kodlayıcı için giriş dizisi  $T = H' \times W'$ ,  $Z = [z_1; z_2; \dots; z_T] \in \mathbb{R}^{T \times C'}$  olmak üzere, her mekansal konum bir sıralı token'a dönüştürülür. Bu dizinin her ögesine Denklem (3.3)'te verilen konumsal gömme eklenerek transformatör kodlayıcı katmanlarına giriş sağlanır. Transformatör kodlayıcı katmanlarında Denklem (3.4) ile (3.8)'e kadar verilen matematiksel işlemler gerçekleştirilir.

CCT'de yer alan sekans havuzlama modülü, modelin sınıflandırma işlemlerinde daha stabil ve verimli sonuçlar üretmesine katkıda bulunur. Sınıf token yerine, tüm dizinin ağırlıklı birleşimi alınır ve sınıf token yöntemine kıyasla daha sağlam bir tasarım sunar. Sekans havuzlama, her token'a ait öğrenilebilir bir skaler ağırlık ile tüm dizi öğelerinin doğrusal kombinasyonudur ve  $Z_i$ : i-inci token;  $W$ : öğrenilebilir parametre vektörü;  $\alpha_i$ : softmax ile normalize edilmiş dikkat ağırlığı olmak üzere Denklem (3.13)'te verildiği gibi

ifade edilir. Sekans havuzlama sonucu elde edilen global temsil Denklem (3.14)'te verildiği gibidir ve bu temsile MLP başlıkları uygulanarak sınıflandırma gerçekleştirilir.

$$\alpha_i = \frac{\exp(W^T Z_i)}{\sum_{j=1}^T \exp(W^T Z_j)} \quad (3.13)$$

$$\tilde{z} = \sum_{i=1}^T \alpha_i Z_i \quad (3.14)$$

CCT'de modelin düzenli çalışmasını sağlamak ve aşırı uyumlama riskini azaltmak için stokastik derinlik (stochastic depth, DropPath olarak da bilinir) isimli bir düzenleme yöntemi kullanılmıştır. Bu yaklaşım, modelin genel performansını artırırken hesaplama maliyetlerini optimize etmektedir. Bu yöntem, eğitim sürecinde artık bağlantıların tamamını olasılıksal olarak devre dışı bırakarak, modelin belirli katmanlara aşırı bağımlılık geliştirmesini engeller ve böylece dayanıklılığı (robustness) artırır. Bir  $x$  girişi verildiğinde, stokastik derinlik işlemi Denklem (3.15)'te verildiği gibi tanımlanmaktadır. Denklem (3.15)'te  $p \in [0,1]$ , bırakılma olasılığını (drop probability) temsil etmekte olup, genellikle ağ derinliği ile doğrusal olarak artacak şekilde ayarlanmaktadır. Çıkarım (inference) aşamasında tüm artık yollar korunmakta, herhangi bir bırakma uygulanmamaktadır.

$$\text{DropPath}(x) = \begin{cases} 0, & \text{with probability } p \\ x, & \text{with probability } 1 - p \end{cases} \quad (3.15)$$

### 3.6 CIT

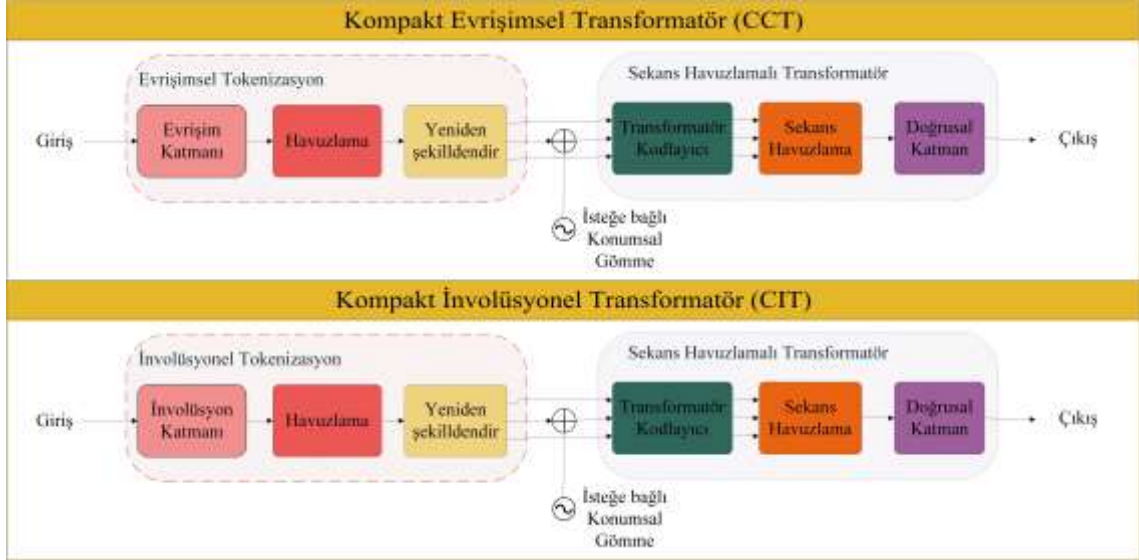
CNN ve ViT, görüntü analizinde kayda değer başarılar elde etmiş olsa da bu modellerin performansı genellikle büyük ölçekli etiketlenmiş veri setlerine ve yüksek hesaplama kapasitesine bağlıdır. Ancak bu gereksinimler, klinik uygulamalarda çoğu zaman sınırlayıcı faktörler olarak karşımıza çıkmaktadır. CNN'ler, sabit boyutlu filtreler aracılığıyla yerel desenleri yakalamada son derece başarılı olmakla birlikte, uzun menzilli bağlamsal bağımlılıkları genellemede yetersiz kalabilmektedir. Öte yandan, ViT

mimarileri uzun mesafeli ilişkileri modellemede etkili olsa da yerellik ve öteleme değişmezliği (translation invariance) gibi ince, bölgeye özgü çıkarımsal önyargılardan yoksundur; bu öznitelikler ise dental anomali radyografilerinde oldukça yaygındır. Bu sınırlılıkları gidermek amacıyla, bu çalışmada panoramik radyografilerden etkin ve sağlam temsil öğrenimini mümkün kılmak üzere geliştirilen, kompakt yapılı bir transformatör mimarisi olan CIT önerilmektedir. Önerilen model, mekansal olarak uyarlanabilir yerel öznitelikleri yakalamak için involüsyon tabanlı bir tokenizasyon yöntemi kullanmakta, aynı zamanda transformatör kodlayıcılarının küresel modelleme yeteneğini de korumaktadır. Bu mimari tasarım ile yerel duyarlılık ve bağlamsal farkındalık arasında etkili bir denge sağlanması ve sınırlı veri içeren pediatrik dental radyografilerde doğru anomali tespiti gerçekleştirilmesi amaçlanmıştır.

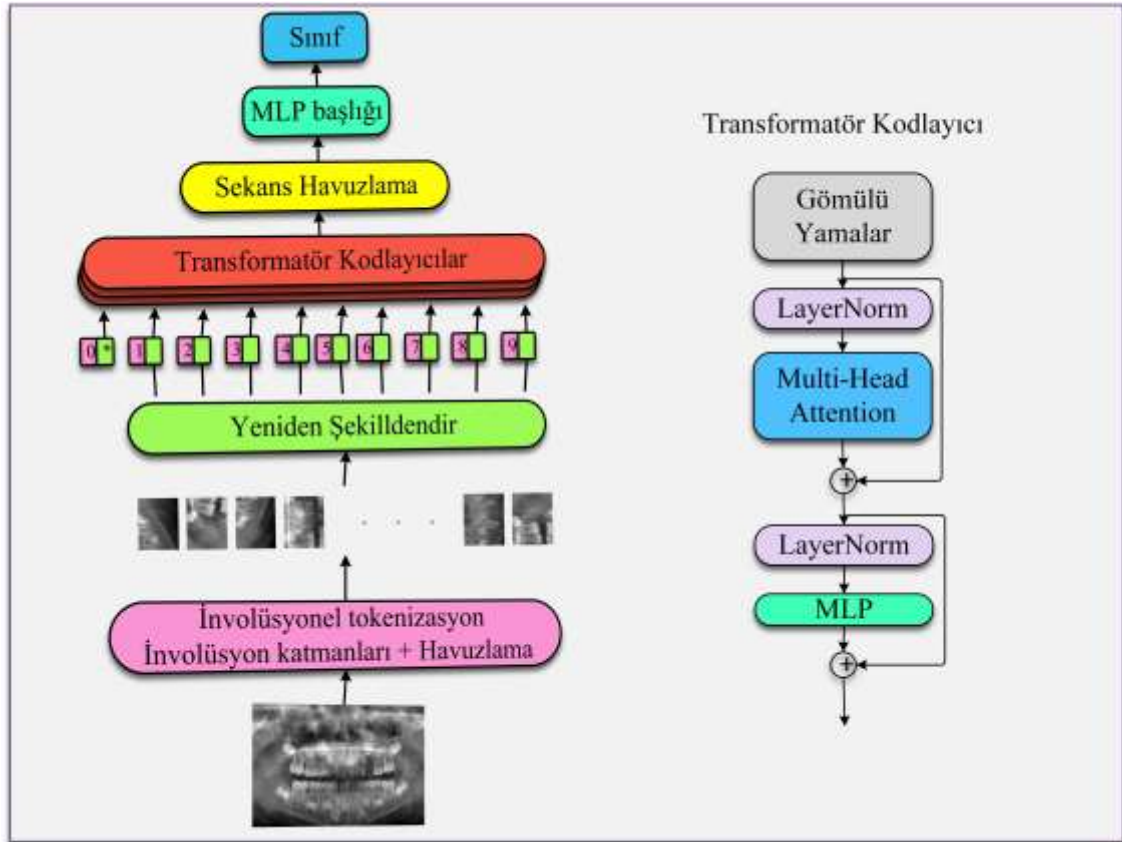
Önerilen CIT modeli, veri verimliliğini artırmak üzere evrimsel tokenizasyon ve sekans havuzlama mekanizmalarını bir araya getiren, kompakt yapılı bir transformatör mimarisi olan CCT temel alınarak geliştirilmiştir. CCT, CNN ve transformatörlerin avantajlarını bütünleştirerek etkili sonuçlar sunmakla birlikte, evrimsel tokenizasyona olan bağımlılığı nedeniyle bazı sınırlamaları da beraberinde getirmektedir. Bu sınırlamalardan biri, evrimsel filtrelerin sabit ve bağlamdan bağımsız olmasıdır; bu durum, mekansal uyarlanabilirliğin yetersiz kalmasına yol açabilmektedir. Bu sorunun üstesinden gelmek için CIT mimarisinde, evrimsel tokenizer yerine involüsyon tabanlı bir tokenizer kullanılmıştır. Bu yapı, yerel görüntü içeriğine dinamik olarak uyum sağlayan konuma özgü filtreler oluşturarak yeni bir öznitelik çıkarım yaklaşımı sunmaktadır. Evrimsel işlemlerinin aksine, involüsyon işlemlerinde filtreler tüm öznitelik haritası boyunca sabit değil, mekansal olarak farklılık göstermektedir. Bu sayede, lokalize dental anomaliler gibi bölgeye özgü varyasyonlar daha verimli şekilde modellenabilmektedir. Bu yaklaşım, yalnızca öğrenilebilir parametre sayısını azaltmakla kalmamakta, aynı zamanda tıbbi görüntüleme görevlerinde kritik öneme sahip ince morfolojik ipuçlarının yakalanma kapasitesini de artırmaktadır.

Şekil 3.7’de, CCT ile önerilen CIT mimarilerinin yapısal karşılaştırması sunulmuştur. Her iki mimari de sekans havuzlama içeren ortak bir transformatör omurgası paylaşmakta olup, CIT modelinde evrimsel tokenizasyon modülü yerine involüsyon tabanlı bir

tokenizer kullanılmakta; böylece mekansal uyarlanabilirlik artırılmakta ve parametre yükü azaltılmaktadır. CIT mimarisinin genel yapısı ise Şekil 3.8’de sunulmaktadır.



Şekil 3.7 CCT ve CIT mimarilerinin kıyaslanması



Şekil 3.8 CIT mimarisinin genel yapısı

Önerilen CIT mimarisinde, tokenizasyon işlemi, her mekansal konuma özgü dinamik filtreler oluşturarak geleneksel evrişimi ikame eden, mekansal olarak uyarlanabilir bir işlem olan involüsyon aracılığıyla gerçekleştirilmiştir. Global olarak paylaşılan filtreler kullanmak yerine, involüsyon işlemi giriş verisinden türetilen içerik duyarlı filtreler üretmektedir. Giriş tensörü  $X \in \mathbb{R}^{H \times W \times C_{in}}$  olarak tanımlandığında çıkış öznitelik haritası  $Y \in \mathbb{R}^{H \times W \times C}$ , her bir mekansal konum için dinamik olarak üretilen yerel filtreler  $K_{ij} \in \mathbb{R}^{H \times W \times C_{in}}$  aracılığıyla Denklem (3.16)'da verildiği şekilde hesaplanmaktadır.

$$K_{ij} = \text{Softmax}\left(\text{Conv}_{1 \times 1}(X_{ij})\right) \quad (3.16)$$

Burada,  $\text{Conv}_{1 \times 1}$  işlemi, giriş tensörü üzerinde uygulanan ve her mekansal konuma özgü filtreler üretmek amacıyla paylaşımlı olarak kullanılan bir nokta-seçimli (pointwise) evrişimdir. Uzamsal boyutu sabit tutulup sadece kanallar arasında öğrenilmiş bir dönüşüm yapılır ve bir tür kanal içi etkileşim sağlayarak parametre sayısını düşüren işlemdir. Softmax fonksiyonu ise alıcı alan (receptive field) içerisindeki ağırlıkların normalize edilmesini sağlamaktadır.

Her bir mekansal konum ve kanal için çıkış değeri, Denklem (3.16) ile tanımlanan filtre kullanılarak yerel komşuluk üzerindeki filtrelenmiş özniteliklerin birleştirilmesi (toplanması) yoluyla elde edilmekte olup, bu işlem Denklem (3.17) ile ifade edilmektedir.

$$Y_{ijc} = \sum_{k=1}^K \sum_{l=1}^K K_{ij}^{(k,l)} \cdot x_{(i+k)(j+l)c} \quad (3.17)$$

Denklem (3.17)'de verilen  $x_{(i+k)(j+l)c}$  ifadesi,  $(i, j)$  konumu etrafındaki  $(k, l)$  uzaklığında yer alan giriş piksel değerini belirtmekte;  $K_{ij}^{(k,l)}$  ise söz konusu mekansal bölge için dinamik olarak üretilen karşılık gelen filtre katsayısını ifade etmektedir. Uygun şekilde yapılandırılan dolgu (padding) ve adım (stride) parametreleri sayesinde, çıkış boyutları giriş boyutları ile aynı kalmaktadır ( $H_{out} = H, W_{out} = W$ ).

Involüsyon işleminin ardından, anlamsal soyutlamayı artırmak ve mekansal fazlalıkları azaltmak amacıyla standart bir havuzlama katmanı uygulanmaktadır. Elde edilen tensör  $Y \in \mathbb{R}^{H' \times W' \times C}$ , transformatör mimarisine uygun sıralı bir gösterime dönüştürülmek üzere Denklem (3.18)'de verildiği gibi yeniden şekillendirilmektedir.

$$Sequence = Reshape(y, [-1, H'.W', C]) \quad (3.18)$$

Bu sıralı yapı içerisinde yer alan her bir öznitelik vektörü  $x_t \in \mathbb{R}^C$ , mekansal bağlam bilgisini modele entegre edebilmek amacıyla aynı boyuttaki bir konumsal gömme vektörü  $p_t \in \mathbb{R}^C$  ile zenginleştirilmektedir. Böylece, transformatör kodlayıcısına sunulan nihai girdi Denklem (3.19)'da verilen şekilde ifade edilmektedir:

$$z_t = x_t + p_t \quad (3.19)$$

Denklem (3.18) ve (3.19) ile tanımlanan bu dönüşüm, mekansal olarak kodlanmış ve bağlam duyarlılığı içeren öznitelikleri, transformatör kodlayıcılarıyla uyumlu bir formata dönüştürmektedir. Involüsyon kullanımının sağladığı avantaj, tokenizasyon aşamasında içerik bağımlı olarak ince düzeyde yerel varyasyonların yakalanabilmesidir. Bu durum, küçük yapısal ve dokusal farklılıkların tanı açısından kritik önem taşıdığı tıbbi görüntüleme uygulamalarında özellikle değerlidir.

Konumsal gömme işleminin ardından, elde edilen token dizisi, birden fazla özdeş katmandan oluşan bir transformatör kodlayıcıya aktarılmaktadır. Her bir katman, MHSA mekanizması ve konuma özgü MLP bileşenlerinden oluşmaktadır. Kodlayıcıya giriş olarak  $Z = [z_1; z_2; \dots; z_t] \in \mathbb{R}^{T \times C}$  tanımlandığında, burada  $z_t \in \mathbb{R}^d$ ,  $t$  zaman adımındaki konumsal olarak gömülmüş token'ı ifade etmektedir. Her bir katmanda, kendine dikkat (self-attention) mekanizması, dikkat ağırlıklı temsilleri Denklem (3.4)'te verildiği şekilde hesaplamaktadır. MHSA mekanizması ise Denklem (3.5)'te verilen şekilde tanımlanmaktadır.

Elde edilen çıktı daha sonra Denklem (3.6)'da verilen, artık bağlantı ve katman normalizasyonu işlemlerine tabi tutulmaktadır. Dikkat mekanizmasının ardından, her bir

tokene bağımsız olarak Denklem (3.7)'de verilen bir MLP uygulanmaktadır. Bu işlem Denklem (3.8)'de verildiği gibi yine bir artık bağlantı ve katman normalizasyonu ile takip edilmektedir.

Transformatör kodlayıcı katmanlardan sonra Denklem (3.13)'te verilen sekans havuzlama uygulanarak sonucunda elde edilen global temsil Denklem (3.14)'te verildiği gibidir ve bu temsile MLP başlıkları uygulanarak sınıflandırma gerçekleştirilir.

Aşırı öğrenmeyi önlemek ve özellikle küçük ölçekli tıbbi veri setlerinde modelin genellenebilirliğini artırmak amacıyla, transformatör kodlayıcıya Denklem (3.15)'te verilen stokastik derinlik tekniği entegre edilmiştir. Stokastik derinlik, her bir örneğe bağımsız olarak uygulanmakta olup, artık bağlantıların yaygın olarak kullanıldığı transformatör tabanlı mimariler için uygun bir düzenleme stratejisi sunmaktadır. Çıkarım aşamasında tüm artık yollar korunmakta, herhangi bir bırakma uygulanmamaktadır.

### **3.7 Eğitim ve Doğrulama Süreçleri**

Uygulamada kullanılan CIT modelinin ayrıntılı konfigürasyonu, hiperparametreleri ve parametre özeti Çizelge 3.1'de verilmiştir. Model, üç temel bileşenden oluşacak şekilde yapılandırılmıştır: (1) involüsyonel tokenizasyon, (2) konumsal gömmelerle zenginleştirilmiş transformatör kodlayıcı ve (3) sıralı yapıya dayalı sınıflandırma (MLP başlığı). Modele giriş olarak verilen  $224 \times 224$  boyutlarında, RGB formatında panoramik dental radyografiler, ilk olarak yeniden ölçekleme, rastgele kırpma ve yatay yansıtma gibi veri artırma işlemlerine tabi tutulmaktadır. Ardından artırılmış görüntü, iki involüsyon katmanının ardışık şekilde istiflendiği involüsyonel tokenizer yapısından geçirilmektedir. Geleneksel evrişimsel işlemlerden farklı olarak, bu katmanlar,  $1 \times 1$  evrişim, yığın normalizasyonu (batch normalization) ve ReLU aktivasyonu ile takip edilen, mekansal olarak uyarlanabilir ve giriş verisine duyarlı filtreler üretmektedir. Her involüsyon bloğunu takiben, adımı 2 olan (stride 2), aynı dolgulu (same padding)  $3 \times 3$  boyutunda maksimum havuzlama katmanları uygulanmakta ve bu sayede hem mekansal çözünürlük azaltılmakta hem de temel yerel öznitelikler korunmaktadır. Elde edilen öznitelik haritası,

doğrusal olarak 64 boyutlu sabit bir gömme (embedding) uzayına yansıtılmakta ve ardından toplam 3.364 adet token içeren bir sekansa dönüştürülmektedir.

CIT mimarisinde içsel bir mekansal önyargı bulunmadığından, mekansal bilginin kodlanması kritik bir öneme sahiptir. Bu nedenle, öğrenilebilir mutlak konumsal gömmeler token sekans dizisine eklenmektedir. Bu işlem, farklı konumlarda aynı özelliklerin meydana gelmesi durumunda modelin ayrım yapabilmesini mümkün kılmakta ve özellikle lokalize dental anomalilerin tespiti açısından önemli katkı sağlamaktadır.

Konumsal bilgi ile zenginleştirilmiş token dizisi, her biri MHSA mekanizması (2 başlık, anahtar boyutu = 32) ve iki adet GELU aktivasyonlu yoğun katmandan oluşan MLP alt katmanı içeren iki ardışık bloktan oluşan bir transformatör kodlayıcıya aktarılmaktadır. Hem dikkat hem de MLP dallarının ardından, modelin genellebilirliğini artırmak ve eğitim kararlılığını sağlamak amacıyla stokastik derinlik düzenleme yöntemi uygulanmaktadır.

Geleneksel ViT mimarilerinden farklı olarak, CIT modelinde sınıf token kullanılmamakta; bunun yerine, sekans havuzlama uygulanmakta ve böylece dikkat ağırlıkları aracılığıyla token temsillerinin dinamik biçimde bir araya getirilmesi sağlanmaktadır. Son aşamada elde edilen temsil, tam bağlantılı bir MLP başlık katmanından geçirilmekte ve germ eksikliği, süpernümere diş ve normal anatomi sınıflarına karşılık gelen üç çıkış birimli softmax aktivasyonu içeren bir yoğun katmanla sonuçlandırılmaktadır.

Hiperparametrelerin yapılandırılması, hiperparametre arama uzayını keşfederek en yüksek doğrulama başarımını sağlayan mimariyi belirleyen KerasTuner kullanılarak seçilmiştir. Eğitim süreci, öğrenme oranı 0,01, mini yığın boyutu (batch size) 16 ve ağırlık bozunumu (weight decay) 0,001 olmak üzere, Adam optimizasyon algoritması (Kingma ve Ba 2014) ile gerçekleştirilmiştir. Adam, özellikle transformatör tabanlı mimarilerde katmanlar arası gradyan varyansının yüksek olabildiği durumlarda, adaptif moment tahmini ve üstün yakınsama hızı nedeniyle oldukça başarılıdır. Adam, öğrenme oranını ve momentleri

kullanarak parametre güncellemesini Denklem (3.20)'de verildiği gibi yapar. Denklem (3.20)'de  $\theta_t$ :  $t$  anındaki parametreler;  $\eta$ : öğrenme oranı;  $\epsilon$ : sayısal kararlılığı artırmak için kullanılan küçük bir sabit;  $\hat{m}_t$  ve  $\hat{v}_t$ : bias düzeltmesi yapılmış momentleri temsil eder.

$$\theta_t = \theta_{t-1} - \alpha \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \epsilon}} \quad (3.20)$$

Öğrenme oranı, doğrulama kaybı 5 ardışık epok boyunca iyileşme göstermediği durumda oranı 0,1 ile çarpan ReduceLROnPlateau geri çağırımı (callback) kullanılarak dinamik biçimde yönetilmiştir. Ayrıca, EarlyStopping yöntemiyle doğrulama doğruluğu 5 epok boyunca gelişmezse eğitim süreci sonlandırılmış; aşırı öğrenmeyi önlemek amacıyla en fazla 50 epokluk sert bir üst sınır uygulanmıştır. Modelin güvenilir şekilde değerlendirilmesini sağlamak için, sınıf dağılımlarını koruyan katmanlı karıştırmalı bölme (stratified shuffle split) yöntemiyle 5-kat tabakalı çapraz doğrulama stratejisi uygulanmıştır.

Sonuçta elde edilen model, toplam 299.820 parametre içermekte olup, bunların 299.772'si öğrenilebilir durumdadır. Model mimarisi, 15 öğrenilebilir katmandan oluşmakta ve ifade gücü ile kompaktlık arasında dikkatle dengelenmiş bir yapı sunmaktadır. Bu yapı, önerilen CIT modelini, özellikle sınırlı veri koşulları altında gerçekleştirilen tıbbi görüntüleme uygulamaları için son derece uygun hale getirmektedir.

Model karşılaştırmalarında koşulların tutarlılığını sağlamak adına, çok sınıflı sınıflandırmada kullanılan aynı yapılandırma ve hiperparametre ayarları, ikili sınıflandırma deneylerinde de korunmuştur. Yapılan tek değişiklik, softmax aktivasyonlu çok nöronlu çıkış katmanının, tek nöronlu sigmoid aktivasyonlu bir yoğun katman ile değiştirilmesi ve kategorik çapraz entropi yerine ikili çapraz entropi kayıp fonksiyonunun kullanılmasıdır. Değerlendirme aşamasında, sigmoid çıkışlara 0,5 eşik değeri uygulanarak sınıf üyeliği belirlenmiştir.

Önerilen CIT modelinin adil ve titiz bir biçimde değerlendirilmesini sağlamak amacıyla, karşılaştırmalı analizlerde SOTA mimarileri kullanılmıştır. Bu kapsamda CCT, ViT ve bir CNN mimarisi, aynı hiperparametre ayarları (öğrenme oranı, mini yığın boyutu, ağırlık bozunumu, optimizasyon algoritması ve maksimum epok sayısı) ile eğitilip test edilerek, önerilen modelle eşit koşullarda karşılaştırılmıştır. Bu tutarlı yapılandırma, model performanslarını doğrudan ve tarafsız biçimde karşılaştırabilmek amacıyla kasıtlı olarak benimsenmiştir.

CNN karşılaştırma modeli olarak, DenseNet, VGG, ResNet, Xception, Inception, Inception-ResNet ve MobileNet gibi önde gelen mimariler, transfer öğrenme yöntemiyle ayrı ayrı eğitilmiş; sadece başlangıç ağırlıkları ImageNet'ten alınmış, geri kalan tüm parametreler yeniden eğitilmiştir. Bu modeller arasında en yüksek tanısıl başarıma ulaşan yapı, nihai değerlendirme için temsilci CNN modeli olarak seçilmiştir. Transformatör tabanlı modeller olan CCT ve ViT için, kodlayıcı bileşenleri tamamen aynı yapılandırmayla kullanılmış; yalnızca tokenizasyon mekanizmaları farklı tutulmuştur. Bu yaklaşım, CIT modelinde önerilen involüsyon tabanlı tokenizasyonun etkisini izole etmek ve onu CCT'nin evrimsel tokenizasyonu ile ViT'nin yama gömme yöntemiyle doğrudan karşılaştırmak amacıyla tasarlanmıştır.

Tüm deneyler, yüksek performanslı bulut bilişim kaynakları sunan Google Colab Pro+ ortamında, Jupyter Notebook arayüzü kullanılarak gerçekleştirilmiştir. Modelin uygulanması ve eğitimi, Python 3 dilinde, derin öğrenme modülleri için TensorFlow Keras API (Chollet 2017) ve değerlendirme metrikleri, veri bölme stratejileri ile çapraz doğrulama rutinleri için Scikit-learn (Pedregosa vd. 2011) kullanılarak yürütülmüştür. Hesaplamalar, paralel eğitim ve transformatör tabanlı işlemleri hızlandıran NVIDIA A100 Tensor Core GPU tarafından desteklenmiştir. Ayrıca,  $\geq 52$  GB RAM kapasitesi, yüksek çözünürlüklü panoramik radyografilerin verimli şekilde yüklenmesi ve işlenmesini mümkün kılmıştır. Bu sistem konfigürasyonu, özellikle transformatör tabanlı mimariler gibi kaynak yoğun modellerin eğitimi açısından, yeniden üretilebilir, ölçeklenebilir ve donanım verimli bir deney ortamı sağlamıştır.

Çizelge 3.1 CIT modelinin konfigürasyonu, hiperparametreleri ve parametre özeti

Konfigürasyon	Hiperparametre
Input (224, 224, 3)	Yığın boyutu = 16
Data Augmentation (224, 224, 3)	Epok = 50
CIT Tokenizer (58, 58, 64)	Öğrenme oranı = 0.01
InvLayer [1×1 Conv(32) + BatchNorm + ReLU + 1×1 Conv] + ReLU, padding 1 3×3 MaxPooling + stride 2 + padding = “same” InvLayer [1×1 Conv(32) + BatchNorm + ReLU + 1×1 Conv] + ReLU, padding 1 3×3 MaxPooling, stride 2, padding = “same” Dense(projection_dim = 64)	Ağırlık bozunumu = 0.001
	Optimizasyon algoritması = Adam
	Projeksiyon Boyutu = 64
	Transformatör katmanları = 2
Position Embedding (3364 tokens, dim=64)	Dikkat kafaları = 2
Transformer Block 1 (3364, 64)	MLP birimleri = [64, 64]
X1 = LayerNorm + MHSA + StochasticDepth Add 1 [embedded_patches + X1] X2 = LayerNorm + MLP [Dense(64) + GELU + Dropout(0.1)](2) + StochasticDepth Add [Add 1 + X2]	Dropout Oranı = 0.1
	Stokastik derinlik max = 0.1
	Kayıp fonksiyonu = Categorical Crossentropy
Transformer Block 2 (3364, 64) Same as Block 1	<b>Parametre Özeti</b>
LayerNorm	Toplam parametre sayısı: 299.820 (1.14 MB)
Sequence Pooling (64,)	Eğitilebilir parametreler: 299.72 (1.14 MB)
Dense(3) + Softmax (3,)	Eğitilemez parametreler: 48 (192.00 B)
	Öğrenilebilir katman sayısı: 15

### 3.8 Performans Metrikleri

Gözetimli sınıflandırma görevlerinde, bir modelin öngörücü güvenilirliğinin değerlendirilmesi, resmi bir performans çerçevesi gerektirir. Bu çerçevenin merkezinde, öngörülen ve gerçek sınıf etiketleri arasındaki ilişkiyi gösteren tablo biçiminde bir gösterim olan karışıklık matrisi yer alır. İkili sınıflandırma problemleri için karışıklık matrisi dört temel bileşenden oluşur:

- Gerçek Pozitifler (TP): Doğru tahmin edilen pozitif vakalar
- Yanlış Pozitifler (FP): Yanlış tahmin edilen negatif vakalar (Tip I hatası)
- Gerçek Negatifler (TN): Doğru tahmin edilen negatif vakalar

- Yanlış Negatifler (FN): Yanlış tahmin edilen pozitif vakalar (Tip II hatası)

İkili sınıflandırma problemlerine ait karışıklık matrisi Şekil 3.9’da verilmiştir. Tıbbi teşhis bağlamında, sınıflandırma hatalarının yorumlanmasına özellikle önem verilmektedir, çünkü bunların klinik etkileri önemli ölçüde farklılık göstermektedir. Tip I hatalar (yanlış pozitifler), sağlıklı bireylerin hatalı bir şekilde hasta olarak tanımlanmasına yol açarak gereksiz testlere, psikolojik sıkıntıya veya aşırı tedaviye neden olabilir. Tersine, Tip II hatalar (yanlış negatifler), atlanan tanılara, gecikmiş müdahalelere ve dolayısıyla artan morbidite veya mortaliteye yol açtıkları için daha ciddi bir risk oluşturmaktadır. Bu nedenle, Tip II hatanın en aza indirilmesi, sağlık hizmetleriyle ilgili sınıflandırma görevlerinde büyük önem taşımaktadır.

		Tahmin edilen sınıf	
		Negatif	Pozitif
Gerçek sınıf	Negatif	TN	FP
	Pozitif	FN	TP

Şekil 3.9 İkili sınıflandırma görevleri için karışıklık matrisi

Karışıklık matrisi bileşenleri, her biri model performansının farklı yönlerini vurgulayan çeşitli değerlendirme ölçütlerinin temelini oluşturur. Modelin ayrımcılık gücünü ve güvenilirliğini yakalamak için ACC, PREC, REC, F1 skoru, AUC, JSC ve MCC dahil olmak üzere kapsamlı bir değerlendirme ölçütü seti kullanılmıştır. PREC, tüm öngörülen pozitifler arasında doğru tahmin edilen pozitif vakaların oranını nicelleştirir ve bu nedenle yanlış pozitiflere karşı hassastır. Diğer yandan REC, tüm gerçek pozitif vakalar arasında doğru tanımlanan gerçek pozitiflerin oranını ölçer ve bu da onu doğrudan yanlış negatiflerden etkiler. PREC ve REC’in harmonik ortalaması olan F1 skoru, özellikle yanlış sınıflandırmanın maliyeti asimetrik olduğunda PREC ve REC’i dengeler. AUC, modelin sınıflar arasında ayırma yeteneğinin eşik değerinden bağımsız bir

değerlendirmesini sağlarken, JSC öngörülen ve gerçek pozitif vakalar arasındaki örtüşme derecesini değerlendirir. Son olarak, MCC, karışıklık matrisinin dört çeyreğini de hesaba katan tek bir skaler metrik sunarak, özellikle dengesiz veri setlerindeki performansı değerlendirmek için uygundur. Bu metriklerin resmi tanımları ve matematiksel formülleri Çizelge 3.2’de özetlenmiştir.

Çizelge 3.2 Performans metriklerine genel bakış

Metrik	Formül	Tanım
Doğruluk (ACC)	$\frac{TP+TN}{TP+FP+FN+TN} \quad (3.21)$	Tüm doğru tahminlerin oranı.
Kesinlik (PREC)	$\frac{TP}{TP+FP} \quad (3.22)$	Doğru pozitif tahminlerin oranı. Tip I hataya yatkınlığı yansıtır.
Geri çağırma (REC)	$\frac{TP}{TP+FN} \quad (3.23)$	Doğru tespit edilen gerçek pozitiflerin oranı. Tip II hatadan kaçınma ile ilgilidir.
F1 Skor	$2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3.24)$	Kesinlik ve geri çağırmanın harmonik ortalaması. Dengesiz veriler için kullanışlıdır.
ROC-AUC	ROC eğrisi integrallemesiyle hesaplanır	ROC eğrisinin altındaki alan. Eşik değerinden bağımsız olarak sınıf ayrılabilirliğini gösterir.
Jaccard benzerlik katsayısı (JSC)	$\frac{TP}{TP+FN+FP} \quad (3.25)$	Öngörülen ve gerçek pozitif kümeler arasındaki örtüşmeyi ölçer.
Matthews korelasyon katsayısı (MCC)	$\frac{TP \times TN - FP \times FN}{\sqrt{(TP+FP)(TP+FN)(TN+FP)(TN+FN)}} \quad (3.26)$	Tüm karışıklık matrisi öğelerini hesaba katan dengeli metrik. Sınıf dengesizliği altında sağlamdır.

### 3.9 İstatistiksel Analiz Yöntemleri

Aynı veri setine uygulanan iki sınıflandırma modelinin öngörü performansını karşılaştırırken yalnızca doğruluk farklılıklarını bildirmek yeterli değildir. Bunun yerine, gözlemlenen bir performans farkının şansa mı bağlı olduğunu yoksa öngörü davranışında gerçek bir ayrımı mı temsil ettiğini belirlemek için istatistiksel anlamlılık testi gereklidir. Çeşitli parametrik olmayan teknikler arasında, McNemar testi, eşleştirilmiş nominal çıktılar üzerinden iki sınıflandırıcıyı karşılaştırmak için yaygın olarak kullanılan bir yöntemdir (Bostanci ve Bostanci 2013).

McNemar testi, eşleştirilmiş ikili verilerin analizine dayanır. Özellikle, iki sınıflandırıcının uyumsuz öngörüler ürettiği, bir sınıflandırıcının doğru, diğerinin yanlış olduğu veya tam tersi, durumlara odaklanır. Bu uyumsuz sonuçlar, Şekil 3.10'da verilen  $2 \times 2$ 'lik bir kontenjans tablosu (contingency table) kullanılarak özetlenir. Bu matristeki anahtar hücreler, iki sınıflandırıcıdan yalnızca biri tarafından yanlış sınıflandırılan örneklerin sayısını temsil eden  $b$  ve  $c$ 'dir.

		Algoritma B	
		Doğru	Yanlış
Algoritma A	Doğru	a	b
	Yanlış	c	d

Şekil 3.10 McNemar testinde kontenjans tablosu

McNemar testinin sıfır hipotezi, her iki sınıflandırıcının da aynı hata oranına sahip olduğunu belirtir, yani  $P(b) = P(c)$ . Uyumsuz çiftlerin toplam sayısı ( $b + c$ ) yeterince büyük olduğunda (genellikle  $\geq 25$ ), McNemar test istatistiği, bir serbestlik derecesine

sahip bir ki-kare ( $\chi^2$ ) dağılımı kullanılarak yaklaşık olarak Denklem (3.27)'de verildiği gibi hesaplanabilir.

$$\chi^2 = \frac{(b-c)^2}{b+c} \quad (3.27)$$

Alternatif olarak, bu test, ki-kare değerini dönüştürerek standart normal (z) dağılımı açısından da Denklem (3.28)'de verildiği gibi ifade edilebilir. Bu z-skoru formülasyonu, özellikle güven aralıklarını ve p-değerlerini hesaplamak için kullanışlıdır ve sınıflandırıcılar arasındaki performans farklılıklarının yönü ve büyüklüğü hakkında daha sezgisel bir anlayış sağlar.

$$z = \frac{b-c}{\sqrt{b+c}} \quad (3.28)$$

Tek kuyruklu veya çift kuyruklu test seçimi şu hipoteze bağlıdır:

- İki kuyruklu bir test, istatistiksel yönden bağımsız olarak iki sınıflandırıcının performansında anlamlı bir fark olup olmadığını değerlendirir (yani,  $P(b \neq c)$ ). İki kuyruklu p-değeri,  $p = 2 \cdot P(Z > |z|)$  şeklinde hesaplanır. Eğer  $p < 0,05$  ise A ile B arasında anlamlı bir fark vardır.
- Tek kuyruklu test, farkın yönü hakkında önceden bir beklenti olduğunda kullanılır. Bu durumda tek kuyruklu p-değeri,  $p = P(Z > z)$ , if  $(b > c)$  şeklinde hesaplanır. Eğer  $b > c$  ise Algoritma A, B'den daha iyi performans göstermiştir.

### 3.10 Açıklanabilir Yapay Zeka Yöntemleri

Derin öğrenme tabanlı görüntü sınıflandırma görevlerinde, özellikle tıbbi görüntüleme gibi yüksek riskli alanlarda, model yorumlanabilirliği, tahminlerin güvenilirliğini ve doğruluğunu doğrulamada hayati bir rol oynar. Grad-CAM, sınıf ayrımcı yerelleştirme haritaları üreten ve giriş görüntüsünün hangi bölgelerinin bir modelin kararına en çok

katkıda bulunduğunu görselleştirmeyi sağlayan, sonradan açıklanabilir bir yöntemdir (Selvaraju vd. 2017).

Grad-CAM, bir hedef sınıf puanının özellik haritalarına göre eğiminin, görüntüdeki uzamsal bölgelerin önemini kodladığı ilkesine dayanır. Grad-CAM, bu eğimleri hesaplayıp ağırlıklı bir toplama işlemi gerçekleştirerek, giriş görüntüsündeki sınıfla ilgili bölgeleri vurgular. Grad-CAM, çıktı skorunun, bir katmandaki uzamsal aktivasyonlara olan gradyanına bakarak önem ağırlıklarını hesaplar. Involüsyon çıktıları konum-özel bilgi taşıdığı için, Grad-CAM ısı haritası da daha yerel ve hassas bölgeleri gösterebilir.  $y^c$ : modelin tahmin ettiği sınıf skoru (logit);  $A^k$ : seçilen katmandan elde edilen k-inci kanal aktivasyonu (geleneksel bir evrişim katmanı ya da içerik duyarlı involüsyon katmanı olabilir, çıktısı uzamsal ve kanallı bir yapıda olmalıdır);  $\alpha_k^c$ : sınıf  $c$ 'nin skoruna katkıda bulunan,  $k$ -inci öznetelik haritasının önem katsayısı olmak üzere Grad-CAM yöntemi, Denklem (3.29)'da verildiği gibi bu katsayıları gradyanların uzamsal ortalaması yoluyla elde eder.

$$\alpha_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{ij}^k} \quad (3.29)$$

Denklem (3.29)'da verilen  $\frac{\partial y^c}{\partial A_{ij}^k}$ :  $y^c$  sınıf skorunun,  $A^k$  öznetelik haritasındaki konum  $(i, j)$ 'deki piksel değerine göre gradyanıdır.  $Z$ : öznetelik haritasının toplam konum sayısıdır (yani  $Z = H \times W$ ). Bu katsayılar, ilgili öznetelik haritalarına ağırlık olarak uygulanır ve sınıfa özgü dikkat haritası Denklem (3.30)'da verildiği şekilde hesaplanır. ReLU aktivasyonu Denklem (3.30)'da yalnızca pozitif katkılar içeren bölgeleri öne çıkarır, böylece görselleştirilen alanlar yalnızca sınıfı destekleyen yapılar olur. Isı haritası daha sonra giriş görüntüsü boyutlarına ölçeklenip üzerine bindirilerek yorumlanabilir.

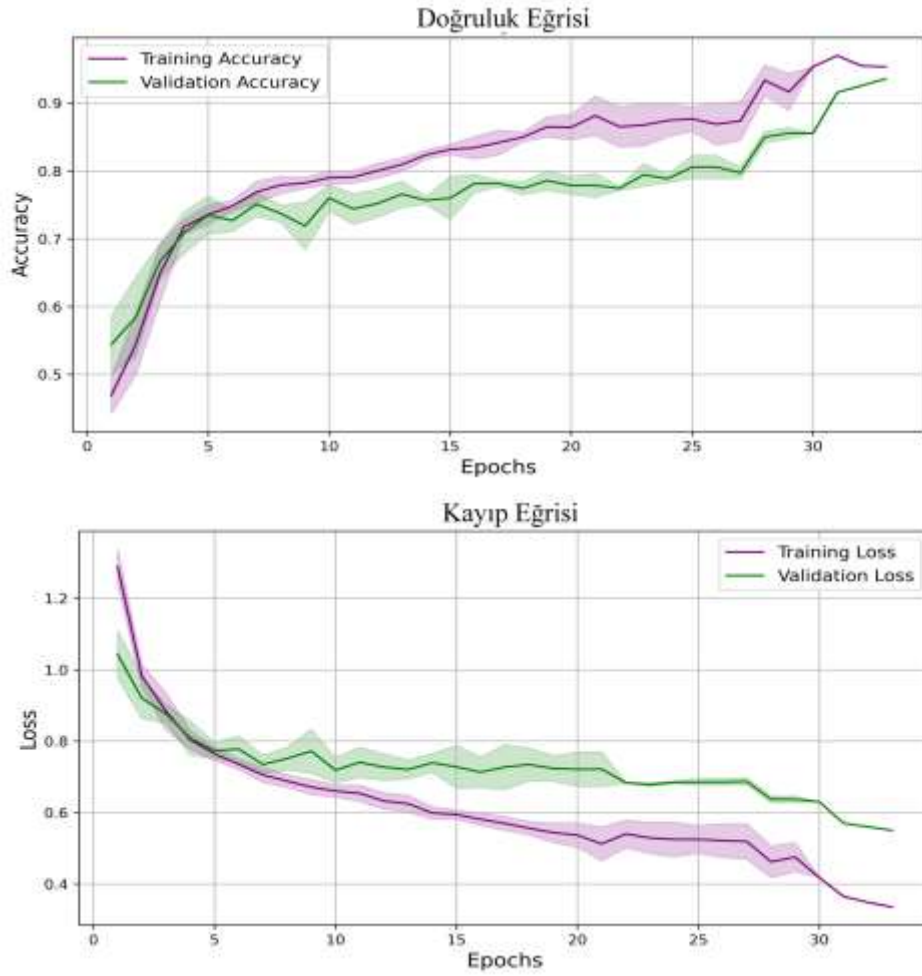
$$L_{Grad-CAM}^c = ReLU(\sum_k \alpha_k^c A^k) \quad (3.30)$$

## 4. BULGULAR

### 4.1 Eğitim ve Doğrulama Performansları

Öğrenme eğrileri, derin sinir ağlarının eğitim dinamiklerini değerlendirmek için vazgeçilmez araçlar olup, modelin eğitim verilerine ne ölçüde uyum sağladığını ve görülmemiş örneklere ne derece genellenebildiğini görsel olarak temsil etmektedir. Bu eğriler, genellikle epoklar boyunca eğitim ve doğrulama doğruluğu ile kayıp değerlerini göstererek, aşırı öğrenme, yetersiz öğrenme ya da kararlı yakınsama gibi durumların ayırt edilmesini mümkün kılar.

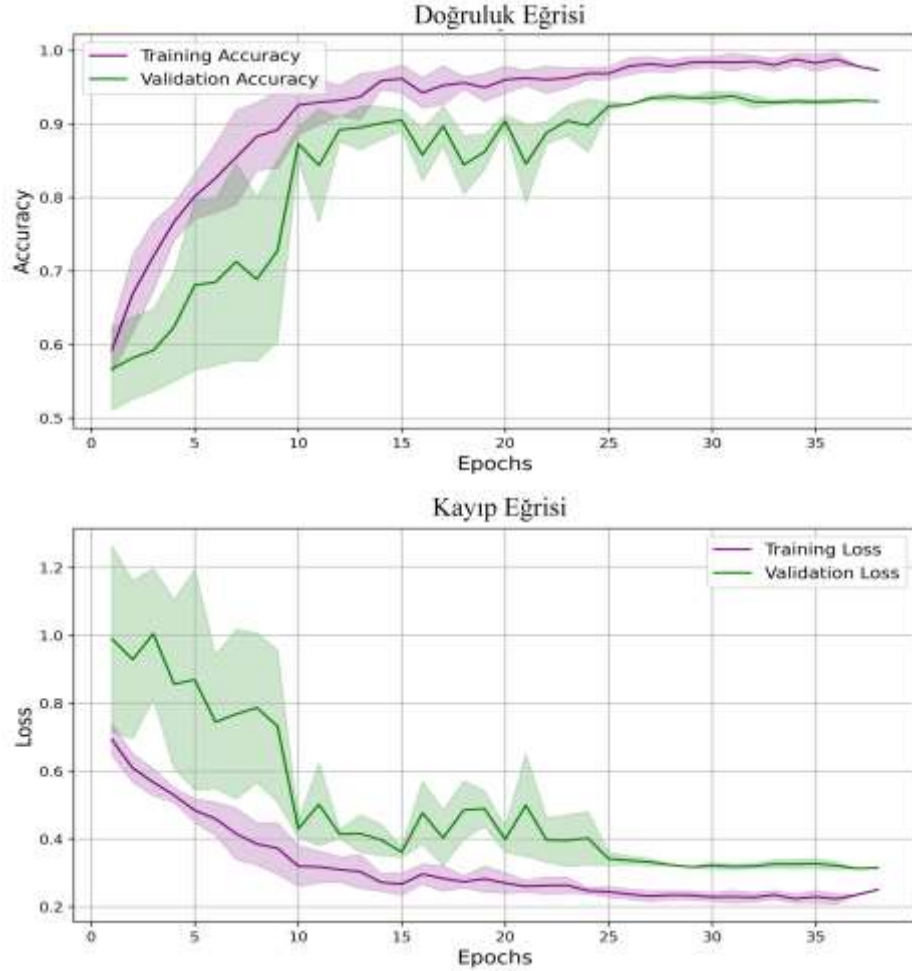
Şekil 4.1, VS1 üzerinde eğitilen CIT modelinin öğrenme eğrilerini göstermektedir. Doğruluk eğrisi, 32 dönem boyunca eğitim ve doğrulama doğruluğunu göstermekte ve minimum aşırı uyumla model performansında tutarlı bir artış göstermektedir. Kayıp eğrisi ise hem eğitim hem de doğrulama kayıplarının istikrarlı bir şekilde azaldığı ve eğitim süreci boyunca istikrarlı bir yakınsamayı göstermektedir. Dar gölgeli alanlar, modelin sağlamlığını yansıtan tekrarlanan çalıştırmalardaki standart sapmayı temsil etmektedir. Üç sınıflı sınıflandırma senaryosunda (VS1), eğitim ve doğrulama doğruluğu arasında mütevazı bir fark gözlenmektedir; bu durum, görevin artan karmaşıklığı nedeniyle beklenebilir bir sonuçtur. Ancak doğrulama başarımları zamanla istikrarlı bir şekilde artmakta olup, modelde uygulanan düzenleme stratejilerinin (örneğin, dropout, stochastic depth) etkili olduğunu göstermektedir. Bu eğriler, CIT modelinin bu çalışmada kullanılan pediatrik panoramik radyografi veri kümesi üzerindeki etkinliğini ve genelleme yeteneğini doğrulamaktadır.



Şekil 4.1 CIT modelinin VS1 üzerindeki eğitim ve doğrulama sürecine ait doğruluk ve kayıp eğrileri

Şekil 4.2, germ eksikliği ve normal vakalar arasında ikili sınıflandırma içeren VS2 için CIT modelinin öğrenme eğrilerini göstermektedir. Doğruluk eğrisi, eğitim ve doğrulama kümeleri için doğruluk eğrilerini gösterirken, kayıp eğrisi 37 eğitim dönemi boyunca ilgili kayıp eğrilerini göstermektedir. Gölge alanlar, farklı doğrulama katlamaları arasındaki performans değişkenliğini gösteren standart sapmaları temsil etmektedir. Model, ilk dönemlerde doğrulukta hızlı bir artış ve ardından yakınsamayı gösteren bir plato eğilimi göstermektedir. Özellikle hem eğitim hem de doğrulama doğrulukları istikrarlı bir şekilde iyileşip birbirine yakın kalmaktadır; bu da modelin iyi genelleştirildiğini ve aşırı uyum belirtileri göstermediğini göstermektedir. Benzer şekilde, eğitim ve doğrulama kayıp eğrileri eş zamanlı olarak azalarak eğitimin sonuna doğru kararlı bir duruma ulaşmakta ve bu da yetersiz uyum veya aşırı uyumun olmadığını daha da doğrulamaktadır. Bu

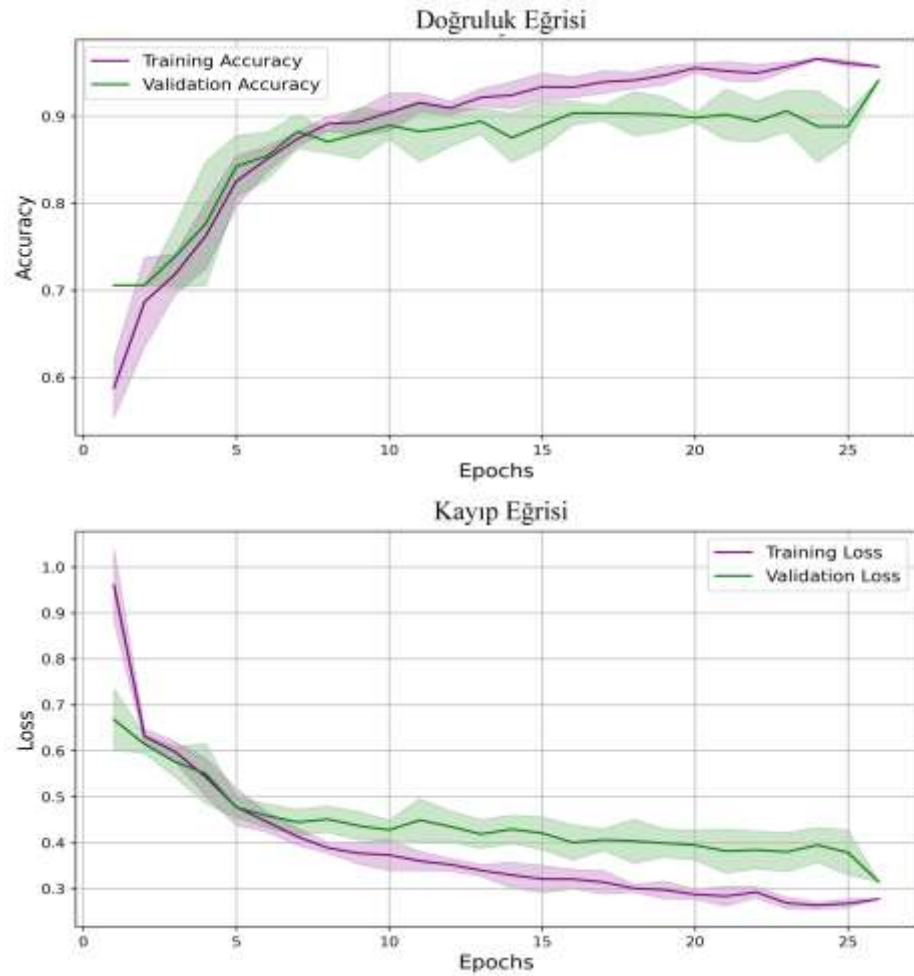
davranış, kararlı yakınsamayı yansıtmakta ve modelin bu ikili görev için ayırt edici özellikleri etkili bir şekilde öğrendiğini göstermektedir.



Şekil 4.2 CIT modelinin VS2 üzerindeki eğitim ve doğrulama sürecine ait doğruluk ve kayıp eğrileri

Şekil 4.3'te, süpernumere dişlerin normal vakalara karşı tespitini içeren ikili sınıflandırma görevi (VS3) için CIT modelinin öğrenme eğrileri sunulmaktadır. Doğruluk eğrisi, 26 dönem boyunca doğruluk eğilimlerini gösterirken, kayıp eğrisi hem eğitim hem de doğrulama kümelerindeki kayıp değerlerinin evrimini temsil etmektedir. Eğitim boyunca hem eğitim hem de doğrulama doğrulukları istikrarlı bir şekilde artarak sırasıyla yaklaşık 0,96 ve 0,93'e ulaşmaktadır; bu da modelin sağlam bir genelleme yeteneğine sahip olduğunu göstermektedir. Nispeten dar güven aralıkları (gölgeli bölgeler), farklı kıvrımlar arasında tutarlı bir performansı yansıtmaktadır. Kayıp eğrilerinde hem eğitim

hem de doğrulama kaybı, aralarında önemli bir sapma olmaksızın sürekli bir düşüş göstermektedir. Bu yakınsama örüntüsü, modelin yetersiz veya aşırı uyumdan muzdarip olmadığını ve bunun yerine kararlı eğitim dinamikleri ve güçlü yakınsama davranışı gösterdiğini doğrulamaktadır. CIT modeli erken dönemlerden itibaren etkili öğrenme göstermektedir ve eğitim ile doğrulama metrikleri arasında güvenilir bir boşluk korumaktadır; bu da süpernümere anomalileri ayırt etmede mimari sağlamlığını daha da vurgulamaktadır.



Şekil 4.3 CIT modelinin VS3 üzerindeki eğitim ve doğrulama sürecine ait doğruluk ve kayıp eğrileri

İkili sınıflandırma senaryolarında (VS2 ve VS3), daha hızlı yakınsama ve eğitim ile doğrulama metrikleri arasında daha sıkı bir uyum gözlenmektedir. Özellikle VS3 veri setinde eğriler neredeyse çakışmaktadır. VS2'de doğrulama kaybında küçük

dalgalanmalar izlenmekle birlikte, bu dalgalanma kontrol altında kalmakta ve genel performansı olumsuz yönde etkilememektedir. Öğrenme sürecinde ani sapmaların veya düzensiz davranışların gözlenmemesi, kararlı bir öğrenme sürecinin göstergesi olarak değerlendirilmektedir. Gözlenen hafif uyumsuzluklar ise, veri setine özgü sınırlılıklara (örneğin sınıf örneklerinin yetersizliği veya sınıf içi varyasyonların belirsizliği) bağlanabilir ve bu durum, ileri düzeyde veri artırma teknikleri ya da örnek çeşitliliğinin artırılması yoluyla iyileştirilebilir. Genel olarak değerlendirildiğinde, öğrenme eğrileri, CIT modelinin verimli şekilde öğrendiğini, güvenilir genelleme performansı sergilediğini ve hem çok sınıflı hem de ikili sınıflandırma görevlerinde sağlam bir dayanıklılık gösterdiğini ortaya koymaktadır. Bu durum, modelin pediatrik dental anomali tespitindeki uygulanabilirliğini desteklemektedir.


## 4.2 Test Performansları

Önerilen CIT modelinin tanısal performansı, üç farklı veri seti üzerinde değerlendirilmiştir: VS1 (çok sınıflı sınıflandırma: germ eksikliği, süpernumere diş ve normal), VS2 (ikili sınıflandırma: germ eksikliği ve normal) ve VS3 (ikili sınıflandırma: süpernumere diş ve normal). Modelin sınıflandırma yeteneklerini ve öğrenme davranışını ortaya koymak amacıyla hem nicel sonuçlar hem de performans eğrileri sunulmuştur. Veri setleri arasındaki karşılaştırmalı analizler, modelin farklı sınıflandırma senaryoları altında gösterdiği genelleme kapasitesine ilişkin önemli çıkarımlar sağlamaktadır.

Şekil 4.4, önerilen CIT modeline ait karışıklık matrislerini göstermektedir. Bu matrisler, test aşamasında elde edilen çıktılar doğrultusunda VS1, VS2 ve VS3 veri setleri için ayrı ayrı sunulmuştur. Her bir karışıklık matrisinde, satırlar gerçek sınıfları, sütunlar ise tahmin edilen sınıfları temsil etmektedir. Diyagonal elemanlar, her bir sınıfa ait doğru sınıflandırma sayısını; diyagonal dışı elemanlar ise hata sınıflandırmaları (FP/FN) ifade etmektedir.

Karışıklık matrislerinden de görülebileceği üzere, CIT modeli tüm veri setlerinde güçlü bir sınıflandırma performansı sergilemiştir. VS1 veri setinde model, 89 adet germ

eksikliği, 57 adet normal ve 22 adet süpernümere dış olgusunu doğru şekilde sınıflandırmıştır; yalnızca sınırlı sayıda hatalı sınıflandırma gerçekleşmiştir. VS2’de ise 89 germ eksikliği ve 57 normal olgunun tamamı doğru şekilde tanımlanarak neredeyse kusursuz bir ayırım başarısı elde edilmiştir. Benzer biçimde, VS3 veri setinde 56 normal ve 23 süpernümere olgu doğru sınıflandırılmış, yalnızca 4 FP ve 2 FN hata kaydedilmiştir.



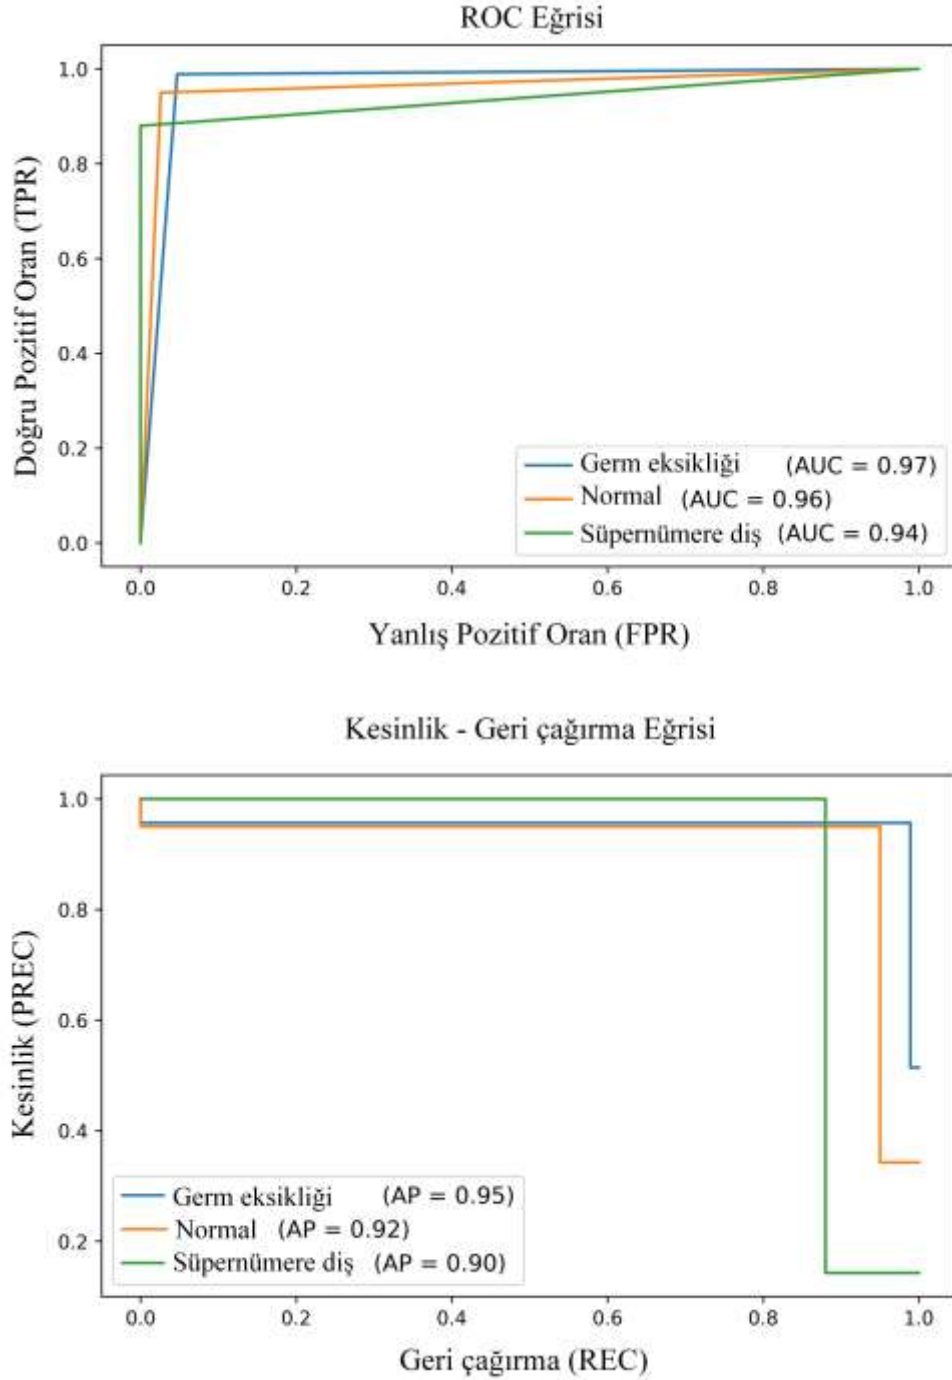
Şekil 4.4 CIT modelinin üç farklı veri seti için karışıklık matrisleri

Bu matrislerin karşılaştırmalı analizi, ikili sınıflandırma görevlerinin (VS2 ve VS3), çok sınıflı sınıflandırmaya (VS1) kıyasla biraz daha yüksek PREC ve REC değerleri sunduğunu ortaya koymaktadır. Bu durum, literatürde yaygın olarak gözlenen, ikili sınıflandırma görevlerinin yapısal olarak daha az karmaşık olması eğilimiyle uyumludur. Bununla birlikte, daha zorlu olan üç sınıflı senaryoda dahi CIT modeli, yüksek doğruluk oranlarını korumuş, özellikle normal ve süpernümere dış sınıfları arasındaki yakın yapısal benzerliğe rağmen sınıflar arası karışıklığı minimum düzeyde tutmayı başarmıştır. Özellikle germ eksikliği sınıfının diğer sınıflardan güçlü şekilde ayrılabilmesi, modelin klinik uygulanabilirliği açısından kritik bir gerekliliği karşıladığını göstermektedir.

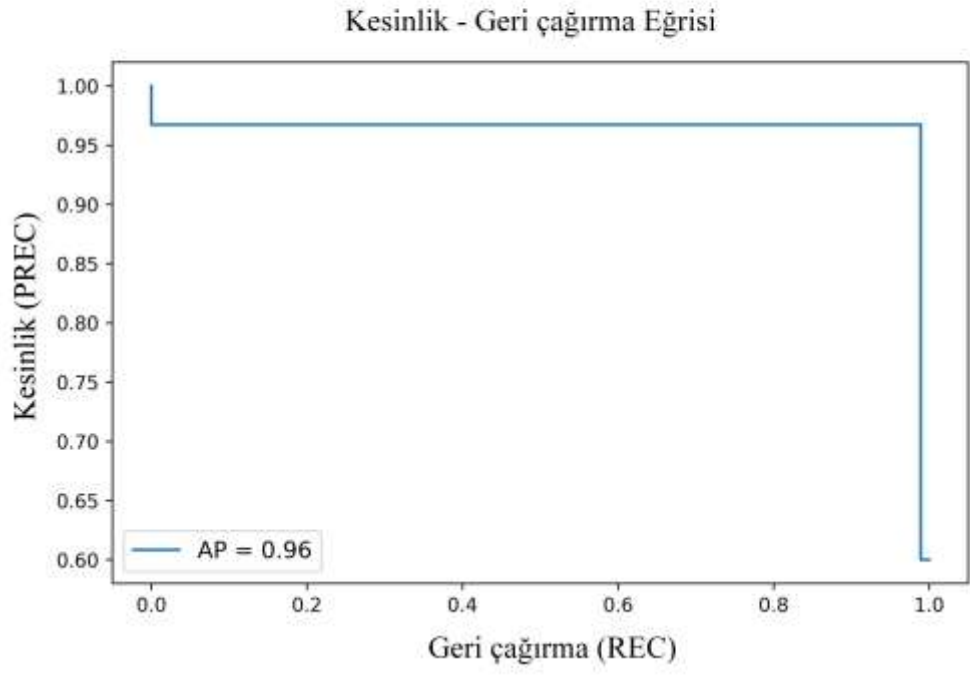
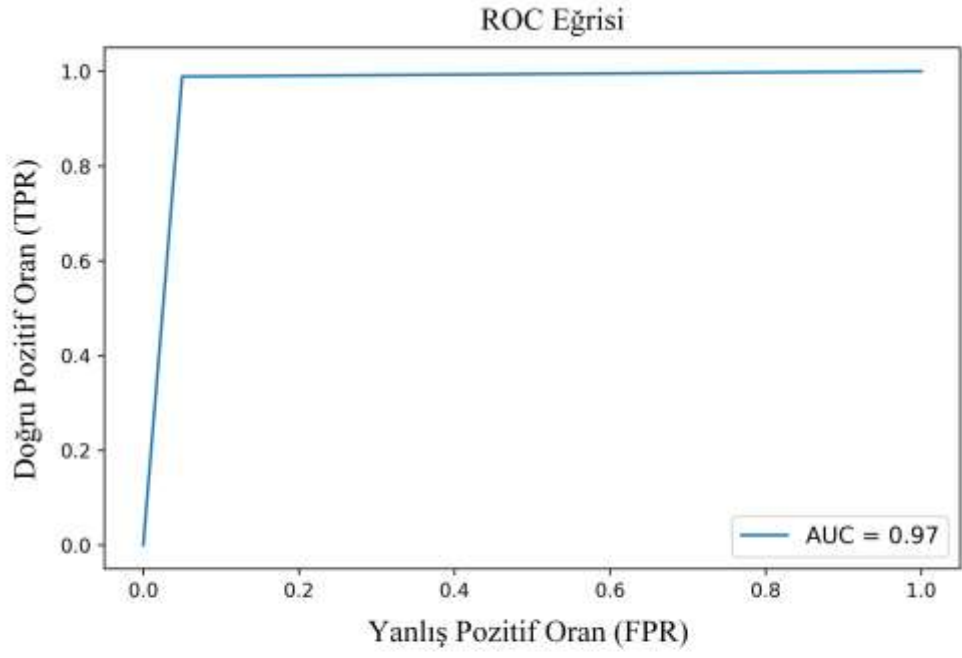
Şekil 4.5, 4.6 ve 4.7 CIT modelinin sırasıyla VS1, VS2 ve VS3 test veri setleri üzerinde elde ettiği ROC eğrilerini ve kesinlik-geri çağırma (precision-recall, PREC-REC) eğrilerini göstermektedir. Çok sınıflı sınıflandırma görevinde (VS1), bir-sınıfa-karşı-diğerleri (one-vs-rest) yaklaşımı kullanılarak germ eksikliği, normal ve süpernümere dış sınıfları için ayrı ayrı ROC ve PREC-REC eğrileri oluşturulmuştur. İkili sınıflandırma görevlerinde (VS2 ve VS3), standart ikili ROC ve PREC-REC eğrileri çizilmiştir. Her bir ROC eğrisinde, çeşitli eşik seviyelerinde doğru pozitif oranı (true positive rate, TPR), yanlış pozitif oranına (false positive rate, FPR) karşı çizilmiştir; PREC-REC eğrilerinde ise, PREC, REC karşısında gösterilerek, özellikle sınıf dengesizliği bulunan durumlarda tamamlayıcı bir değerlendirme perspektifi sunulmuştur.

ROC eğrilerinin incelenmesi, CIT modelinin tüm sınıflandırma görevlerinde yüksek ayırt edicilik performansı sergilediğini ortaya koymaktadır. VS1 için model, germ eksikliği, normal ve süpernümere dış sınıflarında sırasıyla %97, %96 ve %94 AUC skorlarına ulaşmıştır; bu da modelin sınıfa özgü ayırım gücünün yüksek olduğunu göstermektedir. VS2’de (germ eksikliği ve normal), AUC skoru %97 olarak elde edilirken, VS3’te (normal ve süpernümere dış) %93’lük bir AUC değeri rapor edilmiştir. PREC-REC eğrileri de bu bulguları desteklemekte olup, AP değerleri VS1 için sırasıyla %95, %92 ve %90 olarak hesaplanmıştır. İkili sınıflandırma görevlerinde ise, VS2 için %96, VS3 için ise %81 AP değeri elde edilmiştir. Bu karşılaştırmalı analizler, CIT modelinin özellikle germ eksikliği ikili sınıflandırmasında (VS2), ROC-AUC ve AP skorlarının niteliksel olarak mükemmele yakın değerlere ulaştığını göstermektedir. Her ne kadar süpernümere

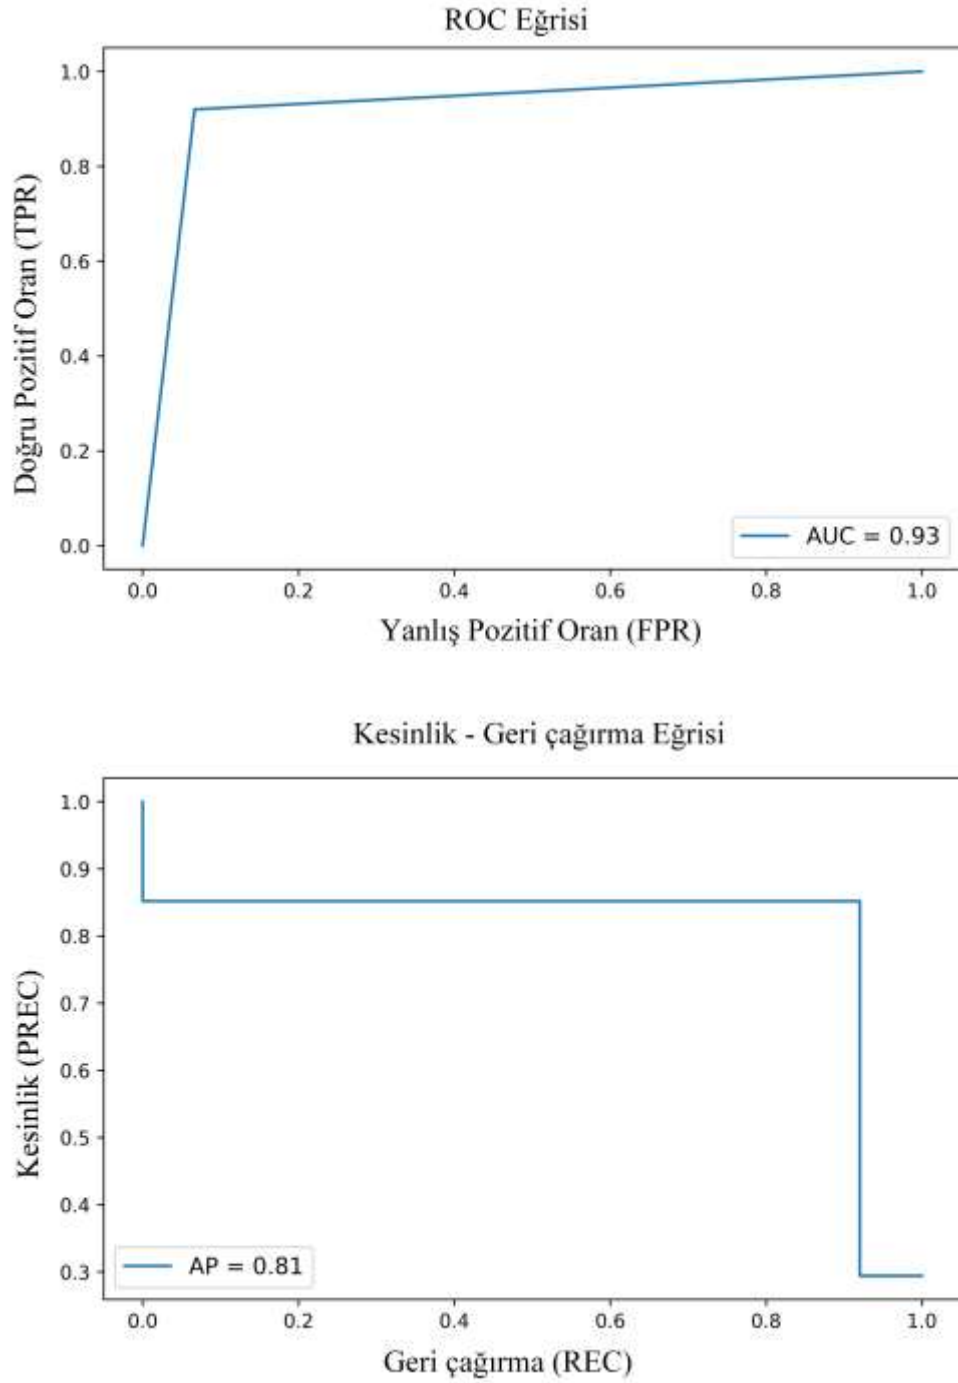
diş tespiti (VS3) senaryosunda %81'lik bir AP değeriyle görelî bir performans düşüşü gözlenirse de bu sonuçlar söz konusu anomalilerin nadir görülmesi ve yapısal karmaşıklığı göz önünde bulundurulduğunda klinik olarak kabul edilebilir düzeydedir.



Şekil 4.5 CIT modelinin VS1 için ROC ve PREC-REC eğrileri



Şekil 4.6 CIT modelinin VS2 için ROC ve PREC-REC eğrileri



Şekil 4.7 CIT modelinin VS3 için ROC ve PREC-REC eğrileri

Çizelge 4.1, CIT modelinin ve karşılaştırmalı üç temel modelin (CCT, ViT ve CNN) VS1, VS2 ve VS3 test veri setleri üzerindeki tanısal performans metriklerini sunmaktadır. VS1’de CIT modeli tüm metriklerde üstün performans göstermiştir: %96,00 ACC, %96,89 PREC, %93,96 REC ve %95,29 F1 skoru elde edilmiştir. Karşılaştırmalı olarak, CCT %86,85 ACC ve %83,67 F1 skoru ile, ViT ise %83,42 ACC ve %74,90 F1 skoru ile

daha düşük başarı göstermiştir. Temsilci CNN modeli olan ResNet152V2, yalnızca %79,42 ACC ve %69,06 F1 skoru ile en düşük performansı sergilemiştir. AUC açısından da CIT %95,76 değeriyle, CCT (%86,05), ViT (%81,31) ve CNN (%77,16)'nin üzerinde yer almıştır. JSC (%91,05) ve MCC (%93,28) değerleri de benzer biçimde, CIT modelinin çok sınıflı dental anomali ayırımında üstünlüğünü doğrulamıştır. En yakın rakip olan CCT, %72,47 JSC ve %78,15 MCC ile geride kalmıştır. Bu sonuçlar, CIT modelinin karmaşık çok sınıflı sınıflandırma problemlerinde dahi yüksek ayırım gücünü koruyabildiğini göstermektedir.

VS2 veri setinde, tüm modellerin başarımı artmış ve bu durum, ikili sınıflandırma görevlerinin daha düşük yapısal karmaşıklık içermesiyle tutarlılık göstermiştir. CIT, %97,33 ACC, %97,50 PREC, %96,94 REC ve %97,20 F1 skoru ile en yüksek performansa ulaşmış; AUC skoru %96,94 olarak kaydedilmiştir. CCT %90,00 ACC ve %89,19 F1 skoruyla ikinci sırada yer alırken, ViT %87,33 ACC ve %86,66 F1 skoruna ulaşmıştır. CNN modeli olarak kullanılan VGG16, %94,00 ACC ve %93,79 F1 skoru ile rekabetçi bir performans göstermiştir; ancak %88,34 JSC ve %87,67 MCC değerleriyle, CIT'nin %94,57 JSC ve %94,45 MCC skorlarının gerisinde kalmıştır. Bu bulgular, CNN'lerin daha basit görevlerde yeterli performans gösterebildiğini, ancak CIT modelinin hem SEN hem de özgüllük (specificity, SPEC) bakımından tüm rakiplerini tutarlı biçimde geride bıraktığını ortaya koymaktadır.

VS3, süpernümere anomalilerin nadirliği ve morfolojik benzerliği nedeniyle daha zorlayıcı bir sınıflandırma senaryosu sunmaktadır. Buna rağmen, CIT modeli %92,94 ACC, %90,86 PREC, %92,66 REC ve %91,68 F1 skoru ile yine en yüksek performansa ulaşmıştır. CCT ve ViT bu görevde belirgin performans düşüşü göstermiş; sırasıyla %82,83 ve %77,64 ACC ile, %82,83 ve %74,92 F1 skorları elde etmişlerdir. CNN modeli olarak seçilen Xception, bu zorlayıcı senaryoya karşı daha dayanıklı bir yapı sergilemiş; %89,41 ACC ve %87,90 F1 skoruna ulaşmıştır. Ancak, bu sonuçlar da CIT modelinin gerisinde kalmıştır. AUC skorları da benzer bir eğilim göstermiş; CIT %92,66 AUC ile en yüksek değeri alırken, CCT %82,83, ViT %77,16 ve CNN %90,16 ile daha düşük başarı göstermiştir. JSC ve MCC metrikleri de bu bulguları desteklemekte ve CIT modelinin üstün genelleme ve anomali tanıma yeteneklerini ortaya koymaktadır.

Üç farklı veri seti üzerindeki test performansları analiz edildiğinde hem sınıflandırma görevinin karmaşıklığının hem de veri setinin büyüklüğünün model başarımını doğrudan etkilediği açıkça görülmektedir. Üç sınıf ve toplam 1.170 örnek içeren en kapsamlı veri seti olan VS1, daha zorlu bir sınıflandırma problemi sunmuştur. Bu artan karmaşıklığa rağmen, CIT modeli tüm metriklerde CCT, ViT ve CNN mimarilerine kıyasla anlamlı şekilde üstün performans sergilemiş, yüksek başarım seviyesini koruyabilmiştir. Bu durum, CIT mimarisindeki involüsyon tabanlı tokenizasyonun, yerel ve küresel öznitelik etkileşimlerinin kritik öneme sahip olduğu çok sınıflı senaryolarda son derece etkili olduğunu göstermektedir.

VS2 veri setinde, germ eksikliği ve normal sınıfları arasında yapılan ikili sınıflandırma görevinde tüm modellerin, VS1'e kıyasla daha yüksek performans gösterdiği izlenmiştir. Bu bulgu, ikili sınıflandırma problemlerinin görece daha düşük karmaşıklık düzeyine sahip olmasıyla uyumludur. Özellikle CNN ve CCT modellerinde dikkate değer bir iyileşme gözlenmiş olsa da CIT modeli üstünlüğünü korumuş ve ACC, REC, F1 skoru ve MCC gibi kritik ölçütlerde en yüksek sonuçlara ulaşmıştır. Modelin görev karmaşıklığı farklılıklarına rağmen tutarlı bir şekilde yüksek performans sergilemesi, CIT mimarisinin sağlamlık ve uyarlanabilirlik özelliklerini güçlendirmektedir. VS2'deki görece yüksek örnek sayısının ( $n = 1.004$ ) genel başarıyı artırıcı etkisi bulunsa da CIT'nin diğer modellerle arasındaki fark yalnızca veri miktarına değil, mimarisel avantajlara da dayandığını ortaya koymaktadır.

VS3 veri seti, en düşük örnek sayısına ( $n = 565$ ) sahip olup, süpernümere dış tespiti gibi nadir anomalilerin ayırt edilmesini hedefleyen en zorlu sınıflandırma görevini temsil etmektedir. Bu görevde, özellikle ViT ve CCT modellerinde belirgin bir performans düşüşü gözlenmiştir. Bu durum, sınırlı veri ortamlarında nadir dental anomalilerin tespitinin güçlüğüne vurgulamaktadır. Bununla birlikte, CIT modeli bu zorlu koşullarda dahi tüm metriklerde diğer modellerin üzerinde performans göstermiş ve veri kısıtlılığına rağmen dikkate değer bir genelleme kapasitesi sergilemiştir. CNN mimarisi, görece rekabetçi sonuçlar üretmiş olsa da özellikle REC ve MCC gibi anomali tespitinde kritik rol oynayan metriklerde CIT'nin gerisinde kalmıştır.

Çizelge 4.1 CIT ve SOTA modellerinin üç farklı veri setindeki performansları

Model	ACC (%)	PREC (%)	REC (%)	F1 Skor (%)	AUC (%)	JSC (%)	MCC (%)
VS1: Germ eksikliği – Normal – Süpernümere dış							
CIT	96,00	96,89	93,96	95,29	95,76	91,05	93,28
CCT	86,85	89,04	80,59	83,67	86,05	72,47	78,15
ViT	83,42	83,23	72,74	74,90	81,31	62,81	71,75
CNN (ResNet152V2)	79,42	77,59	67,11	69,06	77,16	56,21	64,73
VS2: Germ eksikliği – Normal							
CIT	97,33	97,50	96,94	97,20	96,94	94,57	94,45
CCT	90,00	91,52	88,05	89,19	88,05	80,62	79,50
ViT	87,33	86,87	86,66	86,76	86,66	76,73	73,54
CNN (VGG16)	94,00	93,51	94,16	93,79	94,16	88,34	87,67
VS3: Süpernümere dış – Normal							
CIT	92,94	90,86	92,66	91,68	92,66	84,81	83,51
CCT	82,35	79,03	82,83	80,20	82,83	67,44	61,75
ViT	77,64	74,02	77,16	74,92	77,16	60,60	51,09
CNN (Xception)	89,41	86,51	90,16	87,90	90,16	78,67	76,59

### 4.3 Yapay Zeka Modellerinin İnsan Uzmanlarla Kıyaslanması

Yapay zeka tabanlı modelin tanısal başarımını insan uygulayıcılarla karşılaştırmak amacıyla, iki bağımsız uzman grup oluşturulmuştur: Uzman Pedodontist Grubu (UPG) ve Genel Diş Hekimi Grubu (GDG). UPG, klinik deneyimleri 6 ila 9 yıl arasında değişen üç pedodontistten oluşurken; GDG, klinik deneyimi 20 ila 33 yıl arasında olan üç genel diş hekiminden oluşmaktadır. GDG grubunda ayrıca ağız, diş ve çene radyolojisi alanında uzmanlaşmış bir diş hekimini de yer almıştır. Her bir klinisyen, üç sınıflı sınıflandırma görevi içeren VS1 test veri setini, gerçek yaşam koşullarını taklit etmek üzere zaman kısıtlı bir ortamda bağımsız olarak değerlendirmiştir. Gözlemciler arası değişkenliği en aza indirmek ve uzman gruplarıyla model arasında adil bir karşılaştırma gerçekleştirebilmek amacıyla, her iki grup için çoğunluk oyu (majority voting) yöntemiyle her bir vaka için tek bir fikir birliği etiketi (consensus label) oluşturulmuştur. Bu etiketler, gerçek etiketlerle karşılaştırılarak standart performans metrikleri hesaplanmıştır. Elde edilen başarımlara ilişkin sonuçlar, Çizelge 4.2’de sunulmaktadır.

Çizelge 4.2 incelendiğinde, önerilen CIT modelinin tüm değerlendirme metriklerinde her iki uzman grubunun üzerinde performans gösterdiği görülmektedir. CIT modeli, %96,00 ACC, %95,29 F1 skoru ve %93,28 MCC değerleri ile, karmaşık bir üç sınıflı tanı senaryosunda dahi güçlü bir sınıflandırma yeteneği sergilemiştir. İlginç bir şekilde, GDG grubu, UPG grubuna kıyasla anlamlı derecede daha yüksek performans göstermiştir: GDG'nin F1 skoru %91,09, AUC değeri ise %92,71 olarak kaydedilirken, UPG'nin F1 skoru %74,67, AUC değeri ise %80,18 olarak ölçülmüştür. Bu sonuçları daha da bağlandırmak için değerlendiriciler arası uyum analiz edilmiştir. Fleiss'  $\kappa$ , UPG içinde orta düzeyde uyum ( $\kappa = 0,4325$ ) ve GDG içinde zayıf-orta düzeyde uyum ( $\kappa = 0,3620$ ) olduğunu göstermiştir. Çiftler halinde Cohen'in  $\kappa$  değerleri 0,1426 ile 0,6916 arasında geniş bir aralıkta değişmiştir ve bazı uzman çiftlerinin güçlü bir tutarlılık sergilerken diğerlerinin önemli ölçüde farklılaştığını göstermiştir. Referans standardıyla kıyaslandığında, GDG (ACC = %91,43,  $\kappa = 0,8528$ , “neredeyse mükemmel”), UPG'den (ACC = %75,28,  $\kappa = 0,5906$ , “orta-önemli”) daha yüksek bir uyum elde etmiştir. Bu bulgular, panoramik radyografilerden elde edilen diş anomalilerinin teşhisinde insan karar alma sürecinin doğasında var olan heterojenliği vurgulamaktadır. Birlikte ele alındığında, bu sonuçlar iki önemli içgörüyü vurgulamaktadır: (i) insan uzmanların kendileri yalnızca orta düzeyde grup içi ve gruplar arası uyum sergilemiştir ve (ii) CIT modeli, klinisyenler arasında gözlemlenen değişkenlikten daha tutarlı ve tekrarlanabilir çıktılar sağlamıştır. Bu, önerilen çerçevenin, özellikle uzman yorumlarının tutarsızlığa maruz kaldığı durumlarda, güvenilir bir tanı aracı olarak potansiyelini vurgulamaktadır.

Çizelge 4.2 VS1 için CIT ve insan uzmanların sınıflandırma performansları

<b>Model</b>	<b>ACC (%)</b>	<b>PREC (%)</b>	<b>REC (%)</b>	<b>F1 Skor (%)</b>	<b>AUC (%)</b>	<b>JSC (%)</b>	<b>MCC (%)</b>
CIT	96,00	96,89	93,96	95,29	95,76	91,05	93,28
UPG	75,43	80,45	75,43	74,67	80,18	59,94	62,29
GDG	91,43	92,13	91,43	91,09	92,71	84,11	85,75

UPG: Uzman Pedodontist Grubu, GDG: Genel Diş Hekimi Grubu

#### 4.4 İstatistiksel Analiz Bulguları

Önerilen model, SOTA modelleri ve insan uzman grupları arasındaki gözlemlenen performans farklarının istatistiksel olarak anlamlı olup olmadığını değerlendirmek amacıyla, VS1 test veri seti üzerinde iki kuyruklu z-testi yaklaşımıyla McNemar testi uygulanmıştır. Bu test, iki sınıflandırıcının aynı örnekler üzerindeki ikili sınıflandırma sonuçlarını eşleştirilmiş şekilde karşılaştırmakta ve bu doğrultuda  $2 \times 2$ 'lik bir kontenjans tablosu oluşturarak, yalnızca modeller arasındaki çelişkili sınıflandırma durumlarını dikkate almaktadır. Özellikle, bir modelin doğru sınıfladığı ancak diğerinin yanlış sınıfladığı örnekler (ve tam tersi) sayılarak bu asimetri üzerinden z-skoru hesaplanmakta ve bu değerden p-değeri türetilmektedir. Genel olarak  $p < 0,05$  eşliği farkın istatistiksel olarak anlamlı kabul edilmesi için kullanılır; bu durumda, modeller arasındaki performans farkının tesadüfen ortaya çıkma olasılığı düşüktür. Ancak iki kuyruklu McNemar testlerine ek olarak, çoklu karşılaştırmaları kontrol etmek için bir Bonferroni düzeltmesi uygulanmıştır. Önerilen CIT modeli ile her bir karşılaştırmacı (CCT, ViT, CNN, UPG, GDG) arasındaki beş önceden belirlenmiş karşılaştırma odak noktamızı oluşturmaktadır. Buradan yola çıkarak  $\alpha_{adj} = \frac{0,05}{5} = 0,01$ ,  $|z| \geq 2,57$  ayarlanmış bir anlamlılık eşliği sağlanmaktadır. Altı yöntem arasında keşifsel tüm çift karşılaştırmaları da hesaplanmıştır ( $m = 15$ ), ancak çalışmanın temel amacının CIT'yi alternatif yaklaşımlarla karşılaştırmak olması nedeniyle bunların yorumlanması ikincil olarak kabul edilmiştir.

Çizelge 4.3, tüm ikili McNemar testi karşılaştırmalarına ait z-skorlarını raporlamakta; oklar üstünlük yönünü göstermektedir. Bonferroni düzeltilmiş birincil aile ölçütü altında tablo şu şekilde yorumlanır: önerilen CIT modeli, CCT ( $z = 3,26$ ), ViT ( $z = 4,01$ ), CNN ( $z = 4,90$ ) ve UPG'ye ( $z = 5,19$ ) kıyasla anlamlı düzeyde üstündür; buna karşın GDG üzerindeki üstünlüğü düzeltilmiş eşliğe ulaşmamaktadır ( $z = 1,78$ ) ve ihtiyatlı kontrol altında GDG ile istatistiksel olarak farksız kabul edilir. Birincil aile dışında kalan (keşifsel) karşılaştırmalar, GDG'nin UPG'yi ( $z = 4,80$ ), CNN'i ( $z = 3,77$ ) ve ViT'i ( $z = 2,74$ ) aynı eşikte geride bıraktığını, ancak CCT'yi geçemediğini ( $z = 1,56$ ) göstermektedir. Yapay zeka taban çizgileri arasında CCT-ViT ( $z = 1,09$ ), CCT-CNN ( $z$

= 2,19) ve ViT-CNN ( $z = 1,40$ ) karşılaştırmaları anlamlı değildir; buna karşılık CCT, UPG'den anlamlı olarak daha iyidir ( $z = 2,72$ ). ViT-UPG ( $z = 1,97$ ) ve CNN-UPG ( $z = 0,96$ ) de anlamlı değildir. Genel olarak CIT, GDG hariç tüm karşılaştırmalara karşı en yüksek performansını sürdürmekte (GDG ile performans karşılaştırılabilir düzeydedir); öte yandan GDG en güçlü insan grubu olarak öne çıkmakta ve ayarlanmış karar kuralı altında çoğu yapay zeka taban çizgisi birbirinden ayırt edilememektedir.

Duyarlılık analizi (sensitivity analysis) kapsamında çoğulluk kontrolü tüm 15 ikili karşılaştırma için yeniden uygulanmıştır (Bonferroni,  $\alpha_{adj} = 0,0033$ ; iki yönlü kritik değer  $|z| \geq 2,93$ ). Bu daha sıkı ölçüt altında temel sonuçlar değişmemektedir: CIT, CCT'ye ( $z = 3,26$ ), ViT'e ( $z = 4,01$ ), CNN'e ( $z = 4,90$ ) ve UPG'ye ( $z = 5,19$ ) karşı anlamlı biçimde üstündür; buna karşın GDG'ye karşı üstünlüğü anlamlı değildir ( $z = 1,78$ ). Kalan (CIT dışı) çiftler arasında yalnızca GDG'nin EPG'ye ( $z = 4,80$ ) ve CNN'e ( $z = 3,77$ ) üstünlüğü anlamlılığını korumaktadır; GDG-ViT karşılaştırması ( $z = 2,74$ ) ayarlanmış eşiği artık karşılamamakta, GDG-CCT ( $z = 1,56$ ) ise anlamlı değildir. Başlangıç düzeyi yapay zeka modelleri bu düzeyde birbirinden ayırt edilememektedir (CCT-ViT  $z = 1,09$ , CCT-CNN  $z = 2,19$ , ViT-CNN  $z = 1,40$ ) ve UPG'den farkları genişletilmiş düzeltme altında anlamlılığını yitirmektedir (CCT-UPG  $z = 2,72$ , ViT-UPG  $z = 1,97$ , CNN-UPG  $z = 0,96$ ). Genel olarak, sıralama sağlamdır: CIT, GDG ile istatistiksel başa başlık dışında en iyi performansı sürdürürken, GDG en güçlü insan grubu olarak öne çıkmaktadır. Bu durum, derin öğrenme sistemlerinin hala uzman insan bilgisinden öğrenebileceği alanlar bulunduğunu da göstermektedir.

Çizelge 4.3 VS1 için McNemar testinin sonuçları

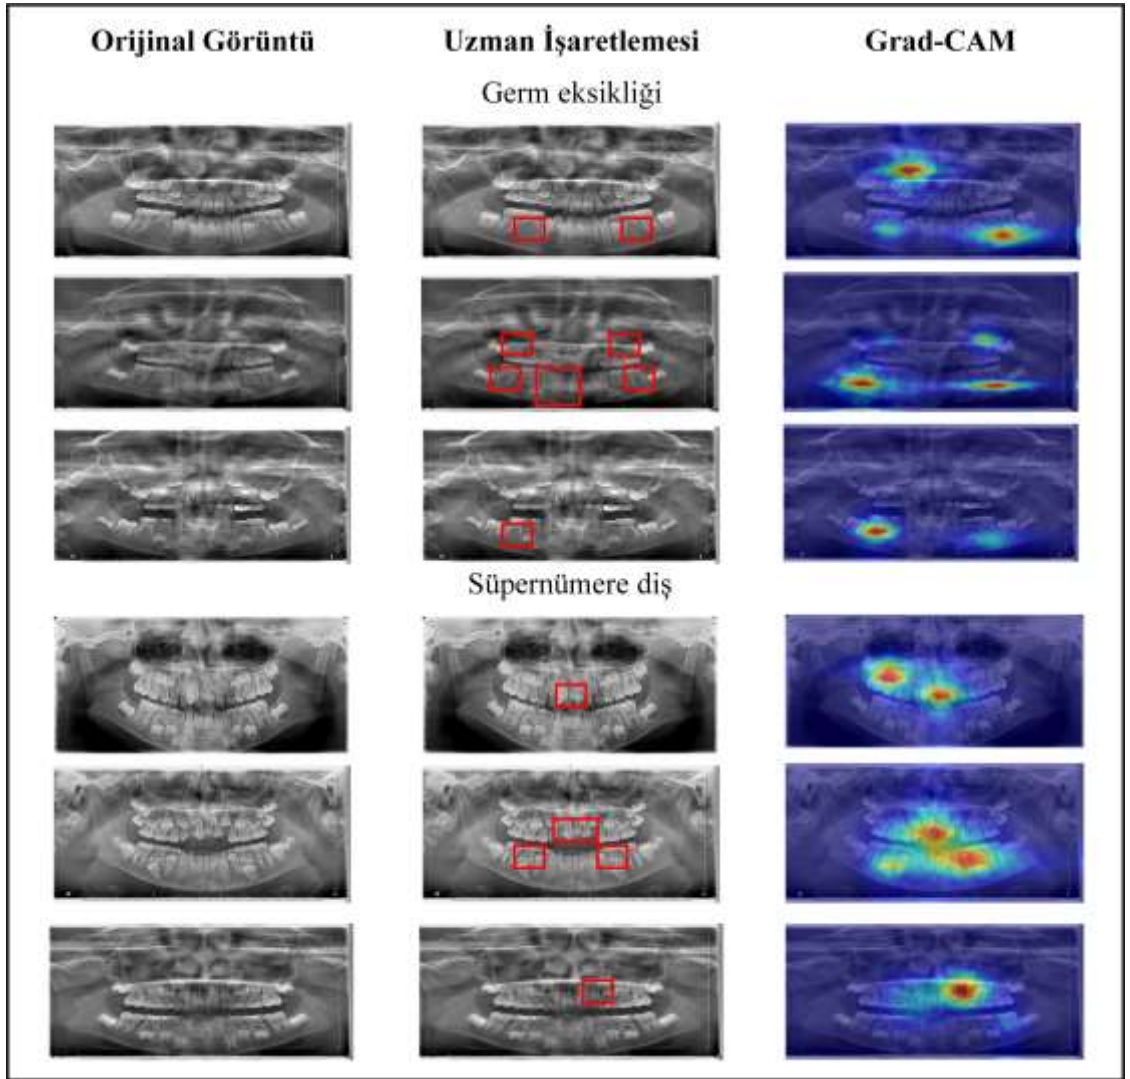
	<b>CCT</b>	<b>ViT</b>	<b>CNN</b>	<b>UPG</b>	<b>GDG</b>
<b>CIT</b>	← 3,26	← 4,01	← 4,90	← 5,19	← 1,78
<b>CCT</b>		← 1,09	← 2,19	← 2,72	↑ -1,56
<b>ViT</b>			← 1,40	← 1,97	↑ -2,74
<b>CNN</b>				← 0,96	↑ -3,77
<b>UPG</b>					↑ -4,80
UPG: Uzman Pedodontist Grubu, GDG: Genel Diş Hekimi Grubu					

#### 4.5 Açıklanabilir Yapay Zeka Bulguları

CIT modelinin yorumlanabilirliğini artırmak ve karar verme mekanizmalarına ilişkin içgörüler sunmak amacıyla, açıklanabilir yapay zeka tekniklerinden yararlanılmıştır. CIT mimarisi, involüsyon tabanlı öznitelik çıkarımı ile transformatör temelli küresel bağlamsal modellemeyi birleştirmektedir. Özellikle CIT tokenizer yapısındaki involüsyon katmanları sayesinde, giriş görüntüsündeki mekansal ilişkiler, transformatör kodlayıcı aşamasından önce korunmaktadır. Ancak, öznitelikler projelendirilip transformatör bloklarında işlendiğinde, veriler sıralı bir formata dönüştürüldüğünden dolayı mekansal karşılık (spatial correspondence) kaybolmaktadır. Bu mimari özellik nedeniyle, mekansal bilgilere dayanan açıklanabilirlik yöntemleri, yalnızca tokenizasyon aşamasında üretilen involüsyonel öznitelik haritaları üzerinde anlamlı şekilde uygulanabilmektedir. Bu nedenle, Grad-CAM uygulaması, sekans projeksiyonundan önceki son involüsyon katmanının çıktısı üzerine gerçekleştirilmiştir. Grad-CAM, hedeflenen sınıfın çıkışı ile öznitelik aktivasyonları arasındaki türevleri hesaplayarak sınıfa özgü ısı haritaları üretir ve böylece ilgili tahminde en fazla katkı sağlayan bölgeleri öne çıkarır. Bu yaklaşım, modelin dikkat mekanizmalarının anlaşılmasını sağlayarak, özellikle tıbbi görüntüleme uygulamalarında model çıktılarının klinik geçerliliğinin desteklenmesi açısından kritik öneme sahiptir.

Şekil 4.9, involüsyonel özniteliklerden türetilen temsili Grad-CAM görselleştirmelerini sunmaktadır. Her bir test örneği için üç sütun gösterilmiştir: orijinal panoramik radyografi, pedodontist tarafından işaretlenmiş dental anomalilere ait ROI'ler ve involüsyonel öznitelik haritalarından türetilmiş Grad-CAM ısı haritası. Germ eksikliği örneklerinde, Grad-CAM aktivasyonları pedodontist tarafından işaretlenen dişsiz alanlarla açık biçimde örtüşmekte ve ön (anterior) ve arka (posterior) bölgelerdeki eksik diş germelerini vurgulamaktadır. Model, birden fazla eksik germ mevcut olduğunda dahi, kritik tanısal bölgelere tutarlı şekilde odaklanabilmektedir. Süpernumere diş vakalarında, Grad-CAM ısı haritaları, uzman etiketlemeleriyle uyumlu olarak ekstra dental yapıların bulunduğu lokalize bölgeleri başarıyla vurgulamaktadır. Özellikle dikkat çekici olan, aktivasyon haritalarının dağınık değil, kompakt ve hedefe yönelik bir dikkat örüntüsü sergilemesidir; bu da CIT modelinin, çevresel anatomik yapılardan etkilenmeden, klinik

açından anlamlı özniteliklere seçici biçimde odaklanabildiğini ortaya koymaktadır. Bu açıklanabilirlik sonuçları, CIT modelinin karar verme süreçlerinin uzman klinik yorumlarla yüksek derecede örtüştüğünü göstermektedir. Grad-CAM görselleştirmelerinde gözlemlenen odaklanmış dikkat, modelin özellikle pediatrik panoramik radyografilerdeki anomali tespiti gibi yüksek mekansal hassasiyet gerektiren senaryolarda, güvenilirliğini ve sağlamlığını desteklemektedir.



Şekil 4.8 Çeşitli test görüntüleri için Grad-CAM görselleri

## 5. TARTIŞMA

CIT modelinin elde ettiği tanısal performans, önerilen mimarinin pediatrik dental anomalilerin tespiti konusunda anlamlı iyileştirmeler sunduğunu ortaya koymaktadır. Tüm veri setlerinde, CIT modeli, temel modeller olan CCT, ViT ve CNN yapılarına kıyasla ACC, PREC, REC, F1 skoru, AUC, JSC ve MCC metriklerinde tutarlı ve üstün performans göstermiştir. Bu üstünlük, yalnızca ikili sınıflandırma görevlerinde değil, aynı zamanda daha karmaşık olan çok sınıflı senaryoda da açıkça gözlemlenmiştir. Bu durum, involüsyon tabanlı tokenizasyonun, transformatör temelli küresel bağlamsal modelleme ile birleştirilmesinin, güçlü ve genellenebilir bir öznitelik çıkarım mekanizması sunduğunu ortaya koymaktadır. Ayrıca, Grad-CAM ile gerçekleştirilen açıklanabilirlik analizleri, modelin tahminlerinin klinik geçerliliğini güçlendirmiş; CIT'nin dikkatini klinik açıdan anlamlı anatomik bölgelere yönlendirdiğini göstermiştir.

CIT mimarisinin temel avantajlarından biri, mimari açıdan kompakt, hafif ve modüler bir yapıya sahip olmasıdır. Sabit evrişim filtreleri yerine uyarlanabilir involüsyon filtreleri kullanılarak, CIT modeli mekansal olarak dinamik öznitelik çıkarımını mümkün kılarken, aynı zamanda son derece düşük sayıda parametre ile çalışmaktadır. Modelin toplam parametre sayısı yalnızca 299.820 olup, yalnızca 15 adet öğrenilebilir katman içermektedir; bu sayı, benzer görevlerde kullanılan klasik ViT ve CNN mimarilerine kıyasla belirgin şekilde daha düşüktür. Bu kompaktlık, hesaplama verimliliğini artırmakta, eğitim süresini kısaltmakta ve aşırı öğrenme riskini azaltmaktadır; bu durum özellikle veri kısıtlılığıyla karakterize edilen tıbbi görüntüleme alanları için büyük önem arz etmektedir. Bunun yanı sıra, CIT'nin modüler yapısı (tokenizer, transformatör kodlayıcı ve sınıflandırma başlığı olmak üzere üç ayrı bileşen), modelin dış radyografisi dışındaki sınıflandırma problemlerine de kolaylıkla uyarlanabilmesini sağlamaktadır. Her bir modül, farklı veri türleri, ölçekler veya çok modlu (multimodal) girdiler için bağımsız biçimde özelleştirilebilir, bu da CIT mimarisini yapısal, yapısal olmayan veya tıbbi veri setleri dahil olmak üzere çok çeşitli görevler için genel amaçlı kullanılabilir bir çözüm haline getirmektedir. Ayrıca, modele entegre edilen stokastik derinlik düzenlemesi, eğitim kararlılığından ödün vermeksizin modelin genellenebilirliğini daha da artırmaktadır. Klasik ViT modelleri çoğunlukla hiperparametrelere duyarlılık ve yüksek

bellek gereksinimleri nedeniyle sınırlamalarla karşılaşırken, CIT modeli, yerel duyarlılık ile küresel bağlamsal çıkarım arasında üstün bir denge sunmakta; bunu yaparken mekansal çıkarımsal önyargıları (spatial inductive biases) etkin biçimde kullanmakta ve transformatör tabanlı ölçeklenebilirliği korumaktadır.

CIT modelinin umut verici performansına rağmen, bu çalışma bir dizi önemli sınırlılığı da kabul etmektedir. İlk olarak, veri seti pediatrik dental görüntüleme açısından makul bir büyüklüğe sahip olsa da genel görüntü işleme görevleriyle karşılaştırıldığında görece olarak küçüktür. Özellikle süpernüme dış sınıfında yer alan örnek sayısının azlığı, modelin bu anomalilerin tüm morfolojik çeşitliliğine maruz kalma düzeyini sınırlayabilir. Sınıflar arasındaki dengesizlik, tabakalı (stratified) örnekleme ve JSC ile MCC gibi dengeye duyarlı değerlendirme metrikleri ile kısmen azaltılmış olsa da bu durum modelin nadir görülen sınıflara karşı duyarlılığını etkileyebilir.

Tek merkezli oluş, bir kusurdan ziyade bir sınırlılıktır; iç tutarlılığı sağlar ancak cihazlar, protokoller ve hasta karmasındaki kurumlar arası değişkenliği yeterince temsil etmeyebilir. Verilerin tek bir kurumdan gelmesine rağmen, merkeze özgü özelliklere aşırı uyum riski yoğunluk ve geometrik artırımlar, normalizasyon ve kalibrasyon-duyarlı değerlendirme ile hafifletilmiştir. Yerel bağlam toplulaştırmasını vurgulayan CIT mimarisi, orta düzey görünüm değişimlerini sönümleyebilir; bununla birlikte panoramik cihazlardaki ve edinim protokollerindeki heterojenlik performansı yine de etkileyebilir. Klinik genellenebilirliği güçlendirmek amacıyla, site-held-out yaklaşımıyla kurumlar arası doğrulama öngörülmekte; doğrudan veri paylaşımının kısıtlı olduğu durumlarda federatif eğitim/değerlendirme benimsenebilmektedir. Olası kurumsal yanlılık, cihaz türleri ve hasta katmanları boyunca alt grup performansları ve kalibrasyonun raporlanmasıyla nicel olarak değerlendirilebilir. Özetle, tek merkezli kaynak sağlama iç tutarlılığı güvence altına almakla birlikte genellenebilirlik açısından bir sınırlılık oluşturmaktadır; bu nedenle farklı görüntüleme koşulları altında dış doğrulama gelecek çalışmalarda planlanmıştır. Pediatrik veri paylaşımına ilişkin etik kısıtlar nedeniyle, çok merkezli çalışmalar sıklıkla uzun süreli yönetim süreçleri gerektirmekte olup bu durum açıkça gözetilen bir translasyonel engel olarak kabul edilmektedir.

Veri seti boyutu ve sınıf dengesizliğinin ötesinde, derlenen veri setinin yapısal bazı sınırlılıkları da modelin daha geniş ölçekte genellenebilirliğini etkilemektedir. Özellikle dikkat çekici bir sınırlılık, veri setinde yer alan tüm vakaların anomali türü bakımından birbirinden bağımsız olmasıdır; başka bir deyişle, hiçbir panoramik radyografide hem germ eksikliği hem de süpernumere diş anomali bir arada bulunmamaktadır. Klinik pratikte bu tür vakalar oldukça nadir görülse de modelin çoklu anomali içeren örnekler üzerinde eğitilmemiş ve doğrulanmamış olması, mevcut CIT modelinin tek bir görüntüde birden fazla farklı anomaliyi aynı anda tanıyamayacağı anlamına gelmektedir. Buna ek olarak, süpernumere sınıfı içerisinde mesiodens tipi vakaların diğer alt türlere (distomolar, paramolar, parapremolar) göre baskın olması, modelin daha nadir görülen alt türleri ayırt etme yetisini sınırlandırmıştır. Her ne kadar kliniğe yansıyan süpernumere vakaların çoğu mesiodens olsa da diğer alt türlerin düşük örnek sayısı, modelin alt türler arasında ayırım yapacak şekilde eğitilmesini engellemiştir.

Bir diğer önemli sınırlılık ise, modelin yalnızca görüntü düzeyinde sınıflandırma yapacak şekilde eğitilmiş olmasıdır; yani, anomali mekansal olarak yerleştirilmemiştir. Görüntülerdeki anomalilerin tam konumlarının elle etiketlenmesi, pedodontist uzmanlar üzerinde zaman ve kaynak açısından önemli bir yük oluşturduğundan, bu çalışma kapsamında manüel bölgeleme (segmentasyon) yapılması mümkün olmamıştır. Bu nedenle mevcut sistem, yalnızca tanısal sınıflandırma sunmakta; ancak açık biçimde anomali konumlandırması (lokalizasyonu) sağlamamaktadır. Bu eksiklik, gelecekte nesne tespiti veya segmentasyon tabanlı yaklaşımlar ile giderilebilir.

Bu çalışmanın özgün yönlerinden biri, dört yaş altı pediatrik hastalarda germ eksikliği şüphesine odaklanan özel bir analiz içermesidir. Erken çocukluk döneminde, özellikle ikinci küçük azı dişi gibi bazı dişler için germ oluşumunun radyografik olarak henüz görünür hale gelmemesi, normal diş gelişiminin sınırları içerisinde değerlendirilebilir. Bu nedenle, bu dönemde bir diş germinin görüntüde bulunmaması, kesin olarak dental agenezi anlamına gelmemektedir. Ancak, potansiyel germ eksikliklerinin erken dönemde tespit edilmesi, olası bir agenezinin daha sonra doğrulanması halinde, yakın izlem ve zamanında müdahale için klinik açıdan kritik öneme sahiptir. Bu gerçeklikten hareketle, çalışmada söz konusu erken dönem vakalar veri setinde tutulmuş; böylece modelin erken

tarama ve risk sınıflandırması kapasitesinin artırılması hedeflenmiştir. Dolayısıyla, yaş gibi demografik değişkenlerin yokluğu bir sınırlılık olarak değerlendirilebilir; ancak bu durum ne çalışmanın yürütülmesini engellemiş ne de modelin performansını etkilemiştir. Demografik değişkenlerin bulunmayışı, veri kümesinin bileşimi ve dahil edilme ölçütleri şeffaf biçimde tanımlandığı ve tanısal etiketler metaveriden türetilmek yerine doğrulanmış klinik sonuçlara dayandırıldığı için, yeniden üretilebilirliği zedelememektedir. Benzer biçimde, çalışma görüntü tabanlı tanıya odaklandığını açıkça belirtmekte ve eksik metaveriyeye ilişkin sınırlılıkları net biçimde raporladığından, tıbbi araştırmalarda beklenen şeffaflık gereklilikleri de ihlal edilmemektedir. Son olarak, demografik alt gruplara göre adillik (fairness) değerlendirmeleri bu bağlamda yapılamamış olsa da, bu tür analizler radyografiye dayalı anomali saptama çerçevelerinin kapsamı dışında olup benzer çalışmalarda da nadiren uygulanabilmektedir. Bunun yerine, model adilliği dolaylı olarak, gerçek yaşam tanısal çeşitliliğini yansıtan, geniş ve klinik olarak doğrulanmış bir veri kümesinin kullanımıyla desteklenmiştir.

Önemli olarak, bu çalışma pediatrik panoramik radyografilerde germ eksikliğinin otomatik tanısına yönelik ilk yapay zeka uygulamasını temsil etmektedir. Germ eksikliği, agenezi spektrumunun en erken gözlemlenebilir evresini oluşturduğundan, bu tür anomalilerin erken dönemde tespit edilmesi klinik açıdan yüksek düzeyde değer taşımaktadır. Bu erken teşhis, proaktif tedavi planlamasını mümkün kılmakta ve kalıcı diş eksikliklerine bağlı olarak gelişebilecek işlevsel ve estetik komplikasyonların önlenmesine katkı sağlamaktadır. Dolayısıyla, önerilen CIT modeli, yalnızca teknik açıdan yapay zeka temelli diş tanı alanını ilerletmekle kalmayıp, aynı zamanda pediatrik bireylerde erken anomali taraması için klinik olarak etkili bir araç sunmaktadır.

İnsan– yapay zeka karşılaştırmalı testlerin ve biçimsel hipotez doğrulamasının dahil edilmesi, çalışmanın iddialarını belirgin biçimde güçlendirmekte ve doğrudan translasyonel hedeflerine hitap etmektedir. Diş hekimliği görüntüleme literatüründe, bu düzeyde istatistiksel katılık içeren klinisyen–model karşılaştırmaları halen yaygın değildir. Gözlemciler arası uyum analizleri klinisyenler arasında ancak orta düzeyde bir uyuma olduğunu göstermiş; performans örüntüleri, radyografik yorumlamada tanısal doğruluğun yalnızca mesleki unvandan ziyade pratik deneyim ve algısal faktörlerce

biçimlendiğini ortaya koymuştur. Bu bağlamda, önerilen CIT modeli uzman pedodontist grubunu geride bırakmış ve ihtiyatlı çoklu karşılaştırma kontrolü altında genel diş hekimleri grubundan istatistiksel olarak farksız bulunmuştur ve heterojen insan yargılarına karşı nesnel ve yeniden üretilebilir çıktılar sağlamıştır. Bu durum, derin öğrenme modellerinin tanısal öznelliği azaltılabileceği ve gözlemciler arası değişkenliği düşürebileceği önermesini desteklemektedir. Ayrıca bulgular, CIT'in yalnızca bağımsız bir tanı aracı olarak değil, klinik uygulamada yardımcı bir sistem olarak da hizmet edebileceğini; bu yönüyle kaynakların kısıtlı olduğu ortamlarda veya pediatrik anomali saptamada deneyimi sınırlı klinisyenler için değerli olabileceğini göstermektedir. İnsan uzmanların VS1 test setini tamamlama süresi ortalama yaklaşık 59 dakika (birim: dk) iken, CIT modeli çapraz doğrulamada katman başına ortalama yalnızca 271.89 s'lik bir eğitim süresine ihtiyaç duymuştur. Bu belirgin fark, modelin sadece çıkarımda değil eğitimde de verimli olduğunu vurgulamakta; CIT'in yeni tanısal görevlere klinik açıdan uygulanabilir bir zaman diliminde yeniden eğitilebileceğini veya ince ayar yapılabileceğini düşündürmektedir.

Diş hekimliğinde yapay zeka uygulamalarına yönelik ilgi giderek artsa da süpernümere diş sınıflandırmasını ele alan mevcut literatürün kapsamı hem sınırlı hem de yöntemsel derinlik açısından yetersizdir. Çizelge 5.1'de özetlendiği üzere, mevcut çalışmaların büyük çoğunluğu, yalnızca mesiodens tespiti üzerine odaklanmış; bu tespitler genellikle InceptionResNetV2, VGG16 veya AlexNet gibi CNN tabanlı mimarilerle gerçekleştirilmiştir. Bu çalışmalar, çoğunlukla orta ile yüksek düzeyde doğruluk rapor etmiş olsalar da çoğunlukla 1000'in altında panoramik görüntü içeren küçük veri setlerine dayanmaktadır. Örneğin, Ahn vd. (2021) ile H. Kim vd. (2024), mesiodens sınıflandırmasında %90'ın üzerinde doğruluk bildirmiştir; ancak bu modeller yalnızca 850 ila 1.100 görüntüden oluşan veri setlerinde eğitilmiştir. Benzer şekilde, Ragodos vd. (2022) gibi daha geniş kapsamlı dental anomali tespiti çalışmalarında ise, süpernümere dişlere özgü özneliklere sınırlı odaklanması ve veri çeşitliliğinin yüksek olması nedeniyle, bu sınıfta belirgin bir performans düşüşü gözlemlenmiştir (AUC = %57,10). Buna karşılık, bu çalışmada sunulan önerilen CIT modeli, 1.170 pediatrik panoramik görüntüden oluşan daha büyük bir veri seti üzerinde eğitilmiş ve aynı anda hem germ eksikliği hem de süpernümere diş sınıflandırması gerçekleştirmiştir; bu, literatürde daha

önce görülmemiş önemli bir ilerlemedir. Ayrıca, Çizelge 5.1’de yer alan çalışmaların yalnızca çok azı, Grad-CAM (Ahn vd. 2021, Ragodos vd. 2022) veya SHAP (Hayashi-Sakai vd. 2024) gibi açıklanabilir yapay zeka yöntemlerini entegre etmiştir. Buna karşın, bu çalışmada Grad-CAM görselleştirmeleri sistematik olarak uygulanmış, böylece modelin karar süreçleri daha şeffaf hale getirilmiştir.

Önemli olarak, CIT modeli %96,00 doğruluk ile önceki çalışmalara eşdeğer ya da üstün tanısal performans sergilemiş; bunu yaparken aynı zamanda mimari verimlilik ve ölçeklenebilirlik özelliklerini de korumuştur. Gerçekleştirilen literatür taramasına göre germ eksikliğinin otomatik tespitine yönelik daha önce doğrudan bir çalışmanın yayımlanmadığı anlaşılmaktadır. Ancak, E. Kim vd. (2024) ile Uyar ve Uyar (2025) tarafından yürütülen agenezi ve hipodonti sınıflandırmasına yönelik bazı güncel çalışmalar mevcuttur. Söz konusu çalışmalar, klinik semptomların radyografik olarak belirginleştiği evrelerdeki anomalileri tespit etmeyi amaçlarken, bu çalışmada önerilen model, germ eksikliğini daha erken bir evrede, henüz radyografik belirtiler oluşmadan yapay zeka temelli olarak öngörebilen ilk yaklaşımdır. Bu proaktif tespit yetisi, gelecekte ortaya çıkabilecek agenezi vakalarının önlenmesinde klinik açıdan kritik bir rol üstlenmektedir. Ayrıca, bu çalışmada sunulan model, daha karmaşık ve belirsiz tanısal hedeflerle çalışmasına rağmen, önceki çalışmalardan daha yüksek bir sınıflandırma doğruluğu (%96,00) elde etmeyi başarmıştır.

Derin öğrenme yaklaşımları dış radyolojisinde etkileyici tanısal başarılar elde etmiş olsa da yalnızca birkaç çalışma yapay zeka performansını insan uzmanların performansı ile sistematik olarak karşılaştırmıştır. Çizelge 5.1’den gözlemlendiği gibi sınırlı literatür arasında, Ahn vd. (2021), mesiodens tespiti için birden fazla CNN’i değerlendirmiş ve InceptionResNetV2’nin %92,40 ACC elde ettiğini, pediatrik uzmanlarına (UPG: %99,00) ve genel diş hekimlerine (GDG: %95,00) yaklaşırken tanı süresini önemli ölçüde azalttığını bildirmiştir. Benzer şekilde, Ragodos vd. (2022), ağız içi fotoğraflarından 10 farklı diş anomalisini tespit etmek için ResNet18 tabanlı bir CNN’i değerlendirmiş ve modelin 10 anomali kategorisinden 7’sinde deneyimli bir diş hekiminden daha iyi performans gösterdiğini ve sınıflandırma görevini çok daha kısa sürede tamamladığını bildirmiştir. Daha yakın zamanda, H. Kim vd. (2024), meziodenslerin segmentasyonu

için ResNet kodlayıcıları ile U-Net'i kullanmış ve yalnızca 7,5 s'lik bir tanı süresiyle genel diş hekimleri (GDG: %96,00) ile karşılaştırılabilir tanı performansı (F1 skor: %95,00) bildirmiştir. Bu sınırlı çalışma grubuyla uyumlu olarak, mevcut çalışma ayrıca yapılandırılmış bir insan-yapay zeka karşılaştırması da gerçekleştirmiştir. Benzersiz bir şekilde, önerilen modelimiz, oldukça deneyimli genel diş hekimleri de dahil olmak üzere her iki insan grubunda da üstün tanı doğruluğu (ACC: %96,00, F1 skor: %95,29, MCC: %93,28) göstermiştir. Özellikle, genel diş hekimleri pediatrik uzmanlardan daha iyi performans gösterirken CIT modeli her ikisinin de tanı yeteneğine erişerek tutarlı ve yüksek performanslı tanı desteği sunma potansiyelini vurgulamıştır. Literatürde bu tür yapay zeka ve insan uzman karşılaştırma çalışmalarının azlığı ve modelimizin uzmanlara göre zorlu sınıflandırma görevindeki güçlü performansı göz önüne alındığında bu tez çalışmasının katkılarından biri olarak bu testlerin uygulanması çalışmanın yeniliğini ve klinik önemini vurgulamaktadır.

Çizelge 5.1 incelendiğinde birkaç çalışmada (Korkmaz vd. 2025, Al Kheraif vd. 2019) rapor edilen ACC oranlarının, bu çalışmada sunulan CIT modelinin performansını az da olsa geçtiği görülmektedir. Bu sınırlı farkın çeşitli olası nedenleri bulunmaktadır. Öncelikle, söz konusu çalışmaların daha büyük veya daha homojen veri setleri (örneğin 1.500 panoramik görüntü) kullanmaları, modelin nadir anomalileri daha dengeli bir şekilde öğrenmesine katkı sağlamış olabilir. İkinci olarak, bu çalışmaların çoğunda yalnızca ikili sınıflandırma senaryolarına odaklanılması, doğası gereği daha az karmaşık görevlerde performansın artmasına yol açabilmektedir; oysa bu çalışmada CIT modeli hem ikili hem de çok sınıflı sınıflandırma görevlerini kapsayacak şekilde daha geniş bir problem alanını ele almaktadır. Bununla birlikte, bu üstünlükler yalnızca veri seti boyutları veya ikili sınıflandırma görevlerinin görece basitliği ile değil, aynı zamanda yöntemsel tercihlerle de ilişkilidir. Örneğin, Korkmaz vd. (2025), çalışmasında performans artışı, DarkNet, DenseNet ve ResNet gibi literatürde uzun süredir kendini kanıtlamış mimarilerin füzyonuna dayandırılmıştır; bu tür hibrit yaklaşımlar doğal olarak tekil modellerden daha yüksek doğruluk sergilemektedir. Benzer şekilde, Al Kheraif vd. (2019) tarafından uygulanan segmentasyon + CNN stratejisi, anomalili bölgelerin önceden belirlenmesine olanak tanımış ve sınıflandırmayı yalnızca ilgi alanlarına odaklamıştır; bu, tüm panoramik görüntü üzerinden öğrenme yapan CIT modeline kıyasla

belirgin bir avantaj sağlamaktadır. Dolayısıyla, söz konusu çalışmaların daha yüksek doğruluk deęerleri rapor etmesi anlaşılır olmakla birlikte, bu durum CIT mimarisinin yenilikçi katkısını gölgelememektedir. CIT, herhangi bir füzyon veya bölge odaklı ön işleme olmaksızın, tek başına ve end-to-end bir çerçevede güçlü performans sergilemiş; üstelik çok sınıflı ve zorlu görevlerde dahi rekabetçi doğruluk oranlarını korumuştur. Bu bağlamda, CIT'nin füzyon tabanlı veya segmentasyon destekli bir yaklaşımla bütünleştirilmesi, gelecekte daha da yüksek başarımlar için güçlü bir araştırma yönü olarak değerlendirilebilir.

Çizelge 5.1 Literatürdeki ilgili sınıflandırma çalışmalarına genel bakış

Kaynak	Teşhis	Yöntem	Veri seti	Performans (ACC %)	Exp-AI	Expert comparison (ACC %)
(Ahn vd. 2021)	Mesiodens	InceptionResNetV2	Panoramik 1.100	92,40	Grad-CAM	UPG: 99.00 GDG: 95.00
(Hayashi-Sakai vd. 2024)	Mesiodens	Binary connect mnist_LeNet	Panoramik 628	81,20	SHAP	-
(Mine vd. 2022)	Süpernumere	VGG16	Panoramik 220	84,00	-	-
(Okazaki vd. 2022)	Süpernumere, Odontoma	AlexNet	Panoramik 150	70,00	-	-
(Ragodos vd. 2022)	Süpernumere, Rotasyon, Agenezi, Mikrodonti, Gömülü, Hipoplazi, Kesici Fissür, Hipokalsifikasyon, Yerinden Oynamış Diş	ResNet18	Ağız içi fotoğraflar 38.486	Süpernumere AUC: 57,10	Grad-CAM	Uzman bir diş hekimine göre model 10 anomaliden 7'sinde daha yüksek F1 skorları elde etti
(Korkmaz vd. 2025)	Süpernumere (Distomolar)	DarkNet, DenseNet and ResNet fusion	Panoramik 263	96,20	-	-
(Al Kheraif vd. 2019)	Süpernumere	Hybrid graph cut segmentation + CNN	Panoramik 1.500	97,07	-	-
(H. Kim vd. 2024)	Mesiodens	U-Net + ResNet	Panoramik 850	92,40	-	UPG: 99.00 GDG: 93.00
(E. Kim vd. 2024)	Agenezi	InceptionResNetV2	Panoramik 806	73,80	-	-
(Uyar ve Uyar 2025)	Hipodontia	VGG19-Bilayered Neural Network	Panoramik 1.068	95,63	-	-
Bu çalışma	Germ eksikliği, Süpernumere	Compact Involucional Transformer (CIT)	Panoramik 1.170	96,00	Grad-CAM	UPG: 75.43 GDG: 91.43

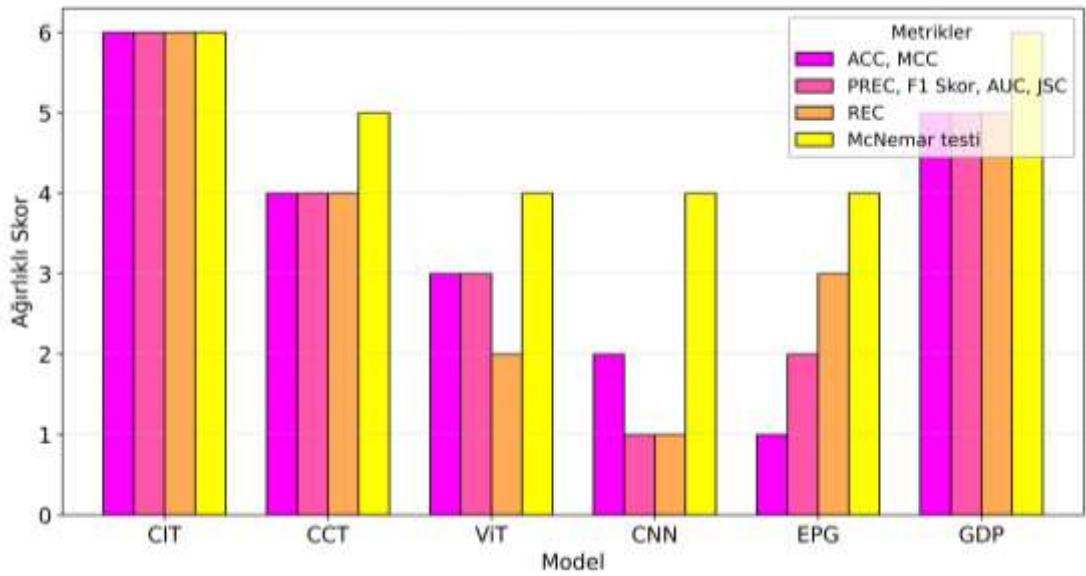
## 6. SONUÇ

Bu çalışmada, pediatrik dental anomalilerin panoramik radyografiler üzerinden otomatik olarak tespit edilmesine yönelik CIT ismini verdiğimiz yenilikçi bir transformatör mimarisi önerilmiştir. Uyarlanabilir involüsyonel tokenizasyon ile hafif yapılı bir transformatör mimarisinin entegrasyonu sayesinde, CIT modeli hem yerel mekansal öznitelikleri hem de uzun menzilli bağlamsal ilişkileri etkili biçimde yakalayabilmiştir. Model, önemli ölçüde azaltılmış parametre sayısı ile hesaplama açısından verimli bir yapı sunarken, aynı zamanda güncel evrimsel ve transformatör tabanlı modellerle karşılaştırıldığında üstün tanısal performans sergilemiştir.

Şekil 5.1, VS1 veri setinden elde edilen sonuçlara dayalı genel performans eğilimlerini özetleyen üst düzey bir görselleştirme sunmaktadır. Bu özet, doğrudan metrik değerlerinin toplanmasına değil, sıralamaya dayalı bir ağırlıklandırılmış puanlama yaklaşımına dayanmaktadır. Her bir değerlendirme metriği için, altı tanı yöntemi (dört yapay zeka modeli ve iki uzman grup), en iyi performanstan (puan = 6) en düşük performansa (puan = 1) kadar sıralanmıştır. Bazı metrikler (örneğin ACC-MCC) farklı modeller arasında aynı sıralama sonuçlarını ortaya koyduğundan, görselleştirmede sadelik sağlamak amacıyla tek bir satırda birleştirilmiştir.

Şekil 5.1’de gözlemlendiği üzere, sıralama temelli özet, ölçütler genelinde açık ve kararlı bir düzeni ortaya koymaktadır. CIT, her grup (ACC-MCC, PREC-F1 skor-AUC-JSC, REC ve McNemar testi) üzerinde en üst sırayı işgal ederek, tutarlı biçimde güçlü ayırt edicilik, PREC ile REC arasında dengeli bir performans ve ikili tutarlılık testlerinde üstünlük göstermektedir. GDG, ikinci sırada yakın bir konumda yer almakta; ACC ve PREC odaklı gruplarda CIT’in hemen altında puanlar almakta ve McNemar testi özetinde birincilikle eşitlenerek VS1 üzerinde genel diş hekimlerinin deneyim güdümlü üstün performansını vurgulamaktadır. CCT, belirgin bir orta katmanı oluşturarak çoğu grupta ViT-CNN-UPG’yi geride bırakmakta ancak CIT-GDG’nin altında kalmaktadır; bu durum, eşik bağımsız (AUC-JSC) ve eşik temelli (ACC-MCC) ölçütlerdeki ara konumu ile tutarlıdır. ViT ve CNN daha düşük sıralarda yer almakta; bu tablo daha zayıf

PREC/REC dengesi ve ikili karşılaştırmalarda CIT'e karşı daha düşük uyumla uyumludur. UPG ise karışık bir profil sergilemekte (daha düşük ACC-MCC, ancak nispeten daha iyi REC ve rekabetçi McNemar testi sıralaması) ve bu durum, bir yetersizlikten ziyade insan grupları içi değişkenliğe işaret etmektedir. Birlikte ele alındığında, Şekil 5.1 McNemar testi tablosunu doğrulamaktadır: CIT genel olarak baskın yöntemdir; GDP, CIT ile başa baş düzeyde insan grupları içinde en güçlü sonuçları vermekte; kalan yapay zeka taban çizgileri ise ölçütler genelinde tutarlı ve yaygın bir üstünlük göstermeden kümeleşmektedir.



Şekil 6.1 VS1'den elde edilen sonuçlara dayalı genel performans özeti

Algoritmik yeniliklerin ötesinde, bu tez çalışması kritik klinik yenilik ve üstünlükler sağlamaktadır. Önemli olarak, bu çalışma, germ eksikliğinin otomatik tanısına yönelik ilk yapay zeka temelli yaklaşımı temsil etmektedir. Germ eksikliği, dental agenezinin radyografik olarak gözlemlenebilen en erken göstergesi olup, erken evrede saptanması klinik müdahalelerin zamanlaması açısından kritik öneme sahiptir. Ek olarak bu tez çalışmasında klinik açıdan farklı iki insan grubuyla yapılan insan-yapay zeka karşılaştırmalı testleri yer almaktadır. Bu testlerin değerlendirilmesi çerçevesinde elde edilen bulgular, CIT modelinin tanısal üstünlüğünü istatistiksel olarak anlamlı şekilde doğrularken, aynı zamanda insan performansındaki klinik deneyim temelli değişkenliği de gözler önüne sermiştir. Elde edilen sonuçlar, CIT modelinin klinik uygulamalarda tutarlı, nesnel ve güvenilir bir tanı desteği sunma potansiyelini vurgulamakta; özellikle

uzman pediatrik hekimlere erişimin sınırlı olduğu sağlık ortamlarında dikkat çekici bir değer önermesi sunmaktadır.

Tezin ana sonuçları aşağıda sıralandığı gibi özetlenebilir:

- Model İkili sınıflandırma görevlerinde (VS2 ve VS3) daha hızlı olmak üzere tüm veri seti yapılandırmalarında hızlı yakınsama ve eğitim-doğrulama metrikleri arasında daha güçlü bir uyum göstererek, aşırı uyum veya yetersiz uyum olmadan sağlam bir genellemeyi doğrulamıştır.
- Önerilen CIT modeli, tüm veri seti yapılandırmalarında (VS1, VS2, VS3) SOTA modellerinden (CCT, ViT, CNN) sürekli olarak daha iyi performans göstererek, karmaşık çok sınıflı senaryolarda bile ACC, F1 skor, AUC, JSC ve MCC metriklerinde en yüksek performansları elde etmiştir.
- CIT modeli, germ eksikliği tespitinde (VS2) %97,00 ACC ve AUC ile neredeyse mükemmel bir tanı performansı elde etmiş ve olası diş agenezisinin erken teşhisi için ilk yapay zeka tabanlı yaklaşım olma potansiyelini vurgulamıştır.
- Süpernümere dişlerin (VS3) nadirliği ve morfolojik benzerliğine rağmen, CIT, sınırlı veri ve dengesiz senaryolarda dayanıklılığını vurgulayarak, rakip modellere kıyasla üstün performansını korumuştur.
- McNemar testine göre insan-yapay zeka karşılaştırması, CIT'nin pedodontist grubuna karşı istatistiksel olarak anlamlı biçimde üstün olduğunu; genel diş hekimleri ile ise istatistiksel olarak farksız (pariteye yakın) bir performans sergilediğini ve uzman yargılarıyla klinik olarak anlamlı örtüşmeyi koruduğunu göstermiştir.
- Açıklanabilirlik analizleri (Grad-CAM), modelin odak bölgelerinin uzman tanımlı ROI'lerle örtüştüğünü doğrulayarak, klinik güvenilirliğini, yorumlanabilirliğini ve insan tanısal muhakemesiyle uyumluluğunu vurgulamıştır.
- Genel olarak, bulgular CIT'yi pediatrik panoramik radyografiler için sağlam, geliştirilebilir ve açıklanabilir bir AI çerçevesi olarak ortaya koymaktadır ve özellikle kaynakların sınırlı olduğu ortamlarda veya deneyimli uzmanların bulunmadığı durumlarda klinik karar vermeyi destekleme potansiyeli yüksektir.

Sonuç olarak, bu tez çalışması ve önerilen yöntemler, erken teşhisi destekleyen, tanısal özneliği azaltan ve klinik iş akışlarını iyileştiren, yorumlanabilir ve yüksek performanslı yapay zeka sistemlerinin dental radyolojiye sorumlu biçimde entegrasyonu yönünde önemli bir adımı temsil etmektedir. Gelecekteki araştırmalar, CIT'nin umut verici sonuçlarını birkaç temel noktaya odaklanarak genişletmelidir. İlk olarak, birden fazla kurumdan ve farklı görüntüleme cihazlarından toplanan daha büyük ve daha çeşitli pediatrik panoramik veri setlerinin entegrasyonu, modelin mevcut kohortun ötesinde genelleştirilebilirliğini doğrulamaya yardımcı olacaktır. İkinci olarak, klinik kayıtlar ve tamamlayıcı radyografik modaliteler (örneğin sefalometrik veya ağız içi görüntüler) dahil olmak üzere çok modlu verilerin dahil edilmesi, diş anomalilerinin tanısal doğruluğunu ve bağlamsal anlayışını artırabilir. Bir diğer umut verici yol ise, gerçek zamanlı klinik ortamlarda veya kaynak kısıtlı ortamlarda kullanıma uygun hafif mimarilerle model verimliliğinin optimizasyonunda yatmaktadır. Ek olarak, gelecekteki çalışmalar, modelin farklı hasta popülasyonları ve yaş grupları arasında istikrarını ve güvenilirliğini değerlendiren uzunlamasına doğrulama çalışmalarına odaklanmalıdır. Son olarak, Grad-CAM'i diğer atıf tabanlı ve kavram tabanlı yöntemlerle birleştirerek açıklanabilirlik çerçevelerinin genişletilmesi, güven ve şeffaflığı daha da artıracak ve nihayetinde sistemin güvenilir bir karar destek aracı olarak klinik entegrasyonunu ve kabulünü kolaylaştıracaktır.

## KAYNAKLAR

- AbuSalim, S., Zakaria, N., Islam, M. R., Kumar, G., Mokhtar, N., and Abdulkadir, S. J. 2022. Analysis of Deep Learning Techniques for Dental Informatics: A Systematic Literature Review. In *Healthcare (Switzerland)*, 10(10), 1892. MDPI. <https://doi.org/10.3390/healthcare10101892>
- Ahn, Y., Hwang, J. J., Jung, Y.-H., Jeong, T., and Shin, J. 2021. Automated Mesiodens Classification System Using Deep Learning on Panoramic Radiographs of Children. *Diagnostics*, 11(8), 1477. <https://doi.org/10.3390/diagnostics11081477>
- Al Kheraif, A. A., Wahba, A. A., and Fouad, H. 2019. Detection of dental diseases from radiographic 2d dental image using hybrid graph-cut technique and convolutional neural network. *Measurement: Journal of the International Measurement Confederation*, 146, 333–342. <https://doi.org/10.1016/j.measurement.2019.06.014>
- Al-Ani, A. H., Antoun, J. S., Thomson, W. M., Merriman, T. R., and Farella, M. 2017. Hypodontia: An Update on Its Etiology, Classification, and Clinical Management. *BioMed Research International*, 2017(1), 9378325. <https://doi.org/10.1155/2017/9378325>
- Antal, G., Zsigmond, A., Till, Á., Orsi, E., Szanto, I., Büki, G., Kereskai, L., Herbert, Z., Hadzsiev, K., and Bene, J. 2024. Case report: Initial atypical skeletal symptoms and dental anomalies as first signs of Gardner syndrome: the importance of genetic analysis in the early diagnosis. *Pathology and Oncology Research*, 30, 1611768. <https://doi.org/10.3389/PORE.2024.1611768/BIBTEX>
- Ariji, Y., Mori, M., Fukuda, M., Katsumata, A., and Ariji, E. 2022. Automatic visualization of the mandibular canal in relation to an impacted mandibular third molar on panoramic radiographs using deep learning segmentation and transfer learning techniques. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, 134(6), 749–757. <https://doi.org/10.1016/J.OOOO.2022.05.014>
- Bacali, C., Tristiu, R., Constantiniuc, M., Pascu, L., Duncea, I., Corbureanu, D., and Crăciun, A. 2024. Supernumerary teeth – general considerations and management strategies. *Health, Sports & Rehabilitation Medicine*, 25(3), 152–157. <https://doi.org/10.26659/PM3.2024.25.3.152>
- Bei, M. 2009. Molecular genetics of tooth development. *Current Opinion in Genetics and Development*, 19(5), 504–510. <https://doi.org/10.1016/j.gde.2009.09.002>
- Bostanci, B., and Bostanci, E. 2013. An evaluation of classification algorithms using Mc Nemar's test. *Advances in Intelligent Systems and Computing*, 201 AISC(VOL. 1), 15–26. [https://doi.org/10.1007/978-81-322-1038-2\\_2/COVER](https://doi.org/10.1007/978-81-322-1038-2_2/COVER)
- Carrillo-Perez, F., Pecho, O. E., Morales, J. C., Paravina, R. D., Della Bona, A., Ghinea, R., Pulgar, R., Pérez, M. del M., and Herrera, L. J. 2022. Applications of artificial intelligence in dentistry: A comprehensive review. *Journal of Esthetic and Restorative Dentistry*, 34(1), 259–280. <https://doi.org/10.1111/jerd.12844>

- Celik, M. E. 2022. Deep Learning Based Detection Tool for Impacted Mandibular Third Molar Teeth. *Diagnostics*, 12(4), 942. <https://doi.org/10.3390/DIAGNOSTICS12040942>
- Chen, T. Y., Wu, H. I., Li, Z. H., Fu, J. A., Chen, C. A., Li, K. C., Liong, S. T., Chi, T. K., and Chen, S. L. 2024. Innovative Approach to Supernumerary Teeth Identification: CNN-Based Intelligent Medical Auxiliary System for Occlusal Radiographs. *Proceedings - 11th IEEE International Conference on Cyber Security and Cloud Computing, CSCloud 2024*, 13–18. <https://doi.org/10.1109/CSCLOUD62866.2024.00010>
- Chollet, F. 2017. *Deep learning with Python*. Simon and Schuster.
- Dai, X., Jiang, X., Jing, Q., Zheng, J., Zhu, S., Mao, T., and Wang, D. 2023. A one-stage deep learning method for fully automated mesiodens localization on panoramic radiographs. *Biomedical Signal Processing and Control*, 80, 104315. <https://doi.org/10.1016/J.BSPC.2022.104315>
- De Aguiar, P. C. S., Mesquita, C. M., Lerner, F. E., Borges, L. B., Rodrigues, R., Vieira, W. A., Paranhos, L. R., and De Brito Júnior, R. B. 2025. Association between agenesis of permanent teeth and other dental anomalies in nonsyndromic patients: Systematic review. *Archives of Oral Biology*, 173, 106223. <https://doi.org/10.1016/j.archoralbio.2025.106223>
- De Coster, P. J., Marks, L. A., Martens, L. C., and Huysseune, A. 2009. Dental agenesis: genetic and clinical perspectives. *Journal of Oral Pathology & Medicine*, 38(1), 1–17. <https://doi.org/10.1111/J.1600-0714.2008.00699.X>
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., and Houlsby, N. 2020. An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. *ICLR 2021 - 9th International Conference on Learning Representations*. <https://arxiv.org/pdf/2010.11929>
- Duke, A., Paterson, M., P. Ashley, M., and MacNab, L. 2023. The genetic basis of hypodontia in dental development. *British Dental Journal*, 235(7), 525–528. <https://doi.org/10.1038/S41415-023-6384-6>,
- Duman, S., Yılmaz, E. F., Eşer, G., Çelik, Ö., Bayrakdar, I. S., Bilgir, E., Costa, A. L. F., Jagtap, R., and Orhan, K. 2023. Detecting the presence of taurodont teeth on panoramic radiographs using a deep learning-based convolutional neural network algorithm. *Oral Radiology*, 39(1), 207–214. <https://doi.org/10.1007/S11282-022-00622-1/FIGURES/5>
- Ha, E. G., Jeon, K. J., Kim, Y. H., Kim, J. Y., and Han, S. S. 2021. Automatic detection of mesiodens on panoramic radiographs using artificial intelligence. *Scientific Reports*, 11(1), 1–8. <https://doi.org/10.1038/s41598-021-02571-x>

- Hassani, A., Walton, S., Shah, N., Abuduweili, A., Li, J., and Shi, H. 2021. Escaping the Big Data Paradigm with Compact Transformers. <https://arxiv.org/abs/2104.05704v4>
- Hayashi-Sakai, S., Nishiyama, H., Hayashi, T., Sakai, J., and Shimomura-Kuroki, J. 2024. Deep learning with convolution neural network detecting mesiodens on panoramic radiographs: comparing four models. *Odontology*, 113(1), 448–455. <https://doi.org/10.1007/S10266-024-00980-8/FIGURES/4>
- He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep Residual Learning for Image Recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016-Decem, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Hinton, G. E., Osindero, S., and Teh, Y. W. 2006. A Fast Learning Algorithm for Deep Belief Nets. *Neural Computation*, 18(7), 1527–1554. <https://doi.org/10.1162/NECO.2006.18.7.1527>
- Jeon, K. J., Ha, E. G., Choi, H., Lee, C., and Han, S. S. 2022. Performance comparison of three deep learning models for impacted mesiodens detection on periapical radiographs. *Scientific Reports*, 12(1), 15402. <https://doi.org/10.1038/s41598-022-19753-w>
- Kadi, H., Kawczynski, M., Bendjama, S., Flores, J. Z., Leong-Hoi, A., de Lastic, H., Balbierer, J., Mabileau, C., Radoux, J. P., Grollemund, B., Jaegle, J., Guebert, C., Bisch, B., and Bloch-Zupan, A. 2024. i-Dent: A virtual assistant to diagnose rare genetic dental diseases. *Computers in Biology and Medicine*, 180, 108927. <https://doi.org/10.1016/J.COMPBIOMED.2024.108927>
- Kaya, E., Gunec, H. G., Aydin, K. C., Urkmez, E. S., Duranay, R., and Ates, H. F. 2022. A deep learning approach to permanent tooth germ detection on pediatric panoramic radiographs. *Imaging Science in Dentistry*, 52(3), 275. <https://doi.org/10.5624/isd.20220050>
- Kim, E., Hwang, J. J., Cho, B. H., Lee, E., and Shin, J. 2024. Classification of presence of missing teeth in each quadrant using deep learning artificial intelligence on panoramic radiographs of pediatric patients. *Journal of Clinical Pediatric Dentistry*, 48(3), 76–85. <https://doi.org/10.22514/JOCPD.2024.062/HTM>
- Kim, H., Song, J. S., Shin, T. J., Kim, Y. J., Kim, J. W., Jang, K. T., and Hyun, H. K. 2024. Image segmentation of impacted mesiodens using deep learning. *Journal of Clinical Pediatric Dentistry*, 48(3), 52–58. <https://doi.org/10.22514/JOCPD.2024.059/HTM>
- Kim, J., Hwang, J. J., Jeong, T., Cho, B.-H., and Shin, J. 2022. Deep learning-based identification of mesiodens using automatic maxillary anterior region estimation in panoramic radiography of children. *Dentomaxillofacial Radiology*, 51(7), 20210528. <https://doi.org/10.1259/dmfr.20210528>

- Kingma, D. P., and Ba, J. 2014. Adam: A Method for Stochastic Optimization. 3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings, 1–15. <http://arxiv.org/abs/1412.6980>
- Kılınç, G., and Çetin, M. 2020. Congenital dental anomalies in the primary dentition. *Atatürk Üniversitesi Diş Hekimliği Fakültesi Dergisi*, 30(2), 247–253. <https://doi.org/10.17567/ataunidfd.599421>
- Korkmaz, O. E., Guller, H., Miloglu, O., Ozbek, İ. Y., Oral, E. A., and Guller, M. T. 2025. The detection of distomolar teeth on panoramic radiographs using different artificial intelligence models. *Journal of Stomatology, Oral and Maxillofacial Surgery*, 126(5), 102151. <https://doi.org/10.1016/J.JORMAS.2024.102151>
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. 2012. ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, 25. <http://code.google.com/p/cuda-convnet/>
- Kuwada, C., Arijji, Y., Fukuda, M., Kise, Y., Fujita, H., Katsumata, A., and Arijji, E. 2020. Deep learning systems for detecting and classifying the presence of impacted supernumerary teeth in the maxillary incisor region on panoramic radiographs. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, 130(4), 464–469. <https://doi.org/10.1016/j.oooo.2020.04.813>
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., and Jackel, L. D. 1989. Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Computation*, 1(4), 541–551. <https://doi.org/10.1162/neco.1989.1.4.541>
- Lee, S., Kim, D., and Jeong, H. G. 2022. Detecting 17 fine-grained dental anomalies from panoramic dental radiography using artificial intelligence. *Scientific Reports* 2022 12:1, 12(1), 1–8. <https://doi.org/10.1038/s41598-022-09083-2>
- Liu, J., Liu, Y., Li, S., Ying, S., Zheng, L., and Zhao, Z. 2022. Artificial intelligence-aided detection of ectopic eruption of maxillary first molars based on panoramic radiographs. *Journal of Dentistry*, 125, 104239. <https://doi.org/10.1016/J.JDENT.2022.104239>
- Lu, Y., Wang, J., Li, L., and Zhang, X. 2024. Three-dimensional evaluation of dental characteristics in patients with Cleidocranial dysplasia. *BMC Oral Health*, 24(1), 1–8. <https://doi.org/10.1186/S12903-024-04353-Z/FIGURES/4>
- Lundberg, S., and Lee, S.-I. 2017. A Unified Approach to Interpreting Model Predictions. *Advances in Neural Information Processing Systems*, 30. <http://arxiv.org/abs/1705.07874>
- Mallineni, S. K., Anthonappa, R. P., Jayaraman, J., and King, N. M. 2025. Radiographic localization of supernumerary teeth: a narrative review. *Frontiers in Dental Medicine*, 6, 1495025. <https://doi.org/10.3389/FDMED.2025.1495025/BIBTEX>
- Maylid, A., Vargas, M., Laura, A., Villanueva, G., Deyanira, L., Paez, G., Del, S., Roa Gonzalez Profesor, C., Morales Gonzalez, Y., Briceño, M. S., Profesor, A.,

- Veracruzana, U., Estela, M., Borges, M., Nohemí, K., Delgado, R., Manuel, J., Soto, S., Roa Gonzalez, C., ... Ancona, B. 2024. Supernumerary teeth in pediatric patients: An updated scoping review. *International Journal of Applied Dental Sciences*, 10(2), 393–397. <https://doi.org/10.22271/ORAL.2024.V10.I2F.1966>
- Meade, M. J., and Dreyer, C. W. 2023. Tooth agenesis: An overview of diagnosis, aetiology and management. *Japanese Dental Science Review*, 59, 209–218. <https://doi.org/10.1016/J.JDSR.2023.07.001>
- Mine, Y., Iwamoto, Y., Okazaki, S., Nakamura, K., Takeda, S., Peng, T., Mitsuhata, C., Kakimoto, N., Kozai, K., and Murayama, T. 2022. Detecting the presence of supernumerary teeth during the early mixed dentition stage using deep learning algorithms: A pilot study. *International Journal of Paediatric Dentistry*, 32(5), 678–685. <https://doi.org/10.1111/ipd.12946>
- Okazaki, S., Mine, Y., Iwamoto, Y., Urabe, S., Mitsuhata, C., Nomura, R., Kakimoto, N., and Murayama, T. 2022. Analysis of the feasibility of using deep learning for multiclass classification of dental anomalies on panoramic radiographs. *Dental Materials Journal*, 41(6), 889–895. <https://doi.org/10.4012/dmj.2022-098>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Müller, A., Nothman, J., Louppe, G., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, É. 2018. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830. <http://arxiv.org/abs/1201.0490>
- Ragodis, R., Wang, T., Padilla, C., Hecht, J. T., Poletta, F. A., Orioli, I. M., Buxó, C. J., Butali, A., Valencia-Ramirez, C., Restrepo Muñeton, C., Wehby, G. L., Weinberg, S. M., Marazita, M. L., Moreno Uribe, L. M., and Howe, B. J. 2022. Dental anomaly detection using intraoral photos via deep learning. *Scientific Reports* 2022 12:1, 12(1), 1–8. <https://doi.org/10.1038/s41598-022-15788-1>
- Sella Tunis, T., Sarne, O., Hershkovitz, I., Finkelstein, T., Pavlidi, A. M., Shapira, Y., Davidovitch, M., and Shpack, N. 2021. Dental Anomalies' Characteristics. *Diagnostics*, 11(7), 1161. <https://doi.org/10.3390/diagnostics11071161>
- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., and Batra, D. 2017. Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization. *Proceedings of the IEEE International Conference on Computer Vision*, 2017-October, 618–626. <https://doi.org/10.1109/ICCV.2017.74>
- Shah, N., Bansal, N., and Logani, A. 2014. Recent advances in imaging technologies in dentistry. *World Journal of Radiology*, 6(10), 794. <https://doi.org/10.4329/WJR.V6.I10.794>
- Shen, Z., Wei, J., Zhang, J., Zhang, Y., and Yao, J. 2025. The prevalence of dental agenesis, supernumerary teeth and odontoma in a Chinese paediatric population: an epidemiological study. *BMC Oral Health*, 25(1), 1–10. <https://doi.org/10.1186/S12903-025-05819-4/TABLES/3>

- Simonyan, K., and Zisserman, A. 2015. Very deep convolutional networks for large-scale image recognition. 3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings. <https://arxiv.org/abs/1409.1556>
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A. 2015. Going Deeper with Convolutions. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition., 1–9.
- Tandon, D., Rajawat, J., and Banerjee, M. 2020. Present and future of artificial intelligence in dentistry. *Journal of Oral Biology and Craniofacial Research*, 10(4), 391–396. <https://doi.org/10.1016/j.jobcr.2020.07.015>
- Uyar, T., and Uyar, D. S. 2025. Assessment of using transfer learning with different classifiers in hypodontia diagnosis. *BMC Oral Health*, 25(1), 68. <https://doi.org/10.1186/S12903-025-05451-2/TABLES/6>
- Vaswani, A., Brain, G., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., and Polosukhin, I. 2017. Attention is All you Need. *Advances in Neural Information Processing Systems*, 30.
- Watted, N., Watted, A., Proff, P., Borbély, P., Ghoul, R., Shilbayih, H. A., Kolomvos, N., and Abu-Hussein, M. 2025. Prevalence, Etiology, Diagnosis, Treatment and Complications of Supernumerary Teeth in The Pediatric Clinic. *Journal of Neonatal Surgery*, 14(21S), 210–226. <https://www.jneonatalurg.com/index.php/jns/article/view/5443>
- WHO. 2022. Global oral health status report: towards universal health coverage for oral health by 2030. In *Dental Abstracts*. <https://www.who.int/publications/i/item/9789240061484>, Erişim Tarihi: 25.08.2025
- Yu, H., Cao, Z., Pang, G., Wu, F., Zhu, H., and Zhu, F. 2025. A deep-learning system for diagnosing ectopic eruption. *Journal of Dentistry*, 152, 105399. <https://doi.org/10.1016/J.JDENT.2024.105399>
- Zheng, J., Li, H., Wen, Q., Fu, Y., Wu, J., and Chen, H. 2025. Artificial intelligent recognition for multiple supernumerary teeth in periapical radiographs based on faster R-CNN and YOLOv8. *Journal of Stomatology, Oral and Maxillofacial Surgery*, 102293. <https://doi.org/10.1016/J.JORMAS.2025.102293>
- Zhu, H., Yu, H., Zhang, F., Cao, Z., Wu, F., and Zhu, F. 2022. Automatic segmentation and detection of ectopic eruption of first permanent molars on panoramic radiographs based on nnU-Net. *International Journal of Paediatric Dentistry*, 32(6), 785–792. <https://doi.org/10.1111/IPD.12964>