

**T.C.
RECEP TAYYİP ERDOĞAN ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ**

**DERİN ÖĞRENME YÖNTEMİ KULLANILARAK GELİŞTİRİLEN
YAPAY ZEKA UYGULAMALARI ARACILIĞIYLA DİAGNOSTİK
DOĞRULUĞUN TESPİTİ**

Dt. Kader BİÇENGİL

**Çocuk Diş Hekimliği Ana Bilim Dalı
Uzmanlık Tezi**

**Tez Danışmanı
Doç. Dr. Ayça KURT**

RİZE-2025

**T.C.
RECEP TAYYİP ERDOĞAN ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ**

**DERİN ÖĞRENME YÖNTEMİ KULLANILARAK GELİŞTİRİLEN
YAPAY ZEKA UYGULAMALARI ARACILIĞIYLA DİAGNOSTİK
DOĞRULUĞUN TESPİTİ**

Dt. Kader BİÇENGİL

**Çocuk Diş Hekimliği Ana Bilim Dalı
Uzmanlık Tezi**

**Tez Danışmanı
Doç. Dr. Ayça KURT**

RİZE-2025

KABUL ve ONAY

Recep Tayyip Erdoğan Üniversitesi Diş Hekimliği Fakültesi Çocuk Diş Hekimliği Anabilim Dalında, Doç. Dr. Ayça KURT danışmanlığında, Kader BİÇENGİL tarafından hazırlanan Derin Öğrenme Yöntemi Kullanılarak Geliştirilen Yapay Zeka Uygulamaları Aracılığıyla Diagnostik Doğruluğun Tespiti adlı bu tez çalışması 11.04.2025 tarihinde yapılan savunma sınavı sonucu oy birliğiyle başarılı bulunmuş ve jürimiz tarafından **Uzmanlık Tezi** olarak kabul edilmiştir.

Jüri Üyeleri

Unvan, Adı Soyadı

Başkan

: Doç. Dr. Volkan ÇİFTÇİ

Üye

: Doç. Dr. Sema AYDINOĞLU

Üye

: Doç. Dr. Ayça KURT

ETİK BEYAN

Çocuk Diş Hekimliği Programından mezun olmak üzere teslim ettiğim “Derin Öğrenme Yöntemi Kullanılarak Geliştirilen Yapay Zeka Uygulamaları Aracılığıyla Diagnostik Doğruluğun Tespiti” adlı tezim, bilim ve araştırma etiği prensiplerine riayet edilerek tarafımdan yazılmıştır.

Recep Tayyip Erdoğan Üniversitesi Diş Hekimliği Fakültesi Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada:

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Kader BİÇENGİL

11.04.2025

TEŞEKKÜR

Uzmanlık eğitimi sürecimde bilgi, tecrübe ve yönlendirmeleriyle bana rehberlik eden, kıymetli hocam ve tez danışmanım Doç. Dr. Ayça KURT'a,

Uzmanlık eğitimi sürecimde bilgi ve tecrübelerinden faydalanma imkânı bulduğum değerli hocam Doç. Dr. Sema AYDINOĞLU'na

Bölümümüzün değerli hocaları Öğr. Gör. İrem OKUMUŞ ve Öğr. Gör. Sena SAKIN ULUBAY'a

Asistanlık eğitimim süresince birlikte çalışarak hem zorlukların üstesinden geldiğimiz hem de keyifli zamanlar geçirdiğimiz, desteğini her an yanımda hissettiğim eş kıdemli arkadaşım Dt. Sude GÜMÜŞ başta olmak üzere tüm çalışma arkadaşlarıma,

Uzmanlık eğitimim boyunca karakteri ve aklıyla ufkumu açan, düştüğüm zamanlarda bana kendimi hatırlatan, sonsuz sabrı ve sevgisiyle her daim yanımda olan sevgili eşim Mehmet Tevfik BİÇENGİL'e,

Hayatım boyunca attığım her adımda bana güvenen, sevgi ve inançlarıyla beni besleyen biricik annem Şenay ÖZBOZKURT'a, babaannem Rabia ÖZBOZKURT'a kardeşlerim Gamzenur ÖZBOZKURT ve Yaşarcan ÖZBOZKURT'a

Sonsuz sevgi ve teşekkürlerimi sunarım.

Bu çalışma Recep Tayyip Erdoğan Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından TSA 2024-1626 nolu proje ile desteklenmiştir.

Dt.Kader BİÇENGİL

ÖZET

Derin Öğrenme Yöntemi Kullanılarak Geliştirilen Yapay Zeka Uygulamaları Aracılığıyla Diagnostik Doğruluğun Tespiti

Amaç: Bu çalışmada amaç derin öğrenme algoritmasıyla eğitilmiş olan yapay zeka modelinin, panoramik radyografide, 5-12 yaş arası çocukların süt molar dişlerindeki arayüz, bukkal ve oklüzal çürük durumunu değerlendirerek bunu farklı tecrübelerle sahip üç diş hekiminin panoramik radyografilerden yaptıkları arayüz, bukkal ve oklüzal çürük teşhisiyle kıyaslamak ve panoramik radyografilerde arayüz, bukkal ve oklüzal çürük tanısındaki performanslarının karşılaştırılmasıdır.

Gereç ve Yöntem: Çalışmada, 2018-2024 yılları arasında Recep Tayyip Erdoğan Üniversitesi'nde tedavi gören 5-12 yaş arası çocuklara ait panoramik radyografiler kullanıldı. Süt molar dişlerdeki arayüz, bukkal ve oklüzal çürükler, üç farklı deneyime sahip diş hekimi tarafından CranioCatch etiketleme yazılımı (Eskişehir, Türkiye) ile etiketlendi. Bu etiketlerle YOLOv8x algoritması kullanılarak bir yapay zeka modeli geliştirildi. Ardından, araştırmacıların ve modelin tanı başarısını karşılaştırmak amacıyla 100 röntgen rastgele seçildi ve yeniden etiketlendi. Bu görüntüler için doğru etiketler, 10 yıllık tecrübeye sahip bir çocuk diş hekimi tarafından belirlendi.

Bulgular: Mevcut çalışmada, elde edilen yapay zeka modelinin genel çürük tespit başarısı orta düzeyde bulundu. Arayüz çürüklerinde başarı orta, oklüzal çürüklerde zayıf, bukkal çürüklerde ise düşük bulundu. Hem yapay zeka modeli hem de diş hekimleri en iyi performansı arayüz çürüklerinde, en düşük performansı ise bukkal çürüklerde gösterdi. Tecrübeli asistanın tespit başarısı, model ve diğer etiketleyicilere kıyasla daha yüksekti.

Sonuç: Çalışmamızda özellikle ara yüz çürükleri ve tecrübeli asistanın gösterdiği başarı dikkat çekmektedir. Elde edilen bulgular, yapay zeka modellerinin tanı sistemlerinin klinik verimliliği ve doğruluğu artırabileceğini göstermekte; bu alanda yapılacak ileri araştırmalar için güçlü bir temel oluşturmaktadır.

Anahtar kelimeler: Derin öğrenme, Diş çürüğü, Panoramik radyografi, Yapay zeka, YOLOv8x,

ABSTRACT

Determination of Diagnostic Accuracy through Artificial Intelligence Applications Developed Using Deep Learning Method

Aim: This study aims to evaluate the diagnostic performance of an artificial intelligence (AI) model trained with a deep learning algorithm in detecting interproximal, buccal, and occlusal carious lesions in the primary molars of children aged 5 to 12 on panoramic radiographs. The diagnostic results of the AI model were compared with those obtained by three dentists with different levels of clinical experience, based on their assessments of the same panoramic radiographs.

Materials and Methods: Panoramic radiographs of children aged 5–12, who received dental treatment at Recep Tayyip Erdoğan University between 2018 and 2024, were retrospectively analyzed. Interproximal, buccal, and occlusal carious lesions in the primary molars were annotated using CranioCatch annotation software (Eskişehir, Türkiye) by three dentists with varying levels of expertise. These labeled datasets were used to train an AI model based on the YOLOv8x algorithm. To compare the diagnostic accuracy of the AI model with the dentists, a set of 100 panoramic radiographs was randomly selected and re-annotated. The ground truth for these images was determined by a pediatric dentist with 10 years of clinical experience.

Results: The AI model demonstrated moderate overall performance in caries detection. Specifically, the detection accuracy was moderate for interproximal caries, weak for occlusal caries, and low for buccal caries. Both the AI model and the human examiners achieved the highest performance in detecting interproximal lesions, whereas the poorest results were observed in the identification of buccal caries. Among all evaluators, the experienced dental assistant achieved the highest diagnostic accuracy.

Conclusion: Our study highlights the notable success in detecting interproximal caries and the superior performance of the experienced assistant. The findings suggest that AI models can enhance the clinical accuracy and efficiency of diagnostic systems, providing a strong basis for future research in this field.

Key words: Artificial intelligence, Deep learning, Dental caries, Panoramic radiography, YOLOv8x

İÇİNDEKİLER

ETİK BEYAN	I
TEŞEKKÜR	II
ÖZET	III
ABSTRACT.....	IV
İÇİNDEKİLER	V
SİMGELER ve KISALTMALAR DİZİNİ.....	VIII
TABLolar DİZİNİ.....	X
ŞEKİLLER DİZİNİ.....	XI
1.GİRİŞ	1
2.GENEL BİLGİLER.....	4
2.1. Diş Çürüğü.....	4
2.2. Diş Çürüklerinin Sınıflandırılması.....	4
2.2.1. Etkilenen Diş Sert Dokusuna Göre Çürükler	4
2.2.2. Dişte Bulundukları Anatomik Yüzeye Göre Çürükler.....	5
2.2.3. İlerleme Hızına Göre Çürükler.....	5
2.2.4. Tedavi Geçmişine Göre Çürükler	6
2.2. Diş Çürüğü Tanı Yöntemleri	6
2.2.1. Geleneksel Yöntemler.....	7
2.2.2. Çürük Tespit Boyaları	10
2.2.3. Geliştirilmiş Görsel Teknikler.....	11

2.2.4. Floresans Teknikler	12
2.2.5. Kamera ve Floresans Tekniklerin Kombinasyonu	13
2.2.6. Optik Kohorens Tomografi (Optical Coherence Tomography-OCT)	16
2.2.7. Elektrik Akımı Kullanılan Yöntemler	17
2.2.8. Raman Spektroskopisi	18
2.2.9. Ultrasonografi/Ultrasonik Görüntüleme Sistemi	19
2.2.10. Terahertz (THz) Teknolojisi	19
2.2.11. Mikro BT/KIBT (Mikro Bilgisayarlı Tomografi (BT)/ Konik Işınlı Bilgisayarlı Tomografi (KIBT))	19
2.2.12. LED (Light Emitting Diode)	20
2.2.13. Yapay Zeka	20
2.3. Yapay Zeka	21
2.3.1. Yapay Zeka Algoritmaları	21
2.3.2. Derin Öğrenme	26
2.3.3. Diş Hekimliğinde Yapay Zeka Uygulamaları ve Geleceği	35
2.3.4. Yapay Zeka ile İlgili Limitasyonlar	37
3. GEREÇ ve YÖNTEM	40
3.1. Çalışmanın Amacı ve Dizaynı	40
3.2. Veri Setinin Hazırlanması	41
3.3. Radyografik Görüntülerin Ön İşlemesi	42
3.4. Panoramik Radyografiler Üzerinde Çürük Lezyonlarının Etiketlenmesi	42
3.5. YOLOv8x Modeli Eğitim Aşaması	43

3.6. Performans Değerlendirme Metrikleri.....	47
4. BULGULAR.....	51
5. TARTIŞMA.....	62
6. SONUÇ ve ÖNERİLER	75
KAYNAKLAR	77
EKLER	90
EK-1 Etik Kurul Onayı	90
EK-2 Dekanlık İzin Belgesi	91
EK-8 İntihal Raporu.....	92

SİMGELER ve KISALTMALAR DİZİNİ

ark.	: Arkadaşları
AAES	: Alternatif Akım Empedans Spektroskopisi
AI	: Artificial Intelligence
BT	: Bilgisayarlı Tomografi
IoU	: Birleşim üzerinden ortalama kesişme
CCD	: Charge Coupled Device
ÇKA	: Çok Katmanlı Algılayıcılar
DİA	: Derin İnanç Ağları
DIFOTI	: Digital Imaging Fiber Optic Transillumination
EAPD	: European Academy of Paediatric Dentistry
ECM	: Electrical Conductance Measurement
FACE	: Fluorescence Aided Caries Excavation
FOTI	: Fiber Optic Transillumination
mAP	: Genel ortalama kesinlik
GP	: Gerçek Pozitif
Hz	: Hertz
JPEG	: Joint Photographic Experts Group/ Görüntü formatı
KIBT	: Konik Işınlı Bilgisayarlı Tomografi
KSA	: Konvolüsyonel Sinir Ağı
kVp	: Kilovolt peak
LED	: Light Emitting Diode

LIFEDT	: Light Induced Fluorescence Evaluator for Diagnosis and Treatment
mA	: Miliamper
MHz	: Megahertz
μm	: Mikrometre
mm	: Milimetre
NILT	: Near Infrared Light Transillumination
nm	: Nanometre
OCT	: Optical Coherence Tomography
PS-OCT	: Polarization Sensitive Optical Coherence Tomography
QLF	: Quantitative Light Induced Fluorescence
RPN	: Region Proposal Network
Sn	: Saniye
cm	: Santimetre
SBM	: Sınırlı boltzman makineleri
SSD	: Single Shot MultiBox Detector
THz	: Terahertz
TSA	: Tekrarlayan sinir ağı
YN	: Yanlış Negatif
YOLO	: You look only once
YP	: Yanlış Pozitif
%	: Yüzde

TABLÖLAR DİZİNİ

Tablo 1. Biyolojik sinir sistemindeki yapıların yapay sinir sistemindeki karşılıkları ⁸⁵	24
--	----

Tablo 2. Yapay zeka modeli ve farklı deneyime sahip üç diş hekiminin her bir çürük sınıfına göre performans değerlendirme metrikleri	52
---	----



ŞEKİLLER DİZİNİ

Şekil 1. Yapay zeka ve alt kümeleri ⁸⁵	21
Şekil 2. Biyolojik sinir hücresi(a), Yapay sinir hücresi(b) ^{96, 97}	24
Şekil 3. Veri seti seçimi akış şeması	42
Şekil 4. YOLOv8x yapay zeka modeli eğitim aşaması.....	44
Şekil 5. YOLOv8x yapay zeka modeli arayüz, oklüzal, bukkal çürük tahmini ..	45
Şekil 6. YOLOv8x yapay zeka modeli validasyon aşamasından örnek görüntü	46
Şekil 7. Çürüklerin değerlendirilmesinde YOLOv8x yapay zeka modelinin test verilerinin ham karmaşıklık matris grafiği	53
Şekil 8. Çürüklerin değerlendirilmesinde YOLOv8x yapay zeka modeli test verilerinin normalize edilmiş (oransal) karmaşıklık matris grafiği	54
Şekil 9. YOLOv8x BoxF1-curve grafiği.....	55
Şekil 10. YOLOv8x BoxP-curve grafiği.....	56
Şekil 11. YOLOv8x BoxPR-curve grafiği	57
Şekil 12. YOLOv8x BoxR-curve grafiği	58
Şekil 13. YOLOv8x MaskF1-curve grafiği.....	59
Şekil 14. YOLOv8x MaskP-curve grafiği.....	59
Şekil 15. YOLOv8x MaskPR- curve grafiği.....	60
Şekil 16. YOLOv8x MaskR-curve grafiği	60
Şekil 17. Epoch ilerleyişine göre YOLOv8x çürük tespiti performans grafikleri.....	61

1.GİRİŞ

Diş çürüğü günümüzde ve birçok popülasyonda yaygın olarak görülen, biyofilmdeki metabolik olayların neden olduğu, kronik, önlenebilir, multifaktöriyel, enfeksiyöz bir hastalıktır.¹ Diş çürüklerinin erken teşhisi; ileri seviyede ağız ve diş sağlığı sorunlarının önüne geçmek ve buna bağlı olarak da tedavi maliyetlerini azaltmanın yanı sıra hastaların yaşam kalitesini artırmak açısından büyük önem taşımaktadır.² Çürük teşhisinde hastadan detaylı bir anamnez alınması, dişin klinik değerlendirilmesi ve teşhise yardımcı araç ve yöntemlerin kullanılması gerekmektedir. Bu amaçla diş hekimliğinde birçok teşhis yöntemi kullanılmaktadır.¹ Klinik uygulamalarda rutin olarak görsel, dokunsal ve radyografik muayene yöntemleri kullanılmaktadır.³ İlerlemiş çürükler ve oklüzal veya bukkal çürükler görsel inceleme ve sondalama yapılarak kolaylıkla tespit edilebilmektedir. Arayüz çürük teşhisinde ise radyografik görüntülerden faydalanılmaktadır. Özellikle panoramik, periapikal ve ısırtma grafipleri klinik uygulamalarda rutin olarak kullanılan üç yaygın radyografi türüdür.⁴

Çoğu diş hekimi, düşük radyasyon dozu, geniş anatomik alanları göstermesi, çok kısa sürede çekim yapılmasına olanak sağlaması, hastanın işleme olan toleransının yüksek olması gibi avantajları nedeniyle panoramik radyografileri kullanmayı tercih etmektedir.⁵ Panoramik radyografilerin; intraoral radyografilere kıyasla daha az ayrıntı vermesi, özellikle premolar bölgede görülen süperpozisyonlar, magnifikasyonlar ve geometrik bozulmalar gibi çeşitli dezavantajları bulunmaktadır.⁶

Çürük lezyonlarının tümü görsel ve dokunsal olarak tanımlanamamaktadır. Tıbbi görüntülemeyle bile diş hekimleri erken çürük lezyonlarını gözden kaçırabilmektedir. Bu nedenle tanı ve tedavi başarısı diş hekimin bireysel performansına bağlı olmaktadır.⁷ Ayrıca röntgen görüntülerinin incelenmesi diş hekimlerinin iş yükünü artırmaktadır. Klinisyenlere objektif çürük teşhisi konusunda yardımcı olmak için mükemmel

tutarlılığa ve doğruluğa sahip bir otomatik tespit yaklaşımı gerekmektedir.⁸ Bu nedenle teknolojik gelişmelerle birlikte, çürüğün saptanması ve derecesinin belirlenmesi amacıyla yeni teşhis yöntemleri geliştirilmektedir.³

Yapay zeka, 1950'lerde ortaya çıkan ve yazılım programları aracılığıyla algoritmalar kullanarak makinelerle bazı işlemler için insan zekasını, davranışlarını insanların bilişsel işlevlerini taklit etme, öğrenme ve problem çözme yeteneği kazandıran bir bilgisayar bilimidir.⁹ Makine öğrenimi, veri toplamadan, öğrenmeyi otomatik olarak gerçekleştiren, kendi kendini düzelten, çevresindeki ortamdan gelişen, insan zekasını taklit eden bir yapay zeka alt dalıdır ve sınırsız veriyi eşzamanlı, hızlı şekilde işleyerek kalıpları tespit edip sınıflandırarak sorunları çözme yeteneği sağlamaktadır.¹⁰ Derin öğrenme ise, 2010'lu yıllarda ortaya çıkan ve büyük veri seti ile çok katmanlı hesaplamalar yaparak parametreleri kendisi keşfeden, makine öğreniminin bir alt dalı olarak tanımlanmaktadır. Bu sistem, özellikle büyük ve karmaşık görüntülerin işlenmesinde kullanılır ve yapay sinir ağlarından çok daha ileri düzeyde bir teknik gelişmeyi temsil etmektedir.¹¹ Tıbbi görüntüleme alanındaki en popüler ve en yaygın kullanılan derin öğrenme modeli konvolüsyonel sinir ağlarıdır (KSA). Bu durum, görüntü verilerini temel alarak üstün algılama, sınıflandırma ve niceliksel değerlendirme performansı sunan verimli kendi kendine öğrenme algoritmaları ve yüksek hesaplama gücünden kaynaklanmaktadır.¹²

Derin öğrenme yöntemi son zamanlarda diş hekimliğinde, özellikle de diş çürüğünün tespitinde popüler bir konu haline gelmektedir.¹³ Derin öğrenme modelleri diş çürüğü tespiti konusunda doğruluğu artırabilmekte ve diş hekimlerinin bunları tespit etmesinde onlara destek olabilmektedir.¹⁴

Diş çürüklerinin erken teşhisi, hem çürükleri önlemede hem de tedavi süreçlerinde hayati bir öneme sahip olmaktadır. Ancak, geleneksel yöntemler çoğu zaman doğruluk

ve verimlilik açısından yetersiz kalmaktadır. Panoramik radyografiler, tanı koymada etkili araçlar olarak kabul edilse de, bu görüntüler üzerinden diş çürüklerini tespit etmek bireysel yorum farklılıklarından ve panoramik radyografilerin görüntü sorunlarından etkilenebilmektedir.¹⁵ Yapay zeka modelleri, özellikle KSA tabanlı modeller, doğru, objektif diş çürüğü teşhisi için muazzam bir potansiyele sahiptir.¹⁶ Yapay zeka teknolojilerinin diş çürüğü teşhis süreçlerine entegre edilmesi; teşhislerin doğruluğunu ve etkinliğini artırma potansiyeli taşıyan umut verici bir yenilik sunmaktadır.¹⁵

Panoramik radyografiler diş hekimliğinde tedavi planlaması ve takibinde kullanılan önemli bir görüntüleme yöntemidir. Bu nedenle, bu çalışmada, süt molar dişlerde ara yüz, bukkal ve oklüzal çürüklerin tespiti için derin bir KSA eğitimi ve KSA'nın performansını asistan insan gözlemciler ile karşılaştırmak faydalı görülmektedir.¹⁷⁻

19

Çalışma için “H0: Derin öğrenme yöntemi kullanılarak geliştirilen yapay zeka modelinin, dental çürüklerin diagnostik doğruluğu üzerinde etkisi yoktur.” ve “H1: Derin öğrenme yöntemi kullanılarak geliştirilen yapay zeka modelinin, dental çürüklerin diagnostik doğruluğu üzerinde etkisi bulunmaktadır.” hipotezleri kuruldu.

Bu çalışmada amaç derin öğrenme algoritmasıyla eğitilmiş olan yapay zeka modelinin, diş hekimliği pratiğinde rutin olarak kullanılan bir görüntüleme yöntemi olan panoramik radyografide, 5-12 yaş arası çocukların süt molar dişlerindeki arayüz, bukkal ve oklüzal çürük durumunu değerlendirerek bunu uzmanlığın farklı senelerinde olan 2 çocuk diş hekimliği araştırma görevlisinin (tecrübeli asistan (K.B.) ve yeni asistan (N.İ.Ş.)), ve stajyer hekimin (S.G.) panoramik radyografilerden yaptıkları arayüz, bukkal ve oklüzal çürük teşhisiyle kıyaslamak ve panoramik radyografilerde arayüz, bukkal ve oklüzal çürük tanısındaki performanslarının karşılaştırılmasıdır.

2.GENEL BİLGİLER

2.1. Diş Çürüğü

Günümüzde en sık görülen kronik hastalıklardan biri olan diş çürüğü, bakterilerin dental plak içerisinde kolonizasyonu, bu ortamda çoğalması ve zamanla diyet ve konak faktörleri ile etkileşime girmesiyle dişin bakteri metabolizması sonucu açığa çıkan asit ürünlerle demineralizasyonuyla oluşan multifaktöriyel, enfeksiyöz bir hastalıktır.²⁰

2.2. Diş Çürüklerinin Sınıflandırılması

2.2.1. Etkilenen Diş Sert Dokusuna Göre Çürükler

2.2.1.1. Mine Çürüğü

Ağız içi ortamın dengesi demineralizasyon yönünde değiştiğinde plak altındaki mine dokusu çözünmeye başlamaktadır. Başlangıç mine lezyonları nemli ağız ortamında ilk görüşte farkedilememekte fakat diş yüzeyi kurutulduğunda translusensliğini kaybeden mine dokusu opak beyaz, tebeşirimsi bir görünüm almaktadır. Bu görünüm “Beyaz nokta lezyonu (White spot lesion)” olarak tanımlanmaktadır. Bu aşamadaki çürük lezyonlarının remineralizasyonları mümkün olmaktadır bu sebeble bu tip lezyonların erken teşhisi önem arz etmektedir. Çürüğün daha ileri safhalarında lezyon klinik olarak kendini belli etmekte, sond takılmakta, renklenme göstermektedir.²¹

2.2.1.2. Dentin Çürüğü

Mine çürüğü ilerleyip mine-dentin sınırına ulaştığında hızla yayılmaktadır. Mine dokusunun bütünlüğü bozulmaktadır ve dentin dokusu ağız ortamıyla ilişkiye geçmektedir ve çürük dentin dokusunda ilerlemektedir. Dentin dokusunun inorganik içeriği mineye kıyasla daha az olduğu için çürük dentin dokusunda mineye göre daha hızlı yayılmaktadır. İlerlemiş dentin çürüklerinde altındaki destek dokuyu kaybeden mine kırılmakta ve gözle görülen bir çürük kavitesi meydana gelmektedir.²²

2.2.2. Dişte Bulundukları Anatomik Yüzeye Göre Çürükler

2.2.2.1. Pit ve Fissür Çürüğü

Pit ve fissürler genellikle dişlerin çiğneme yüzeylerinde yer almakla birlikte, bazı dişlerde palatinal ve lingual bölgelerde de görülebilmektedir. Bu bölgelerde gelişen çürükler, genellikle hızlı ilerleme eğiliminde olup erken teşhis edilmediğinde derin çürük lezyonlarına yol açabilmektedir.²¹

2.2.2.2. Arayüz Çürüğü

Dişlerin mezial veya distal yüzeylerinde temasta oldukları diş ile arasında görülen çürük lezyonlarıdır. Süt azılarının aproksimal kontakt bölgeleri düz ve geniş olduğundan başlangıç seviyesindeki arayüz lezyonların klinik olarak tespiti her zaman mümkün olmayabilir.

2.2.2.3. Servikal Çürük

Mine-sement seviyesinin üstünde, kole bölgesinde görülen çürüklerdir.

2.2.2.4. Düz Yüzey Çürüğü

Arayüz, bukkal ve lingual/palatinal yüzeyler, genel olarak düz yüzeyler olarak tanımlanmaktadır.²¹

2.2.3. İlerleme Hızına Göre Çürükler

2.2.3.1. Akut Çürük

Akut çürük, hızlı ilerleyen ve kısa sürede dentin-pulpa kompleksine ulaşabilen bir çürük tipidir. Bu tür lezyonlar genellikle açık renkli, yumuşak ve nemli bir dokuya sahiptir.²¹

2.2.3.2. Kronik Çürük

Kronik çürükler, genellikle yavaş ilerleyen lezyonlardır. Bu tür lezyonlar, koyu renkli bir görünüm sergilemekle birlikte, diş dokusu tamamen yumuşamamış olup serttir ve kuru görünümüne sahiptir.²¹

2.2.4. Tedavi Geçmişine Göre Çürükler

2.2.4.1. Sekonder Çürük

Sekonder çürük, daha önce restorasyon uygulanmış diş yüzeylerinde, özellikle restorasyonun kenarlarında veya altında gelişen çürüklerdir. Genellikle restorasyonların çevresinde gözlemlendiği için teşhis edilmesi zor olabilmektedir.²¹

2.2.4.2. Rezidüel Çürük

Rezidüel çürük, diş tedavisi sırasında tamamen temizlenmemiş, restorasyonun altında bırakılmış çürük dokusudur. Bırakılan çürük dokusu zamanla ilerleyerek restorasyonun başarısını olumsuz etkileyebilmekte ve yeni bir çürük sürecini başlatabilmektedir.²¹

2.2. Diş Çürüğü Tanı Yöntemleri

Diş hekimliğinde, çürüğün doğru ve kesin bir şekilde teşhis edilmesi, etkili bir tedavi sürecinin ilk ve en önemli adımını oluşturmaktadır.²³ Çürüklerin erken dönemde doğru teşhis edilmesi, başlangıç evresinde müdahale edilip biyofilmin temizlenmesini sağlamaktadır. Bu durumda dentin veya mine dokusunda hasar oluşmuş olsa bile herhangi bir aşamada durdurulabilmekte, dişe karmaşık tedaviler uygulanması yerine, koruyucu, noninvaziv veya minimal invaziv yöntemlerle tedavi imkanı sunmaktadır.²⁴ Pulpa inflamasyonu gibi ilerlemiş komplikasyonlar, çocukların yoğun ağrı yaşamasına, beslenme zorluklarına ve hatta büyüme-gelişme süreçlerinin etkilenmesine neden olabilmektedir. Bu tür ciddi durumlar, genellikle daha invaziv ve karmaşık tedavi yöntemlerini gerektirmekte, bu da çocuklarda tedaviye karşı dental anksiyete geliştirme

riskini artırabilmektedir. Bu nedenle, erken teşhis ve önleyici tedavilerle çürüğün ilerlemesi engellenmesi ve çocuklara uygun, rahatlatıcı, pozitif intiba bırakan, noninvaziv tedavi yaklaşımları uygulanabilmesi çürük teşhis yöntemlerinin ve erken teşhisin önemini ortaya koymaktadır.²⁵

Günümüz teknolojisiyle çürüklerin erken dönemde tespitini kolaylaştırarak çeşitli diş çürüğü tanı yöntemleri geliştirilmiştir.

2.2.1. Geleneksel Yöntemler

2.2.1.1. Görsel ve Dokunsal Muayene

Görsel muayene klinikte yaygın olarak kullanılan bir yöntem olup, bir ışık kaynağı altında (genellikle dental ünitlerin reflektör ışığı) dişlerin inspeksiyonla incelenmesidir.²⁶ Genellikle klinik muayenenin ilk aşaması olarak dokunsal muayene ile birlikte uygulanmaktadır.²⁷

Bu muayene yöntemi lezyon ara yüzde gelişmişse ya da kavitasyon oluşturmamışsa teşhiste yetersiz kalabilmektedir, radyografik yöntemlerden destek alınması gerekmektedir.²⁸

2.2.1.2. Radyografik Muayene

Diş dokusundaki demineralizasyon sonucu meydana gelen çürük lezyonu sağlıklı diş dokusuna göre mineral yoğunluğunun azalmasından ötürü X ışınlarını daha çok geçirip daha az tutmakta ve radyografide radyolusent görünmektedir.²⁹ Bu radyolusent görüntünün radyografilerde farkedilebilir hale gelmesi için diş dokusunda yaklaşık %30-40 oranında bir demineralizasyonun meydana gelmesi gerekmektedir.³⁰ Radyografik muayene klinik muayeneyi desteklemek ve görsel-dokunsal yöntemlerle teşhis edemediğimiz arayüz ve oklüzal yüzeydeki gizli fissür çürüklerinin tespitini sağlamak amacıyla kullanılan önemli bir tanı yöntemi olmaktadır. Radyografik muayene; çürük lezyonlarının tespiti yanısıra diş ve çevre dokuları da incelememizi sağlamaktadır.²⁸

Radyografik muayene, intraoral ve ekstraoral yöntemler olmak üzere iki şekilde yapılmaktadır. İntraoral yöntemler; periapikal, bitewing ve oklüzal yöntemlerdir.³¹ Bu yöntemler içerisinde daha çok periapikal ve bitewing radyografiler çürük tespitinde kullanılmaktadır.

Bitewing radyografiler özellikle arayüz çürüklerinin ve sekonder çürüklerin tespitinde kullanılmakta fakat oklüzal çürüklerin tespiti için de kullanılmaktadır. Çocuk diş hekimliğinde bitewing radyografinin önemli avantajlarından biri ısırma kanadı (bite tab) yardımıyla filmin hastanın ağzında stabil bir şekilde konumlandırılabilmesidir ve süt dişi enfeksiyonlarının daha çok görüldüğü furkal bölgeyi ayrıntılı gösterebilmesidir. Bu özellik, süt dişlerinde doğru teşhisi kolaylaştırmakta hem de uygulama sırasında kullanım pratikliği sağlamaktadır.³²

Ekstraoral yöntemler ise; panoramik radyografi ve konik ışınlı bilgisayarlı tomografiyi (KIBT) içermektedir.³¹

Panoramik Radyografi

Panoramik radyografi maksiller ve mandibular arklarla birlikte çevre yüz yapılarının kondilden kondile tek bir filmde kapsamlı değerlendirilmesine olanak sağlayan, rutin radyolojik muayenede en sık kullanılan ekstraoral radyografi tekniğidir. Panoramik radyografi dental ark ve çevre yapıların tek bir filmde görülüp değerlendirilmesine olanak tanıyarak teşhis için ekstra bir intraoral filmin gerekliliği için öngörü oluşturmaktadır.³³

Panoramik radyografi, bir X ışını kaynağının ve görüntü alıcısının senkronize şekilde resiprokasyon hareketiyle hastanın başı etrafında dönmesiyle elde edilmektedir. X ışını kaynağı ve görüntü reseptörü arasına yerleştirilen görüntüsü istenen tabakaya imaj tabakası (fokal through) adı verilmektedir. Görüntüsü istenen kısım, bu at nalı şeklindeki bölge içerisine yerleştirilmektedir. Bu bölgenin dışında kalan alanlar magnifikasyon ve

distorsiyona uğramakta ve bulanıklaşmaktadır. Bu şekilde sadece görüntüsü istenen alan net olarak incelenmektedir. Dental ark ve incelenecek olan çevre yapının imaj tabakası (fokal through) içerisinde olacak şekilde pozisyonlandırılması gerekmektedir.²⁹

Çekim sırasında görüntüsü istenen objenin boyutu ve doğru pozisyonlandırılması projeksiyon geometrisini yani görüntünün netlik ve çözünürlüğünü, magnifikasyonunu ve distorsiyonunu etkileyip doğru teşhisi engelleyebilmektedir.²⁹

Panoramik radyografilerde görüntü netliği ve çözünürlüğü, obje ile fokal spot arasındaki ilişkiye bağlı olup, hastanın doğru pozisyonlandırılması bu parametreleri doğrudan etkileyen kritik bir faktör olmaktadır.³⁴

Panoramik radyografi cihazlarının tek, iki, üç ve devamlı rotasyon merkezli olmak üzere dört tipi mevcuttur. Minimum magnifikasyon ve distorsiyon için günümüzde devamlı rotasyon yapan tipi kullanılmaktadır.³⁵

Günümüzde konvansiyonel panoramik radyografiler yerini dijital panoramik radyografilere bırakmış olup, kimyasal banyo sürecine bağlı operatör hatalarını ortadan kaldırarak dijital radyolojinin getirdiği görüntü iyileştirme seçenekleri sayesinde daha güvenilir ve tutarlı görüntüler elde edilmesini sağlamaktadır.²⁹

Panoramik radyografide dijital dedektörlerin kontrast çözünürlüğü ve uzaysal çözünürlüğü, görüntü kalitesini belirleyen temel faktörlerdir. Uzaysal çözünürlük (piksel boyutu), birbirine yakın küçük yapıların ayırt edilebilme kapasitesini ifade ederken, kontrast çözünürlüğü (gri seviyelerinin sayısı) ise densite farklarının algılanabilmesidir. Bu iki parametre dijital radyografinin çözünürlüğü ile ilişkili faktörlerdir. Ancak, periapikal ve bitewing radyografilere kıyasla panoramik radyografiler daha düşük uzaysal çözünürlüğe sahiptir. Bu durum, özellikle küçük detayların değerlendirilmesi açısından bazı tanısal sınırlamalara neden olabilmekte ve teşhis için introral radyografi ihtiyacı doğurabilmektedir.^{36, 37}

2.2.2. Çürük Tespit Boyaları

İlk olarak %0,5' lik bazik fuksin kullanılarak tanıtılan bu boyalar, basik fuksinin kanserojen etkileri sebebiyle günümüzde yerini genellikle boya ve propilen glikol içeriğine bırakmıştır.³⁸

Propilen glikol, dentin dokusundaki tabakalar arasında seçici bir boyama işlevi görmekte ve bu mekanizma, temel olarak kollajen fibrilleriyle olan etkileşimlere dayanmaktadır. Enfekte dentinde kollajen fibrilleri arasındaki çapraz bağlar parçalanmışken, etkilenmiş dentinde bu fibrillerin yapısal bütünlüğü korumaktadır. Bu farklılık nedeniyle, propilen glikol, yalnızca enfekte dentin tabakasındaki çapraz bağları bozulan kollajen fibrillere nüfuz ederek bu bölgenin boyanmasını sağlamaktadır. Bu seçici boyama mekanizması, enfekte dokunun diğer tabakalardan ayrıştırılmasına olanak tanımaktadır.^{38, 39}

Genellikle bilinen çürük boyası, propilen glikolde %1 asit kırmızısıdır. Daha yüksek molekül ağırlığına sahip çözücü içeren bu boyanın dentin tübüllerine gereksiz difüzyonu önlediği gösterilmiş ve dentin dokusunun gereksiz uzaklaştırılmasını önlediği bildirilmiştir.⁴⁰

Çalışmalar boyaların çürük kavitesindeki bakterileri değil daha az mineralize olan organik matriksle ilişkili kollojeni boyadığını göstermektedir. Bu durumun daha az mineralize olan mine-dentin sınırında boyamaya sebep olup sağlam diş dokusunun uzaklaştırılmasına sebep olabileceği bildirilmiştir.⁴¹

2.2.3. Geliştirilmiş Görsel Teknikler

2.2.3.1. Fiber Optik ve Dijital Fiber Optik Transilüminasyon Yöntemleri (Fiber Optic Transillumination-FOTI/ Digital Imaging Fiber Optic Transillumination-DIFOTI)

1970 yılında Marcus ve Friedman tarafından geliştirilmiş transilüminasyon mantığına dayalı bir yöntemdir.⁴² Diş plak ve diş taşından arındırılıp izole sağlandıktan sonra reflektör ışığı kapatılmakta, dişe soğuk ışık kaynağından gelen yüksek yoğunluklu beyaz ışık fiber bir uçla dilin bukkal veya lingual yüzünden uygulanmaktadır.⁴³ Sağlam ve çürük diş dokusunun ışık geçirgenlikleri farklıdır. Sağlıklı ve çürük diş dokusu arasında kontrast farkı oluşmaktadır. Çürük bölgeler gölgeli, karanlık alanlar şeklinde görülür.⁴⁴

Ekonomik ve kullanımı kolay bir yöntemdir. Daha çok arayüz çürüklerinin teşhisinde kullanılır fakat duyarlılığı bitewing radyografiler kadar yüksek değildir. Subjektif bir yöntemdir, teşhis ve tedavi için değerlendirmeyi yine klinisyen yapmaktadır. Görüntüler arşivlenemez. Bu dezavantajından dolayı DIFOTI sistemi geliştirilmiştir.⁴⁵ Ucunda küçük bir kamerası olan bu sistemde insan faktörü kaldırılıp veriler dijital olarak charge coupled device (CCD) sensörü ile bilgisayar ortamına aktarılıp kaydedilmektedir.⁴⁶ Fakat bu sistemin de görüntüleri analiz etme yeteneği olmadığından değerlendirme gene klinisyen tarafından yapılmaktadır.^{47, 48} Görüntüleri kaydetme özelliği sayesinde DIFOTI ile çürük lezyonlarının ilerlemeleri değerlendirilip remineralizasyon tedavilerinin sonuçları izlenebilmektedir.⁴⁶

European Academy of Paediatric Dentistry (EAPD) 'nin çocuklarda ve gençlerde çürük lezyonlarının yönetimine yönelik yayınladığı rehberde göre nonkoopere çocuk hastalarda ve/veya ebeveynlerin radyografi alınmasını kabul etmediği durumlarda bu yöntemlerin kullanılabileceği belirtilmiştir.⁴⁹

2.2.3.2.Yakın Kızılötesi Işık Transilmünasyon Yöntemi (Near-infrared Light Transillumination-NILT)

Fried ve ark. tarafından 1995 yılında FOTI-DIFOTI yöntemlerinin geliştirilmiş hali olarak ortaya koyulan transilmünasyon prensibine dayanan bir çürük teşhis yöntemidir.⁵⁰ NILT yönteminde 700-1500 nm dalga boyuna sahip kızıl ötesine yakın görünmeyen ışık kullanılmaktadır. Uzun dalga boyuna sahip ışık daha az saçılmaya uğramakta ve daha derin dokulara nüfuz edebilmektedir. Mine translusent yapıda olduğundan kızılötesi ışık direk iletilirken demineralize alanlardan geçerken saçılma uğramakta ve absorbe edilmektedir. Sağlıklı ve çürük doku arasında belirgin kontrast farkı oluşmaktadır. Çürük diş dokusu gri gölgeler şeklinde görülmektedir.^{51, 52}

2.2.4. Floresans Teknikler

2.2.4.1. Laser Floresans Yöntemi (Diagnodent/Diagnopen)

Lazer Floresans yöntemi sağlam diş dokusu ve çürük doku arasındaki floresans farklılığına dayanan, noninvaiz, objektif ölçüm yapmamızı sağlayan bir çürük teşhis yöntemidir ve güncel çürük teşhis yöntemleri arasında en çok kullanılanıdır.^{53, 54} Bu yöntemle çalışan cihazlardan biri DIAGNOdent (KaVo, Biberach, Almanya)' dir. Bu cihazla diş yüzeyine fiber optik bir uçla 655 nm dalga boyunda kırmızı lazer ışığı diş yüzeyine gönderilmektedir. Gönderilen ışık çürük diş dokusunda sağlam diş dokusuna göre ışığı daha çok yansıtmakta yani daha yüksek yoğunlukta bir floresans oluşmaktadır. Cihazın kalibrasyonu sağlam diş dokusuna göre yapılmaktadır. Sağlam diş dokusunun floresansı çok azdır veya sıfırdır. Oluşan floresans, optik bir kablo aracılığıyla bir fotodiyoda iletilmekte ve cihazın dijital ekranında 0-99 arasında bir sayısal değer olarak görüntülenmektedir.^{55, 56} Bu değer, saptanan floresans yoğunluğuna bağlı olarak çürüğün derecesini kantitatif şekilde ifade etmekte, değer ne kadar yüksekse çürük lezyon o kadar derin olmaktadır. Ayrıca cihazın çürük lezyondaki gösterdiği floresans değerinin

dokunun mineral içeriğinden ziyade enfekte dentindeki özellikle protoporfirin denilen bakteriyel metabolitlerle ilişkili olduğu bildirilmiştir. Enfekte dentin varlığında floresans artışı bu metabolitlerden dolayı daha güçlü olmaktadır.³

Arayüz çürük lezyonlarının teşhisi amacıyla cihaz modifiye edilerek aynı çalışma prensibine sahip Diagnodent Pen (KaVo Dental, Biberach Riss, Almanya) cihazı geliştirilmiştir.⁵⁷

2.2.4.2. Floresans Yardımıyla Çürük Temizleme (Fluorescence Aided Caries Excavation-FACE)

Floresans yardımıyla çürük temizleme cihazı çürük temizlenirken dişe 450 nm dalga boyunda mor ışık uygulanarak diş sert dokularının otoflororesan özellik kazandırıp, çürük tespit boyalarına gerek kalmadan enfekte dentini kolayca tespit edilmesi için geliştirilmiş bir cihazdır. Bu yöntem uygulandığında sağlıklı diş dokuları yeşil, çürük diş dokuları ise turuncu-kırmızı görünmektedir.^{58, 59} Bu teknikte, floresansın daha net gözlemlenebilmesi için mor ışığı bloke eden, ancak yeşil veya turuncu-kırmızı floresans yansımalarını geçiren yüksek geçirgenliğe sahip özel bir filtre kullanılmaktadır. Bu cihaz yardımıyla kavite preparasyonu sırasında enfekte dentinin selektif uzaklaştırılması sağlanıp, sağlam dentin korunduğu için diş dokusunun gereksiz uzaklaştırılması önlenmektedir.^{60, 61}

2.2.5. Kamera ve Floresans Tekniklerin Kombinasyonu

2.2.5.1. Kantitatif Işık Etkili Floresan (Quantitative Light Induced Fluorescence-QLF)

Dişe yüksek yoğunluklu 405 nm dalga boyunda mavi ışık verilerek dişte otofloresans oluşturulmaktadır. Mineral içeriği azalmış olan çürük dokuda ışık saçılmakta ve sağlam diş dokusuna göre floresansında bir azalma gözlenmektedir ve bu azalma CCD kameralarla görselleştirilip bilgisayara kaydedilmektedir. Floresansdaki

%5' in üzerinde görülen bir azalma çürük lezyonunu göstermektedir. Sağlıklı diş dokusu yeşil görünürken, çürük lezyonu demineralizasyondan dolayı floresans özelliği azaldığı için karanlık bölgeler olarak görünmektedir. Dişteki mineral kaybı nicel olarak saptanmakta, çürük lezyon alanı, derinliği ve hacmi ölçülebilmektedir.^{62, 63}

2.2.5.2. Canary

Canary, fototermal radyometri ve lüminesans prensiplerini temel alan enerji dönüşüm teknolojisiyle çalışan, lazer bazlı, ısı ve ışığı birlikte kullanan bir çürük teşhis cihazıdır. Cihazın çalışma prensibi, diş dokusu tarafından absorbe edilen 2 Hz frekanslı atımlı lazer ışığının lüminesansa dönüşümünü ve bu süreçte oluşan ısı salınımının (fototermal radyoterapi) ölçülmesini esas almaktadır. Uygulanan lazer ışığı diş tarafından soğurulduktan sonra düşük düzeyde ısı oluşumu meydana gelmekte fakat bu ısı dişe zarar vermeyecek düzey olmaktadır. Meydana gelen ısı ve ışığın eşzamanlı ölçümüyle diş yüzeyinden 50 µm - 5 mm derinliğine kadar olan çürük lezyonlarının teşhis edilebilmesini sağlamaktadır. Cihazın kullanımı sonucunda elde edilen verilerden bir "Canary sayısı" oluşturulmaktadır. Bu sayı, 0 ile 100 arasında bir değer almakta ve farklı aralıklarda diş dokusunun farklı durumunu yansıtmaktadır. 0-20 aralığı sağlıklı dokuya işaret ederken, 21-70 aralığı doku bozulmasını, 71-100 aralığı ise ileri düzeyde bozulmayı ifade etmektedir.⁶⁴ Demineralizasyona bağlı olarak Canary sayısı artmakta, remineralizasyona bağlı olarak ise azalmaktadır.⁶⁵

2.2.5.3. Soprolife ve Soprocure

Soprolife (Acteon, La Ciotat, Fransa) iki farklı LED (Light Emitting Diode)' i birlikte kullanarak diş yüzeyini aydınlatabilen bir intraoral kamera sistemidir.⁶⁶ LED' lerden biri 450 nm dalga boyunda mavi ışık verirken, bir diğeri gün ışığı modundadır. Bir frekans bandında kesintisiz aydınlatma yapılmaktayken aynı anda diğer frekans bandında oluşan floresansın enerjisi piksellere ulaşmakta ve dişin görüntüsü elde edilmektedir.

Dişin anatomik ve otofloresansının görüntüsü üst üste getirilerek biyolojik dokuların yapısal farklılıkları izlenebilmektedir.⁵³

Kameranın üç farklı kullanım modu bulunmaktadır. Gün ışığı modunda dört adet beyaz LED ışık kullanılırken, tanı ve tedavi modlarında ise ışık kaynağı olarak 450 nm dalga boyuna sahip dört mavi LED tercih edilmektedir. Gün ışığında kahverengi olarak gözlenen çürük dokusu, Soprolife cihazı ile koyu kırmızı renkte görünürken, sağlıklı dentin yeşil renkte izlenmektedir. Mine dokusunun kendine özgü bir floresans rengi bulunmamakla birlikte, dentinden yayılan yeşil ışığın difüzyonu nedeniyle mine yüzeyinde mavimsi bir renk olarak algılanabilmektedir.^{67, 68}

Soprocure (Acteon, La Ciotat, Fransa) adlı daha yeni bir kamera, üç farklı klinik modda kullanılabilmektedir; gün ışığı modu, çürük modu ve periodontal mod. Çürük modu, mine ve dentin çürüklerinin tespitine odaklanırken, periodontal mod ise periodontal dokulardaki inflamasyonun değerlendirilmesini sağlamaktadır. Ayrıca, cihazla elde edilen görüntülerin bilgisayarda saklanabilmesi, tanı ve tedavi süreçlerinde görsel kayıtların kullanımına olanak tanımaktadır.⁵³

2.2.5.4. Soproimaging

Soproimaging (Acteon, La Ciotat, Fransa), çekilen görüntülerin kaydedilmesini ve daha sonra karşılaştırılmasını sağlayan özel bir yazılımdır. Kullanım sırasında kamera, diş yüzeyine konumlandırılarak büyütme ve mod (gün ışığı veya floresans) seçimi yapılmaktadır. Elde edilen görüntüler, Soproimaging yazılımı aracılığıyla kaydedilerek tanı ve tedavi süreçlerinde detaylı analiz ve karşılaştırma olanağı sunmaktadır.⁵³

2.2.5.5. VistaCam

VistaCam (Dürr Dental, Bietigheim-Bissingen, Almanya) 405 nm dalga boyundaki mor ışıkla aydınlatılan dişten yansıyan floresans ışığı dijital bir görüntüye çevirip kaydeden, floresans esaslı, çürük teşhisi yapmaya yarayan bir intraoral kameradır.

Yansıyan ışık; dişin sağlıklı yapısı sağlıklı ise sarı-yeşil floresans (510 nm), çürük ve bakteri metabolitleri varlığında ise kırmızı floresans (680 nm) olarak gözükmemektedir. Yazılım, bu iki floresansdan kırmızının yeşile oranını analiz ederek, sağlıklı diş dokusuyla karşılaştırıp değerlendirilen alanlara 0 ile 3 arasında dereceler atamaktadır. 0-1 sağlıklı mineyi, 1-1,5 başlangıç mine demineralizasyonunu, 1,5-2 derin mine çürüğünü, 2-2,5 dentin çürüğünü, 2,5-3 derin dentin çürüğünü işaret etmektedir.⁵³

2.2.5.6. LIFEDT (Light Induced Fluorescence Evaluator for Diagnosis and Treatment)

Diş dokularının floresans özellikleri birbirinden farklılık göstermektedir. Sağlıklı diş dokusu yeşil renkte bir floresans sergilerken, enfekte dentin siyah-yeşil bir görünüm vermektedir. Enfekte ve etkilenmiş dentin sınırları parlak kırmızı olarak gözlemlenirken, çürüğün uzaklaştırılmasının ardından kavite tabanında görülen sağlıklı dentin asit yeşili bir renk göstermektedir. Bu farklı floresans görünimleri, özellikle kavite hazırlığı sırasında çürük teşhisinde önemli bir rehberlik sağlamaktadır. LIFEDT sistemi, floresans bir kameradan oluşmakta olup, dişin oklüzal yüzeyinin temizlenmesi ve beyaz ışık ile floresans modlarında yüksek büyütme altında incelenmesi esasına dayanmaktadır. Mine ve dentinden yansıyan ışıklardaki değişiklikler sağlıklı diş dokuları ile karşılaştırılarak değerlendirilmektedir.^{53, 68}

2.2.6. Optik Kohorens Tomografi (Optical Coherence Tomography-OCT)

Optik koherens tomografi, biyolojik dokuların kesit görüntülerini oluşturmak için 1310 nm dalga boyunda kızılötesi ışık kullanan, invaziv olmayan, yüksek çözünürlüklü bir görüntüleme yöntemidir. OCT, çalışma sırasında diş minesinin translusent özelliklerinden faydalanan detaylı optik ölçümler sağlamaktadır. Genellikle mine tabakasına odaklanan OCT, başlangıç çürüklerinin tespitinde etkili bir araç olarak

değerlendirilmektedir. Ancak, dentin tabakasına ilerlemiş çürüklerin teşhisinde yetersiz olduğu bildirilmiştir.⁶⁹

Polarizasyona duyarlı optik koherens tomografi (PS-OCT), geleneksel OCT'nin polarizasyon bilgisi sağlayan bir türevidir. Bu cihaz, polarize ışık kullanarak geri saçılan sinyallerden elde edilen polarizasyon bilgilerini iki ayrı kanalda kaydedebilme özelliğine sahiptir. Demineralizasyon derecesi ve lezyon derinliği gibi parametrelerle ilişkilendirilebilmekte, bu da çürük lezyonlarının yapısal değişikliklerini değerlendirmede önemli bir avantaj sunmaktadır.

2.2.7. Elektrik Akımı Kullanılan Yöntemler

2.2.7.1. Elektiriksel İletkenlik Ölçümleri (Electrical Conductance Measurement-ECM)

Sağlıklı diş dokusu ile çürük diş dokusunun elektriksel iletkenlik farkı prensibine dayanarak ölçüm yapılan çürük teşhis yöntemidir. Sağlıklı mine dokusu yüksek mineral içeriğinden dolayı yalıtkan özellik göstermektedir. Dişin yapısında meydana gelen demineralizasyon sonucu oluşan poroziteler tükürük ile dolmaya başlamakta ve buralardaki iyon artışı ile beraber elektiriksel iletkenlik artmaktadır. Demineralizasyonun mine-dentin sınırını geçmesiyle elektriksel iletkenlik değişimi daha kolay ölçülebilir hale gelmektedir.⁷⁰

Elektronik çürük monitörü (ECM, Lode Diagnostic, Groningen, Hollanda), elektriksel iletkenlik ölçümü yaparak çürük teşhisinde kullanılan bir cihazdır. Elektriksel iletkenlik ölçümlerinin en önemli avantajlarından biri, çürük lezyonunun ilerlemesi, durması veya remineralizasyonu hakkında objektif ve tekrarlanabilir veriler sağlayabilmesidir.^{70, 71}

2.2.7.2. Alternatif Akım Empedans Spektroskopisi (AAES)

Alternatif akım empedans spektroskopisi (AAES, CarieScan PRO, Dundee, İskoçya), çürük teşhisinde kullanılan noninvaziv bir teknolojidir ve diş dokularının elektriksel özelliklerini analiz etmeye dayanmaktadır. Çalışma prensibi, diş yüzeyine düşük voltajlı bir akım uygulanarak dişin mineral yoğunluğundaki değişimlerin ölçülmesine dayanmaktadır. Sağlıklı diş dokuları yüksek empedans, yüksek rezistans ve düşük iletkenlik özellikleri sergilerken, demineralizasyon sonucunda çürük dokular daha iletken hale gelmekte, empedans ve rezistans değerleri düşmektedir. Alternatif akım empedans spektroskopisi, ECM' den farklı olarak tek bir frekansta değil çok sayıda ve farklı frekanslar kullanarak ölçüm yapabilme özelliği sayesinde, farklı dokuların elektriksel ve anatomik farklılıklarını hassas bir şekilde belirlerleyebilmektedir.^{72, 73}

CariesScan ve CarieScan Pro, AAES yöntemine dayalı olarak geliştirilmiş cihazlardır.²⁷

2.2.8. Raman Spektroskopisi

Raman spektroskopisi, ışık bazlı, materyalin moleküler bağları ile etkileşerek fotonların saçılması prensibine dayanan bir çürük tespit yöntemidir. Bu teknik, incelenen lezyonun moleküler yapısı hakkında detaylı veri sağlayarak hem in vitro hem de in vivo uygulamalarda moleküler düzeyde bilgi sunmaktadır. Özellikle biyomedikal alanda potansiyel kullanım imkânı bulunan Raman spektroskopisi, başlangıç aşamasındaki çürüklerin teşhisinde önemli bir role sahip olmaktadır.⁷⁴ Polarize Raman spektroskopisi ile yapılan bir çalışmada, geleneksel yöntemlerle saptanamayan başlangıç çürük lezyonlarının ve demineralizasyon bölgelerinin tespit edilebildiği ve yöntemin sensitivite ile spesifite değerlerinin yüksek olduğu rapor edilmiştir.⁷⁵

2.2.9. Ultrasonografi/Ultrasonik Görüntüleme Sistemi

Ultrasonografi yöntemi, yüksek frekanslı ses dalgalarının (1-20 MHz) dokulara iletilmesi ve her dokunun farklı empedans değerlerine sahip olması nedeniyle oluşan farklı eko örüntülerini analiz ederek, dokulardaki patolojik değişiklikleri tespit etmeyi sağlamaktadır.⁷⁶ Ses dalgalarının sağlam ve demineralize dokular içerisindeki iletim hızlarının farklılık göstermesi, dokudaki lezyonların ayırt edilebilmesini, derinlikleri belirlenebilmesini ve lokalizasyonların tespit edilebilmesini sağlamaktadır.⁷⁷

Cihazın probu yardımıyla yüksek frekanslı ses dalgaları dişe uygulanmaktadır. Dokudan yansıyan ses dalgaları (eko) cihazın probu tarafından emilerek dönüştürücü yardımıyla elektriksel impulslara çevrilmekte, osiloskop ekranında elektriksel sinyalleri grafik şeklinde görülmektedir.⁷⁶

2.2.10. Terahertz (THz) Teknolojisi

Terahertz dalgalarının diş dokusunun mineral yoğunluğuna göre farklı şekilde yayıldığı, emildiği ve çürük teşhisini bu prensiple yaptığı bilinmektedir. Terahertz dalgalar, su molekülleri tarafından yüksek oranda emilmelerine rağmen iyonlaştırıcı özellik taşımadıkları için X ışınları ve ultraviyole ışık gibi zararlı etkilerden yoksundur. Bu özellikleri, özellikle pediatrik hastalar ve hamile hastalar gibi hassas hasta gruplarında kullanımının güvenli ve faydalı bir teşhis aracı olabileceği düşünülmektedir.⁷⁸

2.2.11. Mikro BT/KIBT (Mikro Bilgisayarlı Tomografi (BT)/ Konik Işınlı Bilgisayarlı Tomografi (KIBT))

Bu yöntemde bilgisayarlı tomografi cihazıyla μm cinsinden kesitler alınarak yüksek çözünürlüklü kesitsel görüntüler elde edilmekte, kesitlerin bir araya getirilmesiyle dişin 3 boyutlu görüntüsü elde edilmektedir. Dişin kesitsel görüntüsünün elde edilmesiyle klasik radyografilerin dezavantajı olan süperpozisyon önlenmektedir. Kesitsel görüntülemenin çürüğün genişliği ve yeri ile ilgili güvenilir sonuçlar verdiği

rapor edilmiştir. Mineral yoğunluklarındaki değişiklikleri analiz ederek, erken evre diş çürüğü lezyonlarının tespitine katkı sağlamaktadır.⁷⁹

2.2.12. LED (Light Emitting Diode)

The Midwest Caries I.D. (Dentsply, York, PA, USA) 635-880 nm arasında ışık yayan diyot LED'in kullanıldığı, sağlıklı ve demineralize diş dokularının optik özelliklerinin farklı olmasından yararlanarak objektif çürük teşhisi yapan bir cihazdır. Sağlıklı diş dokuları demineralize dokulara göre daha translusent görülmektedir.^{27, 80}

LED uygulamasıyla diştten yansıyan ve kırılan ışık fiber optik bir uçla toplanmakta, elektrik sinyaline dönüştürülmekte, translusentlik ve opaklık değişimlerini algılayabilen bir sistemle bilgisayar ortamında analiz edilmektedir. Demineralizasyon sürecine bağlı olarak LED ışığının rengi yeşilden kırmızıya doğru değişmekte ve bu değişime eşlik eden sesli bir sinyal üretilerek çürük varlığı tespit edilmektedir. Üretilen sesli sinyalin frekansı, lezyonun derinliği ile doğru orantılı olup, sinyalin hızlanması çürüğün daha ileri bir aşamada olduğunu göstermektedir.⁸⁰

2.2.13. Yapay Zeka

Rutin diş çürüğü tespiti, klinik ve radyografik değerlendirmelerle birlikte yapılır. Radyografik muayene objektif bilgiler verir fakat değerlendirme hekimin bilgi ve tecrübesine göre değişiklik gösterebilir. Yapay zeka uygulamalarının klinik ve radyografik değerlendirmelere entegre edilmesi, teşhis sürecine önemli katkılar sağlamaktadır. Bu teknoloji, diş hekimlerinin klinik kararlarını desteklemek, erken dönemde farkedilemeyen çürüklerin tespiti, teşhis doğruluğunu artırmak, diş hekimliği uygulamalarında hız, kalite ve verimlilik açısından diş hekimliğinde önemli avantajları olan çürük tespiti için günümüz ve gelecekte fayda sağlayabilecek bir uygulamadır.⁸¹

Yapay zeka uygulamalarında panoramik ve bitewing radyografiler kullanılacak sisteme yüklenmekte, diş çürükleri sistem tarafından otomatik işaretlenmektedir. Diş

hekimi bu analizden ve klinik muayeneden yararlanarak teşhis ve tedavi planını oluşturabilmektedir.⁸²

2.3. Yapay Zeka

Yapay zekâ, insan beyninin bilişsel işlevlerini ve zekâsını taklit eden, öğrenme, muhakeme etme, planlama, problem çözme ve karar verme gibi bilişsel işlevleri gerçekleştirebilen bilgisayar sistemleri ve algoritmalarını içeren bir teknolojidir.⁸³

Makine öğrenimi, derin öğrenme ve yapay sinir ağları yapay zekayı oluşturan alt kümelerdir. Makine öğrenimi kısaca makinelerin veriden öğrenmesini sağlarken, derin öğrenme büyük veri setlerinden öğrenmek için çok katmanlı sinir ağları kullanmakta ve öğrenmeyi kendi kendine gerçekleştirebilmektedir. Yapay sinir ağları ise insan beynindeki nöronlardan esinlenerek oluşturulan matematiksel modeller olup derin öğrenmenin temelini oluşturmaktadır.⁸⁴



Şekil 1. Yapay zeka ve alt kümeleri⁸⁵

2.3.1. Yapay Zeka Algoritmaları

Yapay zeka algoritmaları bilişsel insan davranışlarının; düşünme, öğrenme, problem çözme gibi yetilerin bilgisayar sistemlerine kazandırılmasını sağlayan tekniklerdir. Uzman sistemler, bulanık mantık, genetik algoritmalar, yapay sinir ağları

yapay zeka algoritmalarıdır. Bu algoritmalarından en bilineni ve öne çıkanı yapay sinir ağlarıdır.⁸⁶

2.3.1.1. Uzman Sistemler

Belirli bir uzmanlık alanında geçmişte elde edilen verileri kullanarak uzmanların bilgi ve deneyimlerini taklit ederek çözüm üreten sistemlerdir. Bu sistemlerle probleme karşı yeni bir tasarım oluşturulmaz, geçmiş deneyimlerin kazandırdığı bilgilerle elde edilen veri tabanını kullanarak çözüm üretmektedir. Bu yüzden ilgili alandaki yenilikler sisteme sürekli tanıtılmalıdır.^{87, 88}

Uzman sistemlerin amacı; uzman kişileri devre dışı bırakmak değil uzmana erişimin sınırlı olduğu durumlarda sorunların çözümüne katkı sağlamaktır.⁸⁹

2.3.1.2. Bulanık Mantık

Klasik mantıktaki kesin doğruluk yaklaşımına karşılık, hayattaki belirsiz ve ara durumları barındıran problemlerin çözümünü modellemek amacıyla geliştirilmiş yapay zeka algoritmasıdır. Kural tabanı; günlük yaşamdaki kesin olmayan, kesin rakamlarla ifade edilemeyen yargılardan oluşmakta, nitelendirmeler kesin yargı değil ara formları içermektedir.⁹⁰

2.3.1.3. Genetik Algoritmalar

Evrin teorisiinden esinlenerek insanlarda kromozomlar üzerinden işleyen genetik süreci problemlerin çözümü için bilgisayar ortamında kromozom benzeri bir veri yapısı üzerinde kodlayarak gerçekleştirilmeye çalışıldığı bir yapay zeka algoritmasıdır. Algoritma, genetik ve doğal seçilimi temel alarak en iyi ve başarılı olanın hayatta kalma prensibiyle çalıştığından fonksiyon optimize edici olarak da bilinmektedir. Belirli bir problemin çözümüne odaklanan uzman sistemler yerine, dinamik ve hızla değişen koşullara uyum sağlayarak farklı senaryoları değerlendirme ve değişken durumlara uygun kararlar alabilme, çözüm üretebilme yeteneğine sahiptir algortimalardır.⁹¹

2.3.1.4. Yapay Sinir Ağları

Yapay sinir ağları, insan sinir hücrelerinin (nöronların) işleyişinden esinlenerek geliştirilmiş ve insan gibi öğrenme, durumlar arasında ilişki kurabilme, verileri sınıflandırma, genelleme, depolama, kullanma ve işleme gibi insan zekasına ait özellikleri taklit ederek oluşturulan yapay sinir hücrelerinin katmanlı bir ağ yapısı oluşturacak şekilde bir araya gelmesiyle oluşan sistemlerdir.⁹² Temel birimleri yapay sinir hücresi veya diğer bir adıyla yapay nöronlardır.⁹³

Yapay Sinir Hücresinin Yapısı


Biyolojik sinir hücreleri temel olarak dendritler, hücre gövdesi (soma), akson ve sinapslardan oluşmaktadır. Bir nöron, diğer nöronlardan gelen sinyalleri dendritleri aracılığıyla almakta ve bu sinyalleri hücre gövdesinde işleyerek akson boyunca iletmektedir. Sinir hücreleri, sinapslar üzerinden birbirleriyle etkileşim kurarak iletişim ağını oluşturmaktadır.⁹⁴

Yapay sinir hücresi, biyolojik nöronların yapısındaki fonksiyonel elemanların matematiksel modellenmesiyle oluşturulmuştur.⁹⁵

Yapay sinir hücresinin yapısı 5 temel birimden oluşmaktadır; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılardır. Biyolojik nöronların yapısındaki dendrit, hücre gövdesi, akson birimlerinin yapay sinir hücresinin yapısal karşılıkları sırasıyla; ağırlıklar, toplama fonksiyonu ve aktivasyon fonksiyonudur.⁸⁵

Tablo 1. Biyolojik sinir sistemindeki yapıların yapay sinir sistemindeki karşılıkları⁸⁵

Biyolojik Sinir Sistemi	Yapay Sinir Sitemi
Nöron	İşlemci Elemanı(Yapay Sinir Hücresi)
Dentrit	Ağırlıklar
Soma	Toplama Fonksiyonu
Akson	Aktivasyon Fonksiyonu
Sinaps	Yapay Nöron Çıkışı



Şekil 2. Biyolojik sinir hücresi (a), Yapay sinir hücresi (b)^{96, 97}

Yapay sinir hücresine iletilen m tane veri **girdisi** $X_1, X_2, \dots, X_n$ şeklinde ifade edilir, dış ortamdan alınan verileri temsil etmektedir. Bu girdiler, ağırlık öğrenme sürecini yönlendiren temel bilgi kaynakları olup, modelin eğitilmesi ve istenilen çıktıları üretmesi açısından kritik bir rol oynamaktadır.⁹⁸

Yapay sinir hücresinde **ağırlıklar** ($w_1, w_2, \dots, w_n$), girdilerin model üzerindeki etkisini ve önem derecesini belirleyen katsayılardır. Ağırlık değerlerinin büyüklüğü veya küçüklüğü, ilgili girdinin yapay sinir hücresindeki önemini belirlemez.⁹⁸

Tüm girdi verileri ($X_1, X_2, \dots, X_m$), kendilerine ait ağırlık değerleri ($W_1, W_2, \dots, W_m$) ile çarpılarak **toplama fonksiyonu** aracılığıyla birleştirilmekte ve işlenmek üzere aktivasyon fonksiyonuna iletilmektedir.⁹⁴

Toplama fonksiyonundan gelen veri **aktivasyon fonksiyonunda** işlenerek bir çıktı oluşturulmaktadır.⁹⁹

Yapay Sinir Ağının Yapısı

Yapay sinir ağları, yapay sinir hücrelerinin katmanlı ağ yapısı oluşturacak şekilde bir araya gelmesiyle oluşmaktadır. Temel birimi yapay sinir hücresidir. Yapay sinir ağı 3 katmandan oluşmaktadır; girdi katmanı, gizli katman ve çıktı katmanı. Girdi ve çıktı katmanı genelde bir tanedir. Yapay sinir ağının temel tabakası gizli katmandır ve bir ağda birden fazla gizli katman bulunabilmektedir. Gizli katman sayısı ve her bir katmandaki nöron sayısı, ağın tasarımına ve tasarımı yapan kullanıcının deneyimi ve bilgi birikimine, bağlı olarak farklılık gösterebilmektedir.¹⁰⁰ Girdi ve çıktı katmanları, ağın dış dünyayla bağlantılı olan katmanlarıdır, diğer tüm nöronlar ise gizli tabakalarda yer almaktadır. Girdi katmanı, veri gruplarının ağa sunulduğu giriş noktalarını içermekte ve bu veriler, bağlantılarındaki ağırlıklar ile çarpılarak gizli katmana iletilmektedir. Gizli katmandaki nöronların girişleri ise, gizli katman ile çıktı katmanı arasındaki bağlantıların ağırlıklarıyla çarpılarak çıktı katmanına aktarılmaktadır. Çıktı katmanı, ağın son katmanı olup, nöronlara gelen girişleri toplayarak uygun bir çıkış değeri üretmektedir. Biyolojik nöral yapılardaki dendritlerin işlevini üstlenen yapay sinir hücresindeki ağırlıklar, çeşitli ayarlamalarla öğrenmeyi sağlarken, bu ağırlık değerleri öğrenme süreci boyunca belirlenmektedir.¹⁰¹

Yapay Sinir Ağlarının Eğitimi

Yapay sinir ağı modellerinin eğitimi, insanın öğrenme sürecine benzer şekilde, belirli bir eğitim veri setinin modele sunulmasıyla gerçekleştirilmektedir. Eğitimin temel

amacı, ağıdaki nöronlar arasındaki bağlantı ağırlıklarını optimize ederek, modelin tahmin ettiği çıktı ile gerçek çıktı arasındaki hatayı en aza indirmektir.¹⁰² Eğitim sürecinde, modelin performansını ve eğitimin gidişatını izlemek amacıyla doğrulama (validasyon) seti adı verilen bağımsız bir veri kümesi kullanılmaktadır. Eğitimin tamamlanmasının ardından, modelin genel performansını değerlendirmek için test seti adı verilen ayrı bir veri kümesi kullanılmaktadır.¹⁰³

Bir yapay sinir ağı modeli, yalnızca eğitim sürecinde sunulan verilerden öğrenebilir; dolayısıyla, eğitim setinin kapsamlı olması büyük önem taşımaktadır. Modelin, eğitim setinde yer alan özellikleri öğrenebilmesi için veri kümesinin yeterli büyüklükte olması gerekmektedir. Ancak, veri kümesinin gereğinden fazla ayrıntı içermesi, sinir ağının ağırlıkları ayarlama zorlanmasına neden olabilmektedir. Bu nedenle, eğitim setinin kapsamlı, dengeli, özenle seçilmiş ve ilgili bilgileri içeren bir yapıya sahip olması, modelin başarılı bir şekilde eğitilmesi açısından önemli olmaktadır.¹⁰³

Yapay sinir ağlarının temel çalışma prensibine göre, girdi katmanına aktarılan veriler, modelin öğrenmesini sağlayan ve sayısal değerler içeren ağırlıklarla çarpılarak işlenmektedir. Bu hesaplamalar sonucunda elde edilen çıktılar, çıktı katmanına iletilerek beklenen değerlerle karşılaştırılmaktadır. Hata fonksiyonu aracılığıyla hesaplanan toplam hata belirlenmekte ve bu hata, modelin ağırlıklarını güncelleyerek hatayı minimize edecek şekilde optimize edilmektedir. Bu süreçte, belirlenen tekrar sayısına veya istenilen hata oranına ulaşıldığında yapay sinir ağının öğrenme sürecinin tamamlandığı kabul edilmektedir.¹⁰⁴

2.3.2. Derin Öğrenme

Yapay zekâ alanında uzun yıllar boyunca, genellikle yalnızca bir veya iki katmandan oluşan ve sığ yapılar olarak adlandırılan algoritmalar tercih edilmiştir. Bu

mimariler, çoğunlukla doğrusal olmayan dönüşümler içermekte olup, karmaşık veri setleri karşısında sınırlı bir öğrenme kapasitesine sahipti. Ancak, veri setlerinin giderek daha büyük ve karmaşık hale gelmesi, yapay sinir ağlarının öğrenme yeteneklerini geliştirmeye yönelik yeni yaklaşımların ortaya çıkmasını sağlamıştır. Bu bağlamda, derin öğrenme algoritmaları, çok katmanlı yapıları (çok sayıda gizli katman içermesi) sayesinde verilerin işlenmesi ve karmaşık problemlerin anlamlandırılmasını kolaylaştıran etkili yöntemler olarak geliştirilmiştir. Derin öğrenme, büyük ölçekli veri setlerinde daha başarılı analizler, tahmin ve çıkarım yapabilme yeteneği sunarak, yapay sinir ağlarının performansını önemli ölçüde artırmıştır.^{105, 106}

Derin öğrenme, çok katmanlı yapısı sayesinde geleneksel makine öğrenimi yöntemlerindeki gibi özellik çıkarma gibi ön işlemlere ihtiyaç duymamaktadır. Derin öğrenme ağlarındaki katmanlar, verileri doğrudan işleyerek öğrenebilme kapasitesine sahip olup, ön işleme gereksinimi olmadan verilerden otomatik olarak özellik çıkarımı gerçekleştirmektedir. Bu süreç, yapay sinir ağlarının katman yapısına entegre edilmiş olup, özellik çıkarımı verilerin işlenmesi sırasında ağ tarafından öğrenilip yapay sinir ağına bu özellik katılmış olur.¹⁰⁷ Özellik çıkarım sürecinin otomatikleştirilmesi, derin öğrenmenin yaygın kullanım alanlarına sahip olmasının en temel nedenlerinden biri olarak öne çıkmaktadır. Bu modellerde her katmanın çıktısı bir sonraki katmana giriş olarak aktarılmakta ve bu ardışık katman yapısı sayesinde giderek daha güçlü temsiller oluşturulmaktadır. Girdi katmanı ile çıktı katmanı arasında birden fazla gizli katmanın yer aldığı bu yapı, derin öğrenme modellerinin etkinliğini artırmakta ve özellikle büyük veri setleri üzerinde yüksek başarı oranları elde edilmesini sağlamaktadır.¹⁰⁸

Derin öğrenmenin makine öğreniminden ayrılan bir diğer önemli yönü, büyük veri setleriyle daha etkili bir şekilde çalışabilmesidir.¹⁰⁹

Derin öğrenme, radyologlar tarafından gerçekleştirilen lezyon tespiti, segmentasyon, sınıflandırma ve izleme gibi süreçlerin yanı sıra, geleneksel yöntemlerle elde edilmesi zor olan tedavi yanıtının öngörülmesi gibi zaman alıcı görevlerin otomatikleştirilmesinde etkin bir şekilde kullanılabilir. ¹¹⁰

2.3.2.1. Derin Öğrenme Mimarileri

Derin öğrenme mimarileri; tekrarlayan sinir ağları (TSA), uzun-kısa süreli hafıza ağları, derin otokodlayıcılar, derin inanç ağları (DİA), üretken rekabet ağları (ÜRA), çok katmanlı algılayıcılar (ÇKA), konvolüsyonel sinir ağları (KSA) ifade etmektedir.

Konvolüsyonel Sinir Ağları (KSA)

Konvolüsyonel sinir ağları, derin öğrenme yöntemleri içinde en yaygın kullanılan modeller arasında olup, katmanlarının en az birinde konvolüsyon işlemi kullanan bir tür ileri beslemeli ve çok katmanlı bir yapıya sahiptir. Konvolüsyonel sinir ağları, yüksek boyutlu verilerden düşük boyutlu ancak anlamlı öznitelikler çıkarma prensibiyle çalışmaktadır. ¹¹¹

Konvolüsyonel sinir ağları, görüntülerin temel özelliklerini çıkararak boyutlarını küçültmekte ancak içerdiği önemli bilgiyi kaybetmeden işlemi gerçekleştirmektedir. Geleneksel görüntü işleme algoritmalarında yaygın olarak karşılaşılan karmaşık özellik çıkarma ve veri yeniden yapılandırma aşamalarına gereksinim duymadan, ham veriyi doğrudan işleyerek anlamlı çıkarımlar yapabilme kapasitesine sahiptir. Konvolüsyonel sinir ağları özellikle iki boyutlu verilerin işlenmesinde, görüntü analizi, sınıflandırma ve nesne tespiti gibi görevlerde etkin bir şekilde kullanılmak için uygun bir mimari sunmaktadır. ¹¹²

Çok katmanlı yapıya sahip olan KSA' larda giriş, evrişim, aktivasyon, havuzlama, tam bağlı ve sınıflandırma katmanlarından oluşmaktadır. Bu katmanlar, öğelere ait özellikleri belirlemekte ve sonrasında sınıflandırma katmanı aracılığıyla bu öğeler

sınıflandırılmaktadır. Her katman, üzerine düşen işlemleri tamamladıktan sonra, nihai sonucu elde etmek için sınıflandırma katmanına aktarmaktadır.¹¹³

Konvolüsyonel sinir ağlarının eğitilmesi

Konvolüsyonel sinir ağlarının eğitimi sürecinde öncelikle ağın mimarisi belirlenmekte; hangi katmanların kullanılacağı, bu katmanların sıralaması ve parametreleri planlanmaktadır. Ardından, giriş parametrelerinin sayısı, filtrelerin boyutları ve miktarı tespit edilmektedir. Eğitim sürecinde, veri kümesinden seçilen bir örnek, belirlenen katmanlar boyunca işlenerek bir çıkış değeri üretilmektedir. Bu süreç ileri yayılım olarak adlandırılmaktadır. Elde edilen çıkış değeri, beklenen değer ile karşılaştırılarak hata hesaplanmaktadır. Hesaplanan hata, ağın öğrenme sürecini iyileştirmek için geriye doğru iletilmekte ve ağırlıklara dağıtılarak güncellenmektedir; bu aşama geri yayılım olarak bilinmektedir. Hata oranı, veri seti ağ üzerinde belirli bir sayıda tekrar işlenerek en aza indirilmeye çalışılmaktadır. Eğitim sürecinin tamamlanmasının ardından test aşamasına geçilmektedir. Test sırasında yalnızca ileri yayılım gerçekleştirilir ve modelin başarımı, hata oranı üzerinden değerlendirilmektedir.¹¹⁴

2.3.2.2. Derin Öğrenme Kütüphaneleri

Derin öğrenme, çeşitli kütüphaneleri bünyesinde barındıran bir yapıya sahiptir. Bu kütüphaneler, uygulama sürecini kolaylaştırarak geliştirme aşamalarını daha verimli hale getirmektedir. Her bir kütüphane, belirli bir işlevi yerine getirmek üzere tasarlanmış olup, farklı hesaplama gereksinimlerine yönelik optimize edilmiştir.¹¹⁵

TensorFlow: Özellikle görüntü işlemede sayısal hesaplamalar için yaygın olarak kullanılan, açık kaynak kodlu bir derin öğrenme kütüphanesidir.¹¹⁶

Torch: Lua ve Python dillerinde çalışabilen bir kütüphane olup, karmaşık problemleri basitleştirerek esnek ve hızlı algoritmalar geliştirmeye olanak tanınmasının

yanı sıra, görüntü ve ses işleme gibi çeşitli veri formatları üzerinde işlem yapabilme imkanı sunmaktadır.¹¹⁶

2.3.2.3. Derin Öğrenme Yönteminin Radyolojik Görüntülerin Analizinde Kullanımı

Derin öğrenme teknolojisindeki ilerlemeler, karmaşık problemlerin daha hızlı ve etkin bir şekilde çözülmesine olanak tanıyarak bireylerin üretkenliğini artırmayı hedeflemektedir. Bu gelişmeler, özellikle sağlık alanında hekimlerin daha doğru teşhisler koymasına katkı sağlayabilir. Derin öğrenme, tıbbi görüntüleme alanlarındaki çeşitli sorunları çözmek için bugünlerde büyük ilgi görmektedir. Radyolojik görüntülerin analizi için sınıflandırma, segmentasyon ve nesne tespiti gibi derin öğrenme yöntemleri kullanılmaktadır.¹¹⁷

Görüntü sınıflandırması: Radyologlar için temel görevlerden biri, her hastanın tıbbi görüntüleri için uygun bir ayırıcı tanıdır ve bu sınıflandırma görevi, bir hastalığın varlığının veya yokluğunun belirlenmesine yönelik oluşumların görüntü üzerinde sınıflandırılmasını, değerlendirilecek görüntü bölgesindeki benzer özellikleri gruplandırmayı içermektedir.¹¹⁷

Segmentasyon: Derin öğrenmede segmentasyon, medikal görüntülerde belirli anatomik yapıları veya anormal oluşumları piksel düzeyinde tanımlamak için kullanılan bir tekniktir.¹¹⁸ Bu yöntem, özellikle tümör tespiti, organ segmentasyonu ve lezyon analizi gibi uygulamalarda yüksek doğruluk sağlayan derin sinir ağları ile gerçekleştirilmektedir. Ancak segmentasyon algoritmalarının bazı yapısal sınırlamaları bulunmaktadır. Örneğin, girdi görüntüsünde işaretlenen bölgelerin pikselleri ile komşu piksellerin büyük ölçüde örtüşmesi, aynı evrişimlerin birçok kez işlenmesine neden olmaktadır. Bu durum, modelin verimliliğini düşürebilmekte ve bellek kullanımını artırabilmektedir. Bu nedenle, segmentasyonun optimizasyonu için U-Net, DeepLab ve

Mask R-CNN gibi ileri düzey mimariler geliştirilmiş, gereksiz hesaplamaların önüne geçilmeye çalışılmıştır.¹¹⁹

Nesne Tespiti: Biyomedikal görüntü analizinde derin öğrenme tabanlı segmentasyon, hastanın lezyonlarının bulunduğu bölgelerin belirlenmesi ve bu lezyonların kategorize edilmesi sürecini kapsamaktadır.¹¹⁷ Segmentasyon modelleri, yalnızca belirli bölgeleri sınıflandıran geleneksel KSA' lardan farklı olarak, nesne tespiti ve sınır belirleme süreçlerini içeren ek bileşenlere sahiptir. Özellikle, regresyon ve bölge önerisi mekanizmaları ile desteklenen bu modeller, tespit edilen yapıların konumlarını hassas bir şekilde belirleyerek detaylı analizler sunmaktadır. Bu yaklaşım, tıbbi görüntülerin pikseller bazında değerlendirilmesini sağlayarak radyolojik tanılarda doğruluğu artırmakta ve klinik karar destek sistemlerinin etkinliğini güçlendirmektedir.¹¹⁸

2.3.2.4. Derin Öğrenme Yöntemleri

R-CNN, Fast R-CNN, Faster R-CNN, SSD (Single Shot MultiBox Detector) ve YOLO (You Only Look Once), CNN tabanlı nesne tespitinde yüksek başarı elde etmiş derin öğrenme algortimaları arasında yer almaktadır. Nesne tespitinde etkinliği kanıtlanmış algortimalar YOLO, SSD ve Faster R-CNN'dir.

Nesne tespitinde en yaygın kullanılan derin öğrenme algortimalarından biri olan YOLO (You Only Look Once), ilk olarak 2015 yılında Redmon ve çalışma arkadaşları tarafından geliştirilmiştir.¹²⁰ İnsan görsel sisteminin, bir sahnedeki nesneleri ve bunların birbirleriyle olan ilişkilerini eşzamanlı olarak algılama yeteneğinden ilham alınarak tasarlanan YOLO, nesne tespit sürecini hızlandıran yenilikçi bir yaklaşım sunmakta, birçok uygulamada tercih edilen güçlü bir derin öğrenme algoritmasıdır.¹²¹ Algoritma, görüntü üzerinde tek bir KSA kullanarak sınırlayıcı kutular içindeki nesneleri belirlemekte ve bu nesnelerin sınıf olasılıklarını gerçek zamanlı olarak tahmin

etmektedir. YOLO' nun en önemli avantajı, geleneksel nesne tespit modellerinden farklı olarak, görüntü üzerindeki nesneleri yinelemeli işlemler gerçekleştirilmeden, yalnızca tek bir defa bakarak tek adımda tahmin edebilmesidir. Bu yaklaşım, modeli bir regresyon problemi olarak ele alarak hem hesaplama sürecini basitleştirmekte hem de tespit hızını artırmaktadır. YOLO, KSA tabanlı yapısı sayesinde yüksek doğrulukla ve düşük gecikme süresiyle nesne tespiti gerçekleştiren hızlı ve verimli bir yapay zeka algoritması olarak öne çıkmaktadır.¹²²

YOLOv1 temel mimarisi, 24 konvolüsyon katmanı ve ardından gelen 2 tam bağlı katmandan ve temel omurga ağı DarkNet mimarisinden oluşan verimli bir nesne tespit algoritmasıdır. Algoritma, özellik haritalarının boyutunu küçültmek ve parametre sayısını optimize etmek amacıyla 1×1 evrişimli katmanları kullanmaktadır. Algoritmanın işlem kapasitesi saniyede 45 kareye ulaşırken, daha hızlı bir versiyon olan Fast YOLO, hafifletilmiş yapısıyla yalnızca dokuz evrişimli katman içererek saniyede 150 kare ve üzeri hızlarda çalışabilmektedir.¹²²

2017 yılında, YOLOv1'de gözlemlenen nesne tespit hataları ve düşük duyarlılık skorları gibi sorunları gidermek amacıyla, 19 evrişim katmanı ve 5 havuzlama katmanı içeren DarkNet-19 mimarisi temel alınarak YOLOv2 algoritması geliştirilmiştir.¹²³

2018 yılında, 53 evrişim katmanına sahip DarkNet-53 mimarisi temel alınarak YOLOv3 algoritması geliştirilmiştir. Bu yeni algoritma, önceki sürümlere kıyasla nesne tespitinde daha yüksek doğruluk sağlamış ve özellikle küçük nesneleri daha etkin bir şekilde tahmin edebilmesine olanak tanıyan çok ölçekli tahmin yeteneği ile öne çıkmıştır.¹²⁴

2020 yılında YOLO algoritmasının nesne tespit hızını artıran yeni sürümü olan YOLOv4'ü tanıtmıştır. Bu modelin geliştirilme sürecinde, yüksek performans gösteren DarkNet-53 mimarisi, CSPNet ile optimize edilerek CSPDarkNet-53 formunda

kullanılmıştır. YOLOv4, önceki sürüm olan YOLOv3'e kıyasla genel ortalama hassasiyet (mAP) skorunu %10, işlem hızını ise %12 oranında artırarak daha verimli bir nesne tespit performansı sunmuştur.¹²⁵

YOLOv5 2020 yılında, YOLOv4 ile benzer bir temel yapıya CSPDarkNet-53 mimarisi üzerine inşa edilmiştir. YOLOv5, farklı boyut ve özelliklere sahip beş farklı versiyona sahiptir. Üç farklı boyutta özellik haritası üretebilme kapasitesine sahiptir.

YOLOv6 ve YOLOv7 algoritmaları sırasıyla Haziran ve Temmuz 2022' de tanıtılmıştır. YOLOv6, omurga yapısı olarak RepVGG veya CSPStackRep mimarilerini kullanmaktadır. Algoritma, iki ana bileşenden oluşmaktadır; tek kanallı geliştirilmiş YOLO (SEC-YOLO) ve çok kanallı geliştirilmiş YOLO (MEC-YOLO). YOLOv6, önceki YOLO sürümlerine kıyasla daha doğru nesne algılama yeteneği sunmakta ve nesne tespit etkinliğini artırmak için tek ve çok kanallı teknikleri birleştirerek daha verimli bir model ortaya koymaktadır.¹²⁶

YOLOv6'nın geliştirilmesinin ardından, aynı yıl içinde YOLOv7 tanıtılmıştır, ağın temel mimarisi çoğunlukla değiştirilmeden bırakılmıştır. Ancak, modelin aktivasyon fonksiyonlarında iyileştirmeler ve bazı parçaların optimizasyonu gerçekleştirilmiştir.¹²⁷ YOLOv7'nin temel yapısında, ağın performansını artırmak amacıyla ELAN modülü kullanılmıştır. YOLOv5 ile benzer bir model boyutuna sahip olmasına rağmen, YOLOv7 daha hızlı çalışmakta ve nesne tespitinde daha doğru ve hızlı sonuçlar üretmektedir. Bu özellikleri, onu nesne tespit dedektörü olarak tercih edilen bir algoritma haline getirmiştir.¹²⁸ YOLOv7, omurga, boyun ve baş bölümlerinden oluşan bir yapıdadır ve girdi görüntülerinin piksel boyutlarının standart hale getirilmesi gerekmektedir. Bu görüntüler, sırasıyla omurga, boyun ve baş bölümlerinde işlendikten sonra, nihai tahmin çıktıları elde edilmektedir.¹²⁹

YOLOv8 Algoritmasının İçeriği

YOLOv8 (You Only Look Once v8), 2003 yılında Ultralytics tarafından geliştirilen, nesne tespiti, görüntü segmentasyonu ve sınıflandırma için kullanılmakta olan en güncel YOLO sürümüdür. Önceki YOLO versiyonlarına kıyasla daha hızlı, daha hassas ve daha verimli bir mimariye sahiptir. YOLOv8, YOLOv5'in bir uzantısıdır ve daha gelişmiş özellikler ve optimizasyonlar ekleyerek performansını artırmak için tasarlanmıştır. Özellikle tıbbi görüntüleme gibi hassas uygulamalar için uygundur. YOLOv8, farklı ölçeklerde ve en-boy oranlarında nesneleri tespit edebilen bir derin öğrenme algoritmasıdır. Modelin eğitilebilmesi için, önceden işlenmiş görüntüler ve bunlara karşılık gelen ek açıklamalar ile beslenmesi gerekmektedir. Eğitim sürecinde model, tahmin edilen değerler ile gerçek değerler arasındaki farkı ölçen bir kayıp fonksiyonunu en aza indirerek nesnelerin konumunu ve sınıfını doğru şekilde tahmin etmeyi öğrenmektedir. Sürecin uzunluğu, kullanılan veri kümesinin büyüklüğüne ve modelin hesaplama karmaşıklığına bağlı olarak değişmektedir.¹³⁰

YOLOv8 algoritması 3 ana bileşenden oluşur;

Omurga: Bir dizi konvolüsyonel katmandan oluşarak görüntü özellik haritalarını farklı katmanlarda hesaplayan ve bu haritaların hiyerarşik olarak oluşturulmasını sağlayan bir yapıdır.

Boyun: Farklı çözünürlüklerdeki özellik haritalarını kullanarak birleştirmekte ve küçük çürüklerin tespit edilmesine katkı sağlamaktadır. Ayrıca başa girdi göndermektedir.

Baş: Birleştirilen özellik haritalarını işleyerek nesne tespiti için sınırlayıcı kutuları ve sınıflandırma puanlarını tahmin eder.¹³¹

YOLOv8 algoritması, 8n, 8s, 8m, 8l ve 8x olmak üzere farklı nesne tespit algoritmaları sunmakta olup, tüm versiyonlar aynı işlevi yerine getirmesine rağmen

model büyüklüğü, işlem hızı ve hesaplanan parametre sayısı 8x algoritmasına doğru artış göstermektedir. YOLOv8x, diğer YOLOv8 versiyonlarıyla aynı temel yapıyı paylaşır ancak daha fazla konvolüsyon katmanı ve genişletilmiş bir algoritma derinliği içerir.¹³⁰

2.3.3. Diş Hekimliğinde Yapay Zeka Uygulamaları ve Geleceği

Yapay zekâ sistemleri, hızla gelişen teknolojiyle birlikte diş hekimliği pratiğinde de önemli bir yer edinmeye başlamıştır. Bilgisayar kullanımının yaygınlaşması, evrensel bilgiye kolay erişim ve sağlık alanında büyük miktarda işlenebilir verinin bulunması, yapay zekânın diş hekimliğinde kullanımını hızlandıran başlıca faktörler arasındadır. Özellikle tıbbi görüntüleme alanında kaydedilen ilerlemeler, dental radyoloji uygulamalarında yapay zekâ destekli sistemlerin kullanımını artırmıştır. Yapay zekâ, dijital veri ile beslenen bir sistem olarak, performansının doğruluğu açısından kullanılan verinin niteliği ve niceliğine bağlıdır.^{132, 133} Son yıllarda derin öğrenme alanında yaşanan gelişmeler, tıbbi görüntülerde nesne tanıma, sınıflandırma ve ölçüm süreçlerini daha etkin hâle getirmiştir.¹¹⁹ Diş hekimliğinde yapay zekâ teknolojileri, klinik süreçlerin verimliliğini ve üretkenliğini artırarak klinisyenlere rehberlik etme potansiyeline sahiptir. Bu teknolojilerin temel avantajı, insan tarafından önceden tanımlanmış kurallar yerine verilerden öğrenme prensibine dayanmasıdır.

Yapay zekânın diş hekimliğinde yaygınlaşması, ağız ve diş hastalıklarının teşhis ve tedavisinde daha yüksek etkinlik, güvenilirlik ve verimlilik sağlayarak daha geniş bir hasta kitlesine kaliteli sağlık hizmeti sunma potansiyelini ortaya koymaktadır.¹³⁴ Klinik karar verme süreci, diş hekimlerinin çeşitli hasta verilerini analiz ederek en uygun tedavi planını belirlemesini gerektirmektedir. Ancak, yoğun hasta trafiği, sınırlı muayene süresi ve klinisyene bağlı faktörler, doğru teşhisin konulmasını zorlaştırabilmektedir. Yapay zekâ uygulamaları, bu süreçte diş hekimlerine rehberlik ederek iş yükünü hafifletmekte, insan kaynaklı hataları en aza indirmekte ve klinik karar alma süreçlerini daha

sistematik ve güvenilir hale getirmektedir. Özellikle radyografik görüntülerin değerlendirilmesi, hastalıkların erken teşhisi ve tedavi planlaması gibi konularda yapay zekâ, büyük veri analizi ve derin öğrenme teknikleri kullanarak klinisyenlere destek sağlamaktadır. Bu sayede, teşhis süreçlerinin daha hızlı ve hassas bir şekilde yürütülmesi mümkün olmakta ve hasta bakım kalitesi önemli ölçüde artırılmaktadır.¹³⁵

Radyografik görüntülerin analizinde derin öğrenme sistemlerin, özellikle KSA'ların kullanımına yönelik çeşitli araştırmalar yürütülmektedir.¹³⁶ Diş hekimliğinde panoramik radyografiler, ağız, diş ve çene yapılarının geniş bir perspektiften değerlendirilmesini sağlayan en yaygın kullanılan görüntüleme yöntemlerinden biridir. Ancak, bu radyografilerin iki boyutlu görüntüleme prensibine dayanması nedeniyle anatomik yapıların üst üste binmesi, kontrast farklılıkları ve çevre dokuların etkisi gibi faktörler, klinik yorumlamada zorluklara yol açabilmektedir. Ayrıca, yoğun klinik çalışma temposu ve hekim yorgunluğu, radyografik değerlendirmelerde hata riskini artırabilmektedir. Bu tür sınırlamaları aşmak ve teşhis sürecini daha güvenilir hale getirmek amacıyla, yapay zekâ destekli sistemler giderek daha fazla kullanılmaktadır. Yapay zekâ tabanlı derin öğrenme algoritmaları, büyük veri setleri üzerinden eğitilerek nesnel ve tekrarlanabilir değerlendirmeler sunmakta, böylece teşhis doğruluğunu artırmakta ve hekimin karar verme sürecini desteklemektedir. Bu sistemler, klinik uygulamalarda iş yükünü azaltarak hekimlerin daha verimli çalışmasına olanak tanırken, hasta bakım kalitesinin de yükseltilmesine katkı sağlamaktadır.^{137, 138}

Çocuk diş hekimliği, hedef yaş grubunun özellikleri nedeniyle ağırlıklı olarak davranış yönlendirme uygulamalarına dayanan bir alan olup, yapay zekâ ile ilgili çalışmaların nispeten sınırlı olduğu bir disiplindir. Bununla birlikte, yetişkin teşhis ve tedavi süreçlerinde elde edilen gelişmelerin çocuk diş hekimliğine uyarlanmasıyla yanı sıra, hasta ve ebeveyn eğitimi, ağrı yönetimi ve davranış yönlendirme teknikleri gibi

alanlarda yapay zeka uygulamalarının geliştirildiği ve son yıllarda çocuk diş hekimliği alanında yapay zeka kullanımıyla ilgili çalışmaların giderek arttığı görülmektedir.¹³² Özellikle süt ve daimi dişlerin tespiti, diş yaşı belirleme, mesiodens ve süpernumerer dişlerin tespiti, ektopik sürme, fissür örtücü uygulamaların sınıflandırılması, erken çocukluk çağı çürüklerinin ve dental plağın tespiti gibi konular ön plana çıkmaktadır.^{139,}¹⁴⁰ Yapay zekâ algoritmalarının çocuklarda ağız sağlığı değerlendirmesi için kullanılmasına yönelik çalışmalar, ebeveyn ve çocuklara uygulanan anketler aracılığıyla veri toplayarak, bu verileri yapay zeka destekli sistemlere entegre edip tedavi gereksinimlerini tahmin etme üzerine yoğunlaşmaktadır.¹⁴¹ Ayrıca, yapay zekâ destekli sistemlerin postoperatif ağrı yönetimi ve kronik ağrı tahmini gibi alanlarda kullanımı, özellikle ağrısını ifade etmekte zorlanan küçük yaş grupları ve özel gereksinimli bireyler için umut vaat etmektedir.¹⁴² Bu tür gelişmeler, çocuk hastaların tedavi süreçlerinde diş hekimleriyle daha etkili iş birliği yapmasını teşvik ederken, teşhis ve tedavi başarısını artırma potansiyeline sahiptir.¹³⁹

2.3.4. Yapay Zeka ile İlgili Limitasyonlar

Diş hekimliğinde yapay zeka uygulamalarının yaygınlaşmasıyla birlikte, bu sistemlerin karar alma süreçlerindeki rolü giderek artmaktadır. Ancak, klinisyenlerin yapay zeka tabanlı sistemlere aşırı bağımlı hale gelmesi, teşhis ve tedavi süreçlerinde sorumluluk paylaşımına dair etik ve hukuki sorunları da beraberinde getirmektedir. Bu nedenle, yapay zeka destekli teşhislerin yalnızca yardımcı bir araç olduğu unutulmamalı ve nihai kararın uzman hekimler tarafından verilmesi gerektiği vurgulanmalıdır.¹⁴³

Yapay zeka algoritmalarının farklı klinik senaryolar ve değişken hasta profilleri karşısında güvenilirliğini sürdürebilmesi için geniş ve çeşitlendirilmiş veri setleriyle eğitilmesi büyük önem taşımaktadır. Derin öğrenme algoritmaları doğrudan veriden

öğrendiğinden radyolojik verilerle yüksek doğruluk elde etmek için veri setinin en az 1000 olması gerekir.^{11, 144}

Mevcut çalışmaların çoğunda kullanılan verilerin sınırlı büyüklükte olması ve hasta bilgilerinin gizliliği nedeniyle veri paylaşımında karşılaşılan engeller, yapay zeka modellerinin genelleştirilebilirliğini kısıtlayan temel faktörlerdir.¹⁴⁵

Klinik karar verme sürecinin yalnızca radyografik görüntülerle değil, anamnez, fiziksel muayene ve diğer tanı yöntemleriyle birlikte değerlendirilmesi gerektiği düşünüldüğünde, mevcut yapay zeka uygulamalarının klinik teşhiste tam anlamıyla yeterli olamadığı görülmektedir.⁸⁴

Görüntü işleme süreçlerinde veri hacminin azaltılması amacıyla yapılan kırpma ve düşük çözünürlükte analiz uygulamaları, teşhis doğruluğunu olumsuz etkileyerek model performansında düşüşe yol açmaktadır.¹⁴⁶

Sonuç olarak, yapay zeka ve teknolojik ilerlemeler sayesinde diş hekimliği önemli bir dönüşüm geçirmekte olup, teşhis ve tedavi süreçlerinde daha hassas, hızlı ve güvenilir yaklaşımlar geliştirilmiştir. Yapay zeka, özellikle tekrarlayan görevlerin otomatikleştirilmesi ve büyük veri setlerinin analiz edilmesi konusunda önemli avantajlar sunarak klinisyenlerin iş yükünü hafifletmekte ve hata payını azaltmaktadır. Ancak, bu sistemlerin klinik uygulamalarda etkili ve güvenilir şekilde kullanılabilmesi için, yapay zeka algoritmalarının farklı hasta grupları ve klinik senaryolara uyarlanabilirliği titizlikle değerlendirilmelidir. Radyologlar ve diş hekimleri, yapay zekanın gelişimine ayak uydurarak bu teknolojiyi etkin bir şekilde kullanabilmek için gerekli terminoloji ve yöntemlere hâkim olmalıdır. Bununla birlikte, yapay zeka destekli otomasyon, uzmanların karar verme süreçlerinin yerine geçmekten ziyade, daha hızlı teşhis, hastalık risk analizleri ve gelişmiş hasta bakım hizmetleri sunarak klinik uygulamaları destekleyici bir rol üstlenmelidir. Özellikle sağlık hizmetlerine erişimin sınırlı olduğu

bölgelerde, yapay zeka tabanlı sistemlerin hastaların taranması ve erken teşhis süreçlerinde önemli katkılar sağlayacağı öngörülmektedir. Ancak, bu teknolojilerin klinik pratikte güvenilir bir şekilde uygulanabilmesi için, farklı kurumlardan elde edilen geniş ve kaliteli veri setleri kullanılarak modellerin doğruluğu ve geliştirilebilirliği kapsamlı bir şekilde test edilmelidir.¹⁴⁷



3. GEREÇ ve YÖNTEM

3.1. Çalışmanın Amacı ve Dizaynı

Çalışmamızın amacı, derin öğrenme yöntemiyle eğitilmiş olan yapay zeka modelinin, diş hekimliği pratiğinde rutin olarak kullanılan bir görüntüleme yöntemi olan panoramik radyografilerde, 5-12 yaş arası çocukların süt molar dişlerindeki arayüz, bukkal ve oklüzal çürük durumunu değerlendirerek, bunu uzmanlığın farklı senelerinde olan iki çocuk diş hekimliği araştırma görevlisinin (tecrübeli asistan (K.B.) ve yeni asistan (N.İ.Ş.)) ve bir stajyer diş hekiminin (S.G.) panoramik radyografiden yaptıkları arayüz, bukkal ve oklüzal çürük teşhisiyle kıyaslamak ve panoramik radyografilerde arayüz, bukkal ve oklüzal çürük tanısındaki performanslarının karşılaştırılması amaçlandı.

Bu çalışmada, çocuk hastalardan alınan panoramik radyografilerden elde edilen görüntülerde arayüz, bukkal ve oklüzal çürük tespit modellerini oluşturmak için YOLOv8x algoritması kullanıldı. Recep Tayyip Erdoğan Üniversitesi Tıp Fakültesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu çalışma için etik kurul onayı vermiştir (karar tarihi, toplantı numarası ve karar no: 23.05.2024/111). Bu çalışma Recep Tayyip Erdoğan Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü birimince desteklenmiştir (Proje Kodu: TSA 2024-1626).

Bu çalışmada, 5-12 yaş arası çocuk hastalardan alınan panoramik radyografilerden elde edilen görüntüler retrospektif olarak incelendi. Bu radyografiler Recep Tayyip Erdoğan Üniversitesi Diş Hekimliği Fakültesi Çocuk Diş Hekimliği Anabilim Dalı' na 2018-2024 yılları arasında muayeneye başvuran hastalardan elde edilen panoramik görüntülerden oluşmaktadır.

Çalışmaya dahil edilme kriterleri;

- Recep Tayyip Erdoğan Üniversitesi, Diş Hekimliği Fakültesi, Çocuk Diş Hekimliği Anabilim Dalı'na muayene için başvuran hastaların,
- Herhangi bir görüntü artefaktı olmayan,
- Değerlendirilecek süt molar dişlerin en az bir kadranda bulunduğu,
- Herhangi bir sendroma işaret eden görüntü ve bulguların olmadığı,
- İyi kalitede ve uygun yaş aralığında (5-12 yaş) alınmış ,
- 66 kVp, 8 mA, 16.6 sn parametreleri ve Planmeca Promax 2D S2 device (Planmeca Oy; Helsinki, Finland) elde edilmiş panoramik radyografi görüntüleri çalışmaya dahil edildi.


Çalışmadan dışlanma kriterleri;

- Herhangi bir görüntü artefaktı olan,
- Değerlendirilecek süt molar dişin olmadığı,
- Herhangi bir sendroma işaret eden görüntü ve bulguların olduğu,
- Görüntü kalitesi kötü ve uygun yaş aralığında olmayan panoramik radyografiler çalışmaya dahil edilmedi.

3.2. Veri Setinin Hazırlanması

Mevcut çalışmada 2018-2024 yılları arasındaki panoramik radyografi arşivi retrospektif olarak taranıp dahil edilme ve dışlanma kriterleri kapsamında 1533 panoramik radyografi etiketleme için kullanıldı. 7 adet panoramik radyografi, süt molar dişlerde çürük içermediğinden yapay zeka modelinin eğitimine kullanılmadı ve 1526 panoramik radyografi görüntüsü yapay zeka modeli eğitiminde kullanıldı.

Çalışmada değerlendirilen panoramik radyografiler, Recep Tayyip Erdoğan Üniversitesi Diş Hekimliği Fakültesi Çocuk Diş Hekimliği Anabilim Dalı'na muayene için başvuran 5-12 yaş arası çocuk hastalardan elde edildi.



Şekil 3. Veri seti seçimi akış şeması

3.3. Radyografik Görüntülerin Ön İşlemesi

Veri setine anonim olarak dahil edilen ve JPEG formatında kaydedilen 1526 adet panoramik radyografi algoritmaların düzgün çalışabilmesi, bütün radyografilerin aynı olması için 1696 piksel olarak tekrar boyutlandırıldı. YOLOv8x modeli 1696 piksel boyutlarında eğitildi. Bu panoramik radyografilerdeki ince detayları net bir şekilde algılayabilmesi için yeterli bir çözünürlük sağlamaktadır. Yeniden boyutlandırılan görüntülerde; arayüz, bukkal ve oklüzal çürük etiketlemeleri yapıldı.

3.4. Panoramik Radyografiler Üzerinde Çürük Lezyonlarının Etiketlenmesi

Bu retrospektif çalışmanın başlangıç aşamasında ilk olarak, çocuk hastalardan alınan panoramik radyografilerden elde edilen aynı görüntüler, önce bir stajyer diş hekimi, sonra asistanlığının ilk yılındaki uzmanlık öğrencisi tarafından(yeni asistan

(N.İ.Ş.)), daha sonra asistanlığının 2. yılındaki uzmanlık öğrencisi (tecrübeli asistan (K.B.)) tarafından CranioCatch etiketleme yazılımı (Eskişehir, Türkiye) kullanılarak üç araştırmacı tarafından etiketlendi. Her iki çenede de tüm dörtte birlik kısımlarda bulunan süt molar dişlerdeki arayüz, bukkal ve oklüzal çürükler etiketlendi. Yapılan etiketlemeler ile YOLOv8x derin öğrenme algoritması kullanılarak bir çürük tespit modeli elde edildi. Etiketleme sürecinin ikinci aşamasında araştırmacıların çürük teşhisindeki performanslarını kendi içlerinde ve elde edilen yapay zeka modeliyle kıyaslamak için kullanılan veri setinin içerisinden rastgele 100 röntgen seçilip etiketleyici diş hekimlerinden aynı şekilde etiketlemeleri istendi, 10 yıllık tecrübeye sahip bir çocuk diş hekimi uzmanı (A.K.) tarafından bu 100 röntgen için doğru cevap etiketleri oluşturuldu.

3.5. YOLOv8x Modeli Eğitim Aşaması


YOLO algoritmasında veri setleri; eğitim veri seti, validasyon veri seti ve test veri setinden oluşmaktadır. Eğitim veri seti, yapay zeka modelinin eğitimi için kullanılmaktadır. Doğrulama için kullanılan validasyon veri seti, yapay zeka modelinin eğitim sürecinden bağımsız olarak tutulup, hiperparametre optimizasyonu ve genel performans değerlendirmesi amacıyla kullanılan; yapay zeka modelinin aşırı öğrenmesini (overfitting) önlemeye yardımcı olan, ancak eğitim sırasında doğrudan öğrenme sürecine dahil edilmeyen veri kümesidir. Test veri seti, yapay zeka modelinin daha önce görmediği örnekler üzerinde performansını tarafsız ve genel geçer bir şekilde değerlendirmek amacıyla kullanılan, eğitim ve doğrulama süreçlerinden bağımsız tutulan ayrı bir veri kümesidir, yapay zeka modelinin başarısını değerlendirmek amacıyla kullanılmaktadır. YOLOv8x modeli de toplamda 1526 radyografi görüntüsü ve 12499 etiket ile eğitildi. Veri setinin %80'i eğitim, %10'u validasyon ve %10'u test için ayrıldı. Eğitimde 1222 görüntü ve 10023 etiket, validasyon aşamasında 152 görüntü ve 1226 etiket, test aşamasında ise 152 görüntü ve 1250 etiket kullanıldı.

Her bir çürük türüne özgü olarak kullanılan eğitim verileri incelendiğinde arayüz çürükleri için 6529 etiket, oklüzal çürükler için 3300 etiket, bukkal çürükler için 194 etiket kullanıldı.

Test aşamasında; arayüz çürükleri için 793 etiket, oklüzal çürükler için 435 etiket, bukkal çürükler için 22 etiket kullanıldı.


Validasyon aşamasında; arayüz çürükleri için 791 etiket, oklüzal çürükler için 406 etiket, bukkal çürükler için 29 etiket kullanıldı.

Şekil 4’de YOLOv8x yapay zeka modeli eğitim aşamasından örnek bir görüntü gösterilmiştir.



Şekil 4. YOLOv8x yapay zeka modeli eğitim aşaması

YOLOv8x yapay zeka modelinin şekil 5’de arayüz, oklüzal, bukkal tahminleri gösterilmiştir.



Şekil 5. YOLOv8x yapay zeka modeli arayüz, oklüzal, bukkal çürük tahmini

Şekil 6’da YOLOv8x yapay zeka modeli validasyon aşamasından örnek bir görüntü gösterilmiştir.



Şekil 6. YOLOv8x yapay zeka modeli validasyon aşamasından örnek görüntü

Yapay zeka modelinin eğitim süreci 800 epoch olarak belirlendi, early stopping yöntemi ile 33. epochda durduruldu. Epoch, yapay zeka modelinin tüm eğitim verisini baştan sona kaç kez gördüğünü belirler. Early Stopping mekanizması, doğrulama kaybı (validation loss) belirli bir sayıda epoch boyunca iyileşmezse eğitimi sonlandırır. Bu çalışmada yapay zeka modeli, 33. epoch’ ta en iyiyi kaydetti 100 epoch daha ilerledi ama bir artış olmadı , bu da 33. epoch’ tan sonra eğitim sürecinde kayda değer bir gelişme olmadığını gösterir. Eğitimin erken durdurulması, yapay zeka modelinin gereğinden fazla eğitilerek aşırı öğrenmesini (overfitting) engellemek için önemlidir. 800 epoch, yapay zeka modelinin uzun süre boyunca eğitilmesine izin verdiğini gösterir. Ancak, eğitim erken durdurma (early stopping) ile kesildiği için, yapay zeka modelinin 800 epoch’a ulaşmadan en iyi performansı elde ettiği görülmektedir.

Yapay zeka modelinin eğitim sürecinde veri artırma yöntemlerinden; HSV-Hue, Hue-Saturation, HSV-Value, Mosaic kullanıldı. Bu yöntemler YOLOv8x yapay zeka

modelini eğitirken kullanılan görüntü işleme yöntemleridir. Bu yöntemler yapay zeka modelinin sağlamlığını ve genelleme yeteneğini geliştirir, yapay zeka modelinin performansını artırmada önemli rol oynar.

YOLOv8x yapay zeka modelinin eğitimi, görselleştirilmesi, değerlendirilmesi, doğruluk analizleri, sonuçların görselleştirilmesi ve analiz edilmesi için Python (Opencv-Pytorch-Numpy-Pandas-Torch Vision-Torch-Tensorboard-Seaborn) kütüphaneleri kullanıldı.

3.6. Performans Değerlendirme Metrikleri

Çürük tespiti amacıyla geliştirilen yapay zeka modelinin farklı çürük sınıflarına ait veri setleri üzerindeki başarısını ve genel çürük tespit başarısını, etiketleyiciler ve etiketleyicilerin kendi içlerindeki çürük sınıflarına ait ve genel çürük tespit başarısını istatistiksel analizi için performans değerlendirme metrikleri kullanıldı.

Yapay zeka modelinin performansını değerlendirmek için karışıklık matrisi kullanıldı; bu yöntem, gerçek etiketlerin bulunduğu test verileriyle yapay zeka modelinin doğruluğunu analiz etmek amacıyla yaygın olarak tercih edilmektedir. Tahmin edilen ile gerçek olan durum arasındaki ilişkiyi özetler. Değerlendirmede iki tip karışıklık matrisi ortaya çıkar; test setine ait ve eğitim setine ait karışıklık matrisi. Yapay zeka modelinin performansını değerlendirmek için asıl olarak test veri setinin karışıklık matrisi kullanılır. Eğitim seti (train set), yapay zeka modelinin öğrenmek için kullandığı veridir. Bu veriye yapay zeka modeli zaten “alışıktır”, dolayısıyla yüksek doğruluk göstermesi doğaldır. Test seti, yapay zeka modelinin hiç görmediği yeni veridir. Gerçek dünyadaki performansını bu set gösterir. Karışıklık matrisi, yapay zeka modelinin başarısını ölçen ve değerlendiren önemli bir araç olarak kabul edilmektedir.¹⁴⁸

Etiketlenmiş verilerin %10' u (152 panoramik görüntü), eğitim sürecinde hiç kullanılmaz, yapay zeka modeli tarafından ilk kez incelenecek olup yapay zeka modelinin

performansını değerlendirmek için test veri seti olarak ayrıldı. Eğitim ve doğrulama aşamalarının ardından, geliştirilen yapay zeka modelinin öngördüğü etiket alanları, test veri setindeki gerçek etiketlerle karşılaştırılarak gerçek pozitif (GP), yanlış pozitif (YP) ve yanlış negatif (YN) değerleri hesaplandı.

Gerçek Pozitif (GP): Yapay zeka modelinin nesnenin mevcut olduğunu belirttiği ve gerçekte de nesnenin var olduğu durumu ifade etmektedir. Modelin, doğru bir şekilde arayüz, bukkal veya oklüzal çürüğü tespit ettiği ve doğru şekilde etiketlediği durumlar

Yanlış Pozitif (YP): Yapay zeka modelinin, nesnenin mevcut olduğunu belirttiği ancak gerçekte nesnenin bulunmadığı durumu ifade etmektedir. Modelin, gerçekte çürük olmayan bir bölgede arayüz, bukkal ya da oklüzal çürük olduğunu yanlış bir şekilde etiketlediği durumlar)

Yanlış Negatif (YN): Yapay zeka modelinin, nesnenin mevcut olmadığını belirttiği ancak gerçekte nesnenin bulunduğu durumu ifade etmektedir. Modelin, gerçekte çürük bulunan bir bölgeyi (arayüz, bukkal veya oklüzal çürük) yanlışlıkla çürük yok olarak etiketlediği durumlar)

GP, YP, YN metrikleri elde edildikten sonra; duyarlılık (validasyon, recall), kesinlik (precision), F1-skoru, genel ortalama kesinlik (Mean Average Precision, mAP) değerleri birleşim üzerinden ortalama kesişme (IoU-Intersection over Union) oranı dikkate alınarak hesaplanmaktadır. Bu ölçütler, çalışmada derin öğrenme yöntemiyle elde edilen yapay zeka modelinin ve etiketleyicilerin çürük tespitindeki etkinliğini değerlendirmek amacıyla kullanıldı.

Birleşim Üzerinden Ortalama Kesişme (IoU-Intersection over Union): Yapay zeka modelinin tahmin ettiği kutucuk ile etiketlenen kutucuk arasındaki örtüşmeyi ölçen bir orandır. Algoritma tarafından çizilen kutu ile dış hekim tarafından çizilen sınırlayıcı kutunun kesişim alanının iki kutunun birleşimine oranıdır. Etiketlenen bölgenin

lokalizasyonunun doğruluğunun değerlendirilmesinde temel rol oynamaktadır. Güvenilir değerlendirme ve nesne tespitte pozitif kabul edilebilmesi için IoU eşik değeri genellikle 0.50 olarak kabul edilmektedir. Bu çalışmada da IoU eşik değeri 0.50 olarak kabul edilmiştir. IoU değeri ne kadar yüksekse yapay zeka modelinin tespit doğruluğu da o kadar yüksek demektir. $\text{IoU} \geq 0.50$ değerlerinin çürük tespitte göre yorumu; IoU değeri 0.50'nin üzerinde olduğunda yapay zeka modelinin tespit ettiği çürük bölgesinin, etiketlenen çürük bölgesiyle yeterli düzeyde örtüştüğü kabul edilmektedir.¹⁴⁹

IoU'nun matematiksel ifadesi $\text{GP}/(\text{GP}+\text{YN}+\text{YP})$ şeklindedir.

Duyarlılık (validasyon, recall): Yapay zeka modelinin gerçek pozitifleri ne kadar başarılı bir şekilde tespit ettiğini göstermektedir. Gerçek çürük vakaları içerisinde yapay zeka modelin doğru şekilde tespit ettiği çürük oranını ifade etmektedir.

Kesinlik (precision): Pozitif olarak tahmin edilen tüm değerler arasında kaç tanesinin gerçek pozitif tahmin olduğunu ölçen bir performans metriğidir. Yapay zeka modelinde pozitif olarak tespit edilen çürüklerden kaç tanesinin doğru çürük tespiti olduğunu göstermek amacıyla kullanılmaktadır. Matematiksel ifadesi $\text{GP} / (\text{GP} + \text{YP})$ şeklindedir.

F1-skor: F1 skoru, kesinlik ve duyarlılığın harmonik ortalaması olup yapay zeka modelinin genel performansını değerlendirmek için kullanılan bir metriktir. Kesinlik ve duyarlılığın dengesiz olduğu durumlarda (örneğin, model çok fazla yanlış pozitif veya yanlış negatif üretiyorsa), F1 skoru yapay zeka modelinin performansını daha adil bir şekilde değerlendirmek için kullanılmaktadır. Matematiksel ifadesi $2\text{GP} / (2\text{GP} + \text{YP} + \text{YN})$ şeklindedir. 0 ile 1 arasında bir değer alır. 1 en yüksek performansı, 0 ise en düşük performansı temsil etmektedir. F1 skoru 1'e yaklaştıkça yapay zeka modelinin çürük tespitte hem doğru pozitifleri yakalama hem de yanlış pozitiflerden kaçınma konusunda başarılı olduğu anlaşılmaktadır. Düşük F1 skoru ise modelin ya yanlış tespitler yaptığı ya

da bazı çürükleri kaçırdığı anlamına gelmektedir. Genellikle 0.7 den büyük olması yapay zeka modelinin performansının iyi olduğunu göstermektedir.

Genel Ortalama Kesinlik (Mean Average Precision, mAP): Yapay zeka modelin performansını ölçen ve kesinlik ile duyarlılık eğrisinin altındaki alanı ifade eden bir metriktir. Bu değer, yapay zeka modelinin doğru pozitif tahminlerini, yanlış pozitif ve yanlış negatifleri dikkate alarak genel doğruluk seviyesini değerlendirmektedir.

mAP, kesinlik (precision) ve duyarlılık (recall) metriklerine dayanarak hesaplanır. Precision-recall eğrisi çizilir. Eğrinin altındaki alan (AP - Average Precision) hesaplanır. Tüm çürük sınıfları için AP hesaplanır ve ortalaması alınarak mAP elde edilir.

mAP_0.5: IoU eşiği %50 olarak kabul edilir. Eğer tahmin edilen çürük alanı, gerçek çürük alanının en az %50'siyle örtüşüyorsa doğru kabul edilir.

mAP_0.5:0.95: IoU eşiği %50 ile %95 arasında değişen farklı eşiklerde hesaplanır ve ortalaması alınır. Bu daha sıkı bir ölçüttür ve genellikle yapay zeka modelinin genel performansını daha iyi gösterir.

mAP değeri 0 ile 1 arasında değişir ve 1'e yaklaştıkça yapay zeka modelinin hem doğru pozitif tespitleri yüksek hem de yanlış pozitif oranı düşük demektir. Çürük tespitinde yüksek bir mAP değeri, yapay zeka modelinin çürük alanlarını doğru şekilde işaretleme yeteneğinin yüksek olduğunu ve klinik açıdan daha güvenilir sonuçlar ürettiğini göstermektedir.

4. BULGULAR

Bu çalışmada 1526 adet panoramik radyografi görüntüsü üzerinde arayüz, bukkal, oklüzal çürüklerin etiketlemeleri yapıldı. Yapılan etiketlemelerin %80 'i eğitim, %10 'u validasyon, %10' u test amaçlı kullanılarak YOLOv8x derin öğrenme algoritması ile çürük tespiti için bir yapay zeka modeli elde edildi.

Elde edilen yapay zeka modelinin ve etiketleme yapan farklı deneyime sahip üç diş hekiminin arayüz, bukkal ve oklüzal çürük teşhisi performansının değerlendirilmesi için şu metrikler kullanıldı: GP, GN, YN, duyarlılık (recall, validasyon, sensivite), kesinlik (precision, netlik) ve F1 skoru. Bu metriklere ek olarak elde edilen yapay zeka modelinin genel performansı ve başarısı, tespit ettiği nesnelerin (çürüklerin) ne kadar doğru olduğu ve ne kadar az hata yaptığı mAP değeri (mAP_0.5, mAP_0.5:0.95) ile değerlendirildi.


Tablo 2' de elde edilen yapay zeka modelinin ve çürük etiketlemesi yapan farklı deneyimlere sahip üç diş hekiminin çürük tespiti performans değerlendirme metrikleri her bir çürük sınıfı için verildi. Ayrıca farklı deneyimlere sahip üç diş hekiminin her birinin genel çürük değerlendirme performans (genel sonuçlar) metrikleri tabloda görülmektedir.

Tablo 2. Yapay zeka modeli ve farklı deneyime sahip üç diş hekiminin her bir çürük sınıfına göre performans değerlendirme metrikleri


Çürük Sınıfı	Performans Değerlendirme Metrikleri	Stajyer Diş Hekimi	1 Yıllık Tecrübeye Sahip Asistan	2 Yıllık Tecrübeye Sahip Asistan	Yapay Zeka Modeli
Arayüz Çürüğü	GP	226	275	415	408
	YP	268	331	116	215
	YN	414	365	225	385
	Kesinlik	0.4575	0.4538	0.7815	0,65489567
	Duyarlılık	0.3531	0.4297	0.6484	0,51450189
	F1 Skoru	0.3986	0.4414	0.7088	0,57627119
Bukkal Çürük	GP	6	2	12	0
	YP	133	60	11	7
	YN	40	44	34	22
	Kesinlik	0.0432	0.0323	0.5217	0
	Duyarlılık	0.1304	0.0435	0.2609	0
	F1 Skoru	0.0649	0.0370	0.3478	0
Oklüzal Çürük	GP	53	59	82	69
	YP	149	152	61	72
	YN	157	151	128	365
	Kesinlik	0.2624	0.2796	0.5734	0,4893617
	Duyarlılık	0.2524	0.2810	0.3905	0,15898618
	F1 Skoru	0.2573	0.2803	0.4646	0,24
Genel Sonuçlar	GP	285	336	509	477
	YP	550	543	188	294
	YN	611	560	387	772
	Kesinlik	0.3413	0.3823	0.7303	0,6186770428
	Duyarlılık (Recall)	0.3181	0.3750	0.5681	0,3819055244
	F1 Skoru	0.3293	0.3786	0.6390	0,4722772277

Yapay zeka modelin mAP_0.5 değeri 0.31, mAP_0.5:0.95 değeri 0.11 olarak bulundu.

Çalışmada, çürük tespiti yapan modelin performansını değerlendirmek amacıyla, gerçek etiketler ile model tarafından yapılan tahminlerin karşılaştırıldığı bir **karmaşıklık matrisi (confusion matrix)** kullanıldı. YOLOv8x modeli test verilerinin karmaşıklık matrisi Şekil 7 ve 8’de verildi.




Şekil 7. Çürüklerin değerlendirilmesinde YOLOv8x yapay zeka modelinin test verilerinin ham karmaşıklık matris grafiği



Şekil 8. Çürüklerin değerlendirilmesinde YOLOv8x yapay zeka modeli test verilerinin normalize edilmiş (oransal) karmaşıklık matris grafiği

Bounding box, bir görüntü üzerinde yer alan nesnelerin yaklaşık konumlarını ve boyutlarını belirlemek amacıyla kullanılan dikdörtgen biçiminde sınırlayıcı bir kutudur. Görüntüdeki nesnenin sol üst ve sağ alt köşe koordinatları (minimum ve maksimum x-y değerleri) esas alınarak tanımlanır. Bu yöntem, nesne tespiti (object detection) algoritmalarında oldukça yaygın olarak kullanılmakta olup, nesnenin konumuna ilişkin temel bir gösterim sunar. Ancak bounding box'lar, nesnenin detaylı kenarlarını veya gerçek şeklini tam olarak yansıtmaz; yalnızca nesnenin genel yerleşimini ve alanını ifade eder. Nesne tespit modellerinin başarımı ise, yapay zeka modeli tarafından tahmin edilen kutu ile gerçek kutu arasındaki örtüşme oranı gibi ölçütlerle değerlendirilmektedir.¹⁵⁰


Şekil 9, YOLOv8x modelinin farklı güven seviyelerinde elde ettiği göre F1 skorunu gösterir. F1 skoru, kesinlik (precision) ve duyarlılık (recall) metriklerinin harmonik ortalaması olup, özellikle dengesiz veri kümelerinde yapay zeka modelinin genel başarımını değerlendirmenin etkili bir göstergedir. Eğrideki yüksek değerler, yapay zeka modelinin ilgili güven seviyelerinde daha dengeli ve başarılı tahminler yaptığını göstermektedir. Farklı çürük sınıflarına göre performans eğrileri ayrı ayrı çizilmiştir. Kalın mavi çizgi ise tüm sınıflar için hesaplanan ortalama F1 skorunu temsil eder, yapay zeka modelinin genel performansını gösterir.



Şekil 9. YOLOv8x BoxF1-curve grafiği


Şekil 10, yapay zeka modelinin farklı güven seviyelerinde (confidence threshold) gerçekleştirdiği kesinliği gösterir. Kesinlik (precision), modelin pozitif olarak sınıflandırdığı örneklerin ne kadarının gerçekten doğru olduğunu ifade eden bir

performans ölçütüdür. Eğri üzerinde görülen yukarı yönlü eğilim, ilgili güven düzeyinde modelin daha isabetli ve güvenilir tahminler ürettiğini göstermektedir.




Şekil 10. YOLOv8x BoxP-curve grafiği

Şekil 11 modelin kesinlik (precision) ve duyarlılık (recall) performansları arasındaki dengeyi görselleştirmektedir. Duyarlılık arttıkça yapay zeka modelinin pozitif örnekleri tespit etme yeteneği artarken, kesinlik ise bu pozitif tahminlerin doğruluğunu yansıtır. Eğrinin üst kısımlarında kalan bölgeler, yapay zeka modelinin yüksek doğrulukta ve aynı zamanda daha geniş kapsamda pozitif örnekleri doğru şekilde tanımlayabildiğini göstermektedir.




Şekil 11. YOLOv8x BoxPR-curve grafiği

Şekil 12 farklı güven seviyelerinde yapay zeka modelinin pozitif sınıfları ne kadar doğru tespit ettiğini gösterir. Duyarlılık (recall), gerçek pozitiflerin ne kadarının model tarafından doğru şekilde tanımlandığını belirtir. Yüksek güven seviyelerinde duyarlılığın azalması, modelin daha az örneği doğru sınıflandırarak daha temkinli bir yaklaşım sergilediğini ifade eder.




Şekil 12. YOLOv8x BoxR-curve grafiği


Mask (maske), görüntü segmentasyonu süreçlerinde her bir piksele bir sınıf etiketi atayarak nesnelerin sınırlarını net bir şekilde belirleyen bir tekniktir. Bu sayede nesnelerin tam şekilleri ve sınırları tespit edilir. Maskeler, özellikle görüntüdeki hedef nesnelerin çevresel ve şekilsel özelliklerinin doğru bir biçimde tanımlanması amacıyla kullanılır. Maske, görüntüdeki piksellerin nesneye ait olup olmadığını, arka plandan ayırarak modelin tespit doğruluğunu artırır ve segmentasyonun doğruluğunu sağlar. Bu teknik, piksel seviyesinde nesne ayırma görevlerinde, yani görüntü segmentasyonu işlemlerinde kullanılır. Yapay zeka modeli yalnızca nesnenin konumunu değil, aynı zamanda şeklini de tanımlar ve her bir nesne için ayrı bir piksel maskesi oluşturur.¹⁵¹ YOLOv8x için segmentasyon grafikleri Şekil 13’de F1-güven, Şekil 14’de kesinlik-güven, Şekil 15’de kesinlik-duyarlılık, Şekil 16’de duyarlılık-güven eğrileri olarak belirtilmiştir.




Şekil 13. YOLOv8x MaskF1-curve grafiği



Şekil 14. YOLOv8x MaskP-curve grafiği




Şekil 15. YOLOv8x MaskPR- curve grafiği



Şekil 16. YOLOv8x MaskR-curve grafiği

Epoch ilerleyişine bağlı olarak performans metriklerinin hızla 1 değerine yaklaşması ve kayıp fonksiyonlarının (loss) 0 değerine yaklaşmaya başlaması, başarılı bir eğitim sürecine işaret eden ve beklenen grafiksel eğilimlerdir. Eğitim kaybı (Training loss) eğrisinde modelin eğitimi sırasında kaybın (loss) nasıl azaldığını incelenmektedir. Eğer kayıp değeri epoch ilerledikçe düzenli olarak düşüyorsa, bu modelin öğrenme sürecinde başarılı olduğunu gösterir. Doğrulama kaybı (Validation loss) eğrisinde eğer doğrulama kaybı da benzer şekilde düşüyorsa, modelin genelleme yeteneği iyi demektir. Ancak, doğrulama kaybı eğitim kaybından daha fazla düşüyorsa veya artıyorsa, aşırı öğrenme (overfitting) sorunuyla karşılaşıyor olabilir. Eğer eğitim kaybı sürekli düşerken doğrulama kaybı bir noktada duraklıyor veya artıyorsa, bu aşırı öğrenme (overfitting) belirtisi olabilir. Bu durumda, model eğitim verisine çok fazla uyum sağlıyor ve genel verilerdeki örüntüleri iyi öğrenemiyor demektir. Underfitting, kayıp değerlerinin başlangıçta çok yüksek olup hiç düşmemesi veya çok yavaş düşmesiyle kendini gösterir. Bu, modelin yetersiz öğrenmesini veya çok basit bir model yapısı kullanıldığını gösterir. Şekil 17’de epoch ilerleyişine göre YOLOv8x çürük tespiti performansı grafikleri belirtilmiştir.



Şekil 17. Epoch ilerleyişine göre YOLOv8x çürük tespiti performans grafikleri

5. TARTIŞMA

Bu tez çalışmasında, Recep Tayyip Erdoğan Üniversitesi Diş Hekimliği Fakültesi Çocuk Diş Hekimliği Anabilim Dalı' na muayene için başvuran 5-12 yaş arasındaki çocuk hastalara ait toplam 1526 panoramik röntgen görüntüsü kullanılmış, bu görüntüler üzerinde arayüz, bukkal ve oklüzal çürükler üç farklı düzeyde deneyime sahip diş hekimi (tecrübeli asistan, yeni asistan ve stajyer diş hekimi) tarafından etiketlendi. Etiketlenen veriler ile YOLOv8x derin öğrenme algoritması kullanılarak bir yapay zeka modeli geliştirildi. Modelin ve etiketleyici diş hekimlerinin çürük tespiti konusundaki diagnostik doğruluğu değerlendirildi. Bu doğrultuda, elde edilen yapay zeka modelinin ve etiketleyici diş hekimlerinin genel ve çürük sınıflarına göre çürük tespit performansları; GP, GN, YN, duyarlılık, kesinlik ve F1 skoru metrikleri kullanılarak değerlendirildi.

Elde edilen bulgulara göre, yapay zeka modelinin özellikle arayüz çürük sınıfında diğer çürük sınıflarına göre daha yüksek duyarlılık ve kesinlik değerlerine ulaştığı, bu çürük sınıfında orta seviyede başarı gösterdiği; oklüzal çürük sınıfında zayıf bir performans gösterdiği ve modelin performansının geliştirilmesi gerektiği; bukkal çürük sınıfında ise düşük performans gösterdiği tespit edildi. Ayrıca, tecrübeli asistanın tarafından yapılan etiketlemelerin, modelin başarısını anlamlı derecede artırdığı görüldü. Bu sonuçlar doğrultusunda, “H0: Derin öğrenme yöntemi kullanılarak geliştirilen yapay zeka modelinin, dental çürüklerin diagnostik doğruluğu üzerinde etkisi yoktur.” hipotezi reddedildi, “H1: Derin öğrenme yöntemi kullanılarak geliştirilen yapay zeka modelinin, dental çürüklerin diagnostik doğruluğu üzerinde etkisi bulunmaktadır.” hipotezi kabul edildi.

Diş çürüğü, birçok toplumda yaygın olarak görülen, multifaktöriyel, önlenabilir, enfeksiyöz bir hastalıktır.¹ Diş çürüklerinin erken teşhisi; dişin ağızda fonksiyonunu sürdürmesine, tedavi maliyetlerinin azaltılmasına, hastanın yaşam kalitesinin

artırılmasına katkı sağlamaktadır.² Ayrıca erken dönemdeki çürük lezyonlarının remineralizasyonu, daha az invaziv veya noninvaziv tedavilerle hasta konforunun daha yüksek olduğu ve dental anksiyetenin azaldığı tedavi seçenekleri sağlamaktadır. Özellikle çocuk hastalarda çürüklerin erken teşhisi daha az invaziv tedavi prosedürleriyle komplike işlemlerin çocuklardaki psikolojik yükünden kaçınmamıza olanak sağlamaktadır. Dental anksiyete ile baş edilmesinde hem diş hekimine hem de çocuk hastaya fayda sağlamış olur. Rutin klinik uygulamalarda görsel, dokunsal, radyografik muayene yöntemleri kullanılmaktadır.²⁵ Panoramik radyografi rutin klinik muayenede en sık kullanılan, dişler ve çevre dokuları geniş perspektifte değerlendirilmesini sağlayan ekstraoral radyografilerdir.¹⁵² Fakat özellikle arayüz çürük teşhisinde yeterince ayrıntı vermemeleri, süperpozisyon, magnifikasyon ve düşük çözünürlük göstermeleri dolayısıyla intraoral radyografilere ihtiyaç duyulabilmektedir.⁶ Çocuk hastalarda özellikle süt molar dişlerde sıklıkla arayüz çürükleri görüldüğünden yardımcı radyografik teşhis yöntemi olarak bitewing radyografilere ihtiyaç duyulmaktadır.³² Fakat bu yöntemlerle diş hekimleri erken çürük lezyonlarını gözden kaçırabilmektedir. Bundan dolayı birçok çürük teşhis yöntemi geliştirilmiştir.³ Diş hekiminin klinik pratikte iş yükünü azaltacak, ekstra teşhis yöntemlerine ihtiyaç duyulamayan, objektif, otomatik tespit yöntemlerinin geliştirilmesine ihtiyaç vardır. Yapay zekanın alt dalı olan derin öğrenme yöntemi günümüzde diş çürüğü teşhisinde popüler bir konu haline gelmiştir. Diş çürüğü tespitinde derin öğrenme yöntemleri diş hekiminin daha erken, doğru ve daha pratik teşhis yapmasına katkı sağlayabilmektedir.⁸

Bu çalışmada rutin klinik muayenede sıklıkla kullanılan panoramik radyografiler üzerinde, süt molar dişlerde arayüz, bukkal ve oklüzal çürüklerin tespiti için KSA eğitimi ve KSA'nın çürük tespit performansının farklı tecrübelerle sahip üç diş hekimi (tecrübeli asistan (K.B.) ve yeni asistan (N.İ.Ş.)) ve bir stajyer diş hekiminin (S.G.)) ile

karşılaştırmak faydalı görüldü. Böylece elde edilen yapay zeka modeli, diş hekimlerinin çürük tespit performansları ve yapay zeka modeli ile diagnostik doğruluğun artırılması ile ilgili bir öngörü sağlanmış olacaktır.

Çalışmamızda veri setini oluştururken panoramik radyografilerden yararlanma nedenlerimiz arasında rutin klinik muayenede en sık kullanılan radyografik teknik olması, tek bir radyografiyle dişler, çene kemikleri, daimi diş germelerinin, büyüme ve gelişimin değerlendirilebilmesi, diş erüpsiyonlarının değerlendirilebilmesi, çocuk hastalarda uygulanmasının kolay olması, çocukların kolay tolere edebildiği bir teknik olması, tek filmde tüm oral yapıları değerlendirme açısından intraoral tekniklere göre daha az radyasyona maruziyet gibi yer almaktadır. Ayrıca nonkoopere çocuk hastalarda uygulama kolaylığı ve tek seferde tüm yapıyı değerlendirme olanağı açısından bu hasta grubunda değerli bir teşhis yöntemi olmaktadır.¹⁵³ Yapay zekanın panoramik radyografi analizinde kullanımıyla ilgili makalelerin çoğu 2019 ve sonrasında yayınlandı.¹⁴ Zanini ve ark.¹⁵⁴ radyografilerde derin öğrenme yöntemi kullanılarak çürük tespiti ve sınıflandırmasıyla ilgili yaptıkları sistematik bir incelemede her radyografi tekniğinin farklı kullanım avantajı olduğunu, panoramik radyografilerin tüm dişlerin kapsamlı görüntülenmesini sunarak analiz ve tespit yeteneğini artırma açısından değerli bir yöntem olarak öne çıktığını söylemişlerdir. Literatürde yapay zeka modeli ile çürük tespiti yapan çalışmalardan farklı radyografi tekniklerini kıyaslayan bir çalışma olmamakla birlikte Rahimi ve ark.¹⁵⁵ derin öğrenme modelleri kullanılarak çürük tespiti yapan çalışmalarda kullanılan diagnostik yöntemlerle ilgili bir sistematik inceleme yapmışlardır. Yapılan sistematik incelemede oluşturulan yapay zeka modellerin diagnostik yöntemlere göre doğruluklarının ağız içi fotoğraflarda %71 ila %96, periapikal radyografilerde %82 ila %99,2, bitewing radyografilerinde %87,6 ila %95,4, yakın kızılötesi transillüminasyon görüntülerinde %68 ila %78, optik koherens tomografi görüntülerinde %88,7 ila %95,2

ve panoramik radyografilerde %86,1 ila %96,1 arasında deđiřtiđini bulmuřlardır. Gelecekte hem panoramik hem de intraoral radyografi yntemlerini ieren, derin ğrenme yntemleri kullanılarak yapılan rk tespitinin kullanılan radyografi tekniđine gre karřılařtırma yapılan alıřmalar planlanabilir. Panoramik radyografilerde iyileřtirmelerin ve grnt iřleme tekniklerinin uygulanmasıyla znrlđnn ve tanıdaki performansının arttıđı Suryani ve ark.¹⁵⁶ karışık diřlenme dnemindeki ocuk hastalarda yaptıkları alıřmada grlmřtr. Bhat ve ark.¹⁵⁷ 2024 yılında 2-13 yař aralıđındaki ocuklardan elde edilen pediatrik panoramik radyografilerde diř rkleri ve diř anomalilerinin tespiti iin zel bir derin ğrenme modeli olan DRA (Diř Radyografisi Analizi)'yı kullanmıřlardır. Histogram eřitleme ve filtreleme yntemlerinin n iřleme teknikleriyle birlikte kullanımıyla, panoramik radyografinin intraoral radyografilere gre dezavantajı olan dzensiz aydınlatma ve kontrastla ilgili sorunları etkili bir řekilde ele alarak genel grnt kalitesini artırılmıřtır. Model rk tespitinde %97,01'lik yksek bir dođruluk elde etmiřtir. Benzer řekilde mevcut alıřmadada YOLOv8x modelini eđitirken grnt iřleme yntemleri kullanıldı, fakat buna rađmen modelin rk tespit performansının orta seviyede olduđu grld. Farklı grnt iřleme yntemlerinin kullanımının faydalı olabileceđi dřnlmektedir.

alıřmamızda panoramik radyografilerde arayz, bukkal ve oklzal rk tespiti iin YOLOv8 algoritması kullanılarak derin ğrenme tabanlı bir yapay zeka modeli geliřtirilmiřtir.  etiketleyici ve elde edilen yapay zeka modelinin arayz, bukkal,oklzal ve genel rk tespit bařarıları deđerlendirmiřtir.

Arayz rkleri  etiketleyici ve yapay zeka modelinin en iyi tespit yaptıđı rk sınıfı olmuřtur. Bunun sebebi ocuklarda st molar diřlerdeki arayz rklerinin sık grlmesine ve rntgende daha belirgin grlmesine bađlı olarak veri setindeki arayz rk sınıfının diđer sınıflara gre daha fazla olması olabilir. Arayz rk

tespitinde en yüksek duyarlılık, kesinlik ve F1 skoru değerleri sırasıyla 0,64, 0,78, 0,70 olup tecrübeli asistanda elde edilmiştir. Tecrübeli asistanın her 100 çürükten 64'ünü doğru şekilde tespit ettiğini söyleyebiliriz. 0,78 kesinlik, tecrübeli asistanın etiklediği çürüklerin ne kadarının gerçekten çürük olduğunu gösterir, tecrübeli asistanın etiklediği arayüz çürüklerinin %78' i gerçekten çürük. 0,70 F1 skoru, duyarlılık ve kesinliğin dengelenmiş bir ölçütü olup tecrübeli asistanın genel doğruluğunu ifade eder. Bu değerlere göre, tecrübeli asistanın çürükleri tespit etmede başarılı ancak hala kaçırdığı çürükler bulunuyor (duyarlılığın 1,0 olmaması). Öte yandan, kesinlik nispeten yüksek olduğu için yanlış çürük tespit etme oranı görece düşük. F1 skoru da dengeli bir performansa sahip olduğunu gösteriyor. Dört model arasındaki kıyası sırasıyla yapay zeka modeli, yeni asistan ve stajyer hekim takip etmiştir. Yapay zeka modelinin duyarlılık, kesinlik ve F1 skoru sırasıyla 0,51, 0,65, 0,57' dir. Bu değerler yapay zeka modelinin gerçek çürüklerin %51,4'ünü doğru tahmin ettiğini, ancak %48,6'sını kaçırdığını gösteriyor. Bu, yapay zeka modelinin çürüklerin neredeyse yarısını atladığını gösteriyor. Özellikle erken teşhis açısından önemli olan çürüklerin kaçırılması, yapay zeka modelinin duyarlılığının daha yüksek olması gerektiğini gösteriyor. Yapay zeka modelinin tahmin ettiği çürüklerin %65,5'inin gerçekten çürük olduğunu gösteriyor. Yanlış pozitif oranı hala biraz fazla, ancak yapay zeka modelinin gereksiz çürük teşhisi yapma eğilimi çok yüksek değil. Bu oran klinik kullanımlar için orta seviyede kabul edilebilir, ancak hatalı çürük tahminleri nedeniyle gereksiz müdahaleler olabileceğini gösteriyor. F1 skoru, kesinlik ve duyarlılık arasındaki dengeyi ölçen bir metriktir. 0,57 değeri, yapay zeka modelinin ne çok fazla YP ürettiğini ne de çok fazla YN ürettiğini gösteriyor. Ancak bu skor, ideal olarak 0,70 veya daha üzerinde olmalıdır. Mevcut değer, modelin dengeli bir performans gösterdiğini ancak hala iyileştirilmesi gerektiğini ortaya koyuyor. Genel olarak arayüz çürüklerinde model orta seviyede bir performans

göstermektedir ancak YN oranı yüksek olduğu için klinik uygulamalarda güvenilirliği artırmak adına daha fazla optimizasyona ihtiyaç vardır. En düşük duyarlılık ve F1 değeri stajyer hekimde elde edilmiştir. Stajyer ve yeni asistanın kesinlik değeri çok az bir farkla stajyer hekimde daha yüksek olmakla birlikte bu iki etiketleyiciyi kıyasladığımızda arayüz çürük performansları arasında az bir farkla yeni asistan daha iyi performans göstermiştir. Daha yüksek bir duyarlılık elde etmek için daha fazla ve çeşitli veri üzerinde etiketleme yapılması veya parametre optimizasyonu yapılması gerekebilir. (etiketlenmiş veri sayısının artırılması, veri çoğaltma (data augmentation) teknikleri, farklı derin öğrenme mimarilerinin kullanılması). Bayatı ve ark.¹⁵⁸ bizim çalışmamıza benzer şekilde arayüz çürüklerinin tespiti için YOLOv8 derin öğrenme modelini kullanarak bir model elde etmişlerdir. Modelin duyarlılık ve F1 skorları sırasıyla %79 ve %82 bulunmuştur. Karakuş ve ark.¹⁵⁹ bizim çalışmamıza benzer şekilde 3 çürük tipinin tespiti için YOLOv8 derin öğrenme yöntemini kullanarak bir model elde etmişler. Etiketlemeleri bitewing radyografiler üzerinde 3 yıllık ve 12 yıllık deneyime sahip radyologlar tarafından yapılmıştır. Ayrıca veri artırma (data augmentation) yöntemleriyle veri sayısı artırılmıştır. Modelin genel performansını değerlendiren kesinlik, duyarlılık, F1 ve mAP skorları 0,96 olarak bulunmuştur.¹⁵⁹ Modelin performansı bizim çalışmamıza göre yüksek ve dengelidir. Bizim çalışmamızla aynı model kullanılmasına rağmen daha yüksek başarı elde etmelerinin sebebi arayüz çürüklerinin teşhisinde esas olarak kullanılan ayırntı ve çözünürlüğün panoramik radyografiye göre daha iyi olduğu bitewing radyografilerini kullanmaları olabilir. Bayatı ve ark.¹⁵⁸'nın çalışması görüntü kalitesindeki tutarsızlıkların kişilerin tecrübesine göre çürük tespitinde gözlemciler arasında farklılıklara sebep olabileceğini söyleyip hekim deneyiminin çürük teşhisindeki önemini de vurgulamıştır.¹⁵⁸ Karakuş ve ark. çalışmasıyla aynı derin öğrenme mimarisini kullanıyor olmamıza karşın elde ettikleri modelin başarısının yüksek çıkmasının sebeplerinden biri

etiketleyici hekimlerin tecrübeleri olabilir. Bitewing radyografi kullanımı veya panoramik radyograflerin görüntüsünü artıracak farklı ön işleme çalışmalarının yapılması, tecrübeli hekimlerle modelin eğitilmesi, modelin başarısını artırabilir. Ayrıca hekimler arasında çürük etiketleme konusunda iş birliği yapılması modelin ve hekimlerin hem çürük tespitinde daha dengeli olmasına hem de modelin başarısının artmasına katkı sağlayabilir. Arayüz çürük tespiti için Faster R-CNN mimarisi kullanılarak bitewing radyograflerde etketleme yapan Chen ve ark.¹⁶⁰ çalışmasında 3 yıldan az deneyime sahip 2 uzmanlık öğrencisi ve bir radyoloğun bitewing radyograflerde arayüz çürük etiketlemeleriyle gerçekleştirilmiştir, uzmanlık öğrencilerinin F1 skoru 0,57, elde edilen modelin F1 skoru 0,74 olarak elde edilmiştir. Bizim çalışmamızda tecrübeli asistanın arayüz çürük tespiti için F1 skoru daha yüksektir fakat modelimizinki daha düşüktür. Bunun sebebi kullanılan modelin farklı olması olabilir. Bizim çalışmamızdaki tecrübeli asistanın F1 skorunun yüksek bulunmasının sebebi hekimlerin tecrübesiyle ilgili olabilir. Chen ve ark. çalışması¹⁶⁰ uzmanlar arasında fikir birliği olsun diye çalışmayı yaparken her hekime tanı kriterleri ve yazılım talimatlarını içeren bir el kitabı verilmesini faydalı görmüş ve bunu çalışmasında uygulamıştır. Modellerinin başarısı bu nedenle de yüksek bulunmuş olabilir.¹⁶⁰ Bayrakdar ve ark¹⁶¹, da bu çalışmalara benzer şekilde bitewing radyograflerde arayüz çürük tespiti için YOLOv3 tabanlı bir derin öğrenme algoritması kullanarak bir model elde etmişlerdir. Etiketlemeleri 10 yıldan fazla deneyime sahip 2 uzman diş hekimi yapmıştır. Çalışmalarında duyarlılık değeri %72,26 olarak bulunmuştur. Bizim çalışmamıza göre daha düşük bir YOLO modeli kullanılmasına rağmen yüksek başarı elde edilmesinin sebebi bitewing radyografi kullanılmış olması ve etiketleyicilerin tecrübelerinden kaynaklı olabilir.¹⁶¹

Bukkal çürük sınıfı üç etiketleyici ve yapay zeka modelinin en düşük çürük tespit performansı gösterdiği sınıf olmuştur. Bukkal çürük tespitinde en yüksek duyarlılık,

kesinlik ve F1 skoru deęerleri sırasıyla 0,26, 0,52, 0,34 olup tecrübeli asistanda elde edilmiştir. Tecrübeli asistan, mevcut bukkal çürüklerin yalnızca %26'sını doğru tespit edebilmiş. Yani, hala kaçırılan birçok çürük var. Tecrübeli asistanın çürük olarak işaretledięi bölgelerin %52'si gerçekten çürük. Bu, nispeten iyi bir deęer ve YP oranının düşük olduğunu gösteriyor. F1 skorunun 0,34 olması, modelin performansının orta seviyede olduğunu gösteriyor, ne çok iyi ne de çok kötü. Özetle, bukkal çürükleri saptamada tecrübeli asistan en iyi performansı gösterse de, duyarlılık hala düşük olduęu için bu sınıf geliştirilmelidir. Stajyer hekim, yeni asistan ve yapay zeka modeli arasında anlamlı bir fark olmamakla birlikte duyarlılık, kesinlik ve F1 deęerleri neredeyse 0'dır. Özellikle stajyer ve yeni asistanın sonuçlarının düşük olması modelin bukkal çürüğü öğrenmesini zorlaştırmış olabilir. Bukkal çürükler tüm etiketleyiciler ve yapay zeka modeli için tespiti zor olan çürük sınıfı olmuştur.¹⁵⁷ Yapay zeka modelinin eğitim aşamasında yalnızca 194 bukkal çürük etiketi bulunuyor, bu da dięer çürük türlerine kıyasla çok düşük bir veri miktarı olduğunu gösteriyor (arayüz etiketi: 6529, oklüzal etiket: 3300). Test aşamasında yalnızca 22 bukkal çürük etiketi var, yani yapay zeka modelinin bu çürük türünü öğrenmesi ve genelleme yapması oldukça zor olabilir. Bu sınıfın iyileştirilmesi gerekmektedir. Görüntü işleme teknikleriyle bukkal çürüklerin görüntüsü iyileştirilebilir, daha fazla bukkal çürük içeren ve genel çürük sınıflarının sayısının dengeli olabildięi bir veri seti kullanılabilir. Dayı ve ark.¹⁶²'nin çalışmasında oklüzal, arayüz ve servikal çürüklerin tespitinde derin öğrenmenin tanısai performansını deęerlendirmeyi amaçladıkları çalışmasında bizim çalışmamıza benzer şekilde servikal çürüklerin F1 skoru düşük bulunmuştur. Bunun sebebi bizim çalışmamıza benzer şekilde servikal çürükler için yetersiz veri setinden ötürü kullanılan derin öğrenme mimarisinin bu tip çürükleri yeterince öğrenememesi olabilir. Dięer bir neden ise panoramik radyografilerin 2 boyutlu görüntüler olması ve bu tip çürüklerin genellikle dişlerin

vestibül ve lingual bölgesinde yer alması, bu nedenle daha yoğun sağlıklı diş dokusu ile örtüşmesi ve aynı zamanda pulpa odasının radyografi üzerindeki radyolüsent yansıması ile örtüşmesi nedeniyle tespit edilmesinin zorluğundan olabileceğini söylemişlerdir. Oklüzal ve arayüz çürüklerinin F1 skoru bizim çalışmamız gibi çürük performansında servikal çürük sınıfına göre daha iyi bulunmuştur fakat değerleri bizim yapay zeka modelimizden yüksektir bunun da sebebi etiketleyicilerin tecrübesi olabilir. (Dayı ve ark. çalışmalarında 8 yıllık tecrübesi olan restoratif diş tedavisi uzmanı ve 5 yıllık tecrübeye sahip radyolog tarafından panoramik görüntüler üzerinden çürük etiketlemeleri yapılmıştır.)

Oklüzal çürük sınıfı üç etiketleyici ve yapay zeka modelinin en iyi 2. tespit yaptığı çürük sınıfı olmuştur. Oklüzal çürük tespitinde en yüksek duyarlılık, kesinlik ve F1 skoru değerleri sırasıyla 0,39, 0,57, 0,46 olup tecrübeli asistanda elde edilmiştir. Tecrübeli asistan oklüzal çürüklerin %39'unu doğru tespit edebilmiş. Bu, tecrübeli asistanın birçok oklüzal çürüğü kaçırdığını ancak diğer gruplara kıyasla daha iyi bir başarı sağladığını gösteriyor. Tecrübeli asistanın çürük olarak işaretlediği bölgelerin %57'si gerçekten çürük. Yani, yanlış çürük tahmini yapma oranı nispeten düşük. F1 skoru 0,46 ile dengeli bir sonuç veriyor, yani tecrübeli asistan diğer gruplara göre ve genel olarak kabul edilebilir bir doğruluk seviyesine ulaşmış. Yapay zeka modelinin oklüzal çürükler için duyarlılık, kesinlik, F1 skoru, değerleri sırasıyla 0,15, 0,48, 0,24 dır. Yapay zeka modelinin duyarlılık ve F1 skoru bakımından stajyer diş hekimi ve yeni asistanın gerisinde kaldı. Kesinlik açısından stajyer diş hekimi ve yeni asistandan daha iyi bulundu fakat duyarlılığı çok düşük bulundu. Yapay zeka modeli birçok çürüğü atlıyor ve çürük tespitinde yetersiz. Yapay zeka modeli, oklüzal çürüklerin yalnızca %15,9'unu doğru tespit edebilmiş, büyük kısmını kaçırmıştır (YN: 365). Yapay zeka modelinin oklüzal çürük olarak tahmin ettiği dişlerin %48,9'u gerçekten oklüzal çürük. Kesinlik ve

duyarlılığı birlikte değerlendiren F1 skoru düşük. Bu, yapay zeka modelinin oklüzal çürükleri tespit etmede zayıf bir performansa sahip olduğunu gösteriyor. Oklüzal çürükleri kaçırma oranı çok yüksek olduğundan, klinik kullanımı için yeterli performans göstermiyor. Bu nedenle, duyarlılığı artıracak şekilde modelin eğitimi güçlendirilmelidir. Bu performans birkaç sebepten dolayı olabilir. Veri setindeki dengesizlik ve eğitim verisinde oklüzal çürük sayısının az olması olabilir. Modelin oklüzal çürükleri daha iyi algılayabilmesi ve öğrenebilmesi için daha fazla eğitim verisi gerekebilir. Oklüzal çürükleri içeren örnekler artırılabilir ve veri seti dengelenebilir. Ayrıca oklüzal çürükler bazen özellikle diş ve çürük bölgelerinin sınırlarını belirlerken yanıltıcı kontrast algısına neden olabilir veya kontrastlarının düşük olmasından diğer yüzeylerden daha zor fark edilir olabilir. Bu optik illüzyonların algılanması gözlemciler arasında onların tecrübelerine bağlı olarak değişir.¹⁶³ Bu tür optik illüzyonların etkisini minimize etmek çürüklerin kontrastını artırmak için röntgen görüntüleri ön işleme tabi tutulup ve kontrast ayarlamaları yapmak faydalı olabilir. Karakuş ve ark.¹⁵⁹ çalışmalarında oklüzal, servikal ve arayüz çürük tespitindeki YP'lerin sebebinin optik illüzyonlar olabileceğini düşünmüş, bunun etiketleyiciler arasında algılanmasının farklı olabileceğini söylemişlerdir. Alternatif model mimarileri denenerek, özellikle düşük duyarlılığı artırmaya yönelik görüntü optimizasyonlar yapılabilir. Dayı ve ark.¹⁶² çalışmasında bizim çalışmamızdan farklı bir derin öğrenme mimarisi kullanılmış olup, etiketleyiciler 5 ve 8 yıllık tecrübeli hekimlerdir. Bundan dolayı oklüzal çürüklerde bizim çalışmamızdan daha iyi bir başarı elde etmiş olabilirler. Stajyer hekim ve yeni asistanın performansları benzerdi fakat yeni asistan daha iyi sonuçlar vermiştir.

Etiketleyicilerin ve yapay zekanın en yüksek duyarlılık, kesinlik ve F1 skoru tecrübeli asistanda elde edilmiştir. Bunun sebebi tecrübeli asistanın etiketleri baz alınarak yapay zeka modelinin elde edilmesi olabilir. Bu sırayı yapay zeka modeli takip etmekle

birlikte en düşük duyarlılık, kesinlik ve F1 skoru stajyer hekimde elde edildi, bu da stajyer hekimin deneyim eksikliğinin tanı başarısını doğrudan etkilediğini gösteriyor. Stajyer hekim ve yeni asistanın performansları benzerdi fakat yeni asistan daha iyi sonuçlar vermiştir. Tichý ve ark.¹⁶⁴ yaptıkları çalışmada 4 uzman ve 3 acemi diş hekimi 100 bitewing radyografi üzerinde etiketleme yapmış, derin öğrenme yöntemi ile oluşturulan otomatik çürük tespit modeli ile çürük tespit performansları kıyaslanmışlardır. Mevcut çalışmaya benzer şekilde otomatik sistemin hata sayısında orijinal etiketleyici dışındaki tüm diş hekimlerinden daha iyi performans gösterdiğini ve IoU açısından en iyiler arasında yer aldığını göstermişlerdir. Mevcut çalışmaya benzer şekilde otomatik yöntemin acemi diş hekimlerinden daha iyi performans gösterdiğini göstermişlerdir. Tichý ve ark.¹⁶⁴ çalışmasında mevcut çalışmadaki gibi çürük tespiti konusunda uzmanlar arasında fikir birliği düşük olduğunu ve derin öğrenmeye dayalı otomatik bir yöntemin çürük tespitinin hem doğruluğunu hem de tekrarlanabilirliğini artırabileceğini söylemişlerdir.

Yapay zeka modelinin duyarlılık, kesinlik ve F1 skoru sırasıyla, 0,38, 0,61, 0,47 dir. Bu verilere bakıldığında yapay zekanın genel çürük tespit performansı orta seviyededir. Yapay zeka modelinin kesinlik ve duyarlılık değerleri arasındaki fark açılmıştır. Bu fark genellikle modelin temkinli tahmin yapmasından kaynaklanır. Yani model, "çürük" demek için yüksek güven gerekir şeklinde davranıyor. Bu da YP oranını azaltıyor (kesinlik artıyor), ama bazı çürükleri gözden kaçırmaya neden oluyor (duyarlılık düşüyor). Yapay zeka modelinin çürük tespit performansını değerlendirmek için ölçülen mAP_{0,5} değeri 0,315' tir. Bu, IoU değeri %50 kabul edildiğinde yapay zeka modelinin %31,5 doğrulukla çürük bölgelerin yaklaşık üçte birini doğru tahmin edebildiğini göstermektedir. Klinik uygulamalar açısından değerlendirildiğinde bu oranın daha yüksek olması, yapay zeka modelinin güvenilirliğini artıracaktır. Daha katı

bir değerlendirme kriteri olan IoU eşiğinin %50'den %95'e kadar değiştirildiği geniş IoU aralığında elde edilen mAP_{0,5:0,95} (ortalama kesinlik değeri) değeri %11,7' dir. Yapay zeka modelinin yüksek kesinlik gerektiren durumlarda yeterince iyi genelleme yapamadığını ve farklı ölçeklerdeki çürükleri tespit etmede zorlandığını göstermektedir. Elde edilen sonuçlar, modelin ortalama bir tespit performansına sahip olduğunu ancak klinik olarak daha güvenilir hale getirilmesi için geliştirilmesi gerektiğini göstermektedir. Özellikle küçük ve belirsiz çürüklerde hata oranının yüksek olması, yapay zeka modelinin duyarlılık ve kesinlik açısından daha fazla optimize edilmesi gerektiğini ortaya koymaktadır. Yapay zeka modelinin daha fazla ve dengeli veri ile eğitilmesi, genel doğruluk seviyesini artırabilir. Farklı veri çoğaltma (data augmentation) ve radyografilerde ön işleme tekniklerinin çeşitlendirilmesi (farklı kontrast ayarları içeren görüntülerle eğitilmesi gibi) yapay zeka modelinin verilere adaptasyonunu ve genelleme yeteneğini artırılabilir. Eğitim veri setindeki arayüz, oklüzal ve bukkal çürük etiketi sayıları sırasıyla 6529, 3300, 194'dür. Yapay zeka modeli, eğitim verisinde en fazla bulunan çürük türünü daha iyi öğrenirken, nadir görülen çürükleri yeterince öğrenemez. Çalışmadaki bulgulara göre bukkal çürüklerin tespitinde modelin başarısız olması (F1 Skoru ≈ 0), veri setindeki dengesizliğin bir sonucu olabilir. Bu dengesizlik, modelin genelleme yapmasını zorlaştırır, diğer çürük türleri üzerindeki performansını ve genel çürük performansını da etkileyebilir. Yapay zeka modeli, bukkal çürük sayısının oldukça az olması çürükleri az gördüğü için bu çürükleri iyi öğrenememesine neden olmuş ve bu durum yapay zeka modelinin genel performansını da olumsuz etkilemiştir. Dayı ve ark. çalışmalarında elde ettikleri yapay zeka modelinin genel çürük tespit performansının düşük çıkmasının sebebi mevcut çalışmaya benzer şekilde servikal çürüklerin veri sayısının azlığının genel model performansını etkilemesinden dolayı olduğunu söylemişlerdir. Yapay zeka modelinin başarısını artırmanın ve daha dengeli çürük tespiti

yapmasını sađlamanın diđer bir yolu da Karakuş ve ark.¹⁵⁹ ve Frutos ve ark.¹⁶⁵ alıřamalarındaki gibi etiketleyiciler arasında fikir birliđinin sađlanması ya da Chen ve ark.'nın¹⁶⁰ alıřmasındaki gibi etiketleyicilere tanı kriterlerini ve yazılımın talimatlarını ieren bir el kitabının verilmesi olabilir. Lee ve ark.'nın¹⁶⁶ alıřmasındaki gibi derin renme kullanarak elde edilen yapay zeka modelinde aradan 3 hafta getikten sonra ikinci kez rk tespiti yapacaklarında nceki rk tespitlerini deđerlendirmeleri istediđinde rk tespitindeki duyarlılıklarının nemli lde iyileřtiđi grlmř, bu da yapay zeka modelinin ayrıca mevcut alıřmanın konusunu destekler řekilde rk teřhisinin diagnostik dođruluđuna katkı sađladıđını ve diř hekimlerinin tanıdaki peerformansının geliřmesine katkı sađlayabileceđini gstermektedir. Bayatı ve ark.¹⁵⁸, Kaur ve ark.¹⁶⁷, ztekin ve ark.¹⁶⁸, Dayı ve ark.¹⁶² yaptıkları alıřmalarda bu řekilde sonu elde etmiřlerdir. Ayrıca farklı derin renme mimarileri kullanarak yapay zeka modelinin geliřtirilmesi genel rk tespit performansını artırabilir. Yavsan ve ark.¹⁶⁹ ocuk hastalardan alınan periapikal radyografilerde derin renme tabanlı bir rk tanı sistemi oluřturmayı amaladıkları alıřmalarında orijinal veri seti iin en yksek dođruluđu veren algoritmayı belirlemek adına aralarında bizim alıřmamızda kullandıđımız YOLOv8x'in de olduđu 13 farklı YOLO versiyonu zerinde eđitim yapılmıřtır. YOLOv5s 90,8 mAP deđerı ile en yksek dođruluk oranının elde edildiđi algoritması olmuřtur. İkinci olarak YOLOv8x de en yksek mAP deđerı elde edilmiřtir.

6. SONUÇ ve ÖNERİLER

Çalışmamızda, YOLOv8x derin öğrenme algoritması kullanılarak geliştirilen yapay zeka modelimizin çürük tespitinde orta düzeyde başarı sağladığı gözlemlendi. Yapay zeka modelimiz arayüz çürük tespitinde orta, oklüzal çürük tespitinde zayıf, bukkal çürük tespitinde düşük başarı gösterdi. Yapay zeka modelimizin ve etiketleyici diş hekimlerimizin en iyi çürük tespit performansı gösterdiği sınıf arayüz çürük sınıfı olup, en düşük performansı gösterdiği sınıf ise bukkal çürük sınıfıdır. Tecrübeli asistanın (K.B.) genel çürük tespit performansı modelimizden ve çürük sınıflarına göre tespit performansı modelden ve diğer etiketleyicilerden yüksek bulundu. Yapay zeka modeli genel çürük tespitinde tecrübeli asistandan (K.B.) sonra 2. en iyi performansı gösterdi. Yeni asistan (N.Ş.) ve stajyer diş hekiminin (S.G.) tüm çürük tiplerinin tespiti üzerindeki genel performansı benzer olsa da yeni asistanın metrikleri daha yüksek bulundu.

Yapay zeka modelinin başarısını artırmak amacıyla daha güçlü veri setlerinin kullanılması, farklı veri çoğaltma ve görüntü işleme yöntemlerinin kullanılması, tecrübeli hekimlerle modelin eğitilmesi, hekimler arasında çürük etiketleme konusunda iş birliği sağlanması gelecekteki çalışmalarda daha dengeli ve başarılı modeller elde edilmesine katkı sağlayabilir. Farklı veri çoğaltma ve ön işleme teknikleriyle kontrast ayarları yapmak özellikle küçük ve farkedilmesi zor oklüzal ve bukkal çürük sınıfında çürük türlerine özgü tanı performansı da iyileştirilebilir. Bukkal çürük sınıfının veri setinin oldukça az olduğu çalışmamızda veri seti artırılmalı, yapay zeka modelinin genel başarısı için çürük sınıflarının veri setlerinin dengeli olması sağlanmalıdır. Özellikle bukkal ve oklüzal çürüklerin tespitinde kullanılan algoritmaların daha da güçlendirilmesi, kliniklerde hata oranlarını en aza indirerek tanı doğruluğunu üst seviyelere taşıyacaktır.

Rutin klinik muayenede tek seferde geniş perspektifte oral yapıları değerlendirmemizi sağlayan ve çocuk diş hekimliğinde intraoral radyografileri tolere

edemeyen ve/veya nonkoopere çocuk hasta grubunda değerli bir teşhis yöntemi olan panoramik radyografilerde yapay zeka ile çürük değerlendirmesi ile ilgili yapılan çalışmalar ümit vericidir. Panoramik radyografinin intraoral radyografilere göre ayrıntı ve çözünürlük özelliklerinin daha düşük olması dezavantajı panoramik radyografilerdeki iyileştirme ve görüntü işleme teknikleriyle düzensiz aydınlatma ve kontrast düzeylerinin ayarlanması ile çözümlenerek tanısal performansı artırılabilir. Yapay zeka modeli ile genel perspektiften oral yapıların değerlendirilmesi avantajı bu iyileştirmelerle panoramik radyografinin kullanılmasıyla elde edilmiş olur.

Derin öğrenme algoritmaları temelli yapay zeka uygulamaları, çocuk hastalara ait panoramik radyografilerde çürük lezyonlarının otomatik olarak tespit edilmesi açısından önemli bir potansiyel sunmaktadır. Bu tür sistemlerin klinik pratiğe entegrasyonu, diş hekimlerinin karar süreçlerini destekleyerek erken tanı ve tedavi planlamasında etkinliğin artırılmasına katkı sağlayıp klinik verimliliği artırabilir. Erken teşhise katkı sağlayıp remineralizasyon protokollerinin de içinde olduğu noninvaziv tedavilere ya da daha az invaziv tedavilere olanak sağlar. Özellikle çocuk diş hekimliği için komplike işlemlerlerin çocuk hastadaki psikolojik yükünün üstesinden gelememizi sağlayarak, çocuğun dental anksiyete ile baş etmesini ve hasta konforu yüksek bir tedavi seçeneği sağlar. Bu katkılar bu teknolojilerin değerini daha da artırmaktadır. Elde edilen bulgular, yapay zeka destekli tanı sistemlerinin klinik verimliliği ve doğruluğu artırdığını göstermekte; bu alanda yapılacak ileri araştırmalar için güçlü bir temel oluşturmaktadır.

KAYNAKLAR

1. Fejerskov O, Kidd E. Dental caries: The disease and its clinical management, 3. Baskı. Iowa, John Wiley & Sons, 2015: 7-13.,
2. Bjørndal L, Larsen T, Thylstrup A. A clinical and microbiological study of deep carious lesions during stepwise excavation using long treatment intervals. Caries Res, 1997; 31: 411-417.
3. Karlsson L. Caries detection methods based on changes in optical properties between healthy and carious tissue. Int J Dent, 2010; 2010: 270729.
4. Lian L, Zhu T, Zhu F ve ark. Deep learning for caries detection and classification. Diagnostics (Basel), 2021; 11: 1672.
5. Flint DJ, Paunovich E, Moore WS. A diagnostic comparison of panoramic and intraoral radiographs. Oral Surg Oral Med Oral Pathol Oral Radiol Endod, 1998; 85: 731-735.
6. White SC PM. Oral radiology principles and interpretation 7. Baskı, St. Louis, Mosby, 2014: 696.
7. Topping GVA, Pitts NB. Clinical visual caries detection. Monogr Oral Sci, 2009; 21: 15-41.
8. Oztekin F, Katar O, Sadak F ve ark. An explainable deep learning model to prediction dental caries using panoramic radiograph images. Diagnostics, 2023; 13: 226.
9. Shan T, Tay FR, Gu L. Application of artificial intelligence in dentistry. J Dent Res, 2021; 100: 232-244.
10. Lee JG, Jun S, Cho YW ve ark. Deep learning in medical imaging: General overview. Korean J Radiol, 2017; 18: 570-584.
11. Hwang JJ JY, Cho BH, Heo MS. An overview of deep learning in the field of dentistry. Imaging Sci Dent, 2019; 49: 1-7.
12. Kılıc MC, Bayrakdar IS, Çelik Ö ve ark. Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs. Dentomaxillofac Radiol, 2021; 50: 20200172.
13. Oztekin F, Katar O, Sadak F ve ark. An explainable deep learning model to prediction dental caries using panoramic radiograph images. Diagnostics, 2023; 13: 226.

14. Turosz N, Chęcińska K, Chęciński M ve ark. Applications of artificial intelligence in the analysis of dental panoramic radiographs: An overview of systematic reviews. *Dentomaxillofac Radiol*, 2023; 52: 20230284.
15. Anil S, Porwal P, Porwal A. Transforming dental caries diagnosis through artificial intelligence-based techniques. *Cureus*, 2023; 15: e41694.
16. Negi S, Mathur A, Tripathy S ve ark. Artificial intelligence in dental caries diagnosis and detection: An umbrella review. *Clin Exp Dent Res*, 2024; 10: e70004.
17. Kasımoğlu Y, Bektaş İ, Çil T ve ark. Türk çocuklarında İki yöntem ile diş yaşı tayininin birbiri ile karşılaştırılması. *KOU Sağ Bil Derg*, 2021; 7: 190-197.
18. Duman SB, Duman S, Bayrakdar IS ve ark. Evaluation of radix entomolaris in mandibular first and second molars using cone-beam computed tomography and review of the literature. *Oral Radiol*, 2020; 36: 320-326.
19. Yasa Y, Çelik Ö, Bayrakdar IS ve ark. An artificial intelligence proposal to automatic teeth detection and numbering in dental bite-wing radiographs. *Acta Odontol Scand*, 2021; 79: 275-281.
20. Balakrishnan M, Simmonds RS, Tagg JR. Dental caries is a preventable infectious disease. *Aust Dent J*, 2000; 45: 235-245.
21. Kidd E. Essentials of dental caries: The disease and its management, 3.Baskı, the disease and its management, OUP Oxford, 2005:
22. Mazzoni A, Tjäderhane L, Checchi V. Role of dentin mmmps in caries progression and bond stability. *J Dent Res*, 2015; 94: 241-251.
23. Gomez J. Detection and diagnosis of the early caries lesion. *BMC Oral Health*, 2015; 15 Suppl 1: S3.
24. Kidd EA FO. Dental caries: The disease and its clinical management. Baskı. Blackwell munksgaard. 2003;
25. Rathee M, Sapra A. Dental caries of chapter. In: (ed/eds). Statpearls, Treasure Island (FL), StatPearls Publishing Copyright © 2025, StatPearls Publishing LLC., 2025:
26. Kühnisch J, Ifland S, Tranaeus S ve ark. In vivo detection of non-cavitated caries lesions on occlusal surfaces by visual inspection and quantitative light-induced fluorescence. *Acta Odontol Scand*, 2007; 65: 183-188.
27. Gürses M, Ünlü N. *Selcuk Dental Journal*, 2017; 4: 153-161.

28. Souza JF, Boldieri T, Diniz MB ve ark. Traditional and novel methods for occlusal caries detection: Performance on primary teeth. *Lasers Med Sci*, 2013; 28: 287-295.
29. White SC, Pharoah, M.J. Oral radiology: Principles and interpretation, elsevier health sciences, canada. 2014;
30. Wenzel A. Bitewing and digital bitewing radiography for detection of caries lesions. *J Dent Res*, 2004; 83 Spec No C: C72-75.
31. Brennan J. An introduction to digital radiography in dentistry. *J Orthod*, 2002; 29: 66-69.
32. <https://toothfairead.Wordpress.Com/2020/01/05/top-tips-on-taking-bitewings-on-children/>
33. Mallya S, Lam E. White and pharoah's oral radiology: Principles and interpretation, Mosby, 2018;
34. Dhillon M, Raju SM, Verma S ve ark. Positioning errors and quality assessment in panoramic radiography. *Imaging Sci Dent*, 2012; 42: 207-212.
35. Molteni R. The way we were (and how we got here): Fifty years of technology changes in dental and maxillofacial radiology. *Dentomaxillofac Radiol*, 2021; 50: 20200133.
36. Shah N, Bansal N, Logani A. Recent advances in imaging technologies in dentistry. *World J Radiol*, 2014; 6: 794-807.
37. Angelopoulos C, Bedard A, Katz JO ve ark. Digital panoramic radiography: An overview. *Seminars in Orthodontics*, 2004; 10: 194-203.
38. Tassery H, Déjou J, Chafaie A ve ark. In vivo diagnostic assessment of dentinal caries by junior and senior students using red acid dye. *Eur J Dent Educ*, 2001; 5: 38-42.
39. Zacharia MA, Munshi AK. Microbiological assessment of dentin stained with a caries detector dye. *J Clin Pediatr Dent*, 1995; 19: 111-115.
40. Hosoya Y, Taguchi T, Tay FR. Evaluation of a new caries detecting dye for primary and permanent carious dentin. *J Dent*, 2007; 35: 137-143.
41. Ansari G, Beeley JA, Reid JS ve ark. Caries detector dyes--an in vitro assessment of some new compounds. *J Oral Rehabil*, 1999; 26: 453-458.
42. Friedman J, Marcus MI. Transillumination of the oral cavity with use of fiber optics. *J Am Dent Assoc*, 1970; 80: 801-809.

43. Mialhe FL, Pereira AC, Meneghim Mde C ve ark. The relative diagnostic yields of clinical, foti and radiographic examinations for the detection of approximal caries in youngsters. *Indian J Dent Res*, 2009; 20: 136-140.
44. Abogazalah N, Eckert GJ, Ando M. In vitro visual and visible light transillumination methods for detection of natural non-cavitated approximal caries. *Clin Oral Investig*, 2019; 23: 1287-1294.
45. Akyildiz M. Diş çürüğünün erken teşhisinde transillüminasyon yöntemleri of chapter. In: (ed/eds). 2019: 14-20.
46. Laitala ML, Piipari L, Sämpe N ve ark. Validity of digital imaging of fiber-optic transillumination in caries detection on proximal tooth surfaces. *Int J Dent*, 2017; 2017: 8289636.
47. Bin-Shuwaish M, Yaman P, Dennison J ve ark. The correlation of difoti to clinical and radiographic images in class ii carious lesions. *J Am Dent Assoc*, 2008; 139: 1374-1381.
48. Schneiderman A, Elbaum M, Shultz T ve ark. Assessment of dental caries with digital imaging fiber-optic transillumination (difoti): In vitro study. *Caries Res*, 1997; 31: 103-110.
49. Kühnisch J, Ekstrand KR, Pretty I ve ark. Best clinical practice guidance for management of early caries lesions in children and young adults: An eapd policy document. *Eur Arch Paediatr Dent*, 2016; 17: 3-12.
50. Fried D, Glena RE, Featherstone JD ve ark. Nature of light scattering in dental enamel and dentin at visible and near-infrared wavelengths. *Appl Opt*, 1995; 34: 1278-1285.
51. Baltacioglu IH, Orhan K. Comparison of diagnostic methods for early interproximal caries detection with near-infrared light transillumination: An in vivo study. *BMC Oral Health*, 2017; 17: 130.
52. Ozkan G, Guzel KGU. Clinical evaluation of near-infrared light transillumination in approximal dentin caries detection. *Lasers Med Sci*, 2017; 32: 1417-1422.
53. Tassery H, Levallois B, Terror E ve ark. Use of new minimum intervention dentistry technologies in caries management. *Aust Dent J*, 2013; 58 Suppl 1: 40-59.

54. Gimenez T, Braga MM, Raggio DP ve ark. Fluorescence-based methods for detecting caries lesions: Systematic review, meta-analysis and sources of heterogeneity. *PLoS One*, 2013; 8: e60421.
55. Chu CH, Lo EC, You DS. Clinical diagnosis of fissure caries with conventional and laser-induced fluorescence techniques. *Lasers Med Sci*, 2010; 25: 355-362.
56. Rechmann P, Charland D, Rechmann BM ve ark. Performance of laser fluorescence devices and visual examination for the detection of occlusal caries in permanent molars. *J Biomed Opt*, 2012; 17: 036006.
57. Hibst R, Paulus R, Lussi A. Detection of occlusal caries by laser fluorescence: Basic and clinical investigations. *Medical Laser Application*, 2001; 16: 205-213.
58. Lai G, Zhu L, Xu X ve ark. An in vitro comparison of fluorescence-aided caries excavation and conventional excavation by microhardness testing. *Clin Oral Investig*, 2014; 18: 599-605.
59. Lai G, Kaisarly D, Xu X ve ark. Microct-based comparison between fluorescence-aided caries excavation and conventional excavation. *Am J Dent*, 2014; 27: 12-16.
60. Lennon AM, Attin T, Martens S ve ark. W. Fluorescence-aided caries excavation (face), caries detector, and conventional caries excavation in primary teeth. *Pediatr Dent*, 2009; 31: 316-319.
61. Lennon AM. Fluorescence-aided caries excavation (face) compared to conventional method. *Oper Dent*, 2003; 28: 341-345.
62. van der Veen MH, de Josselin de Jong E. Application of quantitative light-induced fluorescence for assessing early caries lesions. *Monogr Oral Sci*, 2000; 17: 144-162.
63. Angmar-Månsson B, ten Bosch JJ. Quantitative light-induced fluorescence (qlf): A method for assessment of incipient caries lesions. *Dentomaxillofac Radiol*, 2001; 30: 298-307.
64. Michaelis J, Yu Q, Lallier T ve ark. Quantifying the degree of white spot lesions on enamel caused by different commercial beverages using the canary caries detection system: An in vitro study. *J Dent Res Dent Clin Dent Prospects*, 2022; 16: 29-34.

65. Silvertown JD, Wong BPY, Abrams SH ve ark. Comparison of the canary system and diagnodent for the in vitro detection of caries under opaque dental sealants. *J Investig Clin Dent*, 2017; 8:
66. Hellen A, Mandelis A, Finer Y ve ark. Quantitative remineralization evolution kinetics of artificially demineralized human enamel using photothermal radiometry and modulated luminescence. *J Biophotonics*, 2011; 4: 788-804.
67. Panayotov I, Terrer E, Salehi H ve ark. In vitro investigation of fluorescence of carious dentin observed with a soprolife® camera. *Clin Oral Investig*, 2013; 17: 757-763.
68. Gugnani N, Pandit I, Srivastava N ve ark. Light induced fluorescence evaluation: A novel concept for caries diagnosis and excavation. *J Conserv Dent*, 2011; 14: 418-422.
69. Jones RS, Darling CL, Featherstone JD ve ark. Imaging artificial caries on the occlusal surfaces with polarization-sensitive optical coherence tomography. *Caries Res*, 2006; 40: 81-89.
70. Akyıldız E, Özalp N. Diagnosis of early dental caries by traditional, contemporary and developing imaging methods. *European Annals of Dental Sciences*, 2022; 49: 38-45.
71. Bamzahim M, Shi XQ, Angmar-Månsson B. Occlusal caries detection and quantification by diagnodent and electronic caries monitor: In vitro comparison. *Acta Odontol Scand*, 2002; 60: 360-364.
72. Longbottom C, Huysmans MC. Electrical measurements for use in caries clinical trials. *J Dent Res*, 2004; 83 Spec No C: C76-79.
73. Huysmans MC, Longbottom C, Pitts NB ve ark. Impedance spectroscopy of teeth with and without approximal caries lesions--an in vitro study. *J Dent Res*, 1996; 75: 1871-1878.
74. Evans JW, Zawadzki RJ, Liu R ve ark. Optical coherence tomography and raman spectroscopy of the ex-vivo retina. *J Biophotonics*, 2009; 2: 398-406.
75. Ko AC, Choo-Smith LP, Hewko M ve ark. Detection of early dental caries using polarized raman spectroscopy. *Opt Express*, 2006; 14: 203-215.
76. Ersöz Dde, Oktay Dn. Alternatİf çürük tespİt yöntemlerİ. *Atatürk Üniversitesi Diş Hekimliği Fakültesi Dergisi*, 2002; 2002:
77. Çalışkan Yanikoğlu F, Oztürk F, Hayran O ve ark. Detection of natural white spot caries lesions by an ultrasonic system. *Caries Res*, 2000; 34: 225-232.

78. Kamburoğlu K, Karagöz B, Altan H ve ark. An ex vivo comparative study of occlusal and proximal caries using terahertz and x-ray imaging. Dentomaxillofac Radiol, 2019; 48: 20180250.
79. Bala O, Akgul S. Çürük teşhis yöntemleri. 2016; 2: 34.
80. Strassler HE, Sensi LG. Technology-enhanced caries detection and diagnosis. Compend Contin Educ Dent, 2008; 29: 464-465, 468, 470 passim.
81. G. B. How accurate are artificial intelligence systems at identifying tooth decay, <https://dentistry.Co.Uk/2020/09/04/accurate-artificial-intelligence-tooth-decay>. 2020;
82. <https://www.Dental-tribune.Com/news/artificial-intelligence-technology-powers-award-winning-clinical-research>
83. Mahajan K, Kunte S, Patil K ve ark. Artificial intelligence in pediatric dentistry – a systematic review. 2023; 10:
84. Schwendicke F, Samek W, Krois J. Artificial intelligence in dentistry: Chances and challenges. J Dent Res, 2020; 99: 769-774.
85. Soffer S, Ben-Cohen A, Shimon O ve ark. Convolutional neural networks for radiologic images: A radiologist's guide. Radiology, 2019; 290: 590-606.
86. Tandon D, Rajawat J. Present and future of artificial intelligence in dentistry. J Oral Biol Craniofac Res, 2020; 10: 391-396.
87. Bahrammirzaee A. A comparative survey of artificial intelligence applications in finance: Artificial neural networks, expert system and hybrid intelligent systems. International Journal of Neural Computing and Application, 2010; Available online 20 June 2010:
88. Warwick K. Artificial intelligence: The basics, 2013:
89. Nabyev V. Yapay zeka (artificial intelligence), 2021:
90. YILMAZ ÖĞRÜA, Yayın K. Yapay zeka, KODLAB YAYIN DAĞITIM YAZILIM LTD.ŞTİ., 2021:
91. Mathew TVnd. Genetic algorithm.
92. Atalay M and Celik E. Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamaları - artificial intelligence and machine learning applications in big data analysis. MAKU SOBED, 2017; 155-172.
93. Ergezer H DM, Özdemir E. . Yapay sinir ağları ve tanıma sistemleri. 2003;
94. Öztemel E. Yapay sinir ağları, 2012:

95. Ö. A. Yapay sinir ağlarını kullanarak bir ses tanıma sistemi geliştirilmesi yüksek lisans tezi. Institution, Department. Thesis type, Place: 2005.
96. Krogh A. What are artificial neural networks? Nat Biotechnol, 2008; 26: 195-197.
97. Sinanoğlu C, Kurban AO, Yildirim S. Analysis of pressure variations on journal bearing system using artificial neural network. Industrial Lubrication and Tribology, 2004; 56: 74-87.
98. K. T. Hastalık teşhisi için bir yapay sinir ağları yazılımının tasarlanması ve gerçekleştirilmesi. Bilgisayar mühendisliği anabilim dalı. Konya: Selçuk üniversitesi fen bilimleri enstitüsü. Institution, Department. Thesis type, Place: 2017.
99. Yayık A, Kutlu Y. Yapay sinir ağları ile kriptoloji uygulamaları. Institution, Department. Thesis type, Place: 2013.
100. Kaynar O, Görmez Y, Yıldız M ve ark. Makine öğrenmesi yöntemleri ile duygu analizi - sentiment analysis with machine learning techniques, 2016:
101. Efe MÖ, Kaynak O. Yapay sinir ağları ve uygulamaları, Boğaziçi Üniversitesi, 2000:
102. Chartrand G, Cheng PM, Vorontsov E ve ark. Deep learning: A primer for radiologists. Radiographics, 2017; 37: 2113-2131.
103. Wang S-C. Artificial neural network of chapter. In: (ed/eds). 2003: 81-100.
104. Erickson BJ, Korfiatis P, Akkus Z ve ark. Machine learning for medical imaging. Radiographics, 2017; 37: 505-515.
105. Pesapane F, Codari M, Sardanelli F. Artificial intelligence in medical imaging: Threat or opportunity? Radiologists again at the forefront of innovation in medicine. Eur Radiol Exp, 2018; 2: 35.
106. Janowczyk A, Madabhushi A. Deep learning for digital pathology image analysis: A comprehensive tutorial with selected use cases. J Pathol Inform, 2016; 7: 29.
107. Hao X, Zhang G, Ma S. Deep learning. International Journal of Semantic Computing, 2016; 10: 417-439.
108. El Shawi R, Wahab A, Barnawi A ve ark. Dlbenc: A comprehensive experimental evaluation of deep learning frameworks. Cluster Computing, 2021; 24: 1-22.
109. Schulz H, Behnke S. Deep learning. KI - Künstliche Intelligenz, 2012; 26:

110. Montagnon E, Cerny M, Cadrin-Chênevert A ve ark. Deep learning workflow in radiology: A primer. *Insights Imaging*, 2020; 11: 22.
111. Girshick RB, Donahue J, Darrell T ve ark. Rich feature hierarchies for accurate object detection and semantic segmentation. *2014 IEEE Conference on Computer Vision and Pattern Recognition*, 2013; 580-587.
112. Min S, Lee B, Yoon S. Deep learning in bioinformatics. *Brief Bioinform*, 2017; 18: 851-869.
113. Doğan F, Türkoğlu İ. Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 2019; 10: 409-445.
114. Serbest K, Aktürk S. Nesne tespiti İçin derin öğrenme kütüphanelerinin İncelenmesi. *Journal of Smart Systems Research*, 2022; 3: 97-119.
115. Gündüz G, Cedimoğlu İH. Derin öğrenme algoritmalarını kullanarak görüntüden cinsiyet tahmini. *Sakarya Univ. J. Comput. Inform. Sci.*, 2019; 2: 9-17.
116. Toğaçar M, Ergen B. Biyomedikal görüntülerde derin öğrenme ile mevcut yöntemlerin kıyaslanması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 2019; 31: 109-121.
117. Kim M, Yun J, Cho Y ve ark. Deep learning in medical imaging. *Neurospine*, 2019; 16: 657-668.
118. Heo MS, Kim JE, Hwang JJ ve ark. Artificial intelligence in oral and maxillofacial radiology: What is currently possible? *Dentomaxillofac Radiol*, 2021; 50: 20200375.
119. Litjens G, Kooi T, Bejnordi BE ve ark. A survey on deep learning in medical image analysis. *Med Image Anal*, 2017; 42: 60-88.
120. Zhiqiang W, Jun L. A review of object detection based on convolutional neural network, 2017:
121. Jeong H-J, Park K-S, Ha Y-G. Image preprocessing for efficient training of yolo deep learning networks, 2018:
122. Redmon J, Divvala S, Girshick R ve ark. You only look once: Unified, real-time object detection. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* 27-30 June 2016 2016, pp.779-788.
123. Redmon J, Farhadi A. Yolo9000: Better, faster, stronger, 2017:

124. Redmon J, Farhadi A. Yolov3: An incremental improvement. ArXiv, 2018; abs/1804.02767:
125. Bochkovskiy A, Wang C-Y, Liao H-y. Yolov4: Optimal speed and accuracy of object detection, 2020:
126. Yung NDT, Wong WK, Juwono FH ve ark. Safety helmet detection using deep learning: Implementation and comparative study using yolov5, yolov6, and yolov7. In: 2022 GECOST 26-28 Oct. 2022 2022, pp.164-170.
127. Wang C-Y, Bochkovskiy A, Liao H-y. Yolov7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors, 2022:
128. Cao L, Zheng X, Fang L. The semantic segmentation of standing tree images based on the yolo v7 deep learning algorithm. Electronics, 2023; 12: 929.
129. Liu K, Sun Q, Sun D ve ark. Underwater target detection based on improved yolov7. J. Mar. Sci. Eng., 2023; 11: 677.
130. Terven J, Cordova-Esparza D-M. A comprehensive review of yolo: From yolov1 to yolov8 and beyond, 2023:
131. Bonfanti-Gris M, Herrera A, Paraíso-Medina S ve ark. Performance evaluation of three versions of a convolutional neural network for object detection and segmentation using a multiclass and reduced panoramic radiograph dataset. Journal of Dentistry, 2024; 144: 104891.
132. Buyuk C. Diş hekimliğinde yapay zeka of chapter. In: (ed/eds). 2020: 233-256.
133. Ghods K, Azizi A, Jafari A ve ark. Application of artificial intelligence in clinical dentistry, a comprehensive review of literature. J Dent (Shiraz), 2023; 24: 356-371.
134. Ma J, Schneider L, Lapuschkin S ve ark. Towards trustworthy ai in dentistry. J Dent Res, 2022; 101: 1263-1268.
135. Khanagar SB, Al-Ehaideb A, Maganur PC ve ark. Developments, application, and performance of artificial intelligence in dentistry - a systematic review. J Dent Sci, 2021; 16: 508-522.
136. Carrillo-Perez F, Pecho OE, Morales JC ve ark. Applications of artificial intelligence in dentistry: A comprehensive review. J Esthet Restor Dent, 2022; 34: 259-280.
137. Suzuki K. Overview of deep learning in medical imaging. Radiol Phys Technol, 2017; 10: 257-273.

138. Miki Y, Muramatsu C, Hayashi T ve ark. Classification of teeth in cone-beam ct using deep convolutional neural network. *Comput Biol Med*, 2017; 80: 24-29.
139. Vishwanathaiah S, Fageeh HN, Khanagar SB ve ark. Artificial intelligence its uses and application in pediatric dentistry: A review. *Biomedicines*, 2023; 11:
140. Schlickenrieder A, Meyer O, Schönewolf J ve ark. Automatized detection and categorization of fissure sealants from intraoral digital photographs using artificial intelligence. *Diagnostics (Basel)*, 2021; 11:
141. Krois J, Ekert T, Meinhold L ve ark. Deep learning for the radiographic detection of periodontal bone loss. *Sci Rep*, 2019; 9: 8495.
142. Kalantarian H, Jedoui K, Washington P ve ark. Labeling images with facial emotion and the potential for pediatric healthcare. *Artif Intell Med*, 2019; 98: 77-86.
143. Jayalekshmy R, Unnithan JJ, Kumar AM ve ark. Artificial intelligence-finding new frontiers in oral and maxillofacial radiology. In.
144. Cho J, Lee K, Shin E ve ark. How much data is needed to train a medical image deep learning system to achieve necessary high accuracy. *arXiv: Learning*, 2015;
145. Gianfrancesco MA, Tamang S, Yazdany J ve ark. Potential biases in machine learning algorithms using electronic health record data. *JAMA Intern Med*, 2018; 178: 1544-1547.
146. Chen H, Zhang K, Lyu P ve ark. A deep learning approach to automatic teeth detection and numbering based on object detection in dental periapical films. *Sci Rep*, 2019; 9: 3840.
147. Özkesici MY, Yılmaz S. Oral ve maksillofasıyal radyoloji’de yapay zeka. *Sağlık Bilimleri Dergisi*, 2021; 30: 346-351.
148. Kilic M, Bayrakdar I, Aşçı E ve ark. Derin öğrenme yöntemi kullanılarak geliştirilen yapay zekâ yöntemi ile panoramik radyografilerde dental restorasyonların otomatik tespiti ve sınıflandırılması. *Türkiye Klinikleri J Dental Sci*, 2022; 28: 329-337.
149. Lee KS, Kwak HJ, Oh JM ve ark. Automated detection of tmj osteoarthritis based on artificial intelligence. *J Dent Res*, 2020; 99: 1363-1367.
150. Redmon J, Divvala S, Girshick R ve ark. You only look once: Unified, real-time object detection, 2016:
151. He K, Gkioxari G, Dollar P ve ark. Mask r-cnn, 2017:

152. Flint DJ, Paunovich E, Moore WS. A diagnostic comparison of panoramic and intraoral radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol Endod*, 1998; 85: 731-735.
153. Bayram M, Yıldırım M, Köse A ve ark. Pedodonti anabilim dalı'nda başlangıç muayenesinde alınan panoramik radyografilerin değerlendirilmesi. *Journal of Istanbul University Faculty of Dentistry*, 2011; 45: 41-47.
154. Zanini LGK, Rubira-Bullen IRF, Nunes F. A systematic review on caries detection, classification, and segmentation from x-ray images: Methods, datasets, evaluation, and open opportunities. *J Imaging Inform Med*, 2024; 37: 1824-1845.
155. Mohammad-Rahimi H, Motamedian SR, Rohban MH ve ark. Deep learning for caries detection: A systematic review. *J Dent*, 2022; 122: 104115.
156. Suryani IR, Villegas NS, Shujaat S ve ark. Image quality assessment of pre-processed and post-processed digital panoramic radiographs in paediatric patients with mixed dentition. *Imaging Sci Dent*, 2018; 48: 261-268.
157. Bhat S, Birajdar G, Patil M. Enhanced diagnostic accuracy for dental caries and anomalies in panoramic radiographs using a custom deep learning model. *Cureus*, 2024; 16: e67315.
158. Bayati M, Alizadeh Savareh B, Ahmadinejad H ve ark. Advanced ai-driven detection of interproximal caries in bitewing radiographs using yolov8. *Sci Rep*, 2025; 15: 4641.
159. Karakuş R, Öziç M, 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; 37: 3146-3159.
160. Chen X, Guo J, Ye J ve ark. Detection of proximal caries lesions on bitewing radiographs using deep learning method. *Caries Res*, 2022; 56: 455-463.
161. Bayraktar Y, Ayan E. Diagnosis of interproximal caries lesions with deep convolutional neural network in digital bitewing radiographs. *Clin Oral Investig*, 2022; 26: 623-632.
162. Dayı B, Üzen H, Çiçek İ B ve ark. A novel deep learning-based approach for segmentation of different type caries lesions on panoramic radiographs. *Diagnostics (Basel)*, 2023; 13:

163. Berry HM, Jr. Cervical burnout and mach band: Two shadows of doubt in radiologic interpretation of carious lesions. *J Am Dent Assoc*, 1983; 106: 622-625.
164. Tichý A, Kunt L, Nagyová V ve ark. Automatic caries detection in bitewing radiographs-part ii: Experimental comparison. *Clin Oral Investig*, 2024; 28: 133.
165. Pérez de Frutos J, Holden Helland R, Desai S ve ark. Ai-dentify: Deep learning for proximal caries detection on bitewing x-ray - hunt4 oral health study. *BMC Oral Health*, 2024; 24: 344.
166. Lee S, Oh SI, Jo J ve ark. Deep learning for early dental caries detection in bitewing radiographs. *Sci Rep*, 2021; 11: 16807.
167. Kaur A, Jyoti D, Sharma A ve ark. Deep caries detection using deep learning: From dataset acquisition to detection. *Clin Oral Investig*, 2024; 28: 677.
168. Oztekin F, Katar O, Sadak F ve ark. An explainable deep learning model to prediction dental caries using panoramic radiograph images. *Diagnostics (Basel)*, 2023; 13:
169. Yavsan ZS, Orhan H, Efe E ve ark. Diagnosis of approximal caries in children with convolutional neural networks based detection algorithms on radiographs: A pilot study. *Acta Odontol Scand*, 2025; 84: 18-25.

EKLER

EK-1 Etik Kurul Onayı



T.C.
RECEP TAYYİP ERDOĞAN ÜNİVERSİTESİ
Girişimsel Olmayan Klinik Araştırmalar Etik Kurul Başkanlığı



Sayı : E-40465587-050.01.04-1065
Konu : Etik Kurul

29.05.2024

Sayın Dr. Öğr. Üyesi Ayça KURT

Üniversitemiz Girişimsel Olmayan Klinik Araştırmalar Etik Kuruluna yapmış olduğunuz “Derin Öğrenme Yöntemi Kullanılarak Geliştirilen Yapay Zeka Uygulamaları Aracılığıyla Diagnostik Doğruluğun Tespiti ” isimli başvurunuz etik kurulumuz yönergesine göre 23.05.2024 tarihinde yapmış olduğu toplantıda incelenmiş olup, 2024/111 karar numarası ile bilimsel ve etik yönden uygun bulunmuştur.
Bilgilerinizi ve gereğini saygılarımla rica ederim.

Doç. Dr. Tahsin Gökhan TELATAR
Başkan

Bu belge güvenli elektronik imza ile imzalanmıştır.
Belge Doğrulama Kodu : a582342542ac Belge Takip Adresi: <http://ebys.erdogan.edu.tr/EBYS/eimzadogrulama>

Fener Mah. Zihni Derin Yerleşkesi 53100 Rize / TÜRKİYE
Telefon No :+90 (464) 223 61 26 Faks No :+90 (464) 223 53 76
e-Posta : İnternet Adresi:<http://www.erdogan.edu.tr/>
Kep Adresi:

Bilgi için : BURAK HANKAYA
Bilgisayar İşletmen



EK-2 Dekanlık İzin Belgesi



T.C.
RECEP TAYYİP ERDOĞAN ÜNİVERSİTESİ
Diş Hekimliği Fakültesi Dekanlığı



Sayı : E-61245112-302.08-9695

29.02.2024

Konu : Bilimsel Çalışma İzni (Dr. Öğr. Üyesi
Ayça KURT)

Sayın Dr. Öğr. Üyesi Ayça KURT

İlgi : 28.02.2024 tarihli ve sayılı yazı.

"Derin Öğrenme Yöntemi Kullanılarak Geliştirilen Yapay Zeka Uygulamaları Aracılığıyla Diagnostik Doğruluğun Tespiti" isimli bilimsel çalışma ile ilgili izin talebiniz 6698 sayılı "Kişisel Verilerin Korunması Kanunu" ilgili yönetmelikler ve Hasta Hakları Yönetmeliği'nin "Tıbbi Araştırmalarda Rıza" başlıklı 32. maddesinde yer alan hükümlere riayet edilmesi şartıyla Dekanlığımız tarafından uygun görülmüştür.

Bilgilerinizi ve gereğini rica ederim.

Prof. Dr. Zeynep YEŞİL
Dekan


Bu belge gönderildi elektronik imza ile imzalanmıştır.

Belge Doğrulama Kodu : 61041a2e9e9e

Belge Takip Adresi: <http://idbys.erdogan.edu.tr/EBYS/izin/autogrufirma>

İslampazarı Mahallesi Menderes Bulvarı No:612 Merkez/RİZE / TÜRKİYE
Telefon No :+90 (464) 214 22 65, +90 (464)214 21 81 Faks No :+90 (464)
222 00 02
e-Posta : dis@erdogan.edu.tr İnternet Adresi: <http://www.erdogan.edu.tr/>
Kep Adresi: erdogan@hs01.kep.tr

Bilgi için : ŞAFAK DEMİRCİ
Memu
Dahili: 532



EK-8 İntihal Raporu

Kader Biçengil Tez 18.04.2025 son hai.docx

ORJİNALLIK RAPORU

% 9	% 7	% 4	% 3
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1	nek.istanbul.edu.tr:4444 İnternet Kaynağı	% 1
2	acikbilim.yok.gov.tr İnternet Kaynağı	% 1
3	ojs.omu.edu.tr İnternet Kaynağı	% 1
4	Submitted to Recep Tayyip Erdogan University Öğrenci Ödevi	<% 1
5	sagliktayapayzeka2022.org İnternet Kaynağı	<% 1
6	cdn.istanbul.edu.tr İnternet Kaynağı	<% 1
7	Submitted to Ordu Üniversitesi Öğrenci Ödevi	<% 1
8	www.odmfr.org İnternet Kaynağı	<% 1
9	Esra AŞÇI, Münevver KILIÇ, Özer ÇELİK, İbrahim Şevki BAYRAKDAR et al. "Automatic	<% 1