



T. C.  
GAZİANTEP ÜNİVERSİTESİ  
DİŞ HEKİMLİĞİ FAKÜLTESİ

**ÇOCUK HASTALARDA HİPODONTİ TESPİTİNDE İKİ FARKLI  
DERİN ÖĞRENME ALGORİTMASININ KARŞILAŞTIRILMASI  
VE PERFORMANS ANALİZİ**

Yasemin İSPİR METİN

UZMANLIK TEZİ

ÇOCUK DİŞ HEKİMLİĞİ ANABİLİM DALI

DANIŞMAN

Dr. Öğr.Üyesi Zehra Güner

Gaziantep

2025

## **BEYAN**

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlamasından yazımına kadar bütün aşamalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

28/02/2025

Yasemin İSPİR METİN

## TEŐEKKÜR

Uzmanlık eđitimim ve tez sürecimde bana rehberlik eden, engin bilgisiyle yolumu aydınlatan, sabrıyla destekleyen ve kıymetli katkılarıyla her zaman yanımda olan deđerli hocam ve tez danışmanım Dr. Öğr.Üyesi Zehra GÜNER'e,

Eđitim hayatım boyunca bilgi ve deneyimleriyle bana ilham veren, yol gösteren ve her zaman desteklerini hissettiren deđerli bölüm hocalarım Dr. Öğr.Üyesi Őemsettin YILDIZ ve Dr. Öğr.Üyesi Zübeyde UÇAR GÜNDOĐAR'a,

Birlikte geçirilen saatler, paylaşılan bilgi ve deneyimler sadece akademik deđer, aynı zamanda dostluk açısından da benim için çok kıymetli olan ve bu süreçte destekleri, sabırları ve içtenlikleriyle bana güç veren eş kıdemlilerim Arş. Gör. Derya SARIOĐLU, Arş. Gör. Saadet Nilsu MUTTEPE, Arş. Gör. Büőra YÜCETÜRK'e,

Bu zorlu süreçte her zaman yanımda olan, gösterdiđi fedakârlıklar ve verdiđi manevi güçle, sabrıyla, sevgisiyle ve sonsuz desteđiyle bana güç veren, en yorucu anlarda bile motivasyon kaynađım olan sevgili eşim Uzm. Dt. Ufuk METİN'e,

Sevgileri, sabırları ve destekleriyle her zaman yanımda olan kıymetli aileme,

Sonsuz sevgi, saygı ve teşekkürlerimi sunarım.

# İÇİNDEKİLER

<b>TEŞEKKÜR</b> .....	<b>i</b>
<b>KISALTMALAR VE SİMGELER</b> .....	<b>iv</b>
<b>ŞEKİLLER LİSTESİ</b> .....	<b>vi</b>
<b>TABLolar LİSTESİ</b> .....	<b>viii</b>
<b>ÖZET</b> .....	<b>1</b>
<b>ABSTRACT</b> .....	<b>2</b>
<b>1. GİRİŞ VE AMAÇ</b> .....	<b>3</b>
<b>2. GENEL BİLGİLER</b> .....	<b>6</b>
<b>2.1. Hipodonti (Diş Agenezisi)</b> .....	<b>6</b>
2.1.1. Hipodonti Tanımı ve Tespiti .....	6
2.1.2. Rastlanma Oranı .....	6
2.1.3. Hipodonti Oluşum Nedenleri .....	8
2.1.3.1. Kalıtsal Predispozisyon .....	8
2.1.3.2. Çevresel Predispozisyon .....	9
2.1.4. Diş Agenezisi ve Dişsel Deformiteler .....	9
2.1.5. Konjenital Diş Eksikliğinin Tedavisi .....	10
<b>2.2. Yapay Zeka</b> .....	<b>12</b>
2.2.1. Makine Öğrenimi .....	14
2.2.2. Yapay Nöral Ağlar (Artificial Neural Network-ANN) .....	15
2.2.3. Nöral Ağların Yapısal Özellikleri .....	17
2.2.4. Derin Öğrenme (Deep Learning) .....	19
2.2.5. Derin Öğrenme Mimarileri .....	20
2.2.5.1. Evrişimli Sinir Ağları (ESA, Convolutional Neural Networks-CNN) ..	20

2.2.5.2. YineleneN Nörol Ağları (Recurrent Neural Networks-RNN).....	22
2.2.5.3. Derin Otomatik Kodlayıcılar .....	23
2.2.5.4. Kısıtlı Boltzmann Makineleri .....	23
2.2.5.5. Long-Short/Term Memory (LSTM) .....	24
2.2.5.6. İnanç Tabanlı Derin Öğrenme Modelleri (Deep Belief Networks) .....	24
2.2.6. Derin Öğrenme Modelleri.....	25
2.2.7. Derin Öğrenme Yöntemlerinin Diş Hekimliğinde Kullanımı .....	29
2.2.7.1. Çocuk Diş Hekimliği ve Derin Öğrenme .....	31
<b>3. GEREÇ VE YÖNTEM.....</b>	<b>34</b>
3.1. Veri Setinin Elde Edilmesi .....	34
3.2. Veri Setlerinin Hazırlanması ve Sınıflandırılması.....	35
3.3. Derin Öğrenme Mimarisi ve Model Eğitimi.....	36
3.4. İstatistiksel Analiz.....	38
3.5. Performans Ölçütleri .....	39
3.6. ROC Eğrisi (Receiver Operating Characteristic Curve) ve Kesinlik-Duyarlılık Eğrisi (PR Eğrisi, Precision-Recall Curve) .....	41
<b>4. BULGULAR.....</b>	<b>42</b>
<b>5. TARTIŞMA .....</b>	<b>53</b>
<b>6. SONUÇ VE ÖNERİLER.....</b>	<b>63</b>
<b>7. KAYNAKLAR .....</b>	<b>65</b>

## KISALTMALAR VE SİMGELER

AUC	Area Under Curve (ROC eğrisinin altında kalan alan)
AXIN2	Axis Inhibitor 2
CASNET	Causal Associational Network
CBCT Bilgisayarlı Tomografi)	Cone Beam Computed Tomography (Konik Işınlı
CNN/ESA	Evrişimli Sinir Ağı /Convolutional Neural Network
CSP Net	Cross-Stage Partial Network
DLX	Distal-Less Homeobox
DMFT	Decayed, Missing, Filled Teeth (Çürük, Eksik, Dolgulu Diş)
DN	Doğru Negatif
DP	Doğru Pozitif
EDA	Ectodysplasin A
ESA	Evrişimli Sinir Ağları
FGFR1	Fibroblast Growth Factor Receptor 1
IOU	Intersection Over Union
IRF6	Interferon Regulatory Factor 6
LHX	LIM Homeobox
LSTM	Uzun-Kısa Süreli Hafıza (Long Short-Term Memory)
LTBP3	Latent Transforming Growth Factor Beta Binding Protein 3
MCC	Matthews Korelasyon Katsayısı

MSX1	Muscle Segment Homeobox 1
MSX9	MSH Homeobox 9
PAX9	Paired Box 9
PR Eğrisi	Keskinlik-Duyarlılık Eğrisi (Precision-Recall Curve)
R-CNN Network)	Bölge Tabanlı CNN (Region-based Convolutional Neural Network)
ReLU	Rectified Linear Unit
ResNet	Residual Neural Network
ROC	Receiver Operating Characteristic
SPPF Pooling Fast)	Hızlı Uzamsal Piramit Havuzlama (Spatial Pyramid Pooling)
SSD	Single-Shot Detector
TSA	Tekrarlayan Sinir Ağları
TGFA	Transforming Growth Factor Alpha
VGGNet	Visual Geometry Group Network
WNT10A	Wnt Family Member 10A
YOLO	You Only Look Once
YN	Yanlış Negatif
YP	Yanlış Pozitif

## ŞEKİLLER LİSTESİ

Şekil 2.1. Turing Test (78).....	12
Şekil 2.2. Yapay zeka, makine öğrenimi, yapay sinir ağları ve derin öğrenme arasındaki ilişki (81).....	13
Şekil 2.3. (A) Biyolojik sinir hücresi; (B) yapay sinir hücresi; biyolojik sinaps; (D) yapay sinir ağı sinapsları (92) .....	16
Şekil 2.4. Yapay nöral birim (94).....	16
Şekil 2.5. Basit yapay nöral ağ (93).....	17
Şekil 2.6. Karmaşık yapılı nöral ağ (93).....	18
Şekil 2.7. Doğrusal ve döngüsel yönlü ağ modelleri (93) .....	19
Şekil 2.8. Yinelenen nöral ağ modeli (107).....	23
Şekil 2.9. Derin otomatik kodlayıcı mimarisi (108).....	23
Şekil 2.10. Kısıtlı boltzmann makineleri (107) .....	24
Şekil 2.11. İnanç tabanlı derin öğrenme modelleri (107).....	25
Şekil 2.12. YOLOv5 mimarisi (126).....	28
Şekil 2.13. YOLOv8 mimarisi (126).....	29
Şekil 3.1. Çalışmamız veri seti dahilinde hipodonti bulunan hastalara ait örnek radyografik görüntüler .....	34
Şekil 3.2. Araştırma süreci akış şeması .....	37
Şekil 3.3. Karmaşıklık matrisi .....	38
Şekil 4.1. YOLOv5 modelinin test sürecindeki sınıflandırma sonuçları .....	43
Şekil 4.2. YOLOv5 modeli için karmaşıklık matrisi.....	43
Şekil 4.3. YOLOv5 modeline ait ROC eğrisi.....	44
Şekil 4.4. YOLOv5 modelinin kesinlik-duyarlılık eğrisi .....	45
Şekil 4.5. YOLOv5 modeline ait güven eşiği ve performans metrikleri grafiği .....	46

<b>Şekil 4.6.</b> YOLOv8 modelinin test sürecindeki sınıflandırma sonuçları.....	47
<b>Şekil 4.7.</b> YOLOv8 modelinin için karmaşıklık matrisi.....	48
<b>Şekil 4.8.</b> YOLOv8 modeline ROC eğrisi.....	49
<b>Şekil 4.9.</b> YOLOv8 modelinin kesinlik-duyarlılık eğrisi .....	49
<b>Şekil 4.10.</b> YOLOv8 modeline ait güven eşiği ve performans metrikleri grafiği .....	50



## TABLULAR LİSTESİ

<b>Tablo 2.1.</b> Biyolojik sinir sistemi bileşenleri ve yapay sinir ağlarındaki eşdeğerleri (93) .....	16
<b>Tablo 4.1.</b> YOLOv5 modelinin DP, YP, DN, YN değerleri .....	42
<b>Tablo 4.2.</b> YOLOv5 modeline ait performans ölçütleri .....	44
<b>Tablo 4.3.</b> YOLOv8 modelinin DP, YP, DN, YN değerleri .....	47
<b>Tablo 4.4.</b> YOLOv8 modeline ait performans ölçütleri .....	49
<b>Tablo 4.5.</b> YOLOv5 ve YOLOv8 performans metrikleri değerleri .....	51

## ÖZET

### ÇOCUK HASTALARDA HİPODONTİ TESPİTİDE İKİ FARKLI DERİN ÖĞRENME ALGORİTMASININ KARŞILAŞTIRILMASI ve PERFORMANS ANALİZİ

Yasemin İSPİR METİN

Uzmanlık Tezi, Çocuk Diş Hekimliği Anabim Dalı

Tez Danışmanı: Dr. Öğr.Üyesi Zehra GÜNER

Şubat 2025, Sayfa 79

Hipodonti, üçüncü azı dişleri hariç bir ila altı dişin konjenital olarak eksikliği şeklinde tanımlanan ve sık görülen bir dental anomalidir. Kalıcı dişlerde hipodonti, maloklüzyon, alveolar kemiğin yetersiz büyümesi ve estetik sorunlar gibi komplikasyonlara yol açabilir. Bu komplikasyonların büyük bir kısmı, maliyetli ve karmaşık multidisipliner tedaviler gerektirir. Bu nedenle, pediatrik hastalarda diş kaybını yönetmek için doğru teşhis ve zamanında tedavi büyük önem taşımaktadır. Panoramik radyografiler ile radyografik değerlendirme, diş eksikliklerinin erken yaşlarda tespit edilmesine olanak sağlamaktadır. Bu çalışmanın amacı, panoramik radyografiler kullanılarak çocuk hastalarda hipodontinin erken teşhisinde YOLOv5 ve YOLOv8 algoritmalarının performanslarını karşılaştırmaktır. Algoritmaların doğruluk ve verimliliğini değerlendiren çalışma, yapay zeka tabanlı yaklaşımlarla diş eksikliklerinin erken tespitine katkı sağlamayı ve diş hekimliği alanında yapay zekanın teşhis süreçlerine entegrasyonuna temel oluşturmayı hedeflemektedir. Çalışma kapsamında 8-16 yaş aralığındaki hastaların 1060 panoramik görüntüsü ile veri seti oluşturuldu. YOLOv5 ve YOLOv8 derin öğrenme algoritmalarının sınıflandırma performansı değerlendirildi. Model performanslarını değerlendirmek için karmaşıklık matrisi kullanıldı. YOLOv8, %92,45 doğruluk oranıyla YOLOv5'in %62,3 doğruluk oranına kıyasla çok daha başarılı bir performans sergiledi. Sonuç olarak, bu çalışma, yapay zeka tabanlı derin öğrenme yöntemlerinin hipodonti teşhisinde etkili bir destek aracı olabileceğini göstermektedir. Bu teknolojilerin teşhis doğruluğunu artırma, süreçleri hızlandırma ve hekimlerin iş yükünü azaltma potansiyeli vurgulanmaktadır.

**Anahtar sözcükler:** derin öğrenme, diş eksikliği, hipodonti, yapay zeka, YOLO.

## ABSTRACT

### COMPARISON AND PERFORMANCE ANALYSIS OF TWO DIFFERENT DEEP LEARNING ALGORITHMS IN THE DIAGNOSIS OF HYPODONTIA IN PEDIATRIC PATIENTS

Yasemin İSPİR METİN

Specialization Thesis, Department of Pediatric Dentistry

Supervisor: Assistant Professor Zehra GÜNER

February 2025, Page 79

Hypodontia is a common dental anomaly, defined as the congenital absence of one to six teeth excluding third molars. Hypodontia in permanent teeth can lead to complications such as malocclusion, insufficient growth of alveolar bone, and aesthetic problems. A significant portion of these complications requires costly and complex multidisciplinary treatments. Therefore, accurate diagnosis and timely intervention are crucial for managing tooth loss in pediatric patients. Radiographic evaluation with panoramic radiographs facilitates the early detection of tooth deficiencies at young ages. This study aims to compare the performance of YOLOv5 and YOLOv8 algorithms in the early diagnosis of hypodontia in pediatric patients using panoramic radiographs. By evaluating the accuracy and efficiency of these algorithms, the study aims to contribute to the early detection of tooth deficiencies through artificial intelligence-based approaches and to lay the groundwork for integrating artificial intelligence into diagnostic processes in dentistry. A dataset was created using 1060 panoramic images of patients aged 8 to 16. The classification performance of the YOLOv5 and YOLOv8 deep learning algorithms was evaluated using a confusion matrix to assess model performance. YOLOv8 demonstrated a significantly higher accuracy rate of 92,45% compared to YOLOv5, which achieved an accuracy rate of 62,3%. In conclusion, this study demonstrates that artificial intelligence-based deep learning methods can serve as an effective support tool in diagnosing hypodontia. These technologies can potentially improve diagnostic accuracy, accelerate clinical processes, and reduce the workload of clinicians.

**Keywords:** artificial intelligence, deep learning, hypodontia, tooth deficiency, YOLO.

# 1. GİRİŞ VE AMAÇ

Diş gelişimi, epitel ve mezenkimal hücrelerin stomatoderimde karşılıklı etkileşimleriyle gerçekleşen karmaşık bir süreçtir. Süt dişleri intrauterin yaşamın 6-8. haftaları arasında, kalıcı dişler ise 20. haftada gelişmeye başlar (1). Her bir dişin doğru sayıda, konumda, boyutta, morfolojide ve bileşimde oluşabilmesi, karmaşık genetik ve moleküler düzenlemeler gerektirir. Gelişim sürecinin erken dönemlerindeki bozukluklar ise doğuştan eksik dişler (hipodonti) veya fazla dişler (hiperdonti) gibi sayı anomalilerine neden olabilir (2).

Hipodonti, üçüncü azı dişleri hariç bir ila altı dişin konjenital eksikliği olarak tanımlanan ve sık görülen bir dental anomalidir. Bu durum literatürde konjenital diş eksikliği, diş aplazisi veya diş agenezi gibi çeşitli terimlerle tanımlanmıştır (3). En sık eksik bulunan dişlerin üçüncü büyük azı dişleri olduğu belirlenmiştir. Üçüncü büyük azılar hariç tutulduğunda, en yaygın eksikliği görülen dişlerin mandibular ikinci küçük azı ve maksiller lateral kesici dişler olduğu tespit edilmiştir. Maksiller santral kesiciler, maksiller ve mandibular birinci büyük azılar ile kanin dişlerin eksikliği ise oldukça nadir olup, bu durum genellikle oligodonti vakalarında gözlemlenmiştir (4,5).

Hipodontinin görülme sıklığı kadınlarda erkeklerden daha yüksektir (6). Hipodonti, primer dişlenmeye (%0,5-%2,4) göre kalıcı dişlenmede (%1-%13, üçüncü azı dişleri hariç) daha yaygın olarak görülür (7). Hipodontisi olan bireylerin belirgin iskelet özellikleri ve büyüme paternlerine sahip olup olmadığı belirsiz olsa da mikrodonti, diş yer değiştirmesi, ektopik kalıcı dişler ve primer molarların infraoklüzyonu gibi bazı klinik özellikler sıklıkla gözlemlenmektedir (8). Kalıcı dişlerde hipodonti, maloklüzyon, periodontal travma, alveolar kemiğin yetersiz büyümesi ve estetik sorunlar gibi çeşitli komplikasyonlarla ilişkilidir. Bu sorunların çoğu, maliyetli ve karmaşık multidisipliner tedaviler gerektirir (9). Özellikle gelişim çağındaki çocuklarda iskelet ve alveolar kemik büyümesinin devam etmesi nedeniyle diş kayıplarının yol açtığı bu komplikasyonlar daha ciddi boyutlara ulaşabilir. Bu nedenle, pediatrik hastalarda diş kaybını yönetmek için zamanında tedavi ve doğru teşhis büyük önem taşır (10).

Radyografik incelemeler, diş hekimliğinde hasta yönetimini iyileştirmek, klinik teşhis ve tedavi planlamasına güven kazandırmak amacıyla kullanılan önemli bir araçtır. Özellikle

pedodonti alanında radyografiler, diş çürüklerinin, travmaların ve ağız patolojilerinin tespitinde etkili bir rol oynarken, aynı zamanda kalıcı dişlerin gelişimini, sürme aşamasını ve hipodonti, hiperdonti, kemik patolojileri gibi dental anomalileri değerlendirmek için de kullanılır (11). Ancak, klinisyenin beceri düzeyine bağlı olarak, görüntüleme sırasında oluşabilecek problemler nedeniyle anatomik yapıların üst üste binmesi, görüntülerin bozulması, büyümesi veya küçülmesi, panoramik radyografilerin doğru şekilde yorumlanmasını zorlaştırabilir (12,13).

Diş radyografilerinin kullanımının giderek artmasıyla birlikte, diş hekimlerine bilgisayar destekli analiz konusunda yardımcı olmak büyük bir gereklilik haline gelmiştir ve bu konuda çalışmalar devam etmektedir. Radyografilerden dişlerin otomatik olarak tanınması, diş hekimlerine tedavi süreçlerinde destek sağlayarak iş yüklerini hafifletmek, yorumlama hatalarını ve teşhis sürelerini azaltmak için etkili bir yöntemdir (14).

Günümüzde yapay zeka uygulamaları, özellikle derin öğrenme teknikleri, görüntü sınıflandırma, nesne algılama ve segmentasyon gibi görevlerde yaygın bir şekilde kullanılmaktadır (15). Son zamanlarda derin öğrenme, tıbbi görüntüleme, meme kanseri, kolon kanseri, akciğer hastalıkları, göz hastalıkları, travma ve ortopedi gibi hastalıkların tespiti ve yerinin belirlenmesinde klinisyenlere yardımcı olmak için kullanılmıştır (16). Derin öğrenme, geniş görüntü veri setlerinden klinik verileri hızlı ve doğru bir şekilde çıkarma yeteneği sayesinde, diş hekimliğinde büyük bir potansiyele sahiptir (17). Diş hekimliği alanında yapay zeka uygulamaları diş tespiti ve numaralandırma, restorasyon sınıflandırması, kök kırığı tespiti, mandibular birinci ve üçüncü azı dişlerin kök morfolojisi ve mandibular kanal tespiti, maksiller sinüzit tanısı, osteoporoz değerlendirmesi gibi geniş bir yelpazeyi kapsamaktadır. Ayrıca, radiküler ve dentigeröz kistler, odontojenik keratokistler, ameloblastomalar gibi radyolüsent lezyonların ayırımında etkili bir şekilde kullanılmaktadır (18,19). Yapay zeka tabanlı modeller kullanarak aktif araştırmalar birçok bilimsel alanda devam etmektedir; özellikle YOLO (You Only Look Once), RetinaNet, R-CNN (Region-based Convolutional Neural Network) ve SSD (Single-Shot Detector) gibi algoritmalarla yapılan yapay zeka tespit modelleri üzerine çalışmalar ilerlemektedir. Konvolüsyonel sinir ağlarıyla derin öğrenme algoritmaları olan YOLO ve RetinaNet, iyi performans göstermiştir (18,19,20).

Bu çalışmanın amacı, çocuk hastalarda hipodonti teşhisinde derin öğrenme modeli olan YOLOv5 ile YOLOv8 algoritmalarının performanslarını karşılaştırarak bu

algoritmalarından hangisinin daha doğru ve verimli sonuçlar verdiğini belirlemektir. Araştırma hem algoritmaların sınıflandırma kabiliyetlerini hem de teşhis süreçlerindeki potansiyellerini değerlendirerek, dış hekimliği alanında yapay zekanın uygulanabilirliğini artırmayı hedeflemektedir.



## **2. GENEL BİLGİLER**

### **2.1. Hipodonti (Diş Agenezisi)**

#### **2.1.1. Hipodonti Tanımı ve Tespiti**

Konjenital diş eksikliği (diş agenezisi), çocuklarda en yaygın görülen gelişimsel problemlerdendir (21). Hipodonti, genellikle üçüncü molarlar hariç bir veya daha fazla dişin gelişimsel olarak eksikliğiyle karakterize edilen genel bir terimdir (22).

Hipodonti, diş gelişiminin erken evrelerindeki (başlangıç ve proliferasyon) bozukluklardan kaynaklanır. Bu süreçte, diş germinin gelişiminde genetik, epigenetik ve çevresel faktörler rol oynar. Özellikle genetik mutasyonlar, hipodonti vakalarının büyük bir kısmında belirleyici bir etken olarak öne çıkmaktadır (9).

Bir diş, ağız boşluğunda sürmemişse ve radyografik değerlendirme de herhangi bir varlık göstermiyorsa konjenital olarak eksik kabul edilir. Tüm süt dişleri yaklaşık 3 yaşında, üçüncü molarlar hariç tüm kalıcı dişler ise yaklaşık 12 yaşında sürmelerini tamamlar. Bu nedenle, süt diş eksikliğinin tanısında 3-5 yaş, kalıcı diş eksikliğinin tanısında ise 12-14 yaşlar uygun zaman aralığı olarak kabul edilmektedir. Bununla birlikte, radyografik değerlendirme, diş eksikliklerini daha erken yaşlarda da tespit edilmesini sağlamaktadır. Panoramik radyografiler, hipodonti tanısının doğrulanmasında ve eksik dişlerin konumlarının değerlendirilmesinde yaygın olarak kullanılan önemli bir tanı aracıdır (23).

#### **2.1.2. Rastlanma Oranı**

Süt dişlerinde diş agenezisi nadir görülen bir durum olup, kalıcı dişlerdeki kadar yaygın değildir. Süt ve kalıcı dişlerde hipodonti arasında anlamlı bir ilişki bulunmakta; süt dişlerinde hipodonti görülen bireylerde genellikle ilgili ardıl dişlerin de eksik olduğu rapor edilmektedir (23,24).

Mandibular ikinci premolar, hipodonti vakalarında en sık eksik olduğu tespit edilen diş olup, bunu sırasıyla maksiller lateral kesici ve maksiller ikinci premolar izlemektedir. Ancak, bazı çalışmalarda en çok etkilenen dişlerden en az etkilenenlere doğru sıralamada farklılıklar gözlenmiştir. Bu farklılıklar, genellikle örneklem büyüklüğündeki yetersizlikler veya eksik değerlendirmelerle açıklanabilmektedir. Maksiller santral

kesicilerin, maksiller ve mandibular birinci molarların ve mandibular kaninlerin agenezisi oldukça nadirdir (25–27).

Hipodontinin prevalansı ve dağılımına ilişkin çalışmalar, örneklem büyüklüğü, cinsiyet, ırk ve etnik köken gibi faktörlerin yanı sıra popülasyon özellikleri, katılımcıların yaşı, kullanılan araştırma yöntemleri ve tanı kriterlerine bağlı olarak yüksek derecede değişkenlik göstermektedir (25,28). Yapılan çoğu meta-analiz çalışmasında, kadınların erkeklere kıyasla hipodontiden daha fazla etkilendiği belirtilmiş, en yüksek prevalansın ise Çin popülasyonunda görüldüğü (%7,7 kadınlar, %6,1 erkekler) rapor edilmiştir. Bunun aksine, Suudi Arabistanlı kadınlarda hipodonti oranının %2,2 ile en düşük seviyede olduğu tespit edilmiştir (25,29).

2005 yılında Gelgör ve arkadaşları tarafından Türk toplumu üzerinde yapılan ve 4500 hasta kaydını kapsayan bir çalışmada, üçüncü molarlar hariç hipodonti prevalansı %14,1 olarak tespit edilmiştir. En fazla diş agenezisine, alt ikinci premolar dişlerde rastlanmaktadır. Bunu sırasıyla alt birinci molar dişler, üst lateral kesiciler ve üst birinci molar dişler takip etmektedir (30).

2007 yılında Türk popülasyonu üzerinde gerçekleştirilen bir çalışmada, hipodonti prevalansı %2,63, oligodonti prevalansı ise %0,13 olarak rapor edilmiştir. Araştırma, hipodontinin Türk toplumunda en yaygın görülen dental anomali olduğunu ortaya koymuştur. Eksikliği en sık görülen dişlerin %1,74 oranıyla üst lateral kesiciler olduğu belirlenmiş; bunu maksiller ve mandibular premolarların %0,46 oranıyla takip ettiği bildirilmiştir (31).

2016 yılında Gökkaya ve Kargül tarafından Türk toplumunda yapılan bir diğer çalışmada, hipodonti prevalansı %6,2 olarak belirlenmiştir (%6,3 kızlar, %6 erkekler). Çalışma, cinsiyetler arasında istatistiksel olarak anlamlı bir fark olmadığını göstermiştir. En sık eksikliği tespit edilen diş ise %20,7 oranıyla mandibular sol ikinci küçük azı dişi olmuştur (32).

Konjenital diş eksikliğinin cinsiyete bağlı prevalansı konusunda literatürde tam bir fikir birliği bulunmamaktadır. Bazı araştırmalar, diş eksikliğinin kadınlarda erkeklere göre daha sık görüldüğünü belirtmiştir (25,30,33). Ancak bazı çalışmalar ise cinsiyetler arasında anlamlı bir fark olmadığını rapor etmiştir (34,35,32).

### **2.1.3. Hipodonti Oluşum Nedenleri**

Hipodontinin etiyolojisi üzerine birçok çalışma yapılmış olmasına rağmen, kesin nedenleri tam olarak anlaşılamamıştır. Bununla birlikte, hipodontinin oluşumunda genetik ve çevresel etkenlerin belirgin bir rol oynadığı düşünülmektedir (36,24,37). Diş agenezisi, enfeksiyonlar (ör. kızamıkçık), dentoalveolar süreçlerin apikal bölgesindeki travmalar (kırıklar, geçici diş çekimi), kimyasal maddeler veya ilaçlar (ör. talidomid, kemoterapi), radyasyon tedavisi gibi çevresel faktörlerden kaynaklanabilse de vakaların büyük çoğunluğunun genetik nedenlere dayandığı bilinmektedir (38–41).

#### **2.1.3.1. Kalıtsal Predispozisyon**

Diş eksikliği bazen çevresel faktörlere bağlı olarak ortaya çıkabilse de vakaların büyük çoğunluğunda hipodontinin temelinde genetik bir neden yatmaktadır. Hipodontinin genetik kökeni, bu durumun etiyolojisindeki en önemli etken olarak kabul edilir ve hipodonti hastalarının yakın akrabalarında bu durumun görülme oranı, genel popülasyona kıyasla daha yüksektir (42–44).

Diş agenezisi, izole (nonsendromik) ya da sendromlarla ilişkili (sendromik) bir durum olarak ortaya çıkabilir. Radyasyon, kemoterapi ajanları ve dioksin gibi çevresel faktörler diş gelişimini olumsuz etkileyebilir. Ancak, genetik faktörler diş agenezisinin oluşumunda çevresel etkenlere kıyasla daha belirgin bir rol oynamaktadır. Özellikle erken diş gelişimi sırasında ifade edilen paired box 9 (PAX9), muscle segment homeobox 1 (MSX1), axis inhibitor 2 (AXIN2) ve ectodysplasin A (EDA) genlerindeki mutasyonlarla ilişkili otozomal dominant diş agenezisini destekleyen moleküler çalışmalar bu durumu doğrulamaktadır. Ayrıca, diş agenezisinin monozygotik ikizlerde daha sık görülmesi, genetik faktörlerin önemli bir etkisine işaret etmektedir (45,46).

Her genin, belirli diş gruplarının eksikliğine yol açabilecek bir eğilime sahip olduğu ifade edilmiştir; MSX1 geni premolar eksikliklerinde, PAX9 geni ise molar eksikliklerinde rol oynar (47). Ayrıca msh homeobox 9 (MSX9) genindeki bir nokta mutasyonunun, konjenital eksik ikinci premolarlar ve üçüncü molarlarla ilişkili olduğu tespit edilmiştir (48).

Diş gelişiminde etkili olduğu bilinen distal-less homeobox (DLX), LIM homeobox (LHX), interferon regulatory factor 6 (IRF6), transforming growth factor alpha (TGFA) ve fibroblast growth factor receptor 1 (FGFR1) gibi genlerin mutasyonlarının, diş

sayısında deęişikliklere yol açabileceęi tespit edilmiştir (47,49). Sendromik olmayan hipodonti durumunda ise AXIN2, EDA, latent transforming growth factor beta binding protein 3 (LTBP3) ve Wnt family member 10A (WNT10A) genlerinin bu sürece dahil olduęu ortaya konulmuştur (49,47).

### **2.1.3.2.Çevresel Predispozisyon**

Dişlerin ve bazı kraniyofasiyal yapıların gelişiminde benzer biyolojik süreçler devreye girer (21). Hipodonti ile ilişkili sendromlar, genellikle çeşitli displaziler ve yarıklarla karakterize edilen bir klinik tablo ortaya koymaktadır. Bu kraniyofasiyal anomalilerden bazılarında, çevresel faktörlerin risk artışıyla bağlantılı olduęu uzun zamandır bilinmektedir. Travma, enfeksiyon ve toksin maruziyeti, bu çevresel faktörler arasında en dikkat çeken etmenler olarak değerlendirilmektedir (50).

Gebelik durumunda kullanılan birtakım ilaçların konjenital diş eksikliğine yol açabileceğini vurgulayan çalışmalar ilgili kaynaklarda bulunmaktadır. Örneğin bir araştırmada, gebelikte antikonvülsan ilaç kullanımının dental anomaliler arasında en çok konjenital diş eksikliğine neden olduęu belirtilmiştir (51). Başka bir çalışmada ise Talidomid embriyopatisi olan çocuklarda diş eksikliğinin (%7,7) normal çocuklara (%0,4) göre daha yaygın olduęu bildirilmiştir (50,52).

Erken çocukluk döneminde uygulanan kemoterapi ve radyoterapi tedavilerinin hipodonti oluşumunda rol oynayabileceęi ifade edilmiştir (41,53). Ayrıca, bazı çalışmalar hamilelik sırasında geçirilen kızamıkçık enfeksiyonunun, gelişmekte olan çocukta hipodontiye yol açabileceğini göstermektedir (54). Bununla birlikte, hamilelik sürecinde annenin sağlık durumunun hipodonti ile doğrudan bir ilişkisi bulunmadığına dair sonuçlar da mevcuttur (55).

### **2.1.4. Diş Agenezisi ve Dişsel Deformiteler**

Dental anomalisi bulunan bireylerde, başka bir dental anomali görülme olasılığı, normal popülasyona kıyasla daha yüksektir. Özellikle hipodontisi olan hastalarda diş sürmesinde gecikme, mikrodonti, kron formunun konikleşmesi, süt dişlerinin persistansı, dişlerin farklı pozisyonlarda bulunması gibi çeşitli dişsel anomaliler sıklıkla bir arada görülmektedir (56–58).

Mikrodonti, hipodonti ile sıklıkla ilişkili olan ve vaka raporlarında yaygın olarak bildirilen bir dental anomalidir. Yapılan arařtırmalar, konjenital diř eksikliđi bulunan bireylerde, normalden daha küçük diřlerin sıklıkla gözlemlendiđini ortaya koymaktadır (59). Bir veya birden fazla diři etkileyebilen mikrodonti hem süt diřlerinde hem de daimi diřlerde görülebilmektedir. Mikrodonti ile hipodontinin genetik olarak ilişkili olduđunu ve diř germinin belirli bir boyuta veya diř sayısı eřiđine ulaşamadıđında diř gelişiminin durabileceđini öne sürmüştür (3,60).

Diř gelişimindeki gecikmeler, hipodontiyle ilişkilendirilen yaygın bir özelliktir. Kalıcı diřlerin eksikliđi, süt diřlerinin köklerinin doğal rezorpsiyon sürecini yavaşlatabilir ve bu durum süt diřlerinin ağızda uzun yıllar kalmasına neden olabilir (61). Ayrıca, diř agenezisi olan hastaların yarısına yakınında diřlerin kök/kron oranının azalmıř olduđu tespit edilmiřtir (24). Hollanda'da gerçekleştirilen bir arařtırma ise, taurodontizm ile hipodonti arasında anlamlı bir ilişki olduđunu ortaya koymuřtur. Çalışmada, alt birinci molar diřlerde taurodontizm, oligodontisi bulunan bireylerin %29'unda tespit edilmiřtir. Buna karşılık, kontrol grubunda taurodontizm görülme oranı %10 ile sınırlı kalmıřtır. Bu bulgular, taurodontizm ve hipodonti arasındaki genetik veya gelişimsel bir bağlantıya işaret edebilecek önemli bir kanıt sağlamaktadır (62).

Hipodontinin yaygın özelliklerinden biri de kalıcı diřlerin normalden farklı bir konumda sürmesidir. Bu durum, genellikle diřlerin sürme sürecinde rehberlik sağlayacak komřu diřlerin eksikliđi ya da yeterli alanın bulunmaması nedeniyle meydana gelir. Ayrıca, diřlerin yer deđiřtirmesi (transpozisyon) hipodontisi olan bireylerde daha sık karşılaşılan bir durumdur (63). Ağız içinde geriye eğimli ve aşırı şekilde sürmüř alt kesici diřler, kapanıř derinliđinin artmasına neden olabilir (64).

### **2.1.5. Konjenital Diř Eksikliđinin Tedavisi**

Konjenital diř eksikliđi (hipodonti), çiđneme, konuřma ve estetik gibi işlevleri etkileyen karmařık bir dental anomalidir. Bu durum, bireylerin hem ağız sađlıđını hem de psikolojik durumlarını olumsuz etkileyebilir. Tedavi sürecinde, her hastanın bireysel gereksinimleri ve mevcut dental yapıları göz önünde bulundurularak özel bir tedavi planı oluşturulması önemlidir. Tedavi planı, diř eksikliđinin sayısı ve konumu, fonksiyonel etkiler, hastanın yaşı ve genel sađlık durumu gibi faktörlere göre şekillenir. Ayrıca, mevcut süt ve daimi diřlerin durumu, çürük diřlerin varlıđı, destek dokular, okluzyon,

interokluzal mesafe ve temporomandibular eklemin durumu da değerlendirilerek bireyin yaşam kalitesini destekleyecek bir yaklaşım benimsenmelidir (5,22,65).

Diş eksikliği tedavisinde, ortodontik uygulamalardan implantlara, kuron ve köprülerden sabit veya hareketli, total ya da parsiyel protezlere ve overdenture protezlere kadar çeşitli seçenekler bulunmaktadır (66). İmplant destekli sabit protezler, özellikle genç bireylerde geleneksel protezlerin neden olabileceği estetik, fonetik, fonksiyonel ve psikolojik sorunların önlenmesine yardımcı olmaktadır. Çocuklarda implant uygulamalarının genellikle 16-18 yaşlarından sonra yapılması daha uygun görülmektedir. Ayrıca, üst ve alt çene ön dişlerinin pasif erüpsiyonunun 20 yaşına kadar devam etmesi, diş eti yapısı ve papil yüksekliğinde değişikliklere yol açabileceği için bu süreçte dikkatli bir planlama yapılması gereklidir. Bu yaklaşım hem fonksiyonel hem de estetik sorunların önüne geçilmesini sağlar ve implant uygulamaları için daha elverişli bir zemin hazırlar (5,67-69).

Hipodonti hastalarında diş gelişimi genellikle gecikir ve bu durum ortodontik tedaviyi etkiler (70). Hafif çapraşıklık olan genç hastalarda, erken karma dişlenme döneminde belirli süt dişlerinin çekimi, komşu dişlerin hareketine yardımcı olabilir. Ancak, eksik premolar vakalarında, boşluk kapanmasının genellikle tam olmadığı ve ek tedavilerin gerekebileceği belirtilmiştir. Örneğin, süt ikinci molarların çekimi sonrasında alt çenede 2 mm'lik bir artık boşluk kaldığı rapor edilmiştir (71,72). Buna karşılık, süt ikinci molarların pubertal büyüme atağı öncesinde çekilmesinin, ön çapraşıklık azaltabileceği ve eksik premolar boşluğunu kendiliğinden kapatabileceği gösterilmiştir. Bu hareketler, molarların mezial ve dönme hareketleri ile premolarların distal hareketi sayesinde gerçekleşir. Ayrıca, çekimlerin overjet, overbite veya kesici diş eğimine etkisi olmadığı ifade edilmiştir (73).

Alt ikinci premolar agenezisi için en uygun ortodontik tedavi zamanı erken ergenliktir, çünkü bu dönem kalıcı dişlerin çoğunun sürdüğü ve yüz büyümesinin tamamlandığı zamandır. Ancak yetişkinlerde tedavi, çürükler, periodontal sorunlar ve büyüme potansiyelinin olmaması nedeniyle daha karmaşıktır ve oklüzyon bozukluklarına uyum kapasitesini azaltabilir (64).

Dişlerin gelişimi, eşlik eden dental anomaliler ve alveoler kemiğin durumu erkenden tespit edilerek uygun müdahalelerin gerçekleştirilmesi, ilerleyen süreçte oluşabilecek


ortodontik problemleri azaltacak ve protetik ile implant uygulamalarında karşılaşılabilecek zorlukları ortadan kaldıracaktır.

## 2.2. Yapay Zeka

Yapay zeka, veri setlerinden yararlanarak öğrenebilen, belirli sorunlara çözüm üretebilen ve belirlenmiş görevleri yerine getirirken insan zekasını ve davranışlarını taklit edebilen bir makine sistemi olarak tanımlanabilir (74).

Yapay zeka ile ilgili ilk adımlar, 1943 yılında Warren McCulloch ve Walter Pitts'in gerçekleştirdiği ve "Beynin Boolean Devre Modeli" olarak bilinen önemli bir çalışma ile atılmıştır. Bu çalışma, yapay sinir ağlarının temelini oluşturarak yapay zeka alanının gelişimine önemli katkılar sağlamıştır. McCulloch ve Pitts, sinir hücrelerinin (nöronların) karmaşık etkileşimlerini basit matematiksel ve mantıksal kurallarla açıklamayı amaçlamışlardır (75).

Günümüzde yapay zekanın temelleri, Alan Turing'in geliştirdiği ve şifreli mesajları çözme yeteneğine sahip bir makineye dayandırılmaktadır. İngiliz matematikçi Turing, 1950 yılında bu makineyi geliştirerek yapay zeka alanındaki önemli bir adımı atmıştır. Turing ayrıca, bir makinenin insan zekasını ne ölçüde taklit edebileceğini değerlendiren ve bilgisayarların zeka seviyesini ölçmeye yönelik bir yöntem olan "Turing Testi"nin de mucidi olarak bilinir. 1950 yılında Turing, "Makineler düşünebilir mi?" sorusunu temel alan bir makale yayınlamış ve bu çalışmasında, "Eğer bir insan mevcut bilgileri kullanarak karar verebiliyor veya bir problem çözebiliyorsa, makineler neden bunu yapamıyor?" sorusunun yanıtını aramıştır. Bu fikirler, günümüzde sıkça kullanılan "Turing Testi" kavramının doğuşuna zemin hazırlamıştır (76,77).



Şekil 2.1. Turing Test (78)

Yapay zeka terimi ilk kez 1955 yılında John McCarthy tarafından ortaya atılmış ve 1956 yılında düzenlenen Dartmouth Konferansı'nda kullanılmıştır. Bu konferans, yapay zekanın yeni bir bilim alanı olarak gündeme gelmesini sağlamış ve alanın bilimsel bir nitelik kazanmasına öncülük etmiştir. Yapay zekanın doğuşu olarak kabul edilen Dartmouth Konferansı, bu alanda çalışan birçok araştırmacıyı bir araya getirmiştir.

John McCarthy, Dartmouth Konferansı'nda yapay zeka terimini, “insan benzeri zeki makineler ve bilgisayar programları geliştirme bilimi ve mühendisliği” olarak tanımlamıştır. Yapay zekanın gelişimi ve teknolojik ilerlemeler, bu alanın farklı sektörlerde kullanılmasını sağlamış, özellikle tıp gibi kritik alanlarda önemli uygulamaların ortaya çıkmasına yol açmıştır (79).

Yapay zekanın tıp alanında uygulanabilirliğini göstermek için geliştirilen ilk modellerden biri, CASNET (Causal Associational Network) modeli temel alınarak glokom hastalığı için bir konsültasyon programının geliştirilmesidir. 1976 yılında Nevada'da düzenlenen Oftalmoloji Akademisi toplantısında resmi olarak tanıtılan bu model, nedensel-ilişkisel bir ağ yapısına sahip olup, model oluşturma, konsültasyon ve bir veritabanından oluşan üç farklı programı içermektedir (80).

1950'lerde ortaya çıkan yapay zeka kavramını, 1980'lerde makine öğrenimi teriminin tanımlanması takip etmiş, ardından yapay sinir ağları ve derin öğrenme gibi alt teknikler gündeme gelmiştir. Şekil 2.2' de, yapay zeka ve bu alt teknikler arasındaki ilişki bir Venn diyagramı ile görselleştirilmiştir (81).



**Şekil 2.2.** Yapay zeka, makine öğrenimi, yapay sinir ağları ve derin öğrenme arasındaki ilişki (81)

### 2.2.1. Makine Öğrenimi

Makine öğrenimi, ilk kez 1959 yılında Arthur Samuel tarafından tanımlanmış olup, yapay zekanın bir alt dalı olarak bir veri kümesini bilgisayar algoritmalarıyla eğiterek öğrendiklerini tahmin süreçlerinde kullanmayı amaçlar. Makine öğreniminde kullanılan algoritmalar, büyük miktarda manuel olarak sağlanan verileri analiz ederek, bu verilerden öğrenip doğru ve spesifik yanıtlar üretmek amacıyla geliştirilmiştir. Bu süreç, algoritmanın içindeki parametrelerin ayarlanmasıyla giriş ve çıkış verileri arasında uyum sağlanarak bilgisayarın doğru genellemeler yapabilmesine olanak tanır.

Örneğin, bir makine öğrenme algoritması, radyologlar tarafından normal veya anormal olarak sınıflandırılan binlerce görüntüyü analiz ederek eğitildiğinde, maksillofasiyal bölgede bulunan bir lezyonu normal veya anormal olarak belirleyebilir ya da mevcut bir lezyonu tespit edebilir. Makine öğrenimi algoritmaları, daha fazla veri ile karşılaştıkça kendini geliştirir ve bu sayede daha iyi analiz yaparak yenilikçi çözümler üretebilir (81–83).

Makine öğrenimi, dört temel kategoride değerlendirilir. Bu sınıflandırma, makine öğreniminin bir alt dalı olan derin öğrenme stratejileri için de geçerli bir yaklaşımdır (84).

**Denetimli öğrenme**, makine öğrenimi alanında sıkça kullanılan bir yöntem olup, bir girdi ile bir çıktı arasındaki ilişkiyi örnek girdi-çıkış çiftlerine dayanarak öğrenen bir yaklaşımdır. Bu yöntem, etiketlenmiş bir eğitim veri seti kullanarak bir fonksiyon oluşturmayı ve bu fonksiyonu, yeni girdiler için doğru sonuçları tahmin etmek amacıyla kullanmayı hedefler.

Denetimli makine öğrenimi algoritmaları, dış yardım gerektirir ve bu süreçte girdi veri seti, eğitim ve test veri seti olmak üzere ikiye ayrılır. Eğitim veri seti, algoritmanın tahmin edilmesi veya sınıflandırılması gereken çıktı değişkenini öğrenmesine olanak tanır. Algoritmalar, eğitim veri setinden desenleri öğrenerek, bu bilgiyi test veri setinde tahmin veya sınıflandırma yapmak için uygular (85,86).

**Denetimsiz öğrenme**, modelin eğitilmesi için etiketlenmemiş verilerin kullanıldığı bir yöntemdir. Bu yöntemde model, veriler arasındaki içsel özelliklere dayanarak gruplar oluşturur ve bu gruplamalardan anlamlı çıkarımlar yapmayı hedefler. Makine öğrenimi

algoritmaları, veriler arasındaki ilişkileri keşfederek, belirli görevlerin çözümüne yardımcı olabilecek yapılar geliştirmeyi amaçlar.

Ancak denetimsiz öğrenme, uygulamada başarılı sonuçlar elde etmenin zor olduğu bir yöntemdir. İstenilen başarıya ulaşılabilmesi, yeterli ve uygun bir veri setinin mevcut olmasına bağlıdır. Modelin, verilerin içsel değişkenliklerini doğru bir şekilde analiz ederek anlamlı örüntüler keşfetmesi, yöntemin etkinliğini belirleyen önemli bir faktördür (84).


**Yarı Denetimli Öğrenme**, gerçek dünyada, etiketli verilerin az, etiketlenmemiş verilerin ise bol olduğu durumlarda faydalıdır. Amaç, yalnızca etiketli verilerle elde edilenden daha iyi tahmin sonuçları üretmektir (87).

**Pekiştirmeli Öğrenme**, pekiştirmeli öğrenme, yazılım ve makinelerin çevreden aldığı ödül veya cezalara dayanarak en uygun davranışı öğrenmesini sağlayan bir yöntemdir. Robotik, otonom sürüş, üretim ve lojistik gibi karmaşık alanlarda verimliliği artırmak için kullanılır ancak temel sorunlar için tercih edilmez (84).

### **2.2.2. Yapay Nöral Ağlar (Artificial Neural Network-ANN)**

Beyindeki sinir hücrelerinin etkileşimlerinden ilham alan bu yapılar, karmaşık veri setlerini analiz ederek desen tanıma, sınıflandırma ve tahmin gibi çeşitli görevlerde etkili bir şekilde kullanılabilir (88,89).

Yapay sinir ağları, biyolojik sinir sisteminden esinlenerek geliştirilmiş hesaplamalı analiz araçlarıdır. Paralel işlem yapabilen ve nöron olarak adlandırılan, birbiriyle yüksek derecede bağlantılı bilgisayar işlemcilerinden oluşan bir ağ yapısına sahiptirler (90). Bu ağların temel amacı, insan beyninin işlevlerini taklit eden yapılar oluşturmaktır (91). Biyolojik sinir hücreleri ile yapay sinir ağları arasındaki benzerlikler, Şekil 2.3'te görselleştirilmiştir.

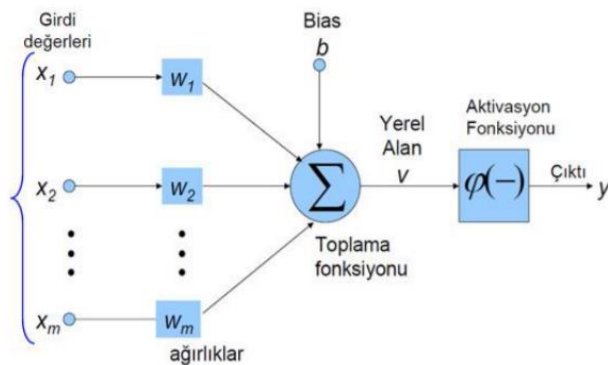


**Şekil 2.3.** (A) Biyolojik sinir hücresi; (B) yapay sinir hücresi; biyolojik sinaps; (D) yapay sinir ağı sinapsları (92)

**Tablo 2.1.** Biyolojik sinir sistemi bileşenleri ve yapay sinir ağlarındaki eşdeğerleri (93)

Biyolojik Sinir Sistemi	Yapay Sinir Sistemi
Nöron	İşlemci Elemanı
Dendrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar

Yapay sinir hücresi, biyolojik sinir hücresinin yapısını ve işlevlerini taklit ederek veri işleme ve öğrenme süreçlerini gerçekleştiren bir yapıdır. Biyolojik sinir sistemi unsurları ve yapay sinir sistemindeki karşılıkları Tablo 2.1’de sunulmuştur. Bu tabloda, biyolojik sinir sistemi bölümlere ayrılarak her bir bileşenin yapay sinir ağı sistemindeki karşılığı belirtilmiştir. Her bir bileşen, yapay sinir hücresinin bilgi alması, bu bilgiyi işlemesi ve anlamlı bir sonuç üretmesi için önemli bir role sahiptir (89).




**Şekil 2.4.** Yapay nöral birim (94)

Yapay sinir ağlarında, her bir nöron belirli giriş değerlerini alır, ağırlıklarla çarpıp toplama fonksiyonuna tabi tutar ve ardından bir aktivasyon fonksiyonuna sokarak çıktıyı üretir (Şekil 2.4). Böylece, ağıın öğrenme süreci veri girişleri ve ağırlık güncellemeleriyle şekillenir (94).

**Girdiler:** Girdiler, biyolojik sinir hücrelerinde olduğu gibi çekirdeğe iletilerek işlenir. **Ağırlıklar ( $w_1, w_2, \dots, w_n$ ):** Girdilerin işlenmesinde kullanılan ve öğrenme sürecinde ayarlanan parametrelerdir. Girdiler, çekirdeğe ulaşmadan önce ağırlıklarıyla çarpılarak sinir hücresine iletilir ve hatayı minimize etmek için optimize edilir. **Toplama Fonksiyonu ( $\Sigma$ ):** Hücreye gelen girdileri ağırlıklarıyla çarpıp toplayarak net girdiyi hesaplar. En sık kullanılan fonksiyon, ağırlık toplama fonksiyonudur ve hücrenin uyarılma seviyesini belirler. **Aktivasyon Fonksiyonu:** Genellikle doğrusal olmayan fonksiyonlar kullanılarak ağıın karmaşık ilişkileri öğrenmesi sağlanır. Örneğin, sigmoid, tanjant hiperbolik ve eşik fonksiyonları gibi farklı aktivasyon fonksiyonları mevcuttur. **Çıktılar:** Aktivasyon fonksiyonunun ürettiği sonuç, sinir hücresinin çıktısıdır. Bu çıktı ya dış dünyaya aktarılır ya da diğer hücrelerde kullanılmak üzere ağına iletilir. Bir hücre, tek bir çıktıyı birden fazla hücreye iletebilir (95,96).


### 2.2.3. Nöral Ağların Yapısal Özellikleri

**Tek katmanlı yapay sinir ağları**, basit nöral ağ yapısıdır. Bu tür ağlarda yalnızca girdi ve çıktı katmanları bulunur, bu sayede girdiler doğrudan çıktılarla ilişkilendirilerek basit bir doğrusal model oluşturulur. Tek katmanlı ağlar, genellikle temel modelleme ve sınıflandırma problemleri için tercih edilmektedir. Tek katmanlı yapay sinir ağı modeli Şekil 2.5'te gösterilmiştir (93).



Şekil 2.5. Basit yapay nöral ağ (93)

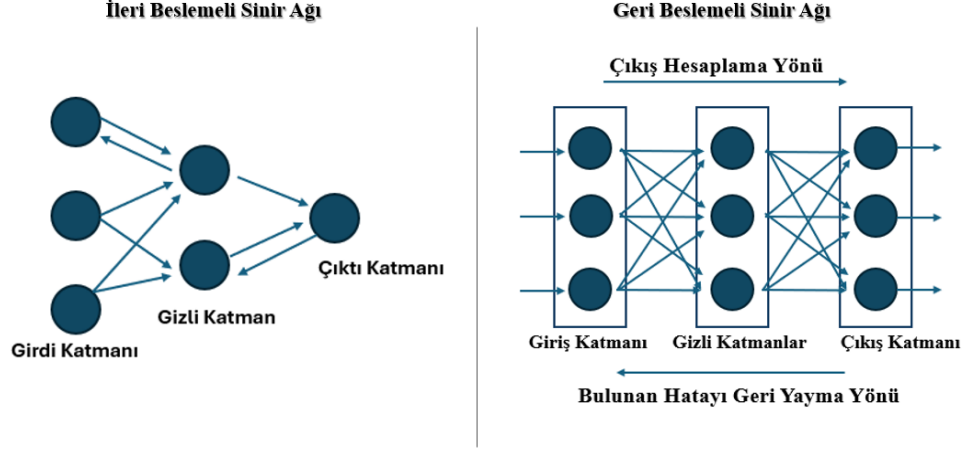
**Çok katmanlı yapay sinir ağları**, girdi katmanı, bilgiyi alır ve işleme katılmadan diğer katmanlara iletir. Gizli katmanlar ise önceki katmanlardan gelen bilgileri işler ve daha karmaşık ve soyut özelliklerin öğrenilmesini sağlar. Çıkış katmanı, işlenmiş bilgiyi sonuca dönüştürür. Bu çok katmanlı yapı, derin öğrenme ve karmaşık görevlerin çözümünde etkili bir şekilde kullanılmaktadır (93,97). Çok katmanlı yapay sinir ağı modeli Şekil 2.6’te gösterilmiştir.



**Şekil 2.6.** Karmaşık yapılı nöral ağ (93)

**İleri beslemeli (doğrusal) yapay sinir ağları**, verilerin girişten çıkışa doğru tek yönde aktığı, geri besleme döngüsü içermeyen bir ağ yapısıdır (Şekil 2.7). Bu ağlar, hızlı yanıt verme özelliğiyle öne çıkar. Veriler, giriş katmanında işlenip sonraki katmanlara aktarılır ve katman sayısı ile nöron sayısı probleme göre belirlenir. Statik bir yapıya sahip olan bu ağlarda, bağlantı ağırlıkları eğitim sırasında ayarlanabilir, ancak geri besleme olmadığından sabit kalır (98,99).

**Geri beslemeli (döngüsel) sinir ağları**, bu ağlar, dinamik hafıza özelliği sayesinde yalnızca mevcut girişlere değil, önceki girişlere de bağlı olarakta işlem yapar. Bu özellik, geçmiş ve mevcut verileri bir arada işleyerek tahmin doğruluğunu artırır (99,100).



Şekil 2.7. Doğrusal ve döngüsel yönlü ağ modelleri (93)

#### 2.2.4. Derin Öğrenme (Deep Learning)

Derin öğrenme, büyük veri kümelerinden otomatik olarak bilgi çıkarma sürecini gerçekleştiren bir makine öğrenimi alt dalıdır ve yapay sinir ağları gibi karmaşık matematiksel modellerden faydalanır. Bu yöntem, bilgisayarların belirli görevleri yerine getirebilmesi için çok katmanlı yapay sinir ağları aracılığıyla karmaşık desenleri ve bağlantıları öğrenmelerini sağlar. Genellikle yüksek düzeyde temsil kapasitesine sahip olan bu çok katmanlı ağlar, derin öğrenme tekniklerinin temelini oluşturur (101,102). Geoffrey Hinton ve çalışma arkadaşlarının 2006 yılında yaptığı araştırmalar, çok katmanlı yapay sinir ağlarının daha verimli şekilde eğitilebileceğini göstermiştir. Bu çalışma, derin öğrenme kavramının temellerini atmış ve yapay zeka alanındaki gelişmeleri önemli ölçüde hızlandırmıştır (102).

Derin öğrenme, yapay zeka alanında yıllardır çözülmesi zor olan sorunların üstesinden gelmede önemli ilerlemeler sağlamıştır. Yüksek boyutlu verilerde karmaşık yapıları keşfetme konusundaki başarısıyla birçok alanda kullanılmaktadır. Görüntü ve konuşma tanıma gibi alanlarda kullanımının yanı sıra, ilaç moleküllerinin aktivitesini tahmin etme, beyin devrelerini modelleme ve DNA mutasyonlarının gen ifadesi üzerindeki etkilerini öngörme gibi birçok alanda üstün performans göstermiştir. Ayrıca, doğal dil anlama, duygu analizi ve dil çevirisi gibi görevlerde de çarpıcı sonuçlar elde etmiştir (103). Derin öğrenme, doğrudan verilerden öğrenme prensibini benimseyerek, geleneksel makine öğrenimi yöntemlerinden ayrılır. Geleneksel makine öğrenimi genellikle önceden tanımlanmış özellikler veya kurallar doğrultusunda modeller geliştirirken, derin öğrenme bu özellikleri verilerden otomatik olarak çıkarma kabiliyetine sahiptir (104).

Derin öğrenme, verilerden otomatik olarak öğrenme sürecini gerçekleştiren bir yapay zeka alanıdır. Bu yöntem, verilerin temsillerinden öğrenmeye dayanır ve alt düzey özelliklerden üst düzey özellikler türeterek hiyerarşik bir yapı oluşturur. Bu yapı, derin öğrenme modellerinin karmaşık veri ilişkilerini daha iyi anlamasını sağlar. Geleneksel makine öğrenimi algoritmalarından farklı olarak, derin öğrenme yöntemlerinde veri miktarı arttıkça algoritmanın performansı ve doğruluk oranı genellikle artar. Daha geniş ve çeşitli veri setleri üzerinde eğitilen derin öğrenme modelleri, daha doğru ve genelleştirilebilir tahminler yapma kapasitesine sahiptir (105).

Derin öğrenme, büyük ölçekli verileri modellemek için birden fazla işlem katmanı ve karmaşık yapılar kullanır. Bu özellikleriyle, makine öğrenimi mimarilerinden farklı olarak, doğrusal olmayan birden fazla dönüşüm içerir. Derin öğrenme mimarileri, farklı veri türlerini temsil edebilmek için çeşitli tasarımlara sahiptir ve bu çeşitlilik, farklı veri kaynaklarına uyum sağlamak için kullanılabilir (106).

Yaygın olarak kullanılan derin öğrenme mimarileri şunlardır: Evrişimli Sinir Ağları (ESA, Convolutional Neural Networks - CNN), Tekrarlayan Sinir Ağları (TSA, Recurrent Neural Networks - RNN), Derin Otomatik Kodlayıcılar, Kısıtlı Boltzmann Makineleri, Uzun-Kısa Süreli Hafıza (UKSH, Long Short-Term Memory - LSTM) ve Derin İnanç Ağları.

ESA, derin öğrenme yapıları arasında en yaygın kullanılan modellerden biridir. Özellikle sınıflandırma ve nesne tespiti gibi görevlerde etkili bir şekilde kullanılmaktadır. Bu ağlar, giriş verisindeki özellikleri belirlemek amacıyla birden fazla katman kullanır ve son olarak sınıflandırma katmanı ile öğeleri gruplandırır (107,108).

## **2.2.5. Derin Öğrenme Mimarileri**

### **2.2.5.1. Evrişimli Sinir Ağları (ESA, Convolutional Neural Networks-CNN)**

CNN, ilk kez LeCun ve arkadaşları tarafından geliştirilmiş ve LeNet adıyla tanıtılmıştır. Gradyan temelli bir yaklaşımı benimseyen bu ağlar, çok katmanlı ve ileri beslemeli yapay sinir ağları olarak tasarlanmıştır (109). Görsel kortekste, temel desenlere tepki veren basit hücreler ve bu desenleri daha karmaşık formlara dönüştüren karmaşık hücrelerden oluşan bir hiyerarşi bulunur. Bu güçlü görsel işleme sistemini taklit eden CNN'ler, yerel bağlantı,

konumdan bağımsızlık ve yerel değişimlere karşı dayanıklılık gibi üç temel prensibe dayanır (103,110).

CNN mimarisi, birbirini takip eden katmanlardan oluşan bir yapıya sahiptir. Bu yapılar, yerel özellikleri tanımlayıp birleştirerek karmaşık desenleri öğrenir ve tanır. CNN'ler, uzamsal bilgileri analiz etme kabiliyetiyle biyomedikal görüntüleme ve biyoinformatik gibi alanlarda geniş bir kullanım potansiyeline sahiptir. Genomik motif tanımlama, omiks verilerdeki etkileşimlerin analizi ve biyomedikal sinyallerin değerlendirilmesi gibi uygulamalarda başarıyla kullanılmaktadır. Önümüzdeki yıllarda CNN'lerin bu alanlardaki etkisinin artarak devam edeceği öngörülmektedir (111).

### **Evrışimli Sinir Ağlarının Katmanları**

**Giriş Katmanı:** Bu katman, ESA'nın ilk aşamasını oluşturur ve veriler bu katmanda ham haliyle ağa aktarılır. Giriş görüntü boyutu, modelin başarımı açısından kritik bir rol oynar. Giriş boyutunun yüksek seçilmesi bellek ihtiyacını, eğitim süresini ve test süresini artırabilir, ancak ağ başarısını olumlu etkileyebilir. Düşük boyutlu giriş ise bellek kullanımını ve işlem süresini azaltırken ağ performansını düşürebilir. Bu nedenle, görüntü analizi için hem hesaplama maliyeti hem de ağ başarımını dengeleyecek uygun bir giriş boyutu belirlenmelidir (112).

**Evrışim Katmanı:** Evrışim katmanı, CNN'lerin temel yapı taşıdır ve girdi verisinden belirgin özelliklerin çıkarılmasını sağlar. Bu işlem, filtreler kullanılarak verinin daha küçük matrislere dönüştürülmesini ve önemli özelliklerin ön plana çıkarılmasını mümkün kılar. Görüntü işleme alanında yüksek doğruluk ve performans sunarak derin öğrenme modellerinin en kritik bileşenlerinden biri haline gelmiştir (113).

**Aktivasyon katmanı:** Bu katmanda, ReLU (Rectified Linear Unit), tanh ve sigmoid gibi aktivasyon fonksiyonları kullanılarak, evrışim katmanından gelen doğrusal (lineer) verinin doğrusal olmayan (non-lineer) bir forma dönüştürülmesi sağlanır. ReLU aktivasyon fonksiyonları, tanh ile kıyaslandığında derin evrışimli sinir ağlarının çok daha hızlı çalışmasını mümkün kılar. Bu hız avantajı nedeniyle ReLU, ESA mimarilerinde sıklıkla tercih edilen bir aktivasyon fonksiyonudur (114,115).

**Havuzlama Katmanı:** Havuzlama katmanı, evrışimli sinir ağlarında yaygın olarak kullanılan ve genellikle aktivasyon katmanlarından sonra yer alan bir bileşendir. Bu katmanın temel amacı, girdi boyutlarını küçülterek ağın hesaplama yükünü ve bellek

ihtiyacını azaltmaktır. Havuzlama işlemleri sırasında bazı veri kayıpları yaşansa da bu durum modelin aşırı ezberlemesini önleyerek eğitim verisine bağımlılığını azaltır. Böylece modelin genelleme yeteneği artırılarak farklı veri setlerinde daha iyi performans göstermesi sağlanır (116).


**Tam bağlı katman:** Bu katman, kendisinden önceki katmandaki tüm nöronlara bağlıdır. Tam bağlantılı katmanın sayısı, kullanılan mimariye göre farklılık gösterebilir. Bu katmanda her bir nöron, önceki katmandaki tüm nöronlarla bağlantı kurar. Bu yoğun bağlantı yapısı nedeniyle tam bağlantılı katman olarak adlandırılır (112).

**Seyreltme katmanı:** ESA'nın büyük veriyle eğitimi sırasında zaman zaman ezberleme eğilimine girebileceği durumların önüne geçmek için kullanılan bir yöntemdir. Bu katman, ağıın bazı düğümlerini rastgele devre dışı bırakarak çalışır. Bu yöntem, ağıın gereksiz detaylara odaklanmasını engeller ve daha genelleştirilebilir, sağlam bir öğrenme süreci sağlamasına yardımcı olur (117).

**Sınıflandırma katmanı:** Sınıflandırılacak nesne sayısına eşit bir çıkış değeri üretir. Örneğin, eğer ağıın 10 farklı nesneyi sınıflandırması gerekiyorsa, sınıflandırma katmanında 10 çıkış birimi bulunur. Bu katman, her sınıf için olasılık değerlerini içeren bir vektör oluşturur ve bu yapı, farklı nesnelerin doğru bir şekilde sınıflandırılmasını sağlar (112).

#### **2.2.5.2. Yinelenen Nörol Ağları (Recurrent Neural Networks-RNN)**


RNN, birimler arasındaki yönlendirilmiş döngüler sayesinde dinamik zamansal davranış sergileyebilen yapay sinir ağı modelleridir (Şekil 2.8). Bu yapılar, girdilerin rastgele dizilerini işleyebilmek için ağıın kendi iç durumunu ve belleğini kullanır. RNN'lerin temel amacı, sıralı bilgileri işleyerek anlam çıkarmaktır. RNN'lerin tekrarlayan olarak adlandırılmasının nedeni, bir dizinin her ögesini (örneğin bir cümledeki kelimeler) önceki çıktılara dayanarak işlemesidir. Bu yapı, özellikle doğal dil işleme (NLP) ve zaman bağımlı veriler için oldukça etkilidir (118).



Şekil 2.8. Yinelenen nöral ağ modeli (107)

### 2.2.5.3. Derin Otomatik Kodlayıcılar

Derin öğrenme mimarilerinden biri olan derin otomatik kodlayıcılar, denetimsiz öğrenme algoritmalarını kullanan sistemlerdir. Bu ağlar, problem çözümüne yönelik gerekli özneliklerin veriden otomatik olarak çıkarılması ve veri boyutunun en az kayıpla sıkıştırılarak azaltılması amacıyla geliştirilmiştir. Yüz ve ses tanıma gibi alanlarda, ayrıca sinyal gürültüsünü temizleme işlemlerinde yaygın olarak kullanılmaktadır (101). Şekil 2.9'da derin otomatik kodlayıcı mimarisi görülmektedir.




Şekil 2.9. Derin otomatik kodlayıcı mimarisi (108)

### 2.2.5.4. Kısıtlı Boltzmann Makineleri

Boltzmann Makineleri, ilk kez 1986 yılında "Harmonium" adıyla ortaya atılmış, ancak uzun bir süre sonra, 2006 yılında Geoffrey Hinton ve ekibi tarafından hızlı bir öğrenme algoritması olarak öne çıkarılmıştır (118). Regresyon, sınıflandırma, modelleme ve boyut indirgeme gibi çeşitli alanlarda kullanılabilen bir derin öğrenme tekniğidir. Bu yöntem genellikle girdi ve gizli katmanlardan oluşan iki katmanlı bir yapı kullanır (Şekil 2.10).

Her bir düğüm, bir nöronu temsil eder ve hesaplamalar bu nöronlar üzerinden gerçekleştirilir. Girdi katmanındaki her düğüm, gizli katmandaki diğer düğümlerle bağlantılıdır, ancak aynı katmandaki düğümler arasında herhangi bir bağlantı bulunmaz (107).




**Şekil 2.10.** Kısıtlı boltzmann makineleri (107)

#### 2.2.5.5. Long-Short/Term Memory (LSTM)

LSTM ağları, uzun vadeli bağımlılıkları öğrenme kapasitesine sahip, özel bir tür tekrarlayan sinir ağıdır. Bu ağlar, bilgileri uzun süreli olarak saklama yeteneğiyle tasarlanmıştır. LSTM modelleri, zamansal bağımlılıkları öğrenme ve karmaşık çok değişkenli dizileri doğru bir şekilde modelleme konusunda oldukça etkilidir. Aynı zamanda, geçmiş bilgileri mevcut veriye entegre etmenin ve gelecekteki bilgileri tahmin etmenin güçlü bir yöntemidir (119).

#### 2.2.5.6. İnanç Tabanlı Derin Öğrenme Modelleri (Deep Belief Networks)

Geoffrey Hinton tarafından geliştirilen Derin İnanç Ağları (DBN), ardışık olarak eklenen RBM katmanlarından oluşur (Şekil 2.11). Her RBM, bir önceki ve bir sonraki katmanla bağlantılıdır, ancak aynı katmandaki düğümler arasında yatay iletişim bulunmaz. DBN'ler, görüntü tanıma ve veri üretimi gibi uygulamalarda kullanılır (102).



**Şekil 2.11.** İnanç tabanlı derin öğrenme modelleri (107)

### 2.2.6. Derin Öğrenme Modelleri

#### LeNet

LeNet-5, 1989 yılında Yann LeCun ve ekibi tarafından tanıtılmış bir mimaridir. CNN modellerinin öncülerinden biri olarak geliştirilen bu model, elle yazılmış posta kodlarını tanımada kullanılmış ve mektuplar üzerindeki testlerde başarılı sonuçlar elde etmiştir. Modelin sınıflandırma doğruluğu %90 seviyelerine ulaşmış, bu da evrişimli sinir ağlarının gerçek dünya uygulamalarında kullanılabileceğini göstermiştir.

LeNet-5, giriş katmanı hariç toplam yedi katmandan oluşmaktadır. Her bir katman, eğitim sürecinde ayarlanabilir parametreler içerir. Model, 32x32 piksel boyutunda bir görüntüyü giriş olarak alır. CNN'lerin temel yapı taşlarından biri olan LeNet-5, tanıtıldığı dönemde uygun donanım eksikliği, özellikle de grafik kartlarının yetersizliği nedeniyle geniş bir kullanıcı kitlesine ulaşamamıştır (120).

#### AlexNet

AlexNet, Alex Krizhevsky ve ekibi tarafından 2012 yılında tanıtılmış bir modeldir. AlexNet, bazıları tam bağlantılı katmanlarla takip edilen beş evrişim katmanı ve üç tam bağlantılı katmandan oluşur. Daha fazla katman kullanılması, performans açısından önemli bir avantaj sağlamış ancak yüksek miktarda kaynak gerektirmiştir. Bu mimari, derin ve geniş evrişimli sinir ağlarının önemini ortaya koyarak önceki yöntemlere kıyasla daha üstün bir performans göstermiş ve derin öğrenme alanında önemli bir dönüm noktası olarak kabul edilmiştir (101,120).

## **GoogLeNet**

GoogLeNet, 22 katmanlı bir derin öğrenme mimarisi olup Inception v1 olarak da bilinir. 2014 yılında Google tarafından tanıtılan model, aynı yıl ImageNet yarışmasını %6,7'lik hata oranıyla kazanmıştır. GoogLeNet'in en önemli yeniliklerinden biri, farklı boyutlardaki filtrelerle paralel olarak çalışan "Inception modülleri"dir. Bu modüller, farklı ölçeklerdeki nesnelere sınıflandırmayı kolaylaştırmak için tasarlanmıştır. Model, verimliliği artırmak ve kaynak kullanımını azaltmak için boyut indirgeme özellikleriyle donatılmıştır. Toplamda dokuz Inception modülü içeren GoogLeNet, derin öğrenme alanında önemli bir adım olmuştur (121).

## **VGGNet (Visual Geometry Group Network)**

VGGNet, Oxford Görsel Geometri Grubu ve DeepMind araştırmacıları tarafından geliştirilen bir evrişimli sinir ağıdır. 16-19 katmanlı derin yapısıyla, 2014 ImageNet yarışmasında konumlandırma görevinde birinci, sınıflandırmada ise ikinci olmuştur. VGGNet, aynı boyuttaki evrişim çekirdeklerini yeniden kullanan blok tabanlı bir yapı kullanır ve bu yaklaşım daha karmaşık görsel özelliklerin öğrenilmesini sağlar. Ancak, büyük boyutu nedeniyle hesaplama hızı düşüktür. Bu modüler yapı, derin sinir ağlarının tasarımında yeni bir standart haline gelmiştir (122).

## **ResNet (Residual Neural Network)**

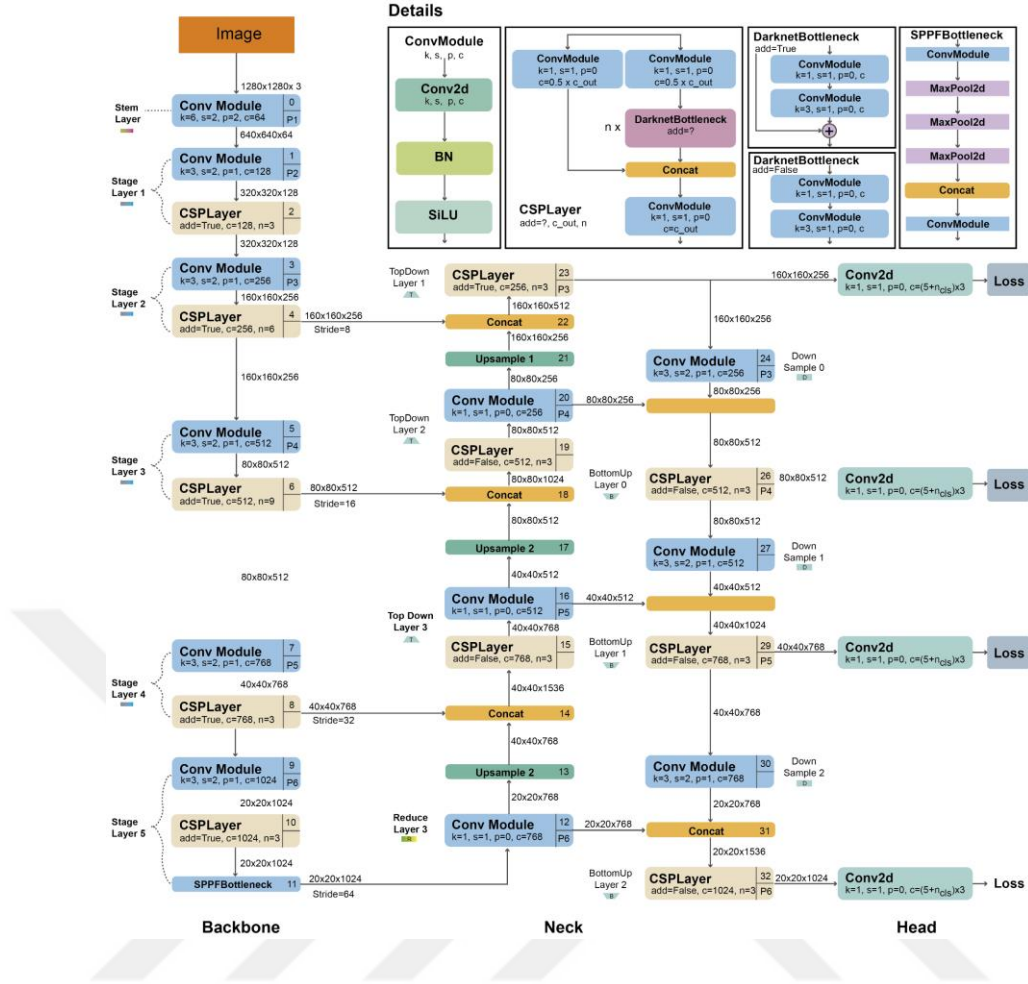
ResNet, 2015 yılında Kaiming He ve ekibi tarafından atlama bağlantıları ve grup normalizasyonu (batch normalization) kullanılarak geliştirilmiş ve aynı yıl düzenlenen ILSVRC ImageNet yarışmasını kazanarak %3.6 gibi düşük bir hata oranı elde etmiştir. Bu oran, insanların %5-%10 aralığındaki hata oranlarıyla kıyaslandığında, ResNet'in görsel tanıma alanında insan seviyesini aştığını göstermektedir. 152 katmanlı bir yapıya sahip olan ResNet, daha önceki mimarilere kıyasla hem derinlik hem de performans açısından önemli bir ilerleme kaydetmiştir. Atlama bağlantıları, modeli daha hızlı yakınsama ve daha yüksek doğruluk için optimize etmiş, aynı zamanda yansıtılmış görüntü sonlandırma gibi uygulamalarda da etkileyici başarılar sağlamıştır (107,121).

## **YOLO (You Only Look Once)**

Nesne tespiti için geliştirilmiş olan YOLO, hızlı ve etkili bir tek aşamalı modeldir. Derin öğrenme yöntemleri arasında yaygın ve popüler hale gelen bu model, 2015 yılında Redmon ve ekibi tarafından tanıtılmıştır. Temel avantajları, modelin kompakt yapısı ve hızlı hesaplama kabiliyetine dayanır. Bu algoritma, sinir ağı üzerinden doğrudan sınırlayıcı kutuların (bounding box) konumunu ve sınıfını tahmin ederek, görüntü veya video gibi girdilerde nesne tespiti yapabilir. YOLO, nesnelerin genel bir görüntü içinde global olarak algılanmasını sağlar ve bu da arka planın yanlışlıkla nesne olarak tanımlanması hatalarını azaltır. YOLO mimarisi, 24 evrişim katmanı ve ardından iki tam bağlantılı katmandan oluşur. Model, ızgara hücreleri içinde birden fazla sınırlayıcı kutu tahmin eder ve en yüksek Intersection Over Union (IOU) değerine sahip kutuyu seçerek tespiti gerçekleştirir. Bu yöntem, hızlı ve gerçek zamanlı nesne tespiti sağlamasıyla öne çıkar (123).

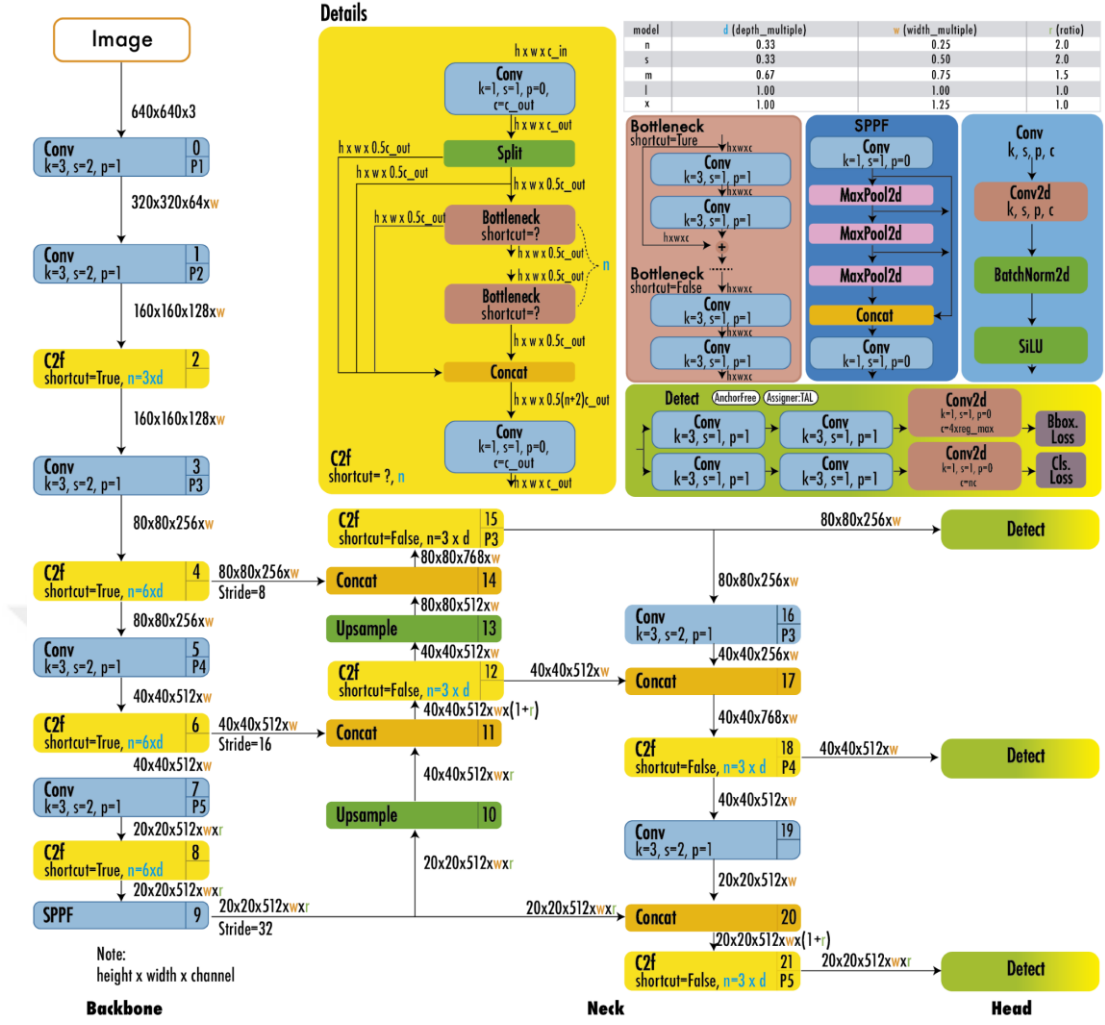
YOLO serisi, gerçek zamanlı nesne tespitinde devrim yaratarak bugüne kadar yaklaşık bir düzine varyant geliştirilmiştir. Bu varyantlar arasında, hız, doğruluk ve verimlilik dengesi açısından YOLOv5 ve YOLOv8 öne çıkmaktadır (124).

YOLOv5, 2020 yılında Ultralytics kurucusu Glen Jocher tarafından tanıtılmış, nesne tespiti alanında önemli bir yenilik olarak öne çıkmıştır. Darknet mimarisi yerine PyTorch kullanılarak geliştirilen YOLOv5, kullanım kolaylığı, yüksek performansı ve esnekliği ile dikkat çekmiştir. PyTorch tabanlı yapısı, önceki sürümlere kıyasla daha hızlı çalışmasını sağlar. YOLOv5, nesne tespiti görevlerinde etkinliğini artırmak için Cross-Stage Partial (CSP) Net ve Hızlı Uzamsal Piramit Havuzlama (SPPF) gibi teknolojilerden yararlanır. CSPNet, ağıın verimliliğini artırırken hesaplama maliyetlerini düşürürken, SPPF, farklı ölçeklerde özellik çıkarımını optimize eder. YOLOv5, gerçek zamanlı nesne tespiti, araç ve yaya tespiti gibi uygulamalarda tercih edilen güçlü bir modeldir (125). YOLOv5'in ayrıntılı mimarisi Şekil 2.12'de gösterilmektedir.



Şekil 2.12. YOLOv5 mimarisi (126)

YOLOv8, Ocak 2023'te Ultralytics tarafından tanıtılan YOLO ailesinin en yeni üyesidir. Önceki sürümlere kıyasla donanım verimliliği ve mimari reformlar sayesinde yüksek performans gösteren YOLOv8'in temel yeniliklerinden biri, daha yüksek çıkarım hızına sahip olması ve kısıtlı uç cihazlarda etkili bir şekilde çalışabilmesidir. Bu özellik, modelin gerçek zamanlı uygulamalar için ideal olmasını sağlamaktadır. YOLOv8'in temel mimarisi, YOLOv5'te kullanılan CSPDarknet yerine C2f modülüyle güncellenmiş bir YOLOv8 CSPDarknet omurgasına sahiptir Ultralytics'in paylaştığı ön benchmark sonuçları, YOLOv8'in mimari ve verimlilik açısından ciddi bir sıçrama yaptığını göstermektedir (Şekil 2.13). Bu gelişmeler, YOLOv8'in nesne tespiti ve diğer bilgisayarla görme görevlerinde endüstriyel ve akademik uygulamalarda daha geniş bir kabul görmesini sağlamaktadır (127,128).



Şekil 2.13. YOLOv8 mimarisi (126)

### 2.2.7. Derin Öğrenme Yöntemlerinin Dış Hekimliğinde Kullanımı

Son yıllarda yapay zeka, diğer sektörlerde olduğu gibi dış hekimliği alanında da hızla gelişim göstermiştir. Dış hekimliği perspektifinden bakıldığında, yapay zeka uygulamaları teşhis, karar verme, tedavi planlaması ve tedavi sonuçlarının tahmini gibi başlıklarda sınıflandırılabilir. Bu uygulamalar arasında en yaygın olanı teşhis sürecidir. Yapay zeka, daha doğru ve hızlı teşhisler yaparak dış hekimlerinin iş yükünü hafifletmektedir. Bir yandan dış hekimleri, karar verme süreçlerinde giderek daha fazla bilgisayar programlarına güvenmekte, diğer yandan dış hekimliğine özel geliştirilen bu programlar daha zeki, hassas ve güvenilir hale gelmektedir. Yapay zeka ile ilgili araştırmalar, dış hekimliğinin tüm alanlarında etkisini göstermeye devam etmektedir (129).

Periodontoloji alanında yapay zeka, periodontitis teşhisi ve olası periodontal hastalık türlerinin sınıflandırılmasında kullanılmaktadır (130). Ayrıca, Krois ve arkadaşları, panoramik radyografilerde periodontal kemik kaybını tespit etmek için evrişimli sinir ağlarını kullanmıştır (131). Lee ve arkadaşları, periodontal olarak risk altında olan dişleri otomatik olarak tespit etmek amacıyla önerilen bir CNN algoritmasının potansiyel faydasını ve doğruluğunu değerlendirmiştir (132). Yauney ve araştırma ekibi, sistemik sağlık verilerini kullanarak geliştirdikleri bir CNN algoritmasıyla periodontal durumların incelenebileceğini öne sürmüştür (133).

Ortodonti alanında yapay zeka, teşhis, tedavi planlaması ve tedavi sonuçlarının öngörülmesi gibi önemli süreçlerde güçlü bir araç olarak öne çıkmaktadır. Geleneksel olarak, maloklüzyon teşhisi ve sefalometrik analizlerde birçok değişkenin dikkate alınması, tedavi planlamasını karmaşık ve zaman alıcı bir süreç haline getirmektedir (134). Yapay zeka algoritmaları, tedavi öncesi ve sonrası yüz fotoğraflarındaki değişiklikleri simüle edebilmekte ve lateral sefalogramlarda iskelet desenleri ile anatomik referans noktalarını doğru bir şekilde belirleyerek hasta-hekim iletişimini kolaylaştırmaktadır (135,136). Yapay sinir ağları ile çekim gerekliliğini değerlendiren sistemler de geliştirilmiştir (137). Ayrıca, otomatik referans noktası belirleme ve iskelet sınıflandırması için derin öğrenme algoritmaları, insan uzmanlarla karşılaştırılabilir doğruluk seviyelerine ulaşmıştır (138,139).

Yapay zeka, protetik diş tedavisinde son yıllarda önemli bir dönüşüm yaratmıştır. Dijital diş hekimliğindeki ilerlemeler, yapay zekayı protez tasarımı ve üretiminde etkili bir araç haline getirmiştir. Özellikle CAD/CAM teknolojisiyle entegre edilen yapay zeka, sabit ve hareketli protezlerin tasarım süreçlerini daha hızlı ve hassas bir şekilde gerçekleştirmektedir. Yapay zeka algoritmaları, diş anatomisini analiz ederek ideal kron veya protez tasarımlarını önerirken, hata oranlarını azaltmakta ve estetik sonuçların doğruluğunu artırmaktadır. Ayrıca, yapay zeka tabanlı sistemler implant yerleştirme süreçlerinde cerrahi rehberlerin oluşturulması ve kemik yapısının değerlendirilmesi gibi kritik aşamalarda kullanılmaktadır. Bu gelişmeler hem hasta memnuniyetini artırmakta hem de tedavi süreçlerini daha etkili ve verimli bir hale getirmektedir (140).

Endodonti alanında yapay zeka, teşhis ve tedavi süreçlerini önemli ölçüde geliştirerek dikkat çekici bir kullanım alanı bulmuştur. Periapikal lezyonların, dikey kök kırıklarının ve kök kanal sisteminin morfolojisinin tespitinde kullanılan yapay zeka algoritmaları, diş

hekimlerinin karar verme süreçlerine büyük ölçüde yardımcı olmaktadır. Özellikle yapay sinir ağları ve derin öğrenme algoritmaları, radyografik görüntülerdeki ince detayları insan gözünden daha hassas bir şekilde analiz edebilir. Örneğin, yapay zeka, konik ışınli bilgisayarlı tomografi (CBCT) gibi 3D görüntüleme tekniklerini kullanarak periapikal lezyonların doğru tespiti ve boyutlarının ölçümünde üstün başarı göstermektedir. Ayrıca, kök kanal tedavisinde çalışma uzunluğunun belirlenmesi gibi hassas prosedürlerde yapay zeka algoritmaları, daha doğru sonuçlar sunarak tedavi başarısını artırmaktadır (141).

Yapay zekanın dental radyoloji alanındaki kullanımı, teşhis doğruluğunu artırma, görüntü segmentasyonunu otomatikleştirme ve tedavi planlamasını geliştirme gibi birçok yenilik sunmaktadır. Konvolüsyonel sinir ağları gibi derin öğrenme teknikleri, diş çürükleri, periodontal hastalıklar ve oral kanser gibi durumların tespitinde yüksek doğruluk oranlarıyla dikkat çekmektedir. Bu yöntemler, panoramik radyograflarda çürüklerin belirlenmesi ve CBCT kullanılarak üç boyutlu kemik segmentasyonu gibi zorlu görevleri başarıyla gerçekleştirmiştir. Ayrıca, otomatik diş segmentasyonu, sınıflandırma ve mandibula yüzey modellerinin oluşturulması gibi süreçleri hızlandırarak manuel müdahaleye duyulan ihtiyacı azaltmış ve hata oranını düşürmüştür. Panoramik röntgenler ve CBCT gibi görüntüler üzerinde yapılan analizlerde, yapay zeka modelleri küçük lezyonları ve doku farklılıklarını insan gözünden daha hassas bir şekilde algılayabilir (142,143).

Yapay zeka, implantoloji alanında teşhis, planlama ve tedavi süreçlerini önemli ölçüde iyileştirme potansiyeline sahiptir. Dental implant çeşitlerinin radyografik görüntüler üzerinden sınıflandırılması, osteointegrasyon başarısının tahmin edilmesi ve implant tasarımlarının optimize edilmesi gibi uygulamalarla öne çıkmaktadır. Özellikle derin öğrenme yöntemleri, panoramik ve periapikal radyografilerde implant türlerini yüksek doğruluk oranlarıyla tanımlayabilmekte ve insan uzman performansını aşabilmektedir. Ayrıca, yapay zeka algoritmaları, hasta özelliklerini ve biyomekanik kriterleri dikkate alarak bireyselleştirilmiş implant tasarımları oluşturmakta, bu da tedavi etkinliğini ve uzun ömürlülüğünü artırmaktadır (144).

### **2.2.7.1. Çocuk Diş Hekimliği ve Derin Öğrenme**

Yapay zeka, çocuk diş hekimliğinde karşılaşılan zorluklara yönelik etkili bir çözüm yolu olarak ön plana çıkmıştır. Çocukların klinik prosedürler sırasında sergilediği iş birliği eksikliği nedeniyle teşhisi zor olan çürükler, plak ve yapısal anomaliler gibi dental

durumların erken tespiti konusunda önemli katkılar sağlamaktadır. Yapay zeka destekli modeller, özellikle konvolüsyonel sinir ağları, dental radyografiler ve ağız içi görüntüleri olağanüstü bir doğrulukla analiz ederek, tekrar eden muayene ihtiyacını azaltmaktadır. Örneğin, derin öğrenme modelleri, diyet alışkanlıkları ve diğer risk faktörlerini değerlendirerek erken çocukluk dönemi çürüklerini tahmin etmekte kullanılırken, makine öğrenimi modelleri sosyo-demografik verilere dayanarak tedavi gereksinimlerini belirlemektedir. Bu gelişmeler, sadece teşhis doğruluğunu artırmakla kalmayıp, aynı zamanda tedavi planlamasını da optimize ederek pediatrik hastalarda ağız sağlığı sonuçlarını iyileştirmektedir (145).

Diş yaşı tahmini üzerine, çocuk diş hekimliğinde yapay zeka kullanılarak gerçekleştirilen birçok çalışma bulunmaktadır. Bunyarit ve arkadaşları, 5-17 yaş arası Malezyalı çocuk ve ergenlerin diş yaşını tahmin etmek için Demirjian indeksine dayalı olarak yapay sinir ağları kullanmış ve bu modellerin diş olgunluk göstergelerine dayanarak kronolojik yaşı doğru bir şekilde tahmin edebildiğini rapor etmişlerdir (146). Baydoğan ve arkadaşları, yaptıkları benzer çalışmada ise, 2-21 yaş arasındaki bireylerden elde edilen toplam 627 panoramik dental görüntüyü kullanarak yaş tahmini gerçekleştirmiştir. Çalışmada, yaş tahmini için derin öğrenmeye dayalı bir model önerilmiş ve başarılı sonuçlar elde edilmiştir (147). Kokomoto ve arkadaşları, yaptıkları çalışmada, otomatik dental yaş tahmini için iki aşamalı bir derin öğrenme modeli geliştirmiştir. Bu yöntem, panoramik radyograflardan dental germeleri tespit etmek için Scaled-YOLOv4 modelini ve gelişimsel aşamaları sınıflandırmak için EfficientNetV2-M modelini kullanmıştır. Çalışmada, modelin doğruluğu ve klinik uygulanabilirliği uzmanların hesaplamalarıyla karşılaştırılmış ve yöntemlerinin, dental yaşın manuel hesaplamasına kıyasla daha hızlı ve kabul edilebilir bir hata oranına sahip olduğu belirlenmiştir (148).

Çocuk diş hekimliğinde diş anomalileri, özellikle konvolüsyonel sinir ağları gibi yapay zeka teknikleri kullanılarak incelenmiştir. Bir çalışmada, çocuklarda panoramik radyograflar üzerinden süpernumerer dişlerin tespiti için AlexNet, VGG16-TL ve InceptionV3-TL gibi modeller kullanılmış ve yüksek duyarlılık ve özgüllük değerleri elde edilmiştir (149). Bir diğer araştırmada ise, orofasiyal yarık bulunan çocuklarda bir dizi diş anomalisini tespit etmek amacıyla derin sinir ağı modeli uygulanmıştır. Çalışma, on farklı diş anomalisi tipini sınıflandırmada diş hekimlerine kıyasla önemli bir verimlilik sağlamıştır (150). Kim ve arkadaşlarının yaptığı bir çalışmada ise, çocuk hastalara ait panoramik radyograflarda gömülü mesiodenslerin tespiti ve segmentasyonu için derin

öğrenme algoritmalarının performansı değerlendirilmiştir. Çalışmada, 3-9 yaş arası çocuklara ait toplam 850 panoramik radyografi kullanılmış ve U-Net semantik segmentasyon algoritması uygulanmıştır. Geliştirilen model, insan uzmanlarla karşılaştırıldığında teşhis doğruluğu açısından benzer sonuçlar göstermiş ve mesiodens teşhis süresini önemli ölçüde hızlandırmıştır (151).

Yapay zekanın çocuklarda diş çürüklerinin tespiti için potansiyeli değerlendirilmiştir. Zhou ve arkadaşlarının yaptığı çalışmada, çocuklarda dental çürüklerin panoramik radyografilerde daha doğru teşhis edilebilmesi için bağlam farkındalığına sahip bir konvolüsyonel sinir ağı geliştirilmiştir. Toplamda 6028 dişi içeren 304 panoramik radyografiden oluşan bir veri seti kullanılmıştır (152). Yapılan bir çalışma kapsamında 66 adet bitewing radyografiden elde edilen 755 proksimal yüzey incelenmiş ve 178 çürük lezyonu uzmanlar tarafından etiketlenmiştir. Model, verilerin artırılması için çeşitli dönüşüm teknikleriyle eğitilmiş ve yüksek bir başarı oranı sergilemiştir (153). Bu çalışmalar, yapay zekanın çocuk diş hekimliğinde erken çürük tespiti ve müdahale planlaması konusundaki potansiyelini ortaya koymuştur.

Diş gelişim evrelerinin değerlendirilmesi hem antropolojik araştırmalar hem de klinik uygulamalar için önemli bir süreçtir. Son yıllarda yapay zeka, özellikle derin öğrenme modelleri, bu sürecin otomatikleştirilmesi ve doğruluk oranlarının artırılması konusunda etkili bir araç olarak öne çıkmıştır. Ong ve arkadaşlarının 2024 yılında yaptığı çalışmada, panoramik radyograflar kullanılarak diş gelişim evrelerinin tam otomatik bir şekilde değerlendirilmesi için derin öğrenme tabanlı bir sistem geliştirilmiştir. 5133 panoramik görüntü üzerinde yapılan bu çalışmada, Demirjian yöntemi temel alınarak diş gelişim evrelerini tespit etmek amacıyla üç aşamalı bir yaklaşım sunmuştur: tespit (YOLOv5), segmentasyon (U-Net), ve sınıflandırma (EfficientNet). Model, dişlerin apikal kısmına odaklanarak gelişim evrelerini doğru bir şekilde belirlemiş ve klinik uygulamalarda diş yaş tahmini ve diş gelişim değerlendirmelerinde destekleyici bir araç olarak kullanılma potansiyeli göstermiştir (154).


### 3. GEREÇ VE YÖNTEM

Bu çalışma, 21.08.2024 tarih ve 2024/296 sayılı karar ile Gaziantep Üniversitesi Klinik Araştırmalar Etik Kurulu tarafından onaylanmıştır. Ayrıca, Gaziantep Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından DHF.UT.24.12 numaralı proje kapsamında desteklenmiş ve Gaziantep Üniversitesi Çocuk Diş Hekimliği Anabilim Dalı'nda gerçekleştirilmiştir. (EK-1)

#### 3.1. Veri Setinin Elde Edilmesi

Bu çalışmada, hipodonti teşhisinde iki farklı derin öğrenme algoritmasının performansını karşılaştırmak ve analiz etmek amacıyla, Gaziantep Üniversitesi Diş Hekimliği Fakültesi Çocuk Diş Hekimliği Anabilim Dalı kliniğine Ocak 2020- Temmuz 2024 yılları arasında başvuran 8-16 yaş arasındaki hastalara ait panoramik radyografiler retrospektif olarak incelendi. Verilerin toplanma süreci detaylı ve dikkatli bir şekilde yürütülerek, güvenilir bir veri seti oluşturulması sağlanmıştır.

Panoramik radyografiler, Gaziantep Üniversitesi Diş Hekimliği Fakültesi'nde kullanılan standart Planmeca Promax 2D cihazı (Planmeca, Helsinki, Finlandiya) ile 66 kVp, 8 mA ve 15,8 saniye pozlama ayarlarında elde edilmiştir. Elde edilen görüntüler, JPEG formatında yüksek çözünürlükte kaydedilerek analiz için hazır hale getirilmiştir. Görüntüler üzerinde herhangi bir kimlik bilgisi bulunmaması adına tüm radyografiler anonimleştirilmiştir. İsim, cinsiyet, adres gibi kişisel bilgiler kaldırılmış ve yalnızca yaş ve teşhis gibi çalışmada kullanılacak temel bilgiler saklanmıştır (Şekil 3.1).



**Şekil 3.1.** Çalışmamız veri seti dahilinde hipodonti bulunan hastalara ait örnek radyografik görüntüler

Bu çalışmaya, 8-16 yaş aralığındaki çocuk hastalara ait toplam 1060 panoramik radyografi dahil edilmiştir. Veri seti, 530'u radyolojik olarak hipodonti tanısı doğrulanmış bireylerden, 530'u ise herhangi bir diş eksikliği bulunmayan bireylerden oluşmaktadır. Çalışmaya dahil edilen tüm radyograflerin, tüm dişlerin eksiksiz ve doğru bir şekilde değerlendirilebilmesine olanak tanıyacak yeterli görüntü kalitesine sahip olması gerekmektedir.

Teşhisi zorlaştıran veya tamamen engelleyen hasta konumlandırma hataları (başın öne, arkaya, sağa veya sola pozisyonlanması, dilin damağa yerleştirilmemesi, alt ön bölgede boyun omurlarının süperpozisyonu, hayalet görüntüleri) ve teknik çekim hataları (yüksek veya düşük yoğunluk, kontrast bozuklukları, fog varlığı, yabancı cisimlerin bulunması, çift ışınlama) içeren panoramik radyografler çalışmaya dahil edilmemiştir.

Bununla birlikte, gelişimsel veya kalıtsal hastalığa sahip bireyler, kraniyofasiyal malformasyon veya herhangi bir sendrom tanısı almış olanlar ile odontogenezis ve dental erüpsiyon sürecini etkileyebilecek bir rahatsızlığı bulunan bireyler çalışma kapsamı dışında bırakılmıştır.

### **3.2. Veri Setlerinin Hazırlanması ve Sınıflandırılması**

Hazırlanan veri setleri CranioCatch (CranioCatch, Eskişehir, Türkiye) yazılımına aktarılmış ve proje oluşturularak sınıflandırma için hazır hale getirilmiştir. Bu çalışmada, panoramik radyografler ikili sınıflandırma (binary classification) yöntemi kullanılarak iki ana sınıfa ayrılmıştır: "hipodonti " ve "normal". İkili sınıflandırma, yalnızca iki sınıf arasında ayırım yapmayı gerektiren bir derin öğrenme yaklaşımıdır ve dental anomaliler gibi belirgin sınıflar arasında ayırım yapmak için etkili bir yöntem olarak kullanılabilir.

Bu süreçte, radyograflerden elde edilen veriler, her bir görüntünün uygun sınıfa atanabilmesi için sınıflandırma etiketleri ile işaretlenmiştir. Sınıflandırma etiketleri atama işlemi, her bir görüntünün "hipodonti" veya "normal" olarak kategorize edilmesini sağlamış ve modelin eğitim verisi için gerekli yapıyı oluşturmuştur. Bu yöntem, modelin doğruluğunu ve genel performansını artırmayı hedeflemiştir.

Radyograflerin sınıflandırılması, 8 yıllık deneyime sahip bir çocuk diş hekimi uzmanı ve 2,5 yıllık deneyime sahip bir araştırma görevlisi tarafından gerçekleştirilmiştir. İki

değerlendirici arasında uyumsuzluk gösteren görüntüler veri setinden çıkarılmış ve yalnızca doğru ve tutarlı şekilde kategorize edilen görüntüler modele dahil edilmiştir. Bu yöntem, modelin hem doğruluk oranını yükseltmiş hem de sınıflandırma performansını optimize etmiştir.

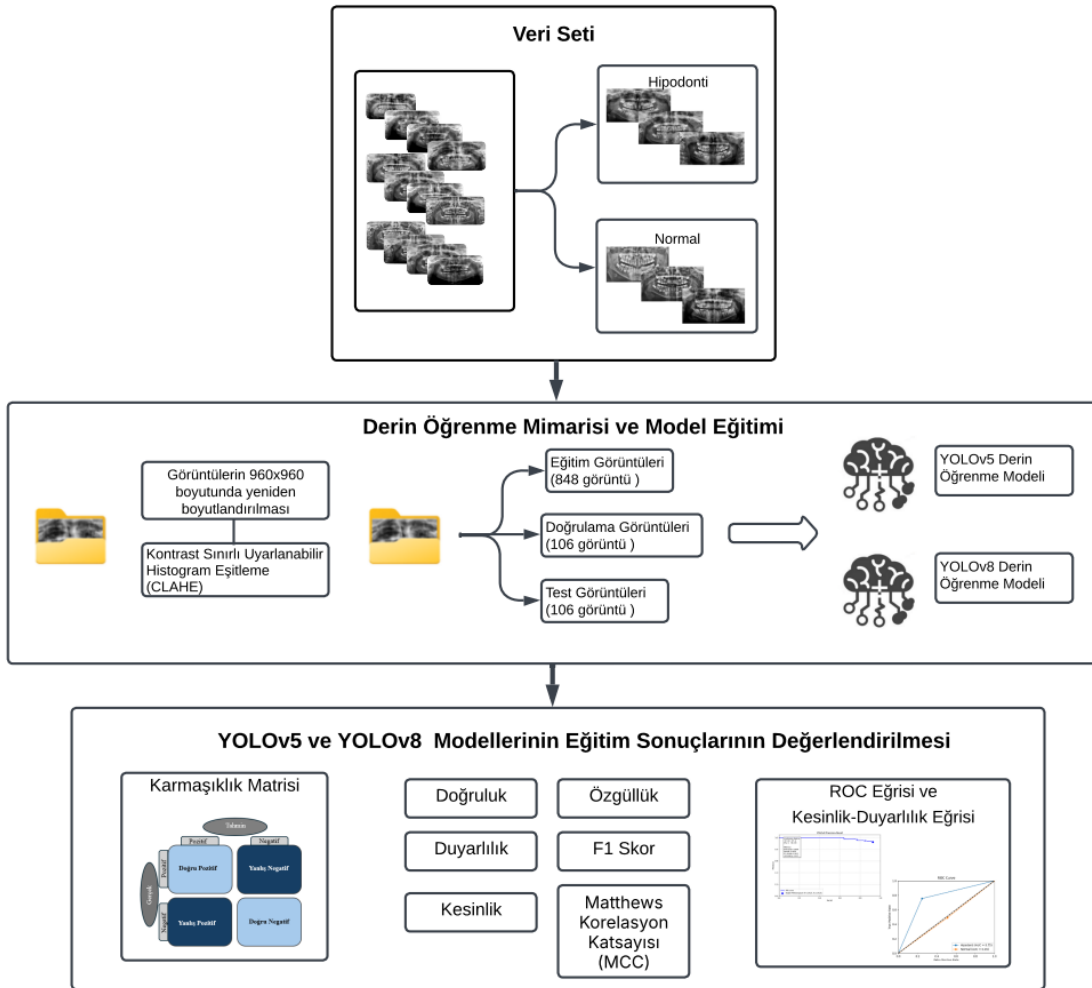
### 3.3. Derin Öğrenme Mimarisi ve Model Eğitimi

Bu çalışmada, hipodonti tespiti için YOLOv5'in geniş versiyonu olan YOLOv5x ve YOLOv8'in geniş versiyonu olan YOLOv8x modelleri kullanılmıştır. Modeller, ikili sınıflandırma görevine uygun şekilde yapılandırılmış ve eğitim süreçleri Python tabanlı PyTorch kütüphanesi kullanılarak gerçekleştirilmiştir. Eğitimde kullanılan veri kümesi, toplamda 1060 panoramik radyografiden oluşmakta olup, eşit şekilde iki sınıfa ayrılmıştır: hipodonti (530) ve normal (530). Görseller, modellerin gereksinimlerine uygun olarak 960x960 piksel boyutlarında yeniden boyutlandırılmıştır. Eğitim için 848 görüntü (424 hipodonti, 424 normal), doğrulama için 106 görüntü (53 hipodonti, 53 normal) ve test için 106 görüntü (53 hipodonti, 53 normal) kullanılmıştır. Her bir iterasyonda 8 görüntü işlenmiş olup, bu durum batch size = 8 olarak ifade edilmektedir. Bu, modelin her eğitim adımında (iterasyon) 8 görüntüyü aynı anda işlediği ve bu 8 görüntü üzerinde hesaplamalar yaptığı anlamına gelir. Model, 700 epoch boyunca eğitilmiştir. Epoch, modelin eğitim veri seti üzerinde tam bir döngü tamamlaması anlamına gelir. Bu durumda, 700 epoch, modelin eğitim veri setini toplamda 700 kez görmesi ve bu veriler üzerinde öğrenme sürecini tekrarlaması demektir. Bu süreç, modelin daha fazla örnek üzerinde çalışmasını sağlayarak doğruluğunu artırmaya katkıda bulunur. Panoramik radyografiler üzerinde, kontrastı iyileştirmek amacıyla yaygın olarak kullanılan bir görüntü iyileştirme yöntemi olan Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (CLAHE) uygulanmıştır. CLAHE ile iyileştirilen görüntüler, modele sağlanan bilgiyi artırmak ve performansı iyileştirmek amacıyla mevcut görüntülere ek kanallar olarak eklenmiştir. Eğitim sürecinde, binary classification görevine uygun olarak sınıflandırma hatalarını minimize etmek için binary cross-entropy kayıp fonksiyonu kullanılmıştır. Ayrıca, model parametrelerinin etkili bir şekilde optimize edilmesi için Adam optimizasyon algoritması tercih edilmiştir.

Eğitim ve değerlendirme süreçleri, yüksek işlem gücüne sahip Dell PowerEdge T640 ve Dell PowerEdge R540 sunucuları üzerinde gerçekleştirilmiştir. Bu donanım altyapısı, büyük boyutlu veri kümelerinin hızlı bir şekilde işlenmesini ve derin öğrenme

modellerinin etkin bir şekilde eğitilmesini sağlamıştır. Bunun yanı sıra, veri dengesini korumak ve optimum performansa ulaşmak için veri kümesi dikkatle organize edilmiştir. Binary sınıflandırma, dental anomalilerin tespiti gibi hedef sınıfların belirgin olduğu problemler için ideal bir yöntem olarak bu çalışmada önemli bir rol oynamıştır. İki sınıf arasındaki net ayırım hem modelin eğitimi hem de performans analizini daha etkili hale getirmiştir.

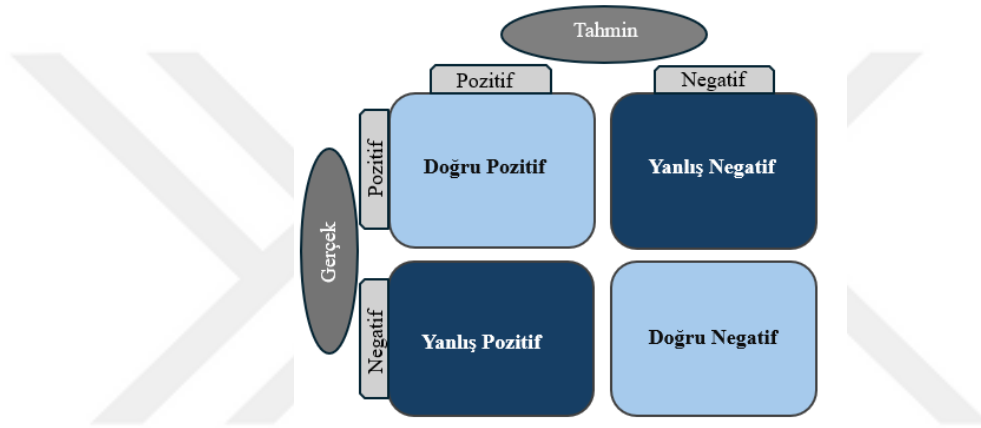
Bu süreçte hem YOLOv5x hem de YOLOv8x modellerinin hipodonti tespitindeki performansları karşılaştırılmış ve sınıflandırma başarıları detaylı bir şekilde analiz edilmiştir.



Şekil 3.2. Araştırma süreci akış şeması

### 3.4. İstatistiksel Analiz

Bu çalışmada, YOLOv5 ve YOLOv8 algoritmalarının performanslarını değerlendirmek ve karşılaştırmak amacıyla karmaşıklık matrisleri oluşturulmuştur. Karmaşıklık matrisi, bir sınıflandırma modelinin doğru ve tahmini sınıflandırmalarına ilişkin detaylı bilgiler sağlar. Modellerin performansı genellikle matristeki bilgilerin değerlendirilmesiyle ölçülür (155). Karmaşıklık matrisleri, doğru pozitif (DP), doğru negatif (DN), yanlış pozitif (YP) ve yanlış negatif (YN) değerlerini içermekte olup, algoritmaların doğru ve yanlış sınıflandırmalarını detaylı bir şekilde görselleştirmek için kullanılmıştır (Şekil 3.3).



**Şekil 3.3.** Karmaşıklık matrisi

Modelin hipodonti sınıflandırma başarısını değerlendirmek amacıyla kullanılan matrisler şu şekilde tanımlanmıştır: Hipodonti bulunan dişlerin doğru bir şekilde sınıflandırılması "doğru pozitif", hipodonti bulunmayan dişlerin doğru bir şekilde sınıflandırılması "doğru negatif" olarak adlandırılmıştır. Bunun yanı sıra, hipodonti bulunmayan dişlerin yanlış bir şekilde hipodonti olarak sınıflandırılması "yanlış pozitif", hipodonti bulunan dişlerin yanlış bir şekilde normal olarak sınıflandırılması ise "yanlış negatif" olarak ifade edilmiştir. Bu tanımlar, modelin sınıflandırma performansını değerlendirmek için temel kriterleri oluşturmuştur.

YOLOv5 ve YOLOv8 modelleri için ROC (Receiver Operating Characteristic) eğrileri çizilmiştir ve ROC eğrilerinin altında kalan alan (AUC, Area Under Curve) hesaplanmıştır. ROC eğrisi ve AUC değeri, algoritmaların genel sınıflandırma yeteneğini değerlendirmek ve hipodonti sınıflandırmasında en yüksek performansı sergileyen modeli belirlemek için kritik bir değerlendirme aracı olarak kullanılmıştır.

Modelin tahmin doğruluğunu optimize etmek ve güvenilir tahminler elde etmek için güven eşiği analizi yapılmıştır. Güven eşiği modelin, bir tahminin doğru olduğuna dair belirli bir güven seviyesinin üstünde olması gerektiğine karar verdiği eşik değeridir. Örneğin, bir güven eşiği 0,5 olarak belirlendiğinde, model yalnızca tahminlerinin doğruluğuna %50 veya daha fazla güvendiği durumlarda bir sınıf ataması yapar. Güven eşiğinin artırılması, modelin daha seçici olmasına neden olur. Başka bir deyişle, düşük güven eşiği daha fazla kabul anlamına gelirken, yüksek güven eşiği daha fazla reddetme anlamına gelir. Bu analiz, yanlış pozitiflerin azaltılması veya doğru pozitiflerin artırılması gibi uygulama ihtiyaçlarına uygun eşik değerinin seçilmesine olanak tanır (156). Algoritmaların güven eşiği 0,25 olarak atanmıştır. Bu eşik değeri, modelin hedef uygulama gereksinimlerine uygun performansı optimize etmesi amacıyla seçilmiştir. Düşük bir güven eşiği, modelin daha fazla tahmini "pozitif" olarak sınıflandırmasına olanak tanıyarak, duyarlılığı artırır. Çalışmanın öncelikli hedeflerinden biri, hipodonti gibi kritik pozitif örneklerin gözden kaçırılmamasını sağlamak olduğundan, düşük bir eşik değeri tercih edilmiştir. Bu yaklaşım, pozitif vakaların kaçırılma riskini azaltarak kritik durumların doğru bir şekilde tespit edilmesine katkıda bulunur. Sonuç olarak, 0.25 güven eşiği, duyarlılık ve model etkinliğinin artırılmasını sağlayarak, çalışmanın amaçlarına uygun optimal bir değer olarak belirlenmiştir.

### **3.5. Performans Ölçütleri**

Algoritmaların sınıflandırma performansları, doğruluk, hassasiyet, duyarlılık, özgüllük, F1 skoru ve Matthews korelasyon katsayısı (MCC) gibi metriklerle değerlendirilmiştir. Bu metrikler, algoritmaların hipodonti tespiti sırasında genel performanslarını ve sınıflandırma etkinliklerini detaylı bir şekilde analiz etmek için kullanılmıştır.

#### **Doğruluk (Accuracy)**

Bir modelin tüm tahminlerindeki genel başarı oranını ifade eder ve DP ile DN tahminlerin, toplam tahminlere oranıyla hesaplanır. Doğruluk, modelin tüm veri setinde ne kadar doğru tahmin yaptığını ölçmek için kullanılır ve özellikle pozitif ve negatif sınıfların dengeli olduğu veri setlerinde etkili bir performans göstergesidir. Ancak, sınıf dengesizliği durumlarında yanıltıcı olabileceği için duyarlılık ve özgüllük gibi metriklerle desteklenerek değerlendirilmelidir (157).

### **Kesinlik (Precision)**

Modelin pozitif olarak tahmin ettiđi sonuçlar içinde ne kadarının gerçekten pozitif olduğunu gösterir. Bu metrik, YP etkisini ölçerek modelin pozitif tahminlerindeki doğruluđunu değerlendirir (157).

### **Duyarlılık (Sensitivity)**

Duyarlılık, bir modelin gerçekten pozitif olan durumları doğru şekilde tespit etme yeteneđini ölçer. Pozitif vakaların ne kadarının doğru şekilde sınıflandırıldığını gösterir ve bu nedenle özellikle yanlış negatif sonuçların (gerçek pozitiflerin tespit edilememesi) önlenmesinde önemlidir (157).

### **Özgüllük (Specificity)**

Bir modelin negatif sınıfları doğru bir şekilde tanımlama yeteneđini ölçen bir metriktir. Yüksek özgüllük, modelin yanlış pozitif tahminlerini en aza indirerek gerçek negatifleri doğru bir şekilde belirleyebildiđini gösterir. Özellikle yanlış pozitif sonuçların istenmeyen sonuçlara yol açtığı durumlarda özgüllük büyük önem taşır (157).

### **F1 Skoru (F1 Score)**

F1 skoru, sınıflandırma problemlerinde modelin başarısını ölçmek için kullanılan bir metriktir. Kesinlik ve duyarlılık arasında harmonik bir ortalama alır. Bu nedenle, özellikle sınıflandırma görevlerinde dengeli bir performans değerlendirmesi sağlar. F1 skor, yanlış negatifler ve yanlış pozitifler gibi hataları hesaba katar. Ancak, bu metrik doğru negatifleri göz önünde bulundurmaz, bu da sınıflandırma doğruluđunu tam olarak yansıtmayabilir (158).

### **Matthews Korelasyon Katsayısı (MCC)**

MCC, bir sınıflandırma modelinin dört temel sonuç kategorisini (Dođru Pozitif, Yanlış Pozitif, Dođru Negatif, Yanlış Negatif) hesaba katarak daha kapsamlı bir performans ölçüsü sağlar. MCC, sınıflandırma problemlerinde dengeli bir metrik olarak kabul edilir ve özellikle dengesiz veri kümelerinde tercih edilir. MCC, tüm sınıflandırma türlerini dengeli bir şekilde değerlendirerek 1'e yakın bir deđer aldığında yüksek performansı ifade eder (158).

Tüm bu analizler, YOLOv5 ve YOLOv8 algoritmalarının hipodonti tespitindeki başarılarını karşılaştırmak ve en etkin derin öğrenme algoritmasını belirlemek amacıyla gerçekleştirilmiştir.

### **3.6. ROC Eğrisi (Receiver Operating Characteristic Curve) ve Kesinlik-Duyarlılık Eğrisi (PR Eğrisi, Precision-Recall Curve)**

ROC eğrisi, modelinin performansını değerlendirmek için kullanılan bir grafikdir. Grafikte x eksenini yanlış pozitif oranı, y eksenini ise doğru pozitif oranı olarak gösterilir. ROC eğrisi, modelin her eşik değerindeki performansını ölçerek, modelin farklı sınıflandırma eşiklerinde ne kadar iyi çalıştığını gösterir. Eğri ne kadar üst sol köşeye yakınsa, modelin genel performansı o kadar iyidir. AUC değeri ise ROC grafiğinin alanını ifade eder ve bu değer 1'e yakınlığı algoritmaların daha üstün başarı sağladığının göstergesidir. PR eğrisinde ise özellikle sınıf dengesizliği bulunan veri setlerinde kullanılan bir değerlendirme grafiğidir. Grafikte x eksenini duyarlılık, y eksenini ise kesinlik olarak gösterilir. PR eğrisi, modelin pozitif sınıfı doğru şekilde tanımlama yeteneğini ve yanlış pozitiflerin düşük olduğu bir performansı bir arada değerlendirmek için kullanılır (159).


## 4. BULGULAR

Bu tez çalışmasında, YOLOv5 ve YOLOv8 derin öğrenme algoritmalarının panoramik radyografilerde hipodonti sınıflandırma performansı incelenmiştir. Her bir modelin başarısı, karmaşıklık matrisi ve performans metrikleri olmak üzere iki ana kategoride değerlendirilmiştir. Performans metrikleri kapsamında doğruluk, hassasiyet, duyarlılık, özgüllük, F1 skoru ve MCC gibi ölçütler kullanılmıştır. Ayrıca, model performansını görselleştirmek ve değerlendirmek amacıyla ROC ve kesinlik-duyarlılık eğrileri kullanılmıştır. ROC eğrisi, modelin farklı eşik değerlerindeki başarısını gösterirken, altında kalan alan (AUC) genel sınıflandırma kapasitesini ölçer. Kesinlik-duyarlılık eğrisi ise modelin pozitif sınıfı doğru tanımlama performansını değerlendirmek için kullanılmıştır.

Hipodonti tespiti için YOLOv5'in geniş versiyonu olan YOLOv5x modeli kullanılmıştır. Eğitim için 848 görüntü (424 hipodonti, 424 normal), doğrulama için 106 görüntü (53 hipodonti, 53 normal) ve test için 106 görüntü (53 hipodonti, 53 normal) kullanılmıştır. Modelin performansı, elde edilen karmaşıklık matrisi ile değerlendirilmiştir. Hipodonti sınıflandırma performansında model, 40 doğru pozitif ve 26 doğru negatif sonuç üretmiştir. Model ayrıca 27 yanlış pozitif ve 13 yanlış negatif değerleriyle sonuçlanmıştır (Tablo 4.1). Yanlış pozitif değerler, modelin hipodonti olmayan durumları yanlış şekilde hipodonti var olarak sınıflandırdığı durumları temsil ederken; yanlış negatifler, hipodonti var olan durumların model tarafından tespit edilemediği durumları ifade etmektedir.


**Tablo 4.1.** YOLOv5 modelinin DP, YP, DN, YN değerleri

Test veri seti	Doğru Pozitif	Yanlış Pozitif	Doğru Negatif	Yanlış Negatif
106	40	27	26	13



**Şekil 4.1.** YOLOv5 modelinin test sürecindeki sınıflandırma sonuçları

Şekil 4.1 YOLOv5 modelinin test sürecinde yaptığı sınıflandırma sonuçlarını temsil etmektedir. Görselde, "hipodonti" ve "normal" etiketleri modelin tahmin ettiği sınıfları ve gerçek sınıfları ifade etmektedir. Görsellerin üzerinde bulunan etiketler, sırasıyla görüntünün gerçek sınıfını ve modelin tahmini göstermektedir. Bu sonuçlar, modelin sınıflandırma performansını değerlendirmek için kullanılan karmaşıklık matrisinin görsel bir temsilini sunmaktadır.



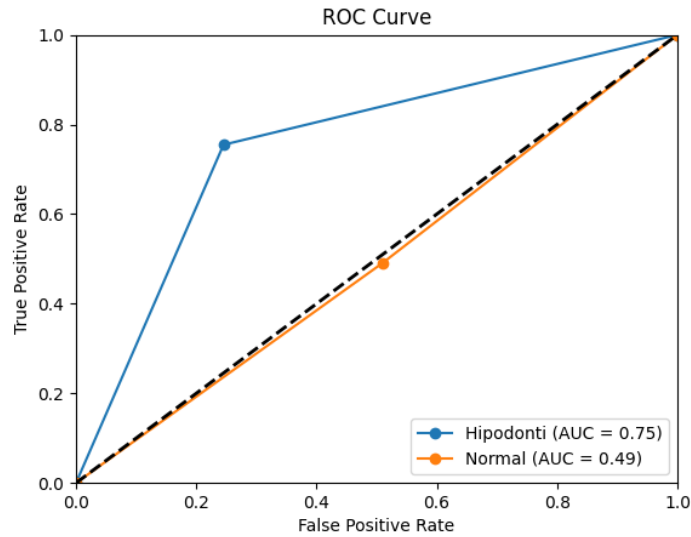
**Şekil 4.2.** YOLOv5 modeli için karmaşıklık matrisi

YOLOv5 modeline ait karmaşıklık matrisi Şekil 4.2 de gösterilmiştir. Matrisin yatay eksenini, model tarafından yapılan tahminleri ("hipodonti" ve "normal"), dikey eksenini ise gerçek sınıfları temsil etmektedir. Bu matris, YOLOv5 modelinin sınıflandırma doğruluğu, duyarlılığı, özgüllüğü gibi performans ölçütlerini hesaplamak için temel alınmıştır.

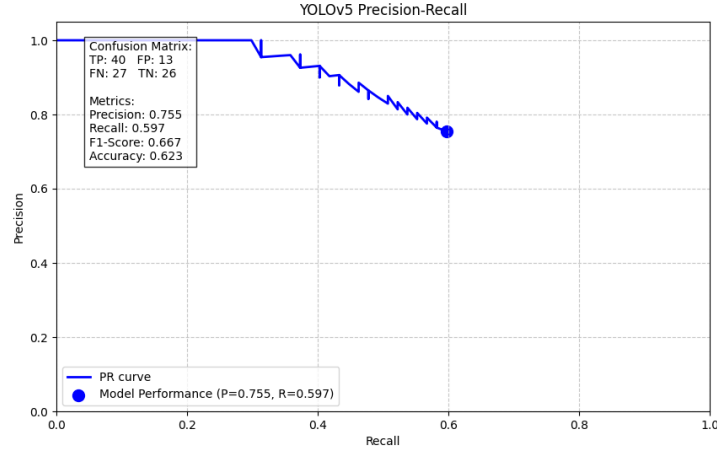
Karmaşıklık matrisi ile hesaplanan YOLOv5 modeline ait performans sonuçları Tablo 4.2'de sunulmuştur. Modelin doğruluğu 0,6226, duyarlılığı 0,5970, özgüllüğü 0,6667, kesinlik değeri 0,7547 ve F1 skoru 0,6667 olarak hesaplanmıştır. Ayrıca, modelin genel dengeyi ve tahmin doğruluğunu ölçen MCC 0,2543 olarak bulunmuştur.

**Tablo 4.2.** YOLOv5 modeline ait performans ölçütleri

	Doğruluk	Duyarlılık	Kesinlik	Özgüllük	F1 Skoru	Matthews Korelasyon Katsayısı
YOLOv5	0,6226	0,5970	0,7547	0,6667	0,6667	0,2543




**Şekil 4.3.** YOLOv5 modeline ait ROC eğrisi



**Şekil 4.4.** YOLOv5 modelinin kesinlik-duyarlılık eğrisi

YOLOv5 modeline ait ROC eğrisi (Şekil 4.3), modelin hipodonti tespiti sırasında doğruluk ve yanlış pozitif oranını ilişkilendirerek performansını göstermektedir. Hipodonti sınıfı için AUC 0.75 olarak ölçülmüştür, bu da modelin hipodontiyi belirlemede makul bir başarı sağladığını gösterir. Ancak, normal sınıf için AUC değeri 0.49'dur, bu da modelin normal sınıfları doğru ayırmada yeterli başarı sağlayamadığını işaret etmektedir. ROC eğrisindeki değerler, modelin genel ayırma kapasitesini ve sınıflar arasındaki doğruluğu anlamak için kritik bir rol oynar.

Şekil 4.4 modelin kesinlik-duyarlılık eğrisini göstermektedir. Yatay eksen duyarlılığı, modelin gerçek pozitifleri doğru bir şekilde tespit etme oranını ifade ederken, dikey eksen kesinliği, modelin yaptığı doğru pozitif tahminlerin toplam pozitif tahminlere oranını göstermektedir. Grafikte eğrinin konumu, modelin kesinlik ve duyarlılık arasındaki dengesini yansıtır. Model, hipodonti sınıflandırmasında kabul edilebilir bir kesinlik sağlamış olsa da, duyarlılık oranı göreceli olarak daha düşüktür. Bu, modelin hipodonti vakalarını ayırt etmede bazı eksikliklere sahip olabileceğini işaret etmektedir.



**Şekil 4.5.** YOLOv5 modeline ait güven eşiği ve performans metrikleri grafiği

Şekil 4.5, YOLOv5 modelinin farklı güven eşiği değerlerinde kesinlik , duyarlılık ve F1 skoru metriklerindeki değişimlerini göstermektedir. Güven eşiği 0.25 olarak seçilmiş ve bu eşik değerinde metriklerin performansına odaklanılmıştır.

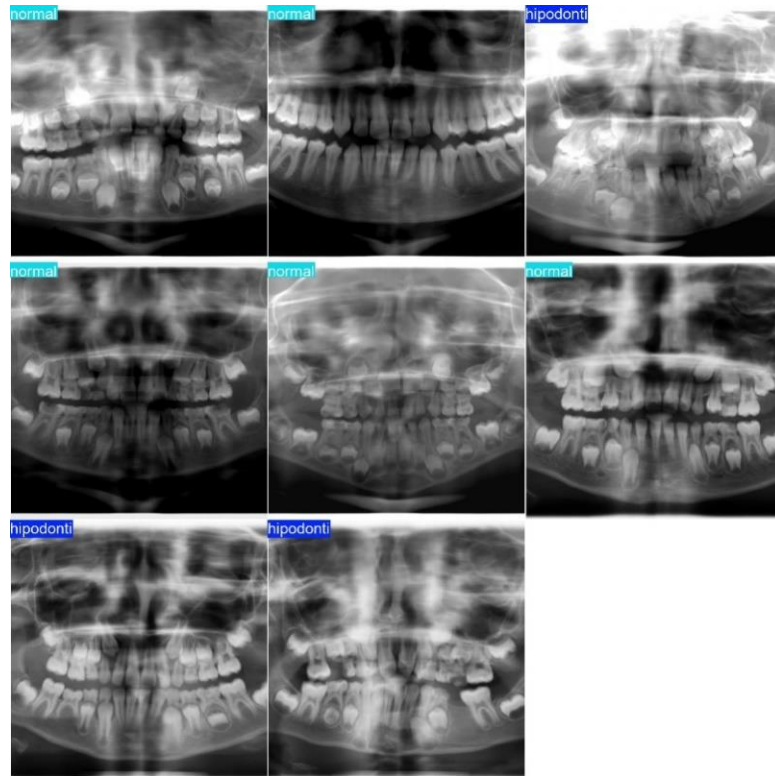
Kesinlik (mavi çizgi), güven eşiği boyunca yüksek bir seviyede sabit kalmakta ve özellikle güven eşiği arttıkça daha istikrarlı bir hale gelmektedir. Bu, modelin pozitif sınıf için doğru tahmin yapma yeteneğinin güven eşiği yükseldikçe iyileştiğini göstermektedir. Ancak duyarlılık (kırmızı çizgi) güven eşiği arttıkça hızlı bir düşüş göstermekte, bu da modelin pozitif örnekleri tespit etme oranının güven eşiği yükseldikçe azaldığını ifade etmektedir. F1 skoru (yeşil çizgi) ise duyarlılık ve kesinlik arasında bir denge kurarak, 0.25 güven eşiğinde yüksek bir performans sergilemektedir.

Bu grafikten, YOLOv5 modelinin düşük güven eşiği seviyelerinde daha fazla pozitif örneği tanımlamaya odaklandığı, ancak bu durumun yüksek kesinlik için bir miktar ödün vermeye neden olduğu anlaşılmaktadır. 0.25 güven eşiği, modelin hem yüksek kesinlik hem de makul duyarlılık arasında bir denge sağladığı bir eşik değeri olarak belirlenmiştir.

Hipodonti tespiti için YOLOv8'in geniş versiyonu olan YOLOv8x modeli kullanılmıştır. Eğitim için 848 görüntü (424 hipodonti, 424 normal), doğrulama için 106 görüntü (53 hipodonti, 53 normal) ve test için 106 görüntü (53 hipodonti, 53 normal) kullanılmıştır. Modelin performansı, elde edilen karmaşıklık matrisi ile değerlendirilmiştir. Hipodonti sınıflandırma için model, 49 doğru pozitif ve 49 doğru negatif sonuç üretmiştir (Tablo 4.3). Bu sonuçlar, modelin hem hipodonti varlığını doğru bir şekilde tespit etme hem de normal durumları doğru bir şekilde sınıflandırma konusundaki başarısını göstermektedir. Yanlış pozitif ve yanlış negatif değerleri ise her biri 4 olarak kaydedilmiştir. Yanlış pozitifler, modelin hipodonti olmayan durumları hatalı şekilde hipodonti var olarak sınıflandırdığı durumları ifade ederken, yanlış negatifler hipodonti var olan durumların model tarafından tespit edilemediği durumları ifade etmektedir.


**Tablo 4.3.** YOLOv8 modelinin DP, YP, DN, YN değerleri

Test veri seti	Doğru Pozitif	Yanlış Pozitif	Doğru Negatif	Yanlış Negatif
106	49	4	49	4



**Şekil 4.6.** YOLOv8 modelinin test sürecindeki sınıflandırma sonuçları

Şekil 4.6 YOLOv8 modelinin test sürecinde "hipodonti" ve "normal" sınıfları için yaptığı tahminleri göstermektedir. Görselde her bir panoramik radyografiye ilişkin modelin tahmin ettiği sınıflar, tahmin doğruluğunu değerlendirmek üzere belirtilmiştir. Üstteki etiketler, modelin her bir görüntüye ilişkin sınıflandırma sonuçlarını (örneğin, "hipodonti" veya "normal") temsil etmektedir. Bu sonuçlar, YOLOv8 modelinin hipodonti sınıflandırma performansının görselleştirilmiş bir özetini sunmaktadır.



Şekil 4.7. YOLOv8 modelinin için karmaşıklık matrisi


Şekil 4.7’da YOLOv8 modeline ait karmaşıklık matrisi sunulmuştur. Matrisin yatay eksenini, modelin tahmin ettiği sınıfları ("hipodonti" ve "normal"), dikey eksenini ise gerçek sınıfları göstermektedir. Bu matris, YOLOv5 modelinin sınıflandırma başarısını değerlendirmek için doğruluk, duyarlılık, özgüllük gibi performans ölçütlerinin hesaplanmasında temel olarak kullanılmıştır.

YOLOv8 modelinin performansını değerlendirmek amacıyla kullanılan metrikler ve bu metriklere ait değerler Tablo 4.4 de gösterilmektedir. Karmaşıklık matrisi kullanılarak hesaplanan bu metriklere göre modelin doğruluk oranı 0,9245 olarak hesaplanmıştır, bu da modelin genel olarak doğru tahmin yapma oranının yüksek olduğunu göstermektedir. Modelin duyarlılık değeri 0,9245 olup, bu değer modelin hipodontiyi doğru bir şekilde sınıflandırma başarısını ifade etmektedir. Özgüllük değeri ise 0,9245 olarak hesaplanmış ve modelin hipodontisi olmayan bireyleri doğru bir şekilde sınıflandırabildiğini

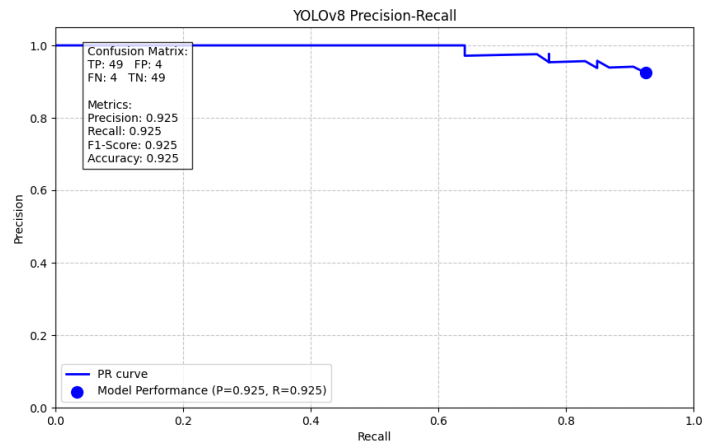
göstermiştir. Kesinlik oranı 0,9245 olup, modelin yaptığı pozitif tahminlerin doğruluğunu yansıtmaktadır. F1 skoru ise 0,9245 olarak bulunmuş ve bu da modelin duyarlılık ve kesinlik arasında iyi bir denge sağladığını ortaya koymaktadır. Matthews Korelasyon Katsayısı 0,8491 olarak hesaplanmış ve modelin genel tahmin performansının güçlü bir göstergesi olarak dikkat çekmiştir.

**Tablo 4.4.** YOLOv8 modeline ait performans ölçütleri

	Doğruluk	Duyarlılık	Kesinlik	Özgüllük	F1 Skoru	Matthews Korelasyon Katsayısı
<b>YOLOv8</b>	0,9245	0,9245	0,9245	0,9245	0,9245	0,8491



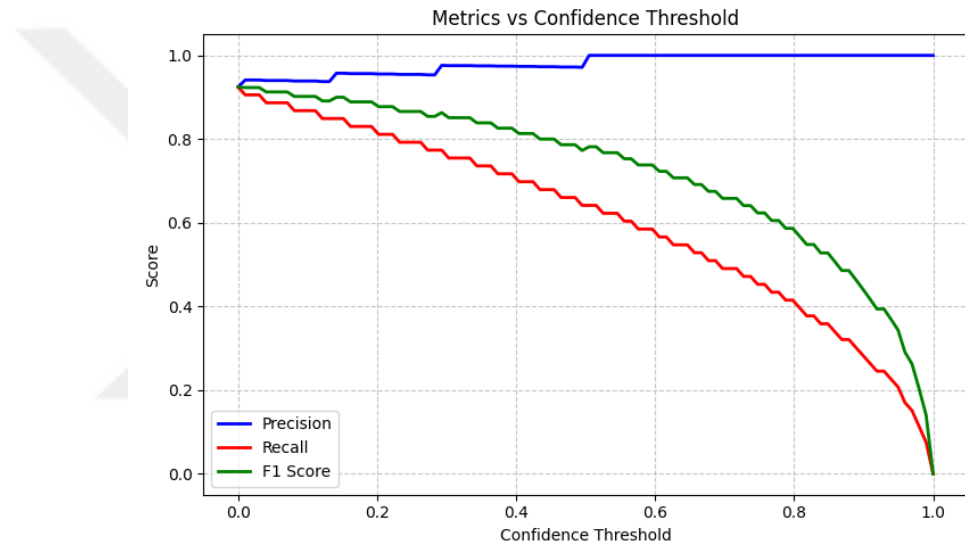
**Şekil 4.8.** YOLOv8 modeline ROC eğrisi



**Şekil 4.9.** YOLOv8 modelinin kesinlik-duyarlılık eğrisi

Şekil 4.8, YOLOv8 modeli için oluşturulan ROC eğrisini göstermektedir. Eğrinin yatay eksenini yanlış pozitif oranı, dikey eksenini ise doğru pozitif oranını temsil etmektedir. Hem "hipodonti" hem de "normal" sınıfları için AUC değeri 0,92 olarak hesaplanmıştır. Bu yüksek AUC değeri, modelin sınıflandırma performansının oldukça başarılı olduğunu ve hipodonti ile normal sınıfları doğru bir şekilde ayırt etme kapasitesini göstermektedir.

YOLOv8 modeline ait kesinlik-duyarlılık eğrisi, modelin kesinlik ve duyarlılık arasındaki ilişkiyi göstermektedir (Şekil 4.9). Eğrinin üst kısmında olması, modelin hem yüksek kesinlik hem de yüksek duyarlılık sağladığını gösterir.



**Şekil 4.10.** YOLOv8 modeline ait güven eşiği ve performans metrikleri grafiği

Şekil 4.10, YOLOv8 modelinin güven eşiği 0'dan 1'e kadar değiştiğinde kesinlik, duyarlılık ve F1 skorundaki değişimlerini göstermektedir. Bu grafikte güven eşiği 0,25 olarak belirlenmiş ve modelin performansı bu eşik değerinde değerlendirilmiştir.

Kesinlik (mavi çizgi), YOLOv8 modelinde güven eşiği arttıkça oldukça kararlı bir şekilde yüksek seviyede kalmaktadır. Bu durum, modelin pozitif sınıf için doğru tahmin yapma kabiliyetinin YOLOv5'e kıyasla daha istikrarlı olduğunu göstermektedir. Duyarlılık (kırmızı çizgi) ise güven eşiği arttıkça daha yavaş bir düşüş sergilemektedir. YOLOv8 modeli, düşük güven eşiğinde bile duyarlılık açısından daha iyi bir performans göstermektedir. F1 skoru (yeşil çizgi) ise, 0,25 güven eşiği seviyesinde maksimuma yakın bir değer almakta ve modelin genel dengesini yansıtmaktadır.

Bu grafikten, YOLOv8 modelinin özellikle kesinlik açısından daha kararlı bir performans sunduğu, duyarlılıkta ise güven eşiği arttıkça daha düşük bir düşüş oranına sahip olduğu görülmektedir. Güven eşiği 0,25, modelin genel başarısını optimize ettiği ve dengeli bir performans sunduğu bir nokta olarak belirlenmiştir.

YOLOv5 ve YOLOv8 modellerinin hipodonti tespiti üzerindeki performansları, elde edilen metrikler ve karmaşıklık matrisleri ışığında karşılaştırılmıştır (Tablo 4.5). YOLOv8, %92,45 doğruluk oranıyla YOLOv5'in %62,3 doğruluk oranına kıyasla çok daha başarılı bir performans sergilemiştir. YOLOv8, %92,45 kesinlik oranı ile YOLOv5'in %75,5 değerinden daha iyi bir performans göstermiş ve bu yüksek kesinlik oranı, modelin hipodonti tahminlerinde daha güvenilir olduğunu göstermektedir. Duyarlılık açısından YOLOv8, %92,45 ile hipodontili bireyleri daha doğru bir şekilde tespit etmiş ve yanlış negatif oranını önemli ölçüde azaltmıştır. Buna karşılık, YOLOv5 %59,7 duyarlılık oranı ile hipodontili vakaları tespit etmede daha zayıf bir performans sergilemiştir. Benzer şekilde, özgüllük açısından YOLOv8, %92,45 ile hipodonti olmayan vakaları daha doğru bir şekilde sınıflandırmış, yanlış pozitif oranını önemli ölçüde düşürmüştür. Buna karşılık, YOLOv5 %66,7 özgüllük oranıyla daha fazla yanlış pozitif tahmin yapmıştır. F1 skoru açısından YOLOv8, %92,45 ile kesinlik ve duyarlılık arasındaki dengeyi başarılı bir şekilde sağlamış, hipodontili bireylerin doğru tespit edilmesiyle yanlış pozitiflerin kontrol altında tutulmasını dengeli bir şekilde gerçekleştirmiştir. YOLOv5 ise %66,8 F1 skoru ile daha düşük bir performans sergilemiştir. Ayrıca, YOLOv8'in daha düşük yanlış pozitif ve yanlış negatif oranları, bu modelin daha az hata yaparak daha güvenilir sonuçlar sunduğunu ortaya koymaktadır. Genel olarak, YOLOv8'in hipodonti tespitindeki üstün performansı, bu tür sınıflandırma görevleri için daha etkili bir model olduğunu göstermektedir.

**Tablo 4.5.** YOLOv5 ve YOLOv8 performans metrikleri değerleri

	Doğruluk	Duyarlılık	Kesinlik	Özgüllük	F1 Skoru	Matthews Korelasyon Katsayısı
<b>YOLOv5</b>	0,6226	0,5970	0,7547	0,6667	0,6667	0,2543
<b>YOLOv8</b>	0,9245	0,9245	0,9245	0,9245	0,9245	0,8491

Karşılaştırma sonucunda, YOLOv8 modeli, tüm metrikler açısından YOLOv5 modeline kıyasla açık bir üstünlük göstermiştir. Bu sonuç, YOLOv8'in hipodonti tespiti gibi sınıflandırma görevlerinde daha yüksek doğruluk, duyarlılık ve özgüllük sağladığını göstermektedir. YOLOv8'in gelişmiş mimarisi ve daha iyi optimize edilmiş parametreleri, hipodonti tespiti gibi klinik uygulamalarda daha güvenilir ve verimli bir çözüm sunmaktadır. Bu nedenle, hipodonti tespiti için YOLOv8'in kullanımı daha uygun bir tercih olarak değerlendirilmektedir.



## 5. TARTIŞMA

Hipodonti, bir veya daha fazla diřin doęuřtan eksik olduęu, dental geliřim sırasında meydana gelen genetik veya çevresel faktörlerden kaynaklanan, bir dental anomali türüdür. Bu durum, sıklıkla klinik olarak belirti göstermemesi nedeniyle genellikle radyografik muayeneler sırasında rastlantısal olarak teşhis edilmektedir. Hipodonti, estetik ve fonksiyonel problemlere yol açarak çiğneme, konuşma ve diř dizilimi gibi alanlarda olumsuz etkiler yaratabilmektedir. Ayrıca hipodonti varlığında komřu diřlerin pozisyonunda kaymalar ve oklüzyon problemleri gibi sekonder sorunlar da gelişebilmektedir (37,160). Bu nedenle hipodontinin erken teşhisi, özellikle büyüme ve gelişim dönemindeki hastalarda, tedavi planlamasının etkinliğini artırmak açısından kritik öneme sahiptir. Erken teşhis edilen vakalarda uygun protetik, ortodontik veya cerrahi müdahalelerle hastaların hem estetik hem de fonksiyonel ihtiyaçlarının karşılanması mümkün olmaktadır (161).

Diř hekimliğinde yapay zeka ve derin öğrenme, özellikle görüntü işleme ve teşhis süreçlerinde önemli bir potansiyel sunmaktadır. Panoramik, periapikal ve CBCT gibi radyografik görüntülerin yanı sıra dental fotoğrafların analizinde derin öğrenme algoritmalarının kullanıldığı çalışmalar; diř sınıflandırması, periapikal lezyonların tespiti, periodontal kemik kaybının değerlendirilmesi ve dental çürüklerin teşhisinde başarılı sonuçlar verdiğini göstermektedir. Bu yöntemlerin doğruluk, duyarlılık ve özgüllük açısından genellikle uzmanlarla karşılaştırılabilir seviyede performans sergilediği belirtilmiştir (162). Bu bağlamda, hipodonti tespitinde derin öğrenme algoritmalarının etkili bir şekilde kullanımı, diř hekimliği alanındaki tanı süreçlerine önemli katkılar sunabilir.

Daimi diřlerde hipodonti görülme sıklığı üzerine yapılan arařtırmalar, bu durumun farklı popülasyonlarda %2,2 ile %10,1 arasında deęişen bir yaygınlığa sahip olduğunu ortaya koymaktadır. Bu farklılıklar, çalışmaların metodolojisi ve katılımcı özelliklerindeki çeşitlilikten kaynaklanabilir. Arařtırmalarda kullanılan dahil edilme kriterleri, etnik köken, örneklem büyüklüğü, yař grupları ve tanı yöntemlerindeki farklılıklar, hipodonti prevalansının deęişkenliğini açıklamada önemli rol oynar (163). Türk toplumunda hipodonti prevalansını inceleyen arařtırmalar, farklı oranlar ve bulgular ortaya koymaktadır. Çalışmalar, hipodonti oranlarının %2,63 ile %14,1 arasında deęiřtiğini ve

en sık eksik dişlerin genellikle alt ikinci premolarlar ve üst lateral kesiciler olduğunu göstermektedir (30–32). Bu prevalans oranları, hipodontinin yaygın bir dental anomali olduğunu ve erken teşhis edilmediği durumlarda hem hastalar hem de klinisyenler için tedavi sürecini uzatan, maliyetleri artıran ve tedaviyi daha karmaşık hale getiren bir faktör olarak karşımıza çıktığını göstermektedir.

Hipodonti teşhisinin doğru bir şekilde yapılabilmesi için radyografik ve klinik incelemelerinin bir arada değerlendirilmesi gerekmektedir. Radyografik inceleme, hipodonti teşhisinin kritik bir parçası olarak rol oynamaktadır (164). Diş tomurcuklarının radyografik olarak görülebilmesi için belirli bir kalsifikasyon seviyesine ulaşması gerektiğinden, çok genç bireylerin dahil edilmesi, kalsifikasyonu yetersiz diş tomurcuklarının eksik diş olarak yanlış teşhis edilmesine yol açabilir (165). Doğuştan eksik dişlerin teşhisi, odontogenez ve kalsifikasyonun başlangıç dönemindeki değişkenlik nedeniyle zorluklar içermektedir. Literatüre göre, mandibular ikinci premolarlar yaklaşık 2-2,5 yaşlarında kalsifikasyona başlar ve bu süreç genellikle 5-6 yaşlarında tamamlanır. Benzer şekilde, üst çene lateral kesici dişlerin gelişimi genellikle 3 yaş civarında başlar ve tacın tamamlanması 4-5 yaşında gerçekleşir (166). Ancak bu dişlerde odontogenez, diğer kalıcı dişlere göre daha fazla değişkenlik göstermekte ve nihai hipodonti teşhisi için genellikle 8-9 yaşına kadar beklenmesi önerilmektedir. Bu yaş aralığı, diş gelişiminin belirgin hale geldiği ve gecikmiş kalsifikasyon vakalarının daha iyi değerlendirilmesine olanak tanıdığı bir dönemdir. Ayrıca, gecikmiş odontogenez vakaları nadiren görülebilmekte ve bu durumlar, takip radyografileri ile değerlendirildiğinde teşhis sürecine katkı sağlamaktadır (167). Bu literatür bilgisine dayanarak, çalışma kapsamında değerlendirme yapılacak yaş aralığı olarak 8-16 yaş seçilmiştir.

Panoramik radyografi, diş hekimliğinde dişlerin ve maksillofasiyal iskeletin iki boyutlu görüntüsünü sağlayan değerli bir görüntüleme yöntemidir (168). Panoramik radyografiler, dişler ve çevresindeki dokuların anatomik ve morfolojik özelliklerini değerlendirmek, diş gelişimini izlemek, dentomaksillofasiyal bölgedeki patolojik anomalileri tespit etmek için kullanılan önemli bir tanı yöntemidir. Bunun yanı sıra, panoramik radyografiler, kapsamlı bir inceleme için diğer görüntüleme yöntemlerine ihtiyaç duyulup duyulmadığını saptamada etkili bir ilk adım olarak kullanılabilir (169). Panoramik radyografi, çocuk diş hekimliğinde tüm maksilla, mandibula ve çevre yapıları tek bir filmde görselleştirmek için önemli bir araçtır. Bu yöntemin sağladığı kapsamlı görüntüleme, karmaşık dental vakalarda teşhis ve tedavi planlamasını kolaylaştırır.

Ayrıca, panoramik radyografiler, çocuk hastalarda düşük radyasyon dozu ile güvenli bir değerlendirme imkânı sunarak hem hastaların hem de ailelerin endişelerini en aza indirir. Bu özellikler, çocuk diş hekimliğinde panoramik radyografinin kritik bir tanı aracı olarak önemini artırmaktadır (170). Bu nedenle çalışmamızda, yapay zekanın hipodonti tespitindeki etkinliğini değerlendirmek amacıyla, klinik uygulamalarda yaygın olarak tercih edilen ve hipodontinin erken teşhisi için uygun görüntüleme imkânı sunan panoramik radyografiler tercih edilmiştir.

Yapay zeka, problem çözme, nesne ve kelime tanıma, karar verme gibi karmaşık görevleri gerçekleştirmek için insan zekasını taklit edebilen makinelerin yeteneği olarak tanımlanır. Yapay zeka, günlük hayatta önemli başarılar elde etmiş ve sağlık dahil birçok alanda geniş bir kullanım alanı bulmuştur (171). Tıp ve diş hekimliğinde hızla benimsenmekte olan yapay zeka teknolojisi, bilgisayarlı görme ile röntgen, manyetik rezonans görüntüleme ve bilgisayarlı tomografi gibi tıbbi görüntüleme verilerini algılayıp yorumlama yeteneği sayesinde öne çıkmaktadır (172). Özellikle radyoloji, dijital olarak kodlanmış görüntülerin bilgisayar diline kolayca çevrilebilmesi sayesinde, yapay zeka için tıp alanında daha erişilebilir bir alan sunmaktadır. Yapay zeka tanı modelleri, radyologların büyük sayıda tıbbi görüntüyü inceleme ve raporlama yükünü hafifletirken, tanısal süreçlerde daha hızlı ve doğru sonuçlar elde etmeyi, öznel hataları azaltmayı ve uzmanların teşhis süreçlerini daha verimli hale getirmeyi sağlar (173,174).

Derin öğrenme yöntemleriyle geliştirilen yapay zeka modellerinin başarısı, eğitim verilerinin doğruluğu ve kesinliğiyle yakından ilişkilidir. Uzmanlar arasındaki bilgi ve beceri farklılıkları, teşhis sonuçlarının doğruluğunu etkileyebilir. Bu nedenle, yapay zeka modellerinin etkin bir şekilde çalışabilmesi için kullanılan eğitim verilerinin tecrübeli uzmanlar tarafından hazırlanması büyük önem taşır. Dolayısıyla derin öğrenme modelinde elde edilen sonuçların başarılı olması için eğitimde kullanılacak veriler deneyimli hekimler tarafından sağlanmalı ve standart referanslarla desteklenmelidir (175). Zhu ve arkadaşlarının birinci daimi azı dişlerinin ektopik sürmesini panoramik radyografilerde tespit etmek amacıyla yaptıkları çalışmada, bir radyoloji uzmanı ve iki uzman çocuk diş hekimi tarafından veriler kontrol edilmiştir (176). Duman ve arkadaşlarının panoramik radyografiler üzerinde taurodont dişlerin tespiti amacıyla kullanılan veriler, bir radyoloji uzmanı bir uzman çocuk diş hekimi ve bir endodontist tarafından işlenmiştir (177). Benzer çalışmalarda olduğu gibi bizim çalışmamızda da derin öğrenme modelinin eğitimi için kullanılan veriler 8 yıllık deneyime sahip bir çocuk

diş hekimi uzmanı ve 2,5 yıllık deneyime sahip bir araştırma görevlisi tarafından doğrulanarak veri setine eklenmiştir.

Derin öğrenme modellerinin eğitimi sırasında daha büyük veri setlerinden yararlanılması, modelin performansını arttırmada ve daha doğru tahminler yapmasında önemlidir (178). Bu tez çalışmasında, Ocak 2020 ile Temmuz 2024 tarihleri arasında fakülte veri tabanından alınan 1060 panoramik radyografiden oluşan veri seti, belirlenen dahil edilme ve dışlanma kriterlerine göre seçilerek oluşturulmuştur. Literatürde derin öğrenme tabanlı yapay zekâ yöntemleri kullanılarak dental anomali tespiti yapılan çalışmalar incelendiğinde, veri setinin çalışmamızla benzerlik gösterdiği görülmektedir. Ahn ve arkadaşları, mesiodens sınıflandırması için 1100 görüntü kullanırken, Kim ve arkadaşları mesiodens tanısı koymak amacıyla 988 görüntüden faydalanmıştır (179,180). Duman ve arkadaşları ise panoramik radyografilerde taurodontizmlı dişlerin teşhisi için CNN tabanlı bir yapay zeka modeli geliştirmiş ve çalışmada 434 görüntü kullanmıştır (177). Ayrıca, Kuwada ve arkadaşları maksiller gömülü süpernümerer dişlerin tanımlanması için 550 görüntüden oluşan bir veri seti kullanarak analizler gerçekleştirmiştir (181).

Derin öğrenme algoritmaları genellikle üç temel görev olan sınıflandırma, tespit ve segmentasyon üzerine yapılandırılır. Sınıflandırma, belirli bir veri parçasını belirli bir kategoriye atamak için kullanılmıştır. Tespit, görüntülerde belirli nesnelerin yerini bulma ve sınıflandırma, segmentasyon ise bir görüntüyü piksel düzeyinde analiz ederek farklı bölgeleri ayırmayı hedefler (182). Mun ve arkadaşlarının farklı derin öğrenme algoritmaları kullanarak panoramik radyografiler üzerinden çatlak dişlerin tespiti yaptığı çalışmada, ikili sınıflandırma (binary classification) yöntemi kullanmışlardır (183). Liu ve arkadaşlarının derin öğrenme tabanlı bir model geliştirilerek panoramik radyografiler üzerinde üst çene birinci daimi molarların ektopik sürmesinin tespit edilmesi amaçladıkları çalışmada, veriler üzerinde ektopik sürme durumlarının tespiti için, tespit yöntemi kullanmışlardır (184). Bizim çalışmamızda panoramik radyografiler binary classification yöntemi kullanılarak iki ana sınıfa ayrılmış ve her bir görüntü uygun sınıfa atanmıştır, bu yöntem, dental anomaliler gibi belirgin sınıfların ayırımında etkilidir.

İlgili çalışmalar gözden geçirildiğinde, diş hekimliği alanında dental anomalilerin tespitine yönelik yapay zeka çalışmalarında çeşitli derin öğrenme modellerinin kullanıldığı görülmektedir. Bunlar arasında AlexNet, ResNet, SqueezeNet, DetectNet, Faster R-CNN ve YOLO gibi algoritmalar yer almaktadır (150,181,185–188).

Pediatric hastaların panoramik radyografilerinde mesiodens varlığını tespit etmek ve sınıflandırmak için SqueezeNet, ResNet-18, ResNet-101 ve Inception-ResNet-V2 derin öğrenme tabanlı modellerin performansını değerlendirmeyi amaçlayan çalışma kapsamında, mesiodens tanısı konmuş 550 hastanın ve mesiodens bulunmayan 550 kontrol hastasının panoramik radyografileri kullanılmıştır. ResNet-101 ve Inception-ResNet-V2 modelleri, tüm metriklerde %90'ın üzerinde doğruluk, kesinlik ve F1 skoru ile en iyi performansı göstermiştir. SqueezeNet modeli ise diğer modellere göre daha düşük doğruluk oranı sunmuştur (180).

Kim ve arkadaşları, çocukların panoramik radyografilerinde mesiodens tespiti için tamamen otomatik bir derin öğrenme modeli geliştirmeyi ve değerlendirmeyi amaçladıkları çalışmada, toplam 988 panoramik radyografi kullanılmışlardır. Bu radyografilerden 489'u mesiodens bulunan hastalardan, 499'u ise mesiodens bulunmayan kontrol grubundan oluşmaktadır. Çalışmada kullanılan DeeplabV3+ adı verilen segmentasyon modeli, anterior bölgedeki ilgi alanını (ROI) otomatik olarak tespit etmektedir, ikinci model olan Inception-ResNet-v2, segmentasyon sonrası üst çene anterior bölgedeki mesiodens varlığını sınıflandırmaktadır. Bu çalışma için performans metrikleri; doğruluk, kesinlik, duyarlılık ve F1 skorları %97.1 olarak kaydedilmiştir. Ayrıca, otomatik segmentasyonun el ile yapılan segmentasyona göre daha yüksek bir başarı sağladığı vurgulanmıştır (179).

Kuwada ve arkadaşlarının yaptığı bir çalışmada, üst çene gömülü süpernumerer dişi bulunan 275 hasta ve gömülü süpernumerer dişi bulunmayan 275 hasta olmak üzere toplam 550 panoramik radyografi kullanılmıştır. Çalışma kapsamında AlexNet, VGG-16 ve DetectNet modelleri kullanılarak üç farklı öğrenme modeli veri setleri üzerinden eğitilmiştir. DetectNet, genel olarak en yüksek tanısal etkinlik değerlerini üretmiştir. VGG-16, DetectNet ve AlexNet'e kıyasla belirgin şekilde daha düşük değerler göstermiştir (181).

Karışık dişlenme döneminde birinci daimi molarların ektopik sürmesini, nnU-Net tabanlı bir yapay zeka modeli eğitimi ile segmentasyonu ve tespitinin amaçlandığı bir çalışmada, 285 panoramik radyografiden elde edilen toplam 438 görüntü incelenmiştir. Ayrıca, nnU-Net'in tespit performansı, farklı deneyim yıllarına sahip üç diş hekiminin performansı ile karşılaştırılmıştır. Performans metriklerine bakıldığında; nnU-Net modeli için kesinlik

0.845, F1 skoru 0.902 ve doğruluk 0.990 değerleri elde edilmiştir, diş hekimlerinin ortalama performans değerleri ise kesinlik 0.539, F1 skoru 0.699 ve doğruluk 0.811 olarak bulunmuştur. Bu çalışma, yapay zeka modelinin, panoramik radyografiler üzerinde birinci daimi molarların ektopik sürmesinin segmentasyonu ve tespitinde daha tutarlı ve doğru bir performans sunduğunu göstermektedir (176).

Duman ve arkadaşlarının yapmış olduğu çalışmada, panoramik radyografilerde taurodont dişlerin varlığını tespit etmek için derin öğrenme tabanlı bir konvolüsyonel sinir ağı (CNN) modeli olan U-Net modeli eğitilmiş ve taurodont dişlerin segmentasyonu ve tespiti gerçekleştirilmiştir. Çalışma kapsamında, 13 yaş üzerindeki hastalara ait toplam 434 panoramik radyografi görüntüsü kullanılmıştır. Model performansı duyarlılık, kesinlik ve F1 skoru gibi metriklerle değerlendirilmiştir. Modelin duyarlılığı 0,86, kesinliği 0,78 ve F1 skoru 0,82 olarak hesaplanmıştır. CNN tabanlı sistem, taurodont dişlerin tespitinde uzman düzeyine yakın sonuçlar elde etmiş ve eğitim verileriyle uyumlu sonuçlar sağlamıştır (177).

Yapay zeka destekli derin öğrenme algoritmaları arasında, YOLO, en popüler CNN tabanlı modellerden biri olarak öne çıkmaktadır. YOLO'nun mimarisi, oldukça basit bir yapıya sahip olmasına rağmen hızlı ve yüksek doğrulukla nesnelere algılayıp sınıflandırılabilir (189). YOLO sürümleri içinde, popüler olan modeller olan YOLOv5 ve YOLOv8, Ultralytics tarafından sırasıyla 2020 ve 2023 yıllarında geliştirilmiştir. Her iki algoritma da kullanım alanlarına göre önemli avantajlar sunar. YOLOv5, kolay kullanım ve entegrasyon özellikleriyle dikkat çekerken, YOLOv8 yüksek çıkarım hızları ve donanım verimliliği sağlamaktadır. Ayrıca, YOLOv8'in modern mimari iyileştirmeleri, tespit işlemlerinde daha yüksek hassasiyet ve doğruluk sunarak gelişmiş bir performans ortaya koyar (190). Bu nedenlerle, çalışmanızda hız ve pratikliği ile öne çıkan YOLOv5, doğruluk ve modern mimari yapısıyla dikkat çeken YOLOv8 kullanılmıştır.

Diş hekimliği alanında, YOLO algoritmasının kullanıldığı bir çok çalışma bulunmaktadır. Panoramik radyografilerde mesiodens tespiti için YOLOv3 altyapısıyla bir yapay zeka modeli kullanılan bir çalışmada, modelin farklı dişlenme gruplarındaki performansı değerlendirilmiştir. Çalışmada süt, karışık ve kalıcı dişlenme gruplarına göre model performansının incelendiği 612 hastaya ait panoramik radyografiler kullanılmıştır. YOLOv3 modelinin, süt dişlenmede %96, karışık dişlenmede %97 ve kalıcı dişlenmede %93 doğruluk oranlarına ulaşılmıştır. Bulunan doğruluk oranlarına bakılınca modelinin

hızlı ve doğru sonuçlar sağlayarak mesiodens tespiti için etkili bir araç olduğu ve klinik uygulamalarda kullanıma potansiyeline sahip olduğu sonucuna varılmıştır (20).

Kaya ve çalışma arkadaşları tarafından gerçekleştirilen bir araştırmada, pediatrik panoramik radyografilerde daimi diş tomurcuklarının otomatik tespiti amacıyla YOLOv4 modelini kullanarak çalışmayı gerçekleştirmişlerdir. Bu çalışmada, modelin kesinlik oranı %94, duyarlılık oranı %91, F1 skoru ise 0,90 olarak rapor edilmiştir. Çalışma, diş eksikliği veya diş fazlılığı gibi anomalilerin erken teşhisi için hızlı ve tutarlı bir teşhis yöntemi sunmaktadır (191).

Beşer ve arkadaşlarının, karışık dentisyon döneminde olan 5-13 yaş aralığında ki çocuk hastalarda diş tespiti ve segmentasyonu için YOLOv5 derin öğrenme modeli kullandığı bir çalışmada, diş tespiti için modelin duyarlılık oranı 0,99, kesinlik 0,99, F1 skoru 0,99 ve ortalama kesinlik (mAP) 0,98; diş segmentasyonu için ise duyarlılık 0,98, kesinlik 0,98, F1 skoru 0,98 ve ortalama kesinlik (mAP) değeri 0,98 olarak bulunmuştur. Bu doğrultuda, YOLOv5 tabanlı derin öğrenme algoritmasının, çocuk hastaların panoramik görüntülerinde süt ve daimi dişleri doğru tespit etme ve segmentasyonunu sağlamada, teşhis ve tedavi süreçlerine katkı sağlama potansiyeline sahip olduğu görülmüştür (192).

Kurt ve arkadaşlarının çalışmasında, çocuk hastaların panoramik radyografilerinden diş gelişim aşamalarını değerlendirmek için derin öğrenme esaslı bir yapay zeka algoritması olan YOLOv5, 1500 veri üzerinden eğitilmiştir. Model, diş gelişim aşamalarını belirlemede oldukça başarılı bulunmuştur. Duyarlılık oranı %99, kesinlik oranı %72 ve F1 skoru %84 olarak hesaplanmıştır. Elde edilen sonuçlar, çocukların diş gelişim aşamalarını otomatik olarak belirlemek için kullanılan YOLOv5 modelinin, diş gelişimi ile kronolojik yaş arasındaki ilişkiyi doğru bir şekilde değerlendirebileceğini göstermektedir (193).

Fitria ve arkadaşlarının yaptığı çalışmada, diş çürüklerinin tespiti, eksik dişlerin belirlenmesi ve dolgulu dişlerin sınıflandırılması amacıyla derin öğrenme tabanlı YOLOv5 ve YOLOv8 modelleri karşılaştırılmıştır. Araştırma, diş hekimlerinin manuel olarak gerçekleştirdiği zaman alıcı çürük tespiti ve Decayed, Missing, Filled Teeth (DMFT) indeksinin hesaplanması sürecini otomatikleştirmeyi hedeflemiştir. YOLOv5 ve YOLOv8 modellerinin farklı versiyonları (n, s, m, l) üzerinde eğitim gerçekleştirilmiş ve modeller, kesinlik, duyarlılık ve ortalama hassasiyet (mAP) metrikleri ile değerlendirilmiştir. YOLOv5l modeli, %90.4 mAP değeri ile en iyi performansı

gösterirken, YOLOv8m modeli %90.6 mAP ile daha yüksek doğruluk sağlamıştır. YOLOv5, hızlı hesaplama süresiyle öne çıkarken, YOLOv8 daha kararlı ve detaylı öğrenme kapasitesi sunmuştur (194).

Pediyatrik hastaların periapikal radyografik görüntülerinde aproksimal çürüklerin tespiti için YOLO algoritmalarının (YOLOv4, YOLOv5, YOLOv6, YOLOv7, YOLOv8) kullanıldığı bir araştırmada, 5-12 yaş arası çocuklardan toplanan 415 radyografik görüntü içeren özgün bir veri seti oluşturulmuştur. Modelin eğitimi sırasında YOLO'nun farklı versiyonları karşılaştırılmış ve en yüksek doğruluk oranı olan %90 ile YOLOv5s modeli seçilmiştir. Modelin diğer performans metrikleri; kesinlik %91, duyarlılık %89 ve F1 skoru %90 olarak hesaplanmıştır (195).

Bitewing radyografilerde interproksimal, oklüzal ve sekonder çürüklerin tespit edilmesi ve sınıflandırılması amacıyla gerçekleştirilen bir çalışmada, YOLOv8 algoritmasını temel alan bir model geliştirilmiştir. Bu model, 860 radyografiden oluşan bir veri kümesi üzerinde değerlendirilmiştir. YOLOv8 algoritmasının test sonuçları oldukça başarılı bulunmuş; modelin doğruluk oranı %97, hassasiyet değeri %93 ve F1 skoru %95 olarak hesaplanmıştır (196).

Derin öğrenme tabanlı YOLO algoritmaları (YOLOv7, YOLOv8 ve YOLOv9) kullanılarak dental radyografilerde çürüklerin tespiti ve sınıflandırılması hedeflenen bir çalışmada, YOLOv8 modeli, %98.2 mAP, %95.4 kesinlik ve %92.2 duyarlılık değerleriyle en yüksek performansı sergilemiş ve diğer iki modelden daha üstün olduğu görülmüştür. YOLOv7 ve YOLOv9 modelleri, özellikle küçük detayların tespiti ve genel doğruluk oranlarında YOLOv8'e göre daha düşük performans göstermiştir. YOLOv8'in daha ileri mimarisi, özellikle küçük veya örtüşen nesnelere algılanmasında yüksek doğruluk sağlamıştır (197).

Mevcut literatürde derin öğrenme algoritmaları kullanılarak hipodonti tespitine yönelik bir çalışmaya rastlanmamıştır. Bu doğrultuda yapılan ilk çalışmalardan biri olan araştırmamızda YOLOv5 modeli, hipodonti tespiti için test edilmiş ve elde edilen sonuçlar değerlendirilmiştir. Modelin kesinlik %75,47 ve F1 skoru %66,67 gibi bazı metrikleri orta düzeyde kabul edilebilir bulunmuş olsa da, duyarlılık %59,70 ve doğruluk %62,26 gibi temel ölçütlerde sınırlı bir başarı göstermiştir. YOLOv5 kullanılarak gerçekleştirilen çalışmamızdan elde edilen veriler aynı derin öğrenme algoritması

kullanılarak yapılan diğer arařtırmaların sonuçlarıyla kıyaslandığında düşük performans gösterdiği gözlemlenmiştir. Bunun nedeni olarak çalışmamızda hipodonti tespiti için ikili sınıflandırma görevine uygun şekilde eğitilen derin öğrenme algoritmasının, görüntülerin tamamını tek bir karar için analiz etmesi olabilir. Bu durum modelin belirli bölgede anomalileri tespit etme kapasitesini sınırlayarak, modelin lokal bilgiyi gözden kaçırmaya neden olabileceğini düşünmekteyiz. Çalışmamızda kullandığımız diğer derin öğrenme modeli olan YOLOv8, YOLOv5 modelinden farklı olarak hipodonti tespitinde daha yüksek bir başarı göstermiştir. Bu modelin, elde edilen performans değerlendirme metrikleri oldukça yüksek bulunmuştur. Modelin duyarlılık %92,45, kesinlik %92,45, doğruluk %92,45 ve F1 skoru %92,45 gibi temel metriklerde yüksek başarı göstermesi, hipodonti tespiti için bu modelin etkili bir yapay zeka çözümü sunduğunu ortaya koymaktadır. Bu elde edilen veriler aynı derin öğrenme algoritması kullanılarak yapılan diğer arařtırmaların sonuçlarıyla kıyaslandığında benzer sonuçlar göstermektedir. YOLOv8 modeli, mimari iyileřtirmeleri ve optimize edilmiş öğrenme süreçleri sayesinde hipodonti tespiti gibi karmaşık görevlerde üstün bir performans sergilemiştir. Özellikle anchor-free yapısı, detaylı lokal anomalilerin daha etkili bir şekilde tespit edilmesini sağlamış ve duyarlılık, kesinlik ve F1 skoru gibi metriklerde modelin performansını artırmıştır.

Hipodonti gibi toplumda yüksek görülme oranına sahip bir dental anomalinin teşhisinde, derin öğrenme algoritmalarının kullanımı, teşhis süreçlerini katkı sağlayabilecek etkili bir araç olarak kullanılabilir. Derin öğrenme modellerinin başarısı, kullanılan verilerin kalitesine ve çeşitliliğine doğrudan bağlıdır. Yüksek doğruluk ve güvenilirlik sağlamak için verilerin tutarlı, doğru ve eksiksiz olması gerekmektedir. Derin öğrenme modelleri genellikle büyük miktarda veri gerektirir, yetersiz veya dengesiz veri setleri, modelin bazı sınıfları öğrenememesine neden olabilir. Özellikle nadir görülen durumlar için az sayıda veri örneği bulunması, modelin bu durumları doğru şekilde tahmin etmesini zorlaştırabilir (198). Çalışmamıza 8-15 yaş aralığındaki 1060 hastanın panoramik radyografisi dahil edilmiştir kullanılan tüm radyografik görüntüler tek bir kurumdan temin edilmiştir. Farklı kurumlardan elde edilecek görüntülerle gerçekleştirilecek çalışmalar, hem veri setinin boyutunu artıracak hem de yapay zekâ modelinin performansını iyileştirecektir. Yapılacak çalışmalarda daha geniş ve dengeli bir veri seti kullanılarak, yapay zekâ modellerinin uyarlanabilirlik ve doğruluk kapasitesi artırılabilir.

Çalışmamızda kullanılan ikili sınıflandırma yöntemi, yalnızca anomalinin varlığını veya

yokluğunu belirlemek üzerine tasarlanmış olup, spesifik bölgelerin tespitini veya anomalinin tam yerinin belirlenmesini sağlamamaktadır. Bu durum, detaylı analiz yapma kabiliyetini sınırlamakta ve anomalinin boyutu, konumu veya çevresindeki yapılarla ilişkisi hakkında bilgi sağlayamamaktadır. Dolayısıyla, lokalizasyon eksikliği, özellikle hipodonti gibi detaylı değerlendirme gerektiren durumlarda sınırlayıcı bir faktör olarak karşımıza çıkmaktadır. Anomaliyi tam olarak lokalize edebilen daha gelişmiş yöntemlerin, tanısal doğruluk ve klinik uygulanabilirlik açısından daha fazla katkı sağlayabileceği düşünülmektedir.

Hipodonti teşhisinde derin öğrenme yöntemlerinin kullanımı, diş hekimlerinin teşhis sürecini hızlandırarak etkili bir destek aracı olarak işlev görebilir. Derin öğrenme algoritmalarının performanslarının ve doğruluk oranının artırılması için daha çok sayıda çalışmaya ihtiyaç duyulmaktadır. Gelecekte, yapay zekâ teknolojilerinin diş hekimliği alanına daha kapsamlı bir şekilde entegrasyonu ile, hipodonti gibi dental anomalilerin erken teşhis ve tedavisi daha hızlı bir şekilde yapılabilir. Bu sayede, hastaların tedavi süreçlerinde hata oranları düşürülerek diş hekimlerinin iş yükü azalacak ve tedavi kalitesi artacaktır.

## 6. SONUÇ VE ÖNERİLER

Bu çalışmada elde edilen verilere göre;

8-16 yaş aralığındaki hastaların panoramik radyografileri üzerinden hipodonti tespiti için derin öğrenme algoritmalarının kullanıldığı çalışmamızda, YOLOv5 modelinin performansı belirli metriklerle değerlendirilmiştir. Modelin kesinlik oranı %75,47, duyarlılık oranı %59,70 olarak bulunmuş, F1 skoru ise %66,67 olarak bulunmuştur. Bu sonuçlar, modelin doğruluk açısından sınırlı bir performans gösterdiğini, ancak hala belirli vakalarda faydalı olabileceğini ortaya koymaktadır. YOLOv8 modelinin performans metriklerine bakıldığında ise modelin kesinlik oranı %92,45, duyarlılık oranı da %92,45, F1 skoru da %92,45 olup genel olarak modelin yüksek performans gösterdiğini ortaya koymaktadır. Bu sonuçlar, YOLOv8'in hipodonti tespiti gibi görevlerde yüksek doğruluk ve güvenilirlik sunduğunu işaret etmektedir. YOLOv8 modeli, tüm metrikler açısından YOLOv5 modeline kıyasla açık bir üstünlük göstermiştir. Bu sonuç, YOLOv8'in daha yeni ve optimize edilmiş bir model olarak hipodonti tespiti gibi sınıflandırma görevlerinde daha yüksek doğruluk, duyarlılık ve özgüllük sağladığını göstermektedir. Hipodonti tespiti için YOLOv8'in kullanımı daha uygun bir tercih olarak değerlendirilmektedir.

Veri setinin yeterli sayıda ve çeşitlilikte olması, yapay zeka modelinin doğruluğu ve genelleme kapasitesi üzerinde doğrudan bir etkiye sahiptir. Dental anomaliler, veri setlerinde yeterince temsil edilmediklerinde, modelin bu durumları doğru bir şekilde öğrenmesi ve tespit etmesi zorlaşır. Bu sorunu aşmak için, veri seti daha geniş ve çeşitlendirilmiş bir şekilde oluşturulmalıdır. Farklı kurumlardan ve coğrafi bölgelerden alınacak çeşitli verilerle, modelin eğitim süreci zenginleştirilebilir. Ayrıca, farklı yaş grupları, cinsiyetler, etnik kökenler ve diş yapısı gibi faktörlerin dahil edilmesi, modelin daha fazla vakayı doğru şekilde öğrenmesini sağlayacaktır. Veri setinin çeşitlendirilmesi, modelin sadece belirli bir popülasyon üzerinde değil, daha geniş bir hasta grubunda da başarılı sonuçlar elde etmesine olanak tanıyacaktır.

Sonuç olarak bu çalışma, yapay zeka tabanlı derin öğrenme yöntemlerinin hipodonti teşhisinde kullanılabilir bir destek aracı olabileceği göstermekte ve gelecekteki araştırmalara yön verecek önemli bir kaynak sunmaktadır. Ayrıca bu teknolojilerin dış

hekimliğinde teşhis doğruluğunu artırma, klinik süreçleri hızlandırma ve hekimlerin iş yükünü azaltma potansiyeline sahip olduğu söylenebilir.



## 7. KAYNAKLAR

1. Sloan AJ. Development of the dentition. In: Forensic Odontology. Chichester, UK: John Wiley & Sons, Ltd; 2013. p. 9–21.
2. Eshgian N, Al-Talib T, Nelson S, Abubakr NH. Prevalence of hyperdontia, hypodontia, and concomitant hypo-hyperdontia. *J Dent Sci.* 2021 Mar;16(2):713–7.
3. Johal A, Huang Y, Toledano S. Hypodontia and its impact on a young person's quality of life, esthetics, and self-esteem. *Am J Orthod Dentofacial Orthop.* 2022 Feb;161(2):220–7.
4. Elsherif N, Rodriguez J, Ahmed F. Prevalence and management of patients with hypodontia: A cross-sectional study. *J Orthod.* 2022 Sep;49(3):332–7.
5. İşman NE. PAX9 genindeki G-1031A ve T-912C polimorfizmleri ile diş eksikliği (Hypodonti ve Oligodonti) ilişkisinin incelenmesi. 2009
6. Sivarajan S, Mani SA, John J, Fayed MMS, Kook YA, Wey MC. The global distribution of permanent canine hypodontia: A systematic review. *Korean J Orthod.* 2021 Jan 25;51(1):55–74.
7. Wu Y, Ma Q, Han B, Shen Y, Wen S. Familial hypodontia in bronze age Northwest China (1046-771BC). *Arch Oral Biol.* 2025 Jan;169:106104.
8. Alhazmi N, Alaqla A, Almuzzaini B, Aldrees M, Alnaqa G, Almasoud F, et al. What could be the role of genetic tests and machine learning of AXIN2 variant dominance in non-syndromic hypodontia? A case-control study in orthodontically treated patients. *Prog Orthod.* 2024 Aug 26;25(1):31.
9. Rakhshan V. Congenitally missing teeth (hypodontia): A review of the literature concerning the etiology, prevalence, risk factors, patterns and treatment. *Dent Res J (Isfahan).* 2015 Jan;12(1):1–13.
10. Kim E, Hwang JJ, Cho BH, Lee E, Shin J. Classification of presence of missing teeth in each quadrant using deep learning artificial intelligence on panoramic radiographs of pediatric patients. *J Clin Pediatr Dent.* 2024 May;48(3):76–85.
11. Schwartz S. Radiographic techniques for the pediatric patient. *J Contemp Dent Pract.* 2000 Nov 15;1(4):60–73.
12. Peretz B, Gotler M, Kaffe I. Common errors in digital panoramic radiographs of patients with mixed dentition and patients with permanent dentition. *Int J Dent.* 2012 Feb 8;2012:584138.
13. Anthonappa RP, King NM, Rabie ABM, Mallineni SK. Reliability of panoramic radiographs for identifying supernumerary teeth in children: Panoramic radiographs for identifying supernumerary teeth in children. *Int J Paediatr Dent.* 2012 Jan;22(1):37–43.

14. Mahdi FP, Motoki K, Kobashi S. Optimization technique combined with deep learning method for teeth recognition in dental panoramic radiographs. *Sci Rep.* 2020 Nov 6;10(1):19261.
15. Ward IR, Laga H, Bennamoun M. RGB-D image-based object detection: From traditional methods to deep learning techniques. In: *RGB-D Image Analysis and Processing*. Cham: Springer International Publishing; 2019. p. 169–201. (Advances in computer vision and pattern recognition).
16. Liu X, Faes L, Kale AU, Wagner SK, Fu DJ, Bruynseels A, et al. A comparison of deep learning performance against health-care professionals in detecting diseases from medical imaging: a systematic review and meta-analysis. *The Lancet Digital Health.* 2019 Oct 1;1(6):e271–97.
17. Estai M, Tennant M, Gebauer D, Brostek A, Vignarajan J, Mehdizadeh M, et al. Deep learning for automated detection and numbering of permanent teeth on panoramic images. *Dentomaxillofac Radiol.* 2022 Feb 1;51(2):20210296.
18. Kwon O, Yong TH, Kang SR, Kim JE, Huh KH, Heo MS, et al. Automatic diagnosis for cysts and tumors of both jaws on panoramic radiographs using a deep convolution neural network. *Dentomaxillofac Radiol.* 2020 Dec 1;49(8):20200185.
19. Yang H, Jo E, Kim HJ, Cha IH, Jung YS, Nam W, et al. Deep learning for automated detection of cyst and tumors of the jaw in panoramic radiographs. *J Clin Med [Internet].* 2020 Jun 12;9(6):1839. Available from: <http://dx.doi.org/10.3390/jcm9061839>
20. Ha EG, Jeon KJ, Kim YH, Kim JY, Han SS. Automatic detection of mesiodens on panoramic radiographs using artificial intelligence. *Sci Rep.* 2021 Nov 29;11(1):23061.
21. Matalova E, Fleischmannova J, Sharpe PT, Tucker AS. Tooth agenesis: from molecular genetics to molecular dentistry. *J Dent Res.* 2008 Jul;87(7):617–23.
22. Nunn JH, Carter NE, Gillgrass TJ, Hobson RS, Jepson NJ, Meechan JG, et al. The interdisciplinary management of hypodontia: background and role of paediatric dentistry. *Br Dent J.* 2003 Mar 8;194(5):245–51.
23. Bailleul-Forestier I, Molla M, Verloes A, Berdal A. The genetic basis of inherited anomalies of the teeth. Part 1: clinical and molecular aspects of non-syndromic dental disorders. *Eur J Med Genet.* 2008 Mar 26;51(4):273–91.
24. Arte S. Phenotypic and genotypic features of familial hypodontia. *taitto.* 2001;28:9128.
25. Polder BJ, Van't Hof MA, Van der Linden FPGM, Kuijpers-Jagtman AM. A meta-analysis of the prevalence of dental agenesis of permanent teeth. *Community Dent Oral Epidemiol.* 2004 Jun;32(3):217–26.
26. Rózsa N, Nagy K, Vajó Z, Gábris K, Soós A, Alberth M, et al. Prevalence and distribution of permanent canine agenesis in dental paediatric and orthodontic patients in Hungary. *Eur J Orthod.* 2009 Aug;31(4):374–9.

27. Hobkirk JA, Brook AH. The management of patients with severe hypodontia. *J Oral Rehabil.* 1980 Jul;7(4):289–98.
28. Wu CC, Wong R, Hagg E. A review of hypodontia: the possible etiologies and orthodontic, surgical and restorative treatment options: conventional and futuristic. 2007 [cited 2024 Nov 25]; Available from: <https://www.semanticscholar.org/paper/A-review-of-hypodontia%3A-the-possible-etiologicalies-and-Wu-Wong/10f1bfd843e0d6a1df711d38d1d718f54b26e417>
29. Mattheeuws N, Dermaut L, Martens G. Has hypodontia increased in Caucasians during the 20th century? A meta-analysis. *Eur J Orthod.* 2004 Feb;26(1):99–103.
30. Gelgör İE, Şişman Y, Malkoç S. Daimi dentisyonda konjenital hipodontinin görülme sıklığı. *Turk Klin J Dent Sci.* 2005;11(2):43–8.
31. Altug-Atac AT, Erdem D. Prevalence and distribution of dental anomalies in orthodontic patients. *Am J Orthod Dentofacial Orthop.* 2007 Apr;131(4):510–4.
32. Gokkaya B, Kargul B. Prevalence and pattern of non-syndromic hypodontia in a group of Turkish children. *Acta Stomatol Croat.* 2016 Mar;50(1):58–64.
33. Topkara A, Sari Z. Prevalence and distribution of hypodontia in a Turkish orthodontic patient population: results from a large academic cohort. *Eur J Paediatr Dent.* 2011 Jun;12(2):123–7.
34. Magnússon TE. An epidemiologic study of dental space anomalies in Icelandic schoolchildren. *Community Dent Oral Epidemiol.* 1977 Nov;5(6):292–300.
35. Rølling S, Poulsen S. Agenesis of permanent teeth in 8138 Danish schoolchildren: prevalence and intra-oral distribution according to gender. *Int J Paediatr Dent.* 2009 May;19(3):172–5.
36. Rohilla M, Rabi T. Etiology of various dental developmental anomalies-Review of literature. *Journal of Dental Problems and Solutions.* 2017;4(2):019–25.
37. Al-Ani AH, Antoun JS, Thomson WM, Merriman TR, Farella M. Hypodontia: An Update on Its Etiology, Classification, and Clinical Management. *Biomed Res Int.* 2017 Mar 19;2017:9378325.
38. Gullikson JS. Tooth morphology in rubella syndrome children. *ASDC J Dent Child.* 1975 Nov;42(6):479–82.
39. Schalk-van der Weide Y, Steen WH, Bosman F. Distribution of missing teeth and tooth morphology in patients with oligodontia. *ASDC J Dent Child.* 1992 Mar;59(2):133–40.
40. Maguire A, Craft AW, Evans RG, Amineddine H, Kernahan J, Macleod RI, et al. The long-term effects of treatment on the dental condition of children surviving malignant disease. *Cancer.* 1987 Nov 15;60(10):2570–5.
41. Näsman M, Forsberg CM, Dahllöf G. Long-term dental development in children after treatment for malignant disease. *Eur J Orthod.* 1997 Apr;19(2):151–9.

42. Pragna T, Patel I. Hypodontia: genetics and future perspectives. [tspace.library.utoronto.ca](https://tspace.library.utoronto.ca/handle/1807/8578) [Internet]. Available from: <https://tspace.library.utoronto.ca/handle/1807/8578>
43. Tan SPK, van Wijk AJ, Prahl-Andersen B. Severe hypodontia: identifying patterns of human tooth agenesis. *Eur J Orthod.* 2011 Apr;33(2):150–4.
44. Vastardis H, Karimbux N, Guthua SW, Seidman JG, Seidman CE. A human MSX1 homeodomain missense mutation causes selective tooth agenesis. *Nat Genet.* 1996 Aug;13(4):417–21.
45. Gerits A, Nieminen P, De Muynck S, Carels C. Exclusion of coding region mutations in MSX1, PAX9 and AXIN2 in eight patients with severe oligodontia phenotype. *Orthod Craniofac Res.* 2006 Aug;9(3):129–36.
46. Vieira AR, Meira R, Modesto A, Murray JC. MSX1, PAX9, and TGFA contribute to tooth agenesis in humans. *J Dent Res.* 2004 Sep;83(9):723–7.
47. Mărgărit R, Andrei OC, Tănăsescu LA, Farcașiu C, Bisoc A, Dina MN, et al. Non-syndromic familial hypodontia: rare case reports and literature review. *Rom J Morphol Embryol.* 2019;60(4):1355–60.
48. Arte S, Nieminen P, Apajalahti S, Haavikko K, Thesleff I, Pirinen S. Characteristics of incisor-premolar hypodontia in families. *J Dent Res.* 2001 May;80(5):1445–50.
49. Tao R, Jin B, Guo SZ, Qing W, Feng GY, Brooks DG, et al. A novel missense mutation of the EDA gene in a Mongolian family with congenital hypodontia. *J Hum Genet.* 2006 Apr 1;51(5):498–502.
50. Brook AH. Multilevel complex interactions between genetic, epigenetic and environmental factors in the aetiology of anomalies of dental development. *Arch Oral Biol.* 2009 Dec;54 Suppl 1:S3–17.
51. Orup HI Jr, Keith DA, Holmes LB. Prenatal anticonvulsant drug exposure: teratogenic effect on the dentition. *J Craniofac Genet Dev Biol.* 1998 Jul;18(3):129–37.
52. Gilbert-Barness E. Teratogenic causes of malformations. *Ann Clin Lab Sci.* 2010 Mar 20;40(2):99–114.
53. Parkin N, Elcock C, Smith RN, Griffin RC, Brook AH. The aetiology of hypodontia: the prevalence, severity and location of hypodontia within families. *Arch Oral Biol.* 2009 Dec;54 Suppl 1:S52–6.
54. Cameron J, Sampson WJ. Hypodontia of the permanent dentition. Case reports. *Aust Dent J.* 1996 Feb;41(1):1–5.
55. Boruchov M, Green LJ. Hypodontia in human twins and families. *Am J Orthod.* 1971 Aug 1;60(2):165–74.
56. Garib DG, Peck S, Gomes SC. Increased occurrence of dental anomalies associated with second-premolar agenesis. *Angle Orthod.* 2009 May;79(3):436–41.

57. Choi SJ, Lee JW, Song JH. Dental anomaly patterns associated with tooth agenesis. *Acta Odontol Scand.* 2017 Apr;75(3):161–5.
58. Al-Abdallah M, AlHadidi A, Hammad M, Al-Ahmad H, Saleh R. Prevalence and distribution of dental anomalies: a comparison between maxillary and mandibular tooth agenesis. *Am J Orthod Dentofacial Orthop.* 2015 Nov;148(5):793–8.
59. Hobkirk JA, Goodman JR, Jones SP. Presenting complaints and findings in a group of patients attending a hypodontia clinic. *Br Dent J.* 1994 Nov 5;177(9):337–9.
60. Pinho S, Ciriaco C, Faber J, Lenza MA. Impact of dental asymmetries on the perception of smile esthetics. *Am J Orthod Dentofacial Orthop.* 2007 Dec;132(6):748–53.
61. Haselden K, Hobkirk JA, Goodman JR, Jones SP, Hemmings KW. Root resorption in retained deciduous canine and molar teeth without permanent successors in patients with severe hypodontia. *Int J Paediatr Dent.* 2001 May;11(3):171–8.
62. Schalk-van der Weide Y, Steen WH, Bosman F. Taurodontism and length of teeth in patients with oligodontia. *J Oral Rehabil.* 1993 Jul;20(4):401–12.
63. Peck S, Peck L, Kataja M. Concomitant occurrence of canine malposition and tooth agenesis: evidence of orofacial genetic fields. *Am J Orthod Dentofacial Orthop.* 2002 Dec;122(6):657–60.
64. Carter NE, Gillgrass TJ, Hobson RS, Jepson N, Eechan JGM, Nohl FS, et al. The interdisciplinary management of hypodontia: orthodontics. *Br Dent J.* 2003 Apr 12;194(7):361–6.
65. Hummel P, Guddack S. Psychosocial stress and adaptive functioning in children and adolescents suffering from hypohidrotic ectodermal dysplasia. *Pediatr Dermatol.* 1997 May;14(3):180–5.
66. Worsaae N, Jensen BN, Holm B, Holsko J. Treatment of severe hypodontia-oligodontia--an interdisciplinary concept. *Int J Oral Maxillofac Surg.* 2007 Jun;36(6):473–80.
67. Cronin RJ Jr, Oesterle LJ. Implant use in growing patients. Treatment planning concerns. *Dent Clin North Am.* 1998 Jan;42(1):1–34.
68. Dietschi D, Schatz JP. Current restorative modalities for young patients with missing anterior teeth. *Quintessence Int.* 1997 Apr;28(4):231–40.
69. Volchansky A, Cleaton-Jones P, Fatti LP. A 3-year longitudinal study of the position of the gingival margin in man. *J Clin Periodontol.* 1979 Aug;6(4):231–7.
70. Dharmo B, Vucic S, Kuijpers MAR, Jaddoe VWV, Hofman A, Wolvius EB, et al. The association between hypodontia and dental development. *Clin Oral Investig.* 2016 Jul;20(6):1347–54.
71. Kokich V Jr. Early management of congenitally missing teeth. *Semin Orthod.* 2005 Sep;11(3):146–51.

72. Lindqvist B. Extraction of the deciduous second molar in hypodontia. *Eur J Orthod.* 1980;2(3):173–81.
73. Mamopoulou A, Hägg U, Schröder U, Hansen K. Agenesis of mandibular second premolars. Spontaneous space closure after extraction therapy: a 4-year follow-up. *Eur J Orthod.* 1996 Dec;18(6):589–600.
74. Putra RH, Doi C, Yoda N, Astuti ER, Sasaki K. Current applications and development of artificial intelligence for digital dental radiography. *Dentomaxillofac Radiol.* 2022 Jan 1;51(1):20210197.
75. McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics.* 1943 Dec;5(4):115–33.
76. Avaner EB, Others. Turing Testi Işığında Düşüncenin Multidisipliner İncelemesi III. *Turk J Bioeth.* 2018;5(4):183–92.
77. Turing A. Computing Machinery and Intelligence (1950). In: *The Essential Turing.* Oxford University PressOxford; 2004. p. 433–64.
78. Wang G, Li X, Xie S. Bilateral Turing Test: Assessing machine consciousness simulations. *Cogn Syst Res.* 2024 Dec;88(101299):101299.
79. Bhutani A, Sanaria2 A. The past, present and future of artificial intelligence. *GLIMS Journal of Management Review and Transformation [Internet].* 2023 Nov; Available from: <https://mrt.greatlakes.edu.in/doi/pdf/10.1177/jmrt.231199305.pdf>
80. Kaul V, Enslin S, Gross SA. History of artificial intelligence in medicine. *Gastrointest Endosc.* 2020 Oct;92(4):807–12.
81. Khanagar SB, Al-Ehaideb A, Maganur PC, Vishwanathaiah S, Patil S, Baeshen HA, et al. Developments, application, and performance of artificial intelligence in dentistry - A systematic review. *J Dent Sci.* 2021 Jan;16(1):508–22.
82. Arsiwala-Scheppach LT, Chaurasia A, Müller A, Krois J, Schwendicke F. Machine learning in dentistry: A scoping review. *J Clin Med.* 2023 Jan 25;12(3):937.
83. Samuel AL. Some studies in machine learning using the game of checkers. *IBM J Res Dev.* 1959 Jul;3(3):210–29.
84. Sarker IH. Machine learning: Algorithms, real-world applications and research directions. *SN Comput Sci.* 2021 Mar 22;2(3):160.
85. Cunningham P, Cord M, Delany SJ. Supervised Learning. In: *Machine Learning Techniques for Multimedia.* Berlin, Heidelberg: Springer Berlin Heidelberg; 2008. p. 21–49.
86. Mahesh B. Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)[Internet].* 2020;9(1):381–6.
87. Learning SS. Semi-supervised learning. *CSZ2006 html.* 2006;5:2.

88. Zou J, Han Y, So SS. Overview of artificial neural networks. *Methods Mol Biol.* 2008;458:15–23.
89. Krenker A, Bešter J, Kos A. Introduction to the artificial neural networks. *Artificial Neural Networks: Methodological Advances and Biomedical Applications InTech.* 2011;1–18.
90. Nichols JA, Herbert Chan HW, Baker MAB. Machine learning: applications of artificial intelligence to imaging and diagnosis. *Biophys Rev.* 2019 Feb;11(1):111–8.
91. Ramesh AN, Kambhampati C, Monson JRT, Drew PJ. Artificial intelligence in medicine. *Ann R Coll Surg Engl.* 2004 Sep;86(5):334–8.
92. Goncalves V, Maria K, da Silv ABF. Applications of artificial neural networks in chemical problems. In: Suzuki K, editor. *Artificial Neural Networks - Architectures and Applications.* InTech; 2013.
93. Öztürk K, Şahin M. Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış. *Takvim-i Vekayi.* 2018 Dec 30;6(2):25–36.
94. Keskenler MF, Keskenler EF. Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi. *Takvim-i Vekayi.* 2017 Dec 29;5:8–18.
95. Yapay sinir ağları ile sistem tanıma. Available from: <https://polen.itu.edu.tr/bitstreams/d176b090-2b62-45a0-9240-27fa5be314b7/download>
96. Öztemel DE. YAPAY SİNİR AĞLARI [Internet]. PapatyaYayincilik, Istanbul. [papatyabilim.com.tr](http://papatyabilim.com.tr); 2003. Available from: [http://papatyabilim.com.tr/PDF/yapay\\_sinir\\_aglari.pdf](http://papatyabilim.com.tr/PDF/yapay_sinir_aglari.pdf)
97. Arı A, Berberler ME. Yapay Sinir Ağları ile Tahmin ve Sınıflandırma Problemlerinin Çözümü İçin Arayüz Tasarımı. 2017 Dec 29;1:55–73.
98. Rojas R. Neural networks: A systematic introduction [Internet]. 1996th ed. Berlin, Germany: Springer; 1996. 502 p. Available from: [https://books.google.com/books/about/Neural\\_Networks.html?id=4rESBwAAQB-AJ](https://books.google.com/books/about/Neural_Networks.html?id=4rESBwAAQB-AJ)
99. Aşkın D, İskender İ, Mamızadeh A. FARKLI YAPAY SİNİR AĞLARI YÖNTEMLERİNİ KULLANARAK KURU TİP TRANSFORMATÖR SARGISININ TERMAL ANALİZİ. *GUMMFD.* 2013;26(4).
100. Asilkan Ö, S. IAG. İkinci el otomobillerin gelecekteki fiyatlarının yapay sinir ağları ile tahmin edilmesi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi.* 2009;14(2):375–91.
101. Krizhevsky A, Sutskever I. Imagenet classification with deep convolutional neural networks. Available from: <https://proceedings.neurips.cc/paper/2012/hash/c399862d3b9d6b76c8436e924a68c45b-Abstract.html>

102. Hinton GE, Salakhutdinov RR. Reducing the dimensionality of data with neural networks. *Science*. 2006 Jul 28;313(5786):504–7.
103. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015 May 28;521(7553):436–44.
104. Kaya U, Yılmaz A, Dikmen Y. Sağlık Alanında Kullanılan Derin Öğrenme Yöntemleri. *Eur J Sci Technol [Internet]*. 2019 Aug 31; Available from: <https://dergipark.org.tr/en/pub/ejosat/article/573248>
105. Schulz H, Behnke S. Deep learning: Layer-wise learning of feature hierarchies. *KI - Künstl Intell*. 2012 Nov;26(4):357–63.
106. Hao X, Zhang G, Ma S. Deep learning. *Int J Semant Comput*. 2016 Sep;10(03):417–39.
107. Doğan F, Türkoğlu İ. Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*. 2019;10(2):409–45.
108. Akın E, Şahin ME. Derin Öğrenme ve Yapay Sinir Ağı Modelleri Üzerine Bir İnceleme. *EMO Bilimsel Dergi*. 14(1):27–38.
109. Lecun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. *Proc IEEE Inst Electr Electron Eng*. 1998;86(11):2278–324.
110. Hubel DH, Wiesel TN. Receptive fields and functional architecture of monkey striate cortex. *J Physiol*. 1968 Mar;195(1):215–43.
111. Min S, Lee B, Yoon S. Deep learning in bioinformatics. *Briefings in Bioinformatics*. 2016 Mar 21;18:851–69.
112. İnik Ö, Ülker E. Modelleri [Internet]. Available from: <https://dergipark.org.tr/en/download/article-file/380999>
113. Ciresan DC, Meier U, Masci J, Gambardella LM, Schmidhuber J. Flexible, high performance convolutional neural networks for image classification. In: *Twenty-second international joint conference on artificial intelligence [Internet]*. Citeseer; 2011. Available from: <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=5a47ba057a858f8c024d2518cc3731fc7eb40de1>
114. Ker J, Wang L, Rao J, Lim T. Deep learning applications in medical image analysis. *IEEE Access*. 2018;6:9375–89.
115. Albawi S, Mohammed TA, Al-Zawi S. Understanding of a convolutional neural network. In: *2017 International Conference on Engineering and Technology (ICET)*. IEEE; 2017. p. 1–6.
116. Hinton GE, Srivastava N, Krizhevsky A, Sutskever I, Salakhutdinov RR. Improving neural networks by preventing co-adaptation of feature detectors [Internet]. *arXiv [cs.NE]*. 2012. Available from:

[https://www.cse.iitk.ac.in/users/cs365/2013/hw2/hinton-srivastava-12\\_NN-prevents-co-adaptation-of-feature-detectors.pdf](https://www.cse.iitk.ac.in/users/cs365/2013/hw2/hinton-srivastava-12_NN-prevents-co-adaptation-of-feature-detectors.pdf)

117. Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R. Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*. 2014;15(1):1929–58.
118. Seker A, Diri B, Balik H. Derin Öğrenme Yöntemleri Ve Uygulamaları Hakkında Bir İnceleme. 2017 Dec 27;3:47–64.
119. Computation N. Long short-term memory. *Neural Comput* [Internet]. 2016; Available from: [https://interactiveaudiolab.github.io/teaching/casa/HorchreiterSchmidhuber\\_LSTM.pdf](https://interactiveaudiolab.github.io/teaching/casa/HorchreiterSchmidhuber_LSTM.pdf)
120. Michalski B, Plechawska-Wójcik M. Comparison of LeNet-5, AlexNet and GoogLeNet models in handwriting recognition. *jcsi*. 2022 Jun 30;23:145–51.
121. Swapna M, Sharma YK, Prasad BMG. CNN architectures: AlexNet, LeNet, VGG, GoogleNet, ResNet. *Int J Recent Technol Eng*. 2020 Mar;8(6):953-959. doi: 10.35940/ijrte.F9532.038620.
122. Cao J. Artificial neural network models for image recognition. *Highlight Sci Eng Technol* [Internet]. 2023 Jul 27; Available from: <https://drpress.org/ojs/index.php/HSET/article/view/10431>
123. Jiang P, Ergu D, Liu F, Cai Y, Ma B. A review of Yolo algorithm developments. *Procedia Comput Sci*. 2022;199:1066–73.
124. Hussain M. YOLOv5, YOLOv8 and YOLOv10: The go-to detectors for real-time vision [Internet]. arXiv [cs.CV]. 2024. Available from: <http://arxiv.org/abs/2407.02988>
125. Vijayakumar A, Vairavasundaram S. YOLO-based object detection models: a review and its applications. *Multimed Tools Appl*. 2024;83:83535–83574. doi: 10.1007/s11042-024-18872-y.
126. Terven J, Córdova-Esparza DM, Romero-González JA. A comprehensive review of YOLO architectures in computer vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *Mach Learn Knowl Extr*. 2023 Nov 20;5(4):1680–716.
127. Tyagi H, Saroj VK, Shahzad M, Agarwal A. Evolution of YOLO: exploring the advancements in YOLOv8 for real-time wildlife detection. *Grenze Int J Eng Technol*. 2024 Jun 15;10(2,Pt 4):4333–9.
128. Mulajkar R, Yede S. YOLO Version v1 to v8 Comprehensive Review. In: 2024 International Conference on Inventive Computation Technologies (ICICT). IEEE; 2024. p. 472–8.
129. Ding H, Wu J, Zhao W, Matinlinna JP, Burrow MF, Tsoi JKH. Artificial intelligence in dentistry—A review. *Front Dent Med* [Internet]. 2023 Feb 20;4. Available from: <https://www.frontiersin.org/articles/10.3389/fdmed.2023.1085251/full>

130. Huang W, Wu J, Mao Y, Zhu S, Huang GF, Petritis B, et al. Developing a periodontal disease antibody array for the prediction of severe periodontal disease using machine learning classifiers. *J Periodontol*. 2020 Feb;91(2):232–43.
131. Krois J, Ekert T, Meinhold L, Golla T, Kharbot B, Wittemeier A, et al. Deep learning for the radiographic detection of periodontal bone loss. *Sci Rep [Internet]*. 2019 Jun 11;9. Available from: <https://www.nature.com/articles/s41598-019-44839-3>
132. Lee JH, Kim DH, Jeong SN, Choi SH. Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. *J Periodontal Implant Sci*. 2018 Apr;48(2):114–23.
133. Yauney G, Rana A, Wong LC, Javia P, Muftu A, Shah P. Automated process incorporating machine learning segmentation and correlation of oral diseases with systemic health. *Annu Int Conf IEEE Eng Med Biol Soc*. 2019 Jul;2019:3387–93.
134. Proffit WR. The evolution of orthodontics to a data-based specialty. *Am J Orthod Dentofacial Orthop*. 2000 May;117(5):545–7.
135. Junaid N, Khan N, Ahmed N, Abbasi MS, Das G, Maqsood A, et al. Development, application, and performance of artificial intelligence in cephalometric landmark identification and diagnosis: A systematic review. *Healthcare (Basel)*. 2022 Dec 5;10(12):2454.
136. Thanathornwong B. Bayesian-based decision support system for assessing the needs for orthodontic treatment. *Healthc Inform Res*. 2018 Jan;24(1):22–8.
137. Xie X, Wang L, Wang A. Artificial neural network modeling for deciding if extractions are necessary prior to orthodontic treatment. *Angle Orthod*. 2010 Mar;80(2):262–6.
138. Park JH, Hwang HW, Moon JH, Yu Y, Kim H, Her SB, et al. Automated identification of cephalometric landmarks: *Angle Orthod*. 2019 Nov;89(6):903–9.
139. Yu HJ, Cho SR, Kim MJ, Kim WH, Kim JW, Choi J. Automated skeletal classification with lateral cephalometry based on artificial intelligence. *J Dent Res*. 2020 Mar;99(3):249–56.
140. Saini R, Alshadid A, Aldosari L. Investigation on the application of artificial intelligence in prosthodontics. *Appl Sci (Basel) [Internet]*. 2022 Dec 23; Available from: <https://www.mdpi.com/2076-3417/13/8/5004>
141. Agrawal P, Nikhade P. Artificial intelligence in dentistry: Past, present, and future. *Cureus*. 2022 Jul;14(7):e27405.
142. Minoos S, Ghasemi F. A narrative review: Dental radiology with deep learning. *International Research in Medical and Health Sciences*. 2024 Oct 25;7(5):23–36.
143. Alam MK, Alftaikhah SAA, Issrani R, Ronsivalle V, Lo Giudice A, Ciccì M, et al. Applications of artificial intelligence in the utilisation of imaging modalities in dentistry: A systematic review and meta-analysis of in-vitro studies. *Heliyon*. 2024 Feb 15;10(3):e24221.

144. Banerjee TN, Paul P, Debnath A, Banerjee S J J O. Unveiling the prospects and challenges of artificial intelligence in implant dentistry. A systematic review. *Journal of Osseointegration*. 2024;16(1):53–60.
145. Naeimi SM, Darvish S, Salman BN, Luchian I. Artificial intelligence in adult and pediatric dentistry: A narrative review. *Bioengineering (Basel)*. 2024 Apr 27;11(5):431.
146. Bunyarit SS, Nambiar P, Naidu MK, Ying RPY, Asif MK. Dental age estimation of Malay children and adolescents: Chaillet and Demirjian's data improved using artificial multilayer perceptron neural network. *Pediatr Dent J*. 2021 Aug;31(2):176–85.
147. Baydoğan MP, Baybars SC, Tuncer SA. Age detection by deep learning from dental panoramic radiographs. *Artificial Intelligence Theory and Applications*. 2022;2(2):51–8.
148. Kokomoto K, Kariya R, Muranaka A, Okawa R, Nakano K, Nozaki K. Automatic dental age calculation from panoramic radiographs using deep learning: a two-stage approach with object detection and image classification. *BMC Oral Health*. 2024 Jan 31;24(1):143.
149. Mine Y, Iwamoto Y, Okazaki S, Nakamura K, Takeda S, Peng TY, et al. Detecting the presence of supernumerary teeth during the early mixed dentition stage using deep learning algorithms: A pilot study. *Int J Paediatr Dent*. 2022 Sep;32(5):678–85.
150. Ragodos R, Wang T, Padilla C, Hecht JT, Poletta FA, Orioli IM, et al. Dental anomaly detection using intraoral photos via deep learning. *Sci Rep*. 2022 Jul 8;12(1):11577.
151. Kim H, Song JS, Shin TJ, Kim YJ, Kim JW, Jang KT, et al. Image segmentation of impacted mesiodens using deep learning. *J Clin Pediatr Dent*. 2024 May;48(3):52–8.
152. Zhou X, Yu G, Yin Q, Liu Y, Zhang Z, Sun J. Context aware convolutional neural network for children caries diagnosis on dental panoramic radiographs. *Comput Math Methods Med*. 2022 Sep 21;2022:6029245.
153. Gonzalez C, Badr Z, Cem Güngör H, Han S, Hamdan MD. Identifying primary proximal caries lesions in pediatric patients from bitewing radiographs using artificial intelligence. *Pediatr Dent*. 2024 Sep 15;46(5):332–6.
154. Ong SH, Kim H, Song JS, Shin TJ, Hyun HK, Jang KT, et al. Fully automated deep learning approach to dental development assessment in panoramic radiographs. *BMC Oral Health*. 2024 Apr 6;24(1):426.
155. Deng X, Liu Q, Deng Y, Mahadevan S. An improved method to construct basic probability assignment based on the confusion matrix for classification problem. *Inf Sci (Ny)*. 2016 May;340-341:250–61.
156. Aslan T, Yağımlı M. İş Sağlığı ve Güvenliğinde Derin Öğrenme Tabanlı Risk Tespit

- ve Analizi. *The Journal of International Scientific Researches*. 2023;8(2):223–36.
157. M H, M.n S. A review on evaluation metrics for data classification evaluations. *Int J Data Min Knowl Manag Process*. 2015 Mar 31;5(2):01–11.
  158. Chicco D, Jurman G. The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genomics*. 2020 Jan 2;21(1):6.
  159. Davis J, Goadrich M. The relationship between Precision-Recall and ROC curves. In: *Proceedings of the 23rd international conference on Machine learning - ICML '06* [Internet]. New York, New York, USA: ACM Press; 2006. Available from: <https://dl.acm.org/doi/abs/10.1145/1143844.1143874>
  160. Kokich VG, Kokich VO. Congenitally missing mandibular second premolars: clinical options. *Am J Orthod Dentofacial Orthop*. 2006 Oct;130(4):437–44.
  161. Tunç EŞ, Bayrak S, Koyutürk AE. Dental development in children with mild-to-moderate hypodontia. *Am J Orthod Dentofacial Orthop*. 2011 Mar;139(3):334–8.
  162. Corbella S, Srinivas S, Cabitza F. Applications of deep learning in dentistry. *Oral Surg Oral Med Oral Pathol Oral Radiol*. 2021 Aug;132(2):225–38.
  163. Eshgian N, Al-Talib T, Nelson S, Abubakr NH. Prevalence of hyperdontia, hypodontia, and concomitant hypo-hyperdontia. *J Dent Sci*. 2021 Mar;16(2):713–7.
  164. Kim YH. Investigation of hypodontia as clinically related dental anomaly: prevalence and characteristics. *ISRN Dent*. 2011;2011:246135.
  165. Rakhshan V. Meta-analysis and systematic review of factors biasing the observed prevalence of congenitally missing teeth in permanent dentition excluding third molars. *Prog Orthod*. 2013 Oct 1;14(1):33.
  166. Moorrees CF, Fanning EA, Hunt EE Jr. Age variation of formation stages for ten permanent teeth. *J Dent Res*. 1963 Nov;42(6):1490–502.
  167. Bicaçci AA, Doruk C, Babacan H. Late development of a mandibular second premolar. *Korean J Orthod*. 2012 Apr;42(2):94–8.
  168. Różyło-Kalinowska I. Panoramic radiography in dentistry. *Clin Dent Rev* [Internet]. 2021 Dec;5(1). Available from: <https://link.springer.com/article/10.1007/s41894-021-00111-4>
  169. Bekiroglu N, Mete S, Ozbay G, Yalcinkaya S, Kargul B. Evaluation of panoramic radiographs taken from 1,056 Turkish children. *Niger J Clin Pract*. 2015 Jan;18(1):8–12.
  170. Sridhar M, Mathew MG. PANORAMIC RADIOGRAPHS AND ITS IMPORTANCE IN PEDIATRIC DENTISTRY—A RETROSPECTIVE STUDY. *International Journal of Clinical Dentistry*. 2022;15(4):669–76.
  171. Hung K, Montalvao C, Tanaka R, Kawai T, Bornstein MM. The use and

- performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review. *Dentomaxillofac Radiol.* 2020 Jan;49(1):20190107.
172. David Naylor C. On the prospects for a (deep) learning health care system. *JAMA.* 2018 Sep 18;320:1099–100.
173. Thrall JH, Li X, Li Q, Cruz C, Do S, Dreyer K, et al. Artificial intelligence and machine learning in radiology: Opportunities, challenges, pitfalls, and criteria for success. *J Am Coll Radiol.* 2018 Mar;15(3 Pt B):504–8.
174. Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. *Med Image Anal.* 2017 Dec;42:60–88.
175. Heo MS, Kim JE, Hwang JJ, Han SS, Kim JS, Yi WJ, et al. Artificial intelligence in oral and maxillofacial radiology: what is currently possible? *Dentomaxillofac Radiol.* 2021 Mar 1;50(3):20200375.
176. Zhu H, Yu H, Zhang F, Cao Z, Wu F, Zhu F. Automatic segmentation and detection of ectopic eruption of first permanent molars on panoramic radiographs based on nnU-Net. *Int J Paediatr Dent.* 2022 Nov;32(6):785–92.
177. Duman S, Yılmaz EF, Eşer G, Çelik Ö, Bayrakdar IS, Bilgir E, et al. Detecting the presence of taurodont teeth on panoramic radiographs using a deep learning-based convolutional neural network algorithm. *Oral Radiol.* 2023 Jan;39(1):207–14.
178. Chen XW, Lin X. Big data deep learning: Challenges and perspectives. *IEEE Access.* 2014 May 16;2:514–25.
179. Kim J, Hwang JJ, Jeong T, Cho BH, Shin J. Deep learning-based identification of mesiodens using automatic maxillary anterior region estimation in panoramic radiography of children. *Dentomaxillofac Radiol.* 2022 Sep 1;51(7):20210528.
180. Ahn Y, Hwang JJ, Jung YH, Jeong T, Shin J. Automated Mesiodens Classification System Using Deep Learning on Panoramic Radiographs of Children. *Diagnostics (Basel)* [Internet]. 2021 Aug 15;11(8). Available from: <http://dx.doi.org/10.3390/diagnostics11081477>
181. Kuwada C, Ariji Y, Fukuda M, Kise Y, Fujita H, Katsumata A, et al. Deep learning systems for detecting and classifying the presence of impacted supernumerary teeth in the maxillary incisor region on panoramic radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol.* 2020 Oct;130(4):464–9.
182. Badea MS, Felea II, Florea LM, Vertan C. The use of deep learning in image segmentation, classification and detection [Internet]. *arXiv [cs.CV]*. 2016. Available from: <http://arxiv.org/abs/1605.09612>
183. Mun SB, Kim J, Kim YJ, Seo MS, Kim BC, Kim KG. Deep learning-based prediction of indication for cracked tooth extraction using panoramic radiography. *BMC Oral Health.* 2024 Aug 16;24(1):952.
184. Liu J, Liu Y, Li S, Ying S, Zheng L, Zhao Z. Artificial intelligence-aided detection

- of ectopic eruption of maxillary first molars based on panoramic radiographs. *J Dent.* 2022 Oct;125(104239):104239.
185. Okazaki S, Mine Y, Iwamoto Y, Urabe S, Mitsuhata C, Nomura R, et al. Analysis of the feasibility of using deep learning for multiclass classification of dental anomalies on panoramic radiographs. *Dent Mater J.* 2022 Nov 30;41(6):889–95.
  186. Askar H, Krois J, Rohrer C, Mertens S, Elhennawy K, Ottolenghi L, et al. Detecting white spot lesions on dental photography using deep learning: A pilot study. *J Dent.* 2021 Apr;107(103615):103615.
  187. Lee S, Kim D, Jeong HG. Detecting 17 fine-grained dental anomalies from panoramic dental radiography using artificial intelligence. *Sci Rep.* 2022 Mar 25;12(1):5172.
  188. Celik ME. Deep learning based detection tool for impacted mandibular third molar teeth. *Diagnostics (Basel).* 2022 Apr 9;12(4):942.
  189. Kang CH, Kim SY. Real-time object detection and segmentation technology: an analysis of the YOLO algorithm. *JMST Adv.* 2023 Sep;5(2-3):69–76.
  190. Chitraningrum N, Banowati L, Herdiana D, Mulyati B, Sakti I, Fudholi A, et al. Comparison study of corn leaf disease detection based on deep learning YOLO-v5 and YOLO-v8. *J Eng Technol Sci.* 2024 Feb 29;56(1):61–70.
  191. Kaya E, Gunec HG, Aydin KC, Urkmez ES, Duranay R, Ates HF. A deep learning approach to permanent tooth germ detection on pediatric panoramic radiographs. *Imaging Sci Dent.* 2022 Sep;52(3):275–81.
  192. Beser B, Reis T, Berber MN, Topaloglu E, Gungor E, Kılıc MC, et al. Correction: YOLO-V5 based deep learning approach for tooth detection and segmentation on pediatric panoramic radiographs in mixed dentition. *BMC Med Imaging.* 2024 Aug 28;24(1):224.
  193. Kurt A, Günaçar DN, Şilbır FY, Yeşil Z, Bayrakdar İŞ, Çelik Ö, et al. Evaluation of tooth development stages with deep learning-based artificial intelligence algorithm. *BMC Oral Health.* 2024 Sep 3;24(1):1034.
  194. Fitria M, Elma Y, Oktiana M, Saddami K, Novita R, Putri R, Rahayu H, Habibie H, Janura S. The deep learning model for decayed-missing-filled teeth detection: a comparison between YOLOv5 and YOLOv8. *Jordan J Comput Inf Technol.* 2024 Sep;10(3):335–49. doi: 10.5455/jjcit.71-1710834785.
  195. Yavsan ZS, Orhan H, Efe E, Yavsan E. Diagnosis of approximal caries in children with convolutional neural networks based detection algorithms on radiographs: A pilot study. *Acta Odontol Scand.* 2025 Jan 6;84:18–25.
  196. Karakuş R, Öziç MÜ, Tassoker M. AI-assisted detection of interproximal, occlusal, and secondary caries on bite-wing radiographs: A single-shot deep learning approach. *J Imaging Inform Med.* 2024 Dec;37(6):3146–59.
  197. Kaur A, Jyoti D, Sharma A, Yelam D, Goyal R, Nath A. Deep caries detection using

deep learning: from dataset acquisition to detection. Clin Oral Investig. 2024 Dec 2;28(12):677.

198. Munappy A, Bosch J, Olsson HH, Arpteg A, Brinne B. Data Management Challenges for Deep Learning. In: 2019 45th Euromicro Conference on Software Engineering and Advanced Applications (SEAA). IEEE; 2019. p. 140–7.

