



**TÜRKİYE CUMHURİYETİ
ANKARA ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ**



**SÜT VE DAİMİ DİŞLERDE ARAYÜZ ÇÜRÜKLERİNİN
TEŞHİSİNDE YAPAY ZEKÂNIN ETKİNLİĞİNİN
DEĞERLENDİRİLMESİ**

Hatice Selin GÜÇLÜ

**PEDODONTİ ANABİLİM DALI
DOKTORA TEZİ**

**DANIŞMAN
Doç. Dr. Akif DEMİREL**

**ANKARA
2025**

TÜRKİYE CUMHURİYETİ
ANKARA ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

SÜT VE DAİMİ DİŞLERDE ARAYÜZ ÇÜRÜKLERİNİN
TEŞHİSİNDE YAPAY ZEKÂNIN ETKİNLİĞİNİN
DEĞERLENDİRİLMESİ

Hatice Selin GÜÇLÜ

PEDODONTİ ANABİLİM DALI
DOKTORA TEZİ

DANIŞMAN

Doç. Dr. Akif DEMİREL

Bu tez çalışması Ankara Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü kapsamında
TDK-2024-3520 proje numarası ile desteklenmiştir.

ANKARA

2025

ETİK BEYAN

Ankara Üniversitesi
Sağlık Bilimleri Enstitüsü Müdürlüğü'ne,

Doktora tezi olarak hazırlayıp sunduğum “Süt ve Daimi Dişlerde Arayüz Çürüklerinin Teşhisinde Yapay Zekânın Etkinliğinin Değerlendirilmesi” başlıklı tez; bilimsel ahlak ve değerlere uygun olarak tarafımda yazılmıştır. Tezimin fikir/hipotezi tümüyle tez danışmanım ve bana aittir. Tezde yer alan deneysel çalışma/araştırma tarafımda yapılmış olup, tüm cümleler, yorumlar bana aittir.

Yukarıda belirtilen hususların doğruluğunu beyan ederim.

Öğrencinin Adı Soyadı: Hatice Selin GÜÇLÜ

Tarih:

İmza:

KABUL VE ONAY

Ankara Üniversitesi Sağlık Bilimleri Enstitüsü

Pedodonti Anabilim Dalı'nda Hatice Selin GÜÇLÜ tarafından
hazırlanan "Süt ve Daimi Dişlerde Arayüz Çürüklerinin Teşhisinde
Yapay Zekânın Etkinliğinin Değerlendirilmesi" adlı tez çalışması
aşağıdaki jüri tarafından DOKTORA TEZİ olarak OY BİRLİĞİ / OY
ÇOKLUĞU ile kabul edilmiştir.

Tez Savunma Tarihi:

.....

..... Üniversitesi

Jüri Başkanı

.....
..... Üniversitesi
Raportör

.....
..... Üniversitesi
Üye

.....
..... Üniversitesi
Üye

.....
..... Üniversitesi
Üye

Tez hakkında alınan jüri kararı, Ankara Üniversitesi Sağlık Bilimleri Enstitüsü Yönetim Kurulu tarafından onaylanmıştır.

Prof. Dr. Fügen AKTAN

Sağlık Bilimleri Enstitüsü Müdürü

ÖZET

Süt ve Daimi Dişlerde Arayüz Çürüklerinin Teşhisinde Yapay Zekânın Etkinliğinin Değerlendirilmesi

Bu tez çalışması, derin öğrenme tabanlı Yolov5x mimarisini kullanarak hem süt hem de daimi dişlere ait bitewing radyografilerde bulunan arayüz çürüklerini otomatik olarak saptayan bir model geliştirmeyi ve modelin tanısallık performansını ayrıntılı metriklerle değerlendirmeyi amaçlamaktadır. Çalışma retrospektif tasarlanmış ve CLAIM 2024 kontrol listesi rehberliğinde yürütülmüştür. Çalışmada 1000'er adet süt ve daimi diş bitewing radyografisi Craniocatch etiketleme modülünde poligonal segmentasyonla işaretlenmiş, toplam 5704 çürük lezyon anotasyonu elde edilmiştir. Görüntüler %80 eğitim, %10 doğrulama, %10 test olacak şekilde ayrılmış, Yolov5x modeli PyTorch ortamında eğitilmiştir. Performans; kesinlik, duyarlılık, F1 skoru ve ROC-AUC gibi ölçütlerle hem grup bazında hem de genel olarak raporlanmıştır. Elde edilen bulgulara göre, süt dişi radyografilerine ait test setinde modelin kesinlik değeri 0,80; duyarlılığı 0,78; F1 skoru 0,79 ve AUC değeri 0,87 olarak hesaplanmıştır. Daimi diş grubunda ise kesinlik 0,78; duyarlılık 0,75; F1 skoru 0,76 ve AUC değeri 0,88 olarak bulgulanmıştır. Süt dişlerinde duyarlılığın hafifçe yüksek seyretmesi, daha belirgin kontrast farkı ve lezyon morfolojisine bağlanmış olup, fark klinik olarak minimal düzeydedir. Test verilerindeki 518 etiketin konfüzyon matrisleri, yanlış pozitif ve negatif oranlarının kabul edilebilir düzeyde olduğunu göstermiştir. Ayrıca, güven skoru eşiklerinin optimize edilmesi, uygulamada yanlış karar riskini daha da azaltılabilecektir. Yolov5x temelli model, süt ve daimi dişlerde arayüz çürüklerini gerçek zamanlı, piksel düzeyinde ve yüksek doğrulukla saptayarak literatürde bildirilen benzer çalışmalarla karşılaştırılabilir seviyede performans sunmuştur. Böylece çocuk hastalarda tarama, tedavi planlaması ve ikinci görüş amaçlı klinik karar destek sistemi olarak kullanılma potansiyeli taşıyabileceği düşünülmektedir. Ancak, tek-merkezli araştırma tasarımı ve yalnızca radyografik görüntülere dayalı eğitim süreci genellenebilirliği sınırlayabileceği için, gelecekte çok-merkezli, yaşa göre dengelenmiş ve multimodal veri içeren diş doğrulamalı çalışmalar yapılması önerilmektedir. Modelin küçük lezyon tespitini iyileştirmek amacıyla farklı segmentasyon mimarileriyle karşılaştırmalı araştırmalar ve gerçek zamanlı klinik entegrasyona odaklanan yazılım geliştirmeleri de potansiyel geliştirme alanlarıdır. Bu tez çalışmasının dahilinde elde edilen bulgular ve çıkarımlar, yapay zekâ destekli radyografik tanı sistemlerinin çocuk diş hekimliği pratiğinde erken çürük teşhis sürecini hızlandırarak tedavi maliyetlerini azaltma ve sağkalımı artırma yönünde önemli bir adım sergilediğini göstermektedir.

Anahtar Sözcükler: Çürük, daimi diş, süt dişi, yapay zekâ

SUMMARY

The Evaluation of the Efficiency of Artificial Intelligence in Approximal Caries Detection in Primary and Permanent Teeth

This thesis aims to develop a model that automatically detects interproximal caries in bitewing radiographs of both primary and permanent teeth using the deep learning-based Yolov5x architecture, and to evaluate the model's diagnostic performance using detailed metrics. The study was designed retrospectively and conducted in accordance with the CLAIM 2024 checklist. In this study, 1000 bitewing radiographs of primary and permanent teeth were annotated with polygonal segmentation in Craniocatch labeling module, resulting in a total of 5704 caries lesion annotations. The images were divided into 80% training, 10% validation, and 10% test sets, and Yolov5x model was trained in PyTorch. Performance was reported both group-wise and overall using metrics such as precision, sensitivity, F1 score and ROC-AUC. According to obtained results, precision of the model in the test set of primary tooth radiographs was calculated as 0.80; sensitivity as 0.78; F1 score as 0.79 and AUC value as 0.87. In the permanent tooth group, precision was 0.78; sensitivity 0.75; F1 score 0.76 and AUC value 0.88. The slightly higher sensitivity in primary teeth was attributed to more pronounced contrast differences and lesion morphology, with the difference being clinically minimal. The confusion matrices of the 518 labels in the test data showed that the false positive and false negative rates were at acceptable levels. Additionally, optimizing confidence score thresholds could further reduce the risk of incorrect decisions in practice. Yolov5x-based model detected interproximal caries in primary and permanent teeth in real time, at the pixel level, and with high accuracy, demonstrating performance comparable to similar studies reported in the literature. Thus, it is considered that the model has the potential to be used as a clinical decision support system for screening, treatment planning, and second opinions in pediatric patients. However, the single-center study design and the training process based solely on radiographic images may limit generalizability, so future studies with multi-center, age-balanced, and multimodal data-inclusive external validation are recommended. Comparative studies with different segmentation architectures to improve small lesion detection and software developments focused on real-time clinical integration are also potential areas for further development. The findings and conclusions obtained within this thesis demonstrate that artificial intelligence-supported radiographic diagnosis systems represent an important step toward accelerating the early caries diagnosis process in pediatric dentistry practice, thereby reducing treatment costs and improving survival rates.

Keywords: Artificial intelligence, caries, permanent tooth, primary tooth

İÇİNDEKİLER

Etik Beyan	ii
Kabul ve Onay	iii
Özet	iv
Summary	v
İçindekiler	vi
Önsöz	viii
Simgeler ve Kısaltmalar	x
Şekiller	xi
Çizelgeler	xii
1. GİRİŞ	1
1.1. Yapay Zekâ	6
1.2. Yapay Zekânın Dış Hekimliğinde Kullanım Alanları	12
1.3. Yapay Zekâ Tabanlı Çürük Tespiti ve Teşhisinin Gelecek Perspektifleri	18
1.4. Yapay Zekâ ile İlişkili Kavramlar ve Çalışma Prensipleri	18
1.5. Yapay Zekâ Tabanlı Modellerde Eğitim, Validasyon ve Test Aşamaları	27
1.5.1. Eğitim Aşaması	27
1.5.2. Validasyon Aşaması	27
1.5.3. Test Aşaması	28
1.6. Çalışmanın Gerekçesi ve Amaç	28
2. GEREÇ ve YÖNTEM	30
2.1. Çalışma Tasarımı ve Rehber Alınan Kılavuzlar	30
2.2. Etik Kurul Onayı ve Etik İlkeler	31
2.3. Araştırmanın Fonlanması ve Giderlerin Karşılanması	31
2.4. Görüntü Verilerinin Sağlanması	31
2.5. Dahil Edilme Kriterleri	31
2.6. Hariç Tutulma Kriterleri	32
2.7. Çalışma Grupları ve Dahil Edilen Radyografik Görüntülerin Dağılımı	32
2.7.1. Süt Dişi Radyografik Görüntüleri	32
2.7.2. Daimi Diş Radyografik Görüntüleri	33
2.8. Görüntü Anonimizasyonu ve Veri Güvenliği	33
2.9. Görüntü Ön İşleme	34
2.10. Etiketleme Süreci	34
2.11. Çalışma Prosedürü ve Veri Setleri	35
2.12. Yapay Zekâ Eğitim Aşamaları	36
2.13. Kullanılan Yapay Zekâ Modeli	36
2.14. Model Validasyon (Doğrulama) Aşaması	37
2.15. Model Test Aşaması	37
2.16. Sonuçların Yorumlanması ve Performans Değerlendirme Metrikleri	38
2.16.1. Doğru Pozitif (DP)	38
2.16.2. Yanlış Pozitif (YP)	38
2.16.3. Yanlış Negatif (YN)	39
2.16.4. Kesinlik (Precision)	39
2.16.5. Duyarlılık (Recall ya da Sensitivity)	39

2.16.6. F1 Skoru	39
2.16.7. Güven Skoru Eğrileri	40
2.16.8. ROC Eğrisi ve AUC	40
3. BULGULAR	41
3.1. Süt Dişı Radyografik Görüntüleri	41
3.2. Daimi Diş Radyografik Görüntüleri	46
4. TARTIŞMA	52
5. SONUÇ ve ÖNERİLER	66
KAYNAKLAR	67
EKLER	76
EK-1. Etik Kurul Onayı	76



ÖNSÖZ

Bu tezin hazırlanma sürecinde değerli bilgi ve yönlendirmeleriyle her zaman yanımda olan, akademik gelişimime büyük katkılarda bulunan saygıdeğer hocam Doç. Dr. Akif DEMİREL'e en derin şükranlarımı sunarım. Titiz akademik yaklaşımı, sabırla verdiği yapıcı geri bildirimleri ve araştırma konusuna olan derin ilgisiyle bana her zaman ilham kaynağı olmuştur. Bu zorlu ve uzun akademik yolculuk boyunca bana yalnızca bilimsel bilgi kazandırmakla kalmayıp, iyi bir bilim insanı olmam için yol gösteren, bitmek bilmeyen sabrı ve engin tecrübesiyle her an yanımda olan kıymetli hocam; zor anlarımda verdiğiniz cesaret ve yönlendirmeleriniz için minnettarım. Sizin bana yalnızca bir hoca değil, aynı zamanda bir abi gibi davranmanız, bana her zaman ayrı bir güç ve güven vermiştir. Her zaman örnek aldığım, saygı ve hayranlık duyduğum bu değerli hocamın öğrencisi olmak benim için büyük bir gurur kaynağıdır.

Ayrıca, tez sürecim boyunca bilgi ve deneyimlerini paylaşarak bana destek olan tüm değerli hocalarıma ve arkadaşlarıma teşekkür ederim. Her biriniz, mesleki gelişimin yanı sıra insani değerlerin önemini de bana aşılıyarak bu yolculuğa anlam kattınız.

Doktora öğrenimim süresince burs desteği aldığım TÜBİTAK Bilim İnsanı Destek Programları Başkanlığı (BİDEB) 2211–Yurt İçi Lisansüstü Burs Programı'na sağladıkları katkı ve destek için teşekkür etmeyi bir borç bilirim.

Hayatımın en büyük şansı olan, varlığıyla her zaman yanımda olduğunu hissettiren, her başarımda gözleri dolu dolu gururlanan ve emeğiyle bu süreçte bana en büyük güç kaynağı olan canım anneme; çalışkanlığı ve azmiyle bana her zaman örnek olan, hayatım boyunca kararlılığı ve desteğiyle yanımda duran canım babama; sırdaşım, en iyi dostum, neşesi ve desteğiyle en zor zamanları bile güzelleştiren, başarılarıyla her daim hepimizi gururlandıran canım kardeşime; hayatım boyunca bana verdiği sevgi, güven ve öğütlerle yanımda olan bir tanecik dedeme; bana hayatımın ilk harflerini ve ilk sayıları sabırla öğreten, sevgisiyle bana öğrenmenin ne kadar kıymetli olduğunu hissettiren ilk öğretmenim anneanneme sonsuz teşekkürlerimi sunarım. Onun dizinin dibinde öğrendiğim ilk kelimeler ve değerler, bugün bu tezin her satırında hayat buluyor. Bana kattığın sevgi, sabır ve merhamet için minnettarım; öğrenmenin anlamını ve kıymetini bana hayatımın en başında öğrettiğin için sana daima teşekkür borçluyum.

Hayatıma kattığı sevgi, huzur ve güven duygusuyla bu yolculuğu anlamlı kılan, her yorgunluğumda omuzuma dokunan, her umutsuz anımda “sen yaparsın” diyerek bana moral veren sevgili eşim Dr. Öğr. Üyesi Merter GÜÇLÜ’ye teşekkür ederim. Onun sabrı, anlayışı ve sonsuz desteği olmasaydı bu yolculuk bu kadar güçlü ve güzel tamamlanamazdı. Mutlu günlerimi paylaşırken gözlerindeki parıltı, zor anlarımda yanımda oluşu, bana sadece bu tezin değil, hayatın her alanında birlikte çok daha büyük başarılarla imza atabileceğimizi gösterdi. İyi ki varsın ve iyi ki yolum seninle kesişmiş.



SİMGELER VE KISALTMALAR

AUC	Area Under the Curve
BT	Bilgisayarlı Tomografi
CLAIM	Checklist for Artificial Intelligence in Medical Imaging
DP	Doğru Pozitif
FOTİ	Fiber Optik Transillüminasyon
FPR	False Positive Rate
IoU	Intersection over Union
LOG	Kayıt
MR	Manyetik Rezonans
QLF	Kantitatif Işıklı Uyarılmış Floresan
ROC	Receiver Operating Characteristic Curve
TPR	True Positive Rate
YN	Yanlış Negatif
YOLO	You Only Look Once
YP	Yanlış Pozitif

ŞEKİLLER

Şekil 1.1. Klasik programlamaya karşı makine öğrenmesi paradigmasını gösteren şematik diyagram	19
Şekil 1.2. Veri bilimi tekniklerinin şematik gösterimi	21
Şekil 1.3. Yapay zekâ sistemlerinin şematik gösterimi	21
Şekil 2.1. Kullanılan veri setine ait süt dişi (a ve b) ve daimi diş (c ve d) bitewing radyografik görüntüleri	33
Şekil 2.2. Süt dişi (a) ve daimi diş (b) bitewing radyografik görüntülerine ait arayüz çürük lezyonlarını etiketleme süreçlerini gösteren görüntüler	35
Şekil 3.1. Süt dişi bitewing radyografilerinde Yolov5x modelinin test aşamasında arayüz çürüklerinin teşhisine ilişkin örnek görüntüler	42
Şekil 3.2. Süt dişi radyografik görüntüleri için elde edilen konfüzyon matrisi	43
Şekil 3.3. Süt dişi radyografileri için segmentasyon bazlı F1-Güven Skoru eğrisi	44
Şekil 3.4. Süt dişi radyografileri için segmentasyon bazlı Kesinlik-Güven Skoru Eğrisi	45
Şekil 3.5. Süt dişi radyografileri için segmentasyon bazlı Duyarlılık-Güven Skoru Eğrisi	46
Şekil 3.6. Daimi diş bitewing radyografilerinde Yolov5x modelinin test aşamasında arayüz çürüklerinin teşhisine ilişkin örnek görüntüler	47
Şekil 3.7. Daimi diş radyografik görüntüleri için elde edilen konfüzyon matrisi	48
Şekil 3.8. Daimi diş radyografileri için segmentasyon bazlı F1-Güven Skoru Eğrisi	49
Şekil 3.9. Daimi diş radyografileri için segmentasyon bazlı kesinlik-güven skoru eğrisi	50
Şekil 3.10. Daimi diş radyografileri için segmentasyon bazlı duyarlılık-güven skoru eğrisi	51

ÇİZELGELER

Çizelge 2.1. Eğitim, validasyon ve test veri setleri ile ilişkili radyografik görüntü sayıları	36
Çizelge 2.2. Eğitim, validasyon ve test veri setleri ile ilişkili etiket sayıları	36
Çizelge 3.1. Yolov5x modelinin süt dişi radyografilerindeki performans metrikleri	43
Çizelge 3.2. Yolov5x modelinin daimi diş radyografilerindeki performans metrikleri	48



1. GİRİŞ

Dünya genelinde en yaygın görülen kronik hastalıklardan biri olan çürük, asit üreten bakteriler ile fermente olabilen karbonhidratlar arasındaki uzun süreli karmaşık olaylar sonucunda oluşur. Bu süreçte dişler ve tükürük gibi birçok konak faktörü de önemli rol oynar (Selwitz vd., 2007). Diş çürüğü, dişlerde mikroorganizmaların yol açtığı yerel bir yıkım olarak özetlenebilir. Bu süreçte mine, dentin ve sement gibi normalde mineralize olan diş yapısı asit üretiminin artışı ve bu asidin diş yüzeyine zarar vermesiyle zarar görür (Iannucci ve Radiography, 2017). Şiddetli olgularda diş çürükleri; yoğun ağrıya, sert doku kaybına, oral apse oluşumuna ve fasiyal bölgede şişlik gelişimine yol açabilmektedir (Selwitz vd., 2007). Diş çürüğünün bu karmaşık etiyojisi, etkin önleme ve tedavi stratejileri geliştirilmesi açısından kapsamlı bir anlayış ve arayış gerektirmektedir (Bordoni vd., 2021; Machiulskiene vd., 2020; Pitts vd., 2021; Selwitz vd., 2007).

Çocuklarda diş çürüğünün; genel sağlık durumu, fiziksel büyüme ve gelişim, yaşam kalitesi ile eğitim süreci üzerinde önemli ölçüde olumsuz etkiler oluşturduğu literatürde ortaya konmuştur. Özellikle tedavi edilmeyen diş çürükleri, ağrı ve enfeksiyonlara neden olarak çocukların beslenme alışkanlıklarını bozmakta ve buna bağlı olarak yetersiz beslenme ile büyüme geriliğine yol açabilmektedir (Sheiham, 2006). Nitekim yapılan bir çalışmada, şiddetli diş çürüğüne sahip üç yaşındaki çocukların, çürüğü bulunmayan akranlarına kıyasla ortalama bir kilogram daha düşük vücut ağırlığına sahip olduğu bildirilmiştir (Acs vd., 1992). Benzer şekilde, Türkiye örneğinde yapılan araştırmalarda da çürüğe sahip çocukların, çürüğü olmayan yaşlılarına göre istatistiksel olarak anlamlı düzeyde daha düşük kilo ve boya sahip oldukları ortaya konmuştur (Ayhan vd., 1996). Bu durumun yalnızca beslenme yetersizliğinden değil, aynı zamanda çürüğe bağlı olarak oluşan ağrının çocukların uyku kalitesini olumsuz etkilemesinden kaynaklandığı; dolayısıyla yetersiz uykunun da büyüme ve gelişim üzerinde benzer olumsuz sonuçlara yol açtığı belirtilmektedir (Low vd., 1999).

Diş çürüğü, yalnızca fiziksel sağlıkla sınırlı kalmayıp çocukların psikolojik ve sosyal gelişimlerini de önemli ölçüde etkileyen yaygın bir sağlık sorunudur. Diş çürükleri çocuklarda özgüven eksikliği, sosyal ortamlarda kendini geri çekme ve arkadaşlık ilişkilerinde bozulmalar gibi bir dizi psikososyal probleme yol açabilmektedir. Bu durumun özellikle estetik kaygı ve sürekli ağrı ile ilişkili olduğu; çocukların gülümsemekten kaçındığı, mutsuzluk yaşadığı ve genel yaşam kalitesinin azaldığı bildirilmektedir (Corrêa-Faria vd., 2020; Fernandez vd.,

2022; Filstrup vd., 2003; Zaror vd., 2022). Bu veriler, ağız ve diş sağlığının yalnızca tıbbi değil, aynı zamanda ruhsal ve sosyal bütünlük açısından da erken yaşlardan itibaren korunması gerektiğini açıkça ortaya koymaktadır.

Diş çürüğüne bağlı olarak gelişen ağrı ve enfeksiyonların, çocuklarda okul devamsızlıklarını artırdığı ve sınıf içi dikkat süresini olumsuz etkilediği bildirilmektedir. Bu tür sağlık sorunları, öğrencilerin akademik performansında belirgin düşüşlere yol açabilmektedir. Nitekim ağız ve diş sağlığı yetersiz olan çocukların okul başarılarının daha düşük düzeyde olduğuna ilişkin bulgular literatürde yer almaktadır (Jackson vd., 2011). Ayrıca, dental ağrı nedeniyle ebeveynlerin çocuklarını sağlık kuruluşlarına götürmek zorunda kalmaları, iş gücü kaybına ve dolayısıyla ekonomik yükün artmasına neden olmaktadır (Gift, 1997; Jackson vd., 2011). Bu durum yalnızca bireyleri değil, aynı zamanda toplumun genel ekonomik yapısını da olumsuz etkilemektedir. Nitekim, diş çürüğünün ilerlemesiyle birlikte tedavi süreçlerinin daha karmaşık ve maliyetli hale gelmesi hem bireysel düzeyde hem de sağlık sistemleri üzerinde artan bir finansal yük oluşturmaktadır (Righolt vd., 2018). Tüm bu bulgular, çürüğün erken tespit edilmesinin öneminin yanı sıra çürüğün erken evrelerinde uygulanacak koruyucu yaklaşımların ve zamanında müdahalenin, uzun vadede tedavi maliyetlerini düşürerek ekonomik açıdan önemli kazanımlar sağlayacağını göstermektedir. Erken teşhisin yalnızca ekonomik faydalarla sınırlı kalmadığı, aynı zamanda çocuğun genel yaşam kalitesine de olumlu katkılar sunduğu dikkate değerdir (Zaror vd., 2022).

Bununla birlikte, erken dönemde uygulanan dental tedavilerin, çocukların psikolojik ve sosyal yaşamlarında kayda değer iyileşmeler sağladığı gösterilmiştir. Bu iyileşmeler, ağrı düzeyinin azalması, uyku ve beslenme düzeninin yeniden sağlanması gibi fiziksel çıktılarına ek olarak; çocukların daha fazla gülümsediği, okul performanslarının arttığı ve sosyal etkileşim becerilerinde gelişim gözlemlendiği biçiminde raporlanmıştır (Cunnion vd., 2010; Filstrup vd., 2003).

Tüm bu nedenlerden yola çıkarak, çürük lezyonlarının mümkün olan en erken evrede tespit edilmesi hem koruyucu hem de minimal girişimsel diş hekimliği yaklaşımlarının uygulanabilirliğini artırmaktadır. Bu bağlamda, klinik ve radyografik olarak çürük teşhis yöntemlerinin irdelenmesi son derece faydalı olacaktır. Diş çürüğünün erken teşhisi, yalnızca klinik muayeneyle değil, çeşitli destekleyici tanı araçlarının entegrasyonu ile daha güvenilir hale gelmektedir. Bu kapsamda, görsel-taktiksel değerlendirme, radyografik inceleme ve son

yıllarda hızla gelişen dijital ve yapay zekâ tabanlı sistemler, çürük teşhisinde önemli roller üstlenmektedir. Geleneksel ve modern teşhis yöntemlerinin avantaj ve sınırlılıklarının karşılaştırılması, doğru ve zamanında teşhis için uygun stratejilerin belirlenmesini gerektirmektedir. Çürüğün görsel ve dokunsal muayene ile subjektif olarak değerlendirilmesi ve radyografik yorumlama, geleneksel çürük teşhis yöntemi olarak tanımlanmaktadır (Selwitz vd., 2007).

Görsel muayene, diş çürüğü lezyonlarının tespitinde en yaygın kullanılan yöntem olup, klinik uygulamalarda rutin olarak gerçekleştirilen ve kolay uygulanabilir bir teknik olması nedeniyle tercih edilmektedir (Pitts, 1993). Çürüğün tespiti için en sık ayna, sond ve ışık kullanılmaktadır (Neuhaus vd., 2009). Bu yöntemin özgülüğünün yüksek olduğu, yani sağlıklı yüzeylerin doğru bir şekilde tanımlanmasında etkili olduğu gösterilmiştir. Ancak, çürük lezyonlarının doğru şekilde tespit edilmesine ilişkin duyarlılığının düşük olduğu ve sonuçlarının tekrarlanabilirliğinin sınırlı kaldığı bildirilmektedir. Bu düşük tekrarlanabilirlik, yöntemin öznel doğasından kaynaklanmaktadır (Bader vd., 2002).

Klinik çalışmalarda elde edilen bulgulara göre, daimi dişlerde görsel muayene yöntemiyle arayüz çürük lezyonlarının tespitine ilişkin duyarlılık oranları yaklaşık olarak %30 düzeyindedir (Mialhe vd., 2003; Peers vd., 1993). Novaes vd. (2009), gerçekleştirdiği bir çalışmada süt azı dişlerinin arayüzlerinde yer alan kavite oluşmuş lezyonların saptanmasında da benzer duyarlılık değerlerine ulaşmıştır (Novaes vd., 2009). Bu veriler, yalnızca görsel muayeneye dayanan değerlendirmelerin sınırlılıklarını ortaya koymakta, özellikle kavite içeren arayüz çürük lezyonlarının yaklaşık %70'inin bu yöntemle atlanabileceğini göstermektedir.

Geleneksel bir çürük teşhis yöntemi olan görsel muayenede, dokunsal değerlendirme belirtildiği üzere bir sond yardımıyla gerçekleştirilir. Bu yöntemin, radyografik görüntüleme ile desteklenmesi durumunda tanısal güvenilirliğinin arttığı literatürde genel kabul görmektedir. Klinik değerlendirme sürecinde; çürük varlığı ya da yokluğu, sond ve radyografi gibi görece basit tanı araçlarının yanı sıra, lezyonun rengi, translüsensitesi ve sertliği gibi subjektif klinik bulgulara dayalı olarak belirlenmektedir (Zandoná ve Zero, 2006). Bununla birlikte, sond kullanımına ilişkin bazı önemli sınırlılıklar da mevcuttur. Sond ile yapılan fiziksel muayene sırasında uygulanan mekanik kuvvetin, yüzeysel olarak remineralize olma potansiyeli taşıyan lezyonlarda yapısal bozulmaya neden olabileceği bildirilmiştir. Ayrıca,

sondun diş yüzeylerinde gezdirilmesiyle birlikte karyojenik bakterilerin bir yüzeyden diğerine taşınması riski, çürük gelişimini hızlandırarak invaziv tedavi gereksinimini artırabilmektedir (Ekstrand vd., 1987; Nickerson ve Orton, 1997). Tüm bunlara ek olarak, görsel ve sond muayenesinin özellikle aproksimal bölgelerde ve okluzal fissürlerde yer alan çürük lezyonlarını saptamada yetersiz kaldığı, bu bölgelerdeki çürüklerin uzun süre fark edilmeden ilerleyebildiği belirtilmektedir (Ismail, 2004).

Radyolojik muayene ise çürük lezyonlarının belirlenmesi amacıyla dişlerin kapsamlı görsel muayenesine ek olarak en sık yararlanılan yardımcı muayene yöntemidir. Özellikle görsel muayenenin yetersiz kaldığı bölgelerde radyolojik incelemeyle gözden kaçabilecek çürük lezyonlarının teşhisi kolaylaşmıştır. Radyografi ile başlangıç çürük lezyonlarının teşhisinin yapılabilmesi için diş dokusunda %30-40 oranında mineral kaybının oluşması gerekirken çürüğün aktif ya da inaktif olduğu radyografi kullanılarak ayırt edilememektedir (White ve Pharoah, 2014).

Panoramik radyografi, geniş anatomik yapıları tek bir görüntüde sunabilme kapasitesi, düşük düzeyde radyasyon maruziyeti, kısa çekim süresi ve hastalar tarafından genellikle iyi tolere edilmesi nedeniyle diş hekimliğinde sıkça tercih edilen bir görüntüleme yöntemidir. Bu özellikleri sayesinde, özellikle genel ağız içi değerlendirmelerde ve ön tanı aşamalarında önemli bir tanısal araç olarak kullanılmaktadır (Flint vd., 1998). Bununla birlikte, panoramik görüntülemenin bazı dezavantajları da mevcuttur. İntraoral radyografilerle karşılaştırıldığında, ayrıntı çözünürlüğünün yetersizliği, premolar bölgelerde sık rastlanan süperpozisyonlar, görüntü büyütme etkileri ve geometrik distorsiyonlar, elde edilen görüntülerin tanısal doğruluğunu sınırlayabilmektedir (White ve Pharoah, 2014). Bu tür sınırlamaları telafi etmek amacıyla, tanının netleştirilmesi ve detaylı değerlendirme yapılabilmesi için panoramik radyografinin periapikal ve/veya bitewing radyografiler ile desteklenmesi yaygın bir klinik uygulama halini almıştır (Bozdemir ve Yarbaşı, 2019).

Görsel muayeneye ek olarak bitewing radyografisinin kullanımı, dentin düzeyindeki arayüz ve okluzal çürük lezyonlarının daha yüksek duyarlılıkla saptanmasına olanak sağlamakta; aynı zamanda lezyonun derinliğine ilişkin daha isabetli bir tahminde bulunulmasına imkân tanımaktadır. Ayrıca, çürük lezyonlarının izlenmesi sürecinde, yalnızca klinik muayeneye dayalı değerlendirmelere kıyasla daha güvenilir ve objektif sonuçlar elde edilebilmektedir (Wenzel, 2004). Bu bağlamda, arayüz çürüklerinin tanısında tercih edilecek

en iyi yöntemin bitewing radyografi olduđu gösterilmiştir (Kamburođlu vd., 2012). Bu yöntem, hastanın ısırabileceđi “kanat” yapısına sahip özel bir film tutucu ile uygulanır. Ancak, yüzeylerin birbiri üzerine akışması, konik kesim hataları (cone cut) ya da belirli yüzeylerin görüntülenmemesi gibi artefaktların önlenbilmesi için, teknik uygulamanın dikkatle yürütölmesi gerekmektedir. Uygun şartlar altında elde edilen bitewing radyografiler, mevcut klinik değerdendirmeyi tamamlayıcı nitelikte önemli tanısal bilgiler sunmaktadır (Wenzel, 2004). Bununla birlikte, yöntemle ilişkin bazı sınırlılıklar da bulunmaktadır. Özellikle aproksimal yüzeylerde tedavi kararlarının verilmesinde bu sınırlamalar dikkate alınmalıdır. Öncelikle, radyografik görüntüler, histolojik değerdendirmelerle karşılaştırıldığında lezyon derinliğini olduđundan daha sığ gösterebilmekte ve mine düzeyindeki erken evre ürük lezyonlarını yeterince hassas biçimde yansıtamamaktadır (Pitts, 1996; Wenzel, 2004). Diđer yandan, radyografiler ürük lezyonunun aktif ya da inaktif olduđunu belirleyememekte; özellikle aproksimal bölgelerde tedavi kararları açısından kritik öneme sahip olan kavitasyon varlığını doğrudan tespit edememektedir (Wenzel, 2004). Tüm bu sınırlılıklarına karşın, radyografik görüntölmenin ürük teşhisinde destekleyici bir yöntem olarak kullanılması değerdendirildiğinde, bu yöntemin klinik uygulamalarda yer almasını haklı kılmaktadır. Bu bağlamda, özellikle bitewing tekniđi hem okluzal hem de aproksimal yüzeylerde, klinisyenlerin doğru ve zamanında tedavi kararları alabilmesine önemli katkılar sunmaktadır (Pitts, 1996).

Son yıllarda geleneksel ürük teşhis yöntemlerine ek olarak ürük tanısına yönelik gelişmiş teknolojik yöntemler ön plana çıkmaktadır. Dijital radyografi, lazer floresan sistemleri (ör. DIAGNOdent), fiber optik transillüminasyon (FOTI) ve kantitatif ışıkla uyarılmış floresan (QLF) gibi yöntemler; ürük lezyonlarının derinliğini, yayılımını ve aktivitesini objektif ve hassas biçimde değerdendirme imkânı sunmaktadır. Bu sistemler, özellikle lezyonun invaziv müdahale gerektirip gerektirmediđini belirleme konusunda klinisyene önemli bilgiler sağlayarak, gereksiz restoratif işlemlerin önlenmesine katkıda bulunmaktadır (Ismail, 2004).

Diş hekimliğinde, diđer sađlık alanlarında olduđu gibi hastalıkların ve patolojilerin yönetimi ve tedavisi için öncelikle tanı aşamasının doğru bir şekilde gerçekleştirilmiş olması gerekli bir ön koşuldur. Doğru tanı için hasta hikayesi ile birlikte fizik muayene, radyolojik görüntölleme ya da hastalığa özgü diđer tetkiklerin bir bütün olarak değerdendirilmesi final tedavinin başarısı açısından oldukça önemlidir (Özkesici ve Yılmaz, 2021). Bununla birlikte, son yıllarda diş hekimliğinde tanı ve tedavi planlamasının oluşturulmasında teknolojik

gelişmeler klinisyene rehber olabilmektedir. Özellikle mühendislik bilimleri ve yazılım sektörü dış hekimliği alanları ile birlikte çalışmakta, bunun sonucu olarak da insana ve iş gücüne bağımlılık zamanla azalmaktadır. Bu kapsamda, birçok alanda olduğu gibi dış hekimliğinde de popülerlik kazanmaya başlayan fenomenlerden biri de yapay zekâ ve yapay zekâ ile ilişkili diğer yöntemlerdir. Bu durum, yapay zekâ uygulamalarının adaptasyona açık ve geliştirilebilir bir alan olduğuna kanıt niteliğindedir (Özkesici ve Yılmaz, 2021).

1.1. Yapay Zekâ

Yapay zekâ, minimum insan müdahalesi ile bir bilgisayarın akıllı davranış olarak adlandırılan olguları algılaması ve bu algılardan oluşturulan çıktıların farklı alanlardaki kullanımlarını ifade eden genel bir terimdir (Hamet ve Tremblay, 2017). Başka bir deyimle yapay zekâ, bir bilgisayarın ya da bilgisayar destekli bir makinenin, genellikle insan davranışını taklit etme, herhangi bir probleme çözüm yolu bulma, anlama, bir algı oluşturma, genelleme ve geçmişteki deneyimlerinden öğrenme gibi yüksek mantıksal süreçlere ilişkin görevleri yerine getirme yeteneği olarak tanımlanır (Nabiyev, 2012).

Yapay zekâ algoritmaları bilgisayar tabanlı programlamaya ihtiyaç duymadan büyük miktarda veri üzerinde çalışıp, farklı matematiksel algoritmalar ile farklı çözümler sunabilmektedir. Ayrıca, yapay zekâ modülleri istatistiksel analizlerin çözemeyeceği türden problemlerin de sonuçlandırılmasını sağlayabilir (Ghahramani, 2015; Jordan ve Mitchell, 2015). Klinisyenin bu veriyi kategorize etmesine gerek kalmaksızın anlamlı birer çıktı alabilmek yapay zekâ ile mümkün hale gelmektedir. Patoloji kesitleri, radyolojik görüntüler, serbest metinler ve monitörize edilmiş grafik verileri kategorizasyonda kullanılabilir (Celtikci, 2018).

Yapay zekâ kavramı, 1956 yılında bu alanda gerçekleştirilen bir konferansta John McCarthy tarafından ortaya konmuştur. Ancak makinelerin insan davranışlarını taklit etme ve gerçekten düşünebilme ihtimali, bundan daha önce Alan Turing'in geliştirdiği ve insanı makinelerden ayırmayı amaçlayan Turing testi ile gündeme gelmiştir. (Özkesici ve Yılmaz, 2021).

Günümüzde yapay zekâ, kişisel asistanlar (Alexa, Siri, Google Asistan vb.), sistemleri, havacılık uygulamaları ve bilgisayar oyunları dahil olmak üzere günlük yaşamın pek çok

alanına entegre olmuştur. Son yıllarda ise yapay zekâ, süreçleri hızlandırıp doğruluğu artırarak hasta bakımını iyileştirmek amacıyla tıp alanında kullanılmaya başlanmış ve daha kaliteli sağlık hizmetlerinin sunulmasına zemin hazırlamıştır. Radyolojik görüntüler, patoloji örnekleri ve hastaların elektronik sağlık kayıtları makine öğrenimi yöntemleriyle analiz edilerek, hastaların tanı ve tedavi süreçlerine katkı sağlamakta ve hekimlerin karar verme yetilerini desteklemektedir (Mintz ve Brodie, 2019).

Yapay zekâ ve ilişkili diğer öğrenme modelleri son yıllarda teknolojinin en dikkat çekici alanlarından biri haline gelmiş ve birçok sektörde köklü değişimlere yol açmıştır. Günlük hayatımızdan iş dünyasına, sağlık hizmetlerinden sanayiye kadar pek çok alanda yapay zekânın etkileri her geçen gün artmaktadır. İnsan benzeri kararlar alabilen, öğrenebilen ve büyük veri setlerini analiz edebilen yapay zekâ sistemleri, birçok iş sürecini hızlandırmakta ve verimliliği artırmaktadır. Ancak bu teknolojinin sunduğu fırsatlar kadar, getirdiği riskler ve tartışmalar da mevcuttur. Yapay zekânın avantaj ve dezavantajlarını anlamak, onun gelecekteki rolünü daha iyi kavrayabilmek için önemlidir.

Yapay zekânın avantajları incelenecek olursa, algoritmaların uygulanması yoluyla bilgisayar yazılımı, insan deneklerin yaşamları boyunca edinebileceklerinden çok daha kısa bir sürede çok daha fazla deneyim kazanabilir, büyük miktarda veriyi hızla işleyebilir, tekrarlayan görevleri insanlardan daha hızlı ve hatasız gerçekleştirebilir. Böylece süre azalırken verimlilik artmış olur. Örnek vermek gerekirse, 40'tan fazla üretken kariyer yılı boyunca, bir radyolog yaklaşık 225.000 adet radyografik görüntüye bakabilirken yapay zekâ bu sayı ile başlayabilir ve kısa bir süre içinde milyonlarca taramaya ulaşabilir, böylece doğruluğunu daha da geliştirebilir (Mintz ve Brodie, 2019). Ayrıca, insanlar karar alırken birçok faktörü analiz ederken duygusal bakış açısından etkilenerek kararlar verebilmektedirler. Ancak yapay zekâ destekli bir makine, programlandığı şekilde, duygusal bakış açısından etkilenmeden çalışmaktadır (Bhbosale vd., 2020).

Karmaşık analizleri insan hatasına yer bırakmadan gerçekleştirebilen yapay zekâ sistemleri, yüksek oranlarda doğru sonuçlar sunabilmektedir. Bu özellik, hassasiyet gerektiren alanlarda önem teşkil etmektedir. Ek olarak, yapay zekâ sistemleri, makine öğrenimi algoritmaları sayesinde yeni verilerle sürekli olarak kendini geliştirebilir ve daha iyi performans gösterebilmektedir. Her yeni deneyim ile daha akıllı ve etkili hale gelebilmektedir. Bununla birlikte, yapay zekâ sistemleri günün her saatinde yorulmadan kesintisiz

çalışabilmektedir, böylece kullanıcılarına 7/24 hizmet olanağı tanımaktadır (Bhbosale vd., 2020).

Yapay zekâ sistemleri ile birlikte büyük veriler kolayca analiz edilerek daha iyi kararlar alınmasına yardımcı olabilmektedir. Örneğin, sağlıkta teşhis süreçlerinde veya finansal analizlerde karmaşık verileri işleyip doğru kararlar verebilmektedir. Yapay zekâ tabanlı algoritmalar, tıbbi literatürü inceleyerek hekimlere güncel en iyi uygulamalar hakkında bilgi ve öneriler sağlayabilir. Bu durum, doktorların kendi uzmanlık alanlarındaki en yeni gelişmeleri takip etmelerine ve mesleki becerilerini sürekli olarak geliştirmelerine katkıda bulunur (Dave ve Patel, 2023). Ek olarak, rutin ve tekrarlayan görevleri devralarak insan iş gücüne olan ihtiyacı azalıp çalışanların daha az yorulmasına ve böylece daha stratejik görevlere odaklanmalarını sağlamaktadır (Khanzode ve Sarode, 2020). Yapay zekâ uygulamaları sayesinde kullanıcıların davranışlarını ve tercihlerini analiz ederek kişiselleştirilmiş deneyimler sunulabilmekte olup, sağlık hizmetleri ve dijital pazarlama gibi bireysel ihtiyaçların bulunduğu alanlarda özelleştirilmiş çözümler sağlanmasına olanak tanınmaktadır.

Sağlık alanında mevcut bilim, test verileri ve uzaktan teşhis cihazları ile hasta takibinden elde edilen verilerin yapay zekâ analizine dayanan tedavi kararları, tedavi etkinliğini önemli ölçüde artırma vaadi taşımaktadır. Herkes için standart tedavilerin işe yaramadığı gerçeğiyle hareket eden araştırmacılar, her bireyin geçmişi ve genetik yapısının karmaşıklığı göz önünde bulundurularak bu yönde ilerlemektedir. Örneğin, bir kanser hastası için teknoloji, hücre biyolojisini moleküler düzeyde modelleyerek belirli tümörler için en iyi ilacı bulmayı hedefler (Bughin vd., 2017). Kişiselleştirilmiş sağlık verileri sağlayan yapay zekâ algoritmaları, hastaların tıbbi geçmişlerini ve yaşam tarzı unsurlarını analiz ederek her bireye özel sağlık önerileri sunabilir. Bu sayede hastalar, kendi sağlık durumlarını daha iyi kavrayabilir ve bakım süreçleriyle ilgili daha bilinçli kararlar alabilirler (Dave ve Patel, 2023). Bir diğer önemli uygulama ise uzaktan izleme sistemleridir. Yapay zekâ destekli uzaktan izleme sistemleri ile hastaların hayati belirtileri takip edilebilir ve olası sorunlar sağlık hizmeti sağlayıcılarına bildirilir. Bu da erken müdahaleye, daha iyi hasta sonuçlarına ve sağlık tesislerine yapılan yüz yüze ziyaretlerin azalmasına yol açabilir. Yapay zekânın sağlık hizmetlerini geliştirmek için kullanıldığı bir diğer alan ise sanal danışmanlıklardır. Bu yöntem sayesinde hastalar, sağlık merkezlerine fiziksel olarak gitmek zorunda kalmadan uzaktan tıbbi destek ve tedavi alabilmektedir (Dave ve Patel, 2023). Ayrıca yapay zekâ, karmaşık biyobelirteçleri tanımlayabilir ve her gün milyonlarca simülasyon deney yaparak

kombinasyon tedavileri arayabilir. Birçok şirket halihazırda yapay zekâ teknolojilerini bireylerin tedavilerini kişiselleştirmek için kullanmaktadır. “Mindmaze”, felç hastalarının rehabilitasyonunu optimize etmek için yapay zekâyı kullanırken “Ginger.io” ise her hastanın metabolizması ve diğer faktörlere dayalı olarak ilaç alımı için en uygun zamanı önermektedir (Bughin vd., 2017).

Son yıllarda yapay zekânın tıbbi radyolojide kullanımı, yalnızca tanı süreçlerinin hızını ve doğruluğunu artırmakla kalmamış, aynı zamanda hasta güvenliğine de önemli katkılar sağlamıştır. Yapay zekâ teknolojilerinin bu alandaki bir diğer önemli avantajı, hastaların maruz kaldığı radyasyon miktarını azaltma potansiyelidir. Tıbbi görüntüleme prosedürleri sırasında hastaların aldığı radyasyon, özellikle sık sık görüntüleme gereken hastalar için risk oluşturabilir. Bu nedenle, radyasyon dozunu en aza indirmek, tıbbi görüntüleme süreçlerinde hayati bir öneme sahiptir. Yapay zekâ algoritmaları, görüntüleme protokollerini optimize ederek, tıbbi görüntüleme işlemleri sırasında hastaların aldığı radyasyon dozunu en aza indirebilir. Bu da hasta güvenliğini önemli ölçüde artırabilir ve zararlı etkilerin riskini azaltabilir (Dave ve Patel, 2023).

Belirtilen avantajların yanı sıra, yapay zekânın tıp ve diş hekimliği eğitime entegrasyonu, son yıllarda önemli bir ivme kazanmış ve hem öğrenciler hem de eğitmenler için çeşitli faydalar sağlamıştır. Yapay zekâ teknolojisinin eğitim alanında sunduğu en dikkat çekici uygulamalardan biri, sanal simülasyon ve eğitim sistemleridir. Geleneksel eğitim yöntemlerinin sınırlamalarını aşan bu yenilikçi yaklaşım, öğrencilerin karmaşık tıbbi ve dental prosedürleri sanal hastalar üzerinde uygulamalarına olanak tanır. Bu sayede öğrenciler, gerçek hastalar üzerinde hata yapma riskini ortadan kaldırarak, güvenli ve kontrollü bir ortamda daha fazla pratik yapma şansına sahip olurlar (Dave ve Patel, 2023).

Sanal simülasyonlar, öğrencilere kendi hızlarında çalışma imkanı sunarak kişiselleştirilmiş bir öğrenme deneyimi sağlar. Her öğrenci, ihtiyaçlarına göre belirli prosedürleri tekrar edebilir ve ustalaşana kadar uygulama yapabilir. Bu durum, geleneksel eğitim ortamlarında sınırlı olan tekrarlama fırsatını artırır. Bunun yanı sıra yapay zekâ tabanlı simülasyonlar, eğitmenlere öğrencilerin performansını objektif bir şekilde değerlendirme ve geri bildirim sağlama konusunda da yardımcı olur (Dave ve Patel, 2023). Sonuç olarak, yapay zekânın tıp ve diş hekimliği eğitime entegrasyonu, öğrenci gelişimini hızlandıran, eğitimi daha erişilebilir ve verimli hale getiren bir devrim niteliği taşımaktadır. Simülasyonlar ve

teşhis araçları ile hem öğrencilerin öğrenme süreçlerini iyileştirirken hem de tıbbi uygulamaların kalitesini artırma potansiyeline sahiptir. Bu teknolojinin, gelecekte sağlık profesyonellerinin eğitime ve hastaların tedavi süreçlerine olan katkıları giderek daha fazla önem kazanacaktır.

Belirtilen avantajlara ek olarak yapay zekâ sistemlerinin bazı dezavantajları da bulunmaktadır. Bilgisayar destekli teşhis sistemlerinin, tıp ve diş hekimliğinin çeşitli alanlarında uygulandığında yüksek verimlilik ve iyileştirilmiş sonuçlar sağladığı görülmüştür. Özellikle son yıllarda, derin öğrenmenin öne çıkan araştırma alanlarından biri olan evrişimli sinir ağları önemli gelişmeler kaydetmiş ve görüntü analizi süreçlerinde algılama, sınıflandırma ve segmentasyon gibi görevlerde üstün performans göstermiştir. Ancak, derin evrişimli sinir ağı tabanlı algoritmaların yüksek başarı ve güvenilirlik düzeylerine rağmen, diş hekimliğinde temel araştırmalarda ve klinik uygulamalarda kullanımının hâlen büyük ölçüde sınırlı olduğu dikkat çekmektedir (Lee vd., 2020). Öte yandan, yapay zekânın otomasyon yoluyla rutin ve tekrarlayan görevleri devralması bazı alanlarda iş kayıplarına yol açabileceği düşünülmektedir. Özellikle üretim ve müşteri hizmetleri gibi sektörlerde bu sistemlerin yaygınlaşmasıyla insan iş gücüne olan talebin azalmasıyla işsizliğin artmasına neden olabileceği ön görülmektedir (Khanzode ve Sarode, 2020).

Büyük veri altyapısı, güçlü işlemciler ve uzman mühendislik bilgisi gerekmesi sebebiyle genellikle yapay zekâ sistemlerinin geliştirilmesi ve uygulanması yüksek maliyetlidir (Khanzode ve Sarode, 2020). Buna ek olarak, bu sistemler zarar gördüğünde tamir etmek ekstra para ve kaynak maliyetine neden olmaktadır (Bhbosale vd., 2020). Bununla beraber, yapay zekâ sistemlerinin yaygınlaşmasıyla insanların bu sistemlere aşırı bağımlı hale gelebileceği düşünülmektedir. Eleştirel düşünme ve problem çözme yeteneklerinin zayıflamasına neden olabilecek bu durumun yapay zekâ sistemi arızalandığında insanların kriz yönetiminde yetersiz kalmasına sebep olabileceği düşünülmektedir (Khanzode ve Sarode, 2020). Ek olarak, insanların yapay zekâ uygulamalarına alışıp tembelleşecekleri ve bu durumun gelecek nesiller için bir sorun haline gelebileceği de düşünülmektedir (Bhbosale vd., 2020).

Son yıllarda, özellikle yapay zekâ sistemlerinin otonom hale gelmesiyle kontrolün tamamen makinelere geçmesi riski ortaya çıkabileceği ve yapay zekânın yanlış kararlar alması veya insan müdahalesi olmadan hatalı davranışlar sergilemesi durumunda ciddi sonuçlara yol

açabileceği ihtimali olduğu düşünülmektedir. Otonom sistemlerde güvenlik ve kontrol mekanizmalarının doğru bir şekilde uygulanmamasının büyük riskler doğurabileceği bildirilmiştir (Bhbosale vd., 2020). Ayrıca, ekip yönetiminde, insan ilişkileri vazgeçilmez bir unsurdur. Yapay zekâ sistemlerinin verimlilik açısından insanlardan daha üstün yanları bulunmaktadır, ancak bir ekip içinde insan bağımlı ve dayanışmayı sağlayamamaktadırlar (Bhbosale vd., 2020).

Yapay zekâ algoritmaları eğitildikleri verilere dayanarak öğrenirler ve sadece programlandıkları görevleri yerine getirebilirler. Tasarımlarının veya programlarının dışında kalan durumlarda başarısız olabilir ya da alakasız sonuçlar verebilirler (Bhbosale vd., 2020). Nadir vakalarla başa çıkma açısından değerlendirilecek olursa, en gelişmiş metodolojilerle geliştirilen bir yapay zekâ uygulaması yaygın teşhislerde insan performansına yaklaşabilir veya hatta onu aşabilirken, bir göğüs röntgeni ya da bilgisayarlı tomografi taramasında bulunan nadir ya da sıra dışı durumlar söz konusu olduğunda zorluklar yaşanabilmektedir. Bu durumlar, bir radyolog tarafından kolayca teşhis edilebilmesine rağmen modelin eğitim verilerinde yer almamış veya doğru bir şekilde etiketlenmemiş olabilir (Safdar vd., 2020). Ayrıca eğitim için kullanılan verileri taraflı ya da eksikse ortaya yanlış sonuçlar çıkabilmektedir, bu da büyük bir dezavantajdır (Bhbosale vd., 2020).

Yapay zekânın tıp eğitiminde ve sağlık hizmetlerinde artan kullanımına rağmen, bazı endişeler de mevcuttur. Özellikle tıbbi teşhis ve tedavilerde insan dokunuşunun ve empati anlayışının kaybolabileceği konusu endişe yaratmaktadır (Dave ve Patel, 2023). Öte yandan, yapay zekâ teknolojileri, karmaşık çıkarımlar ve tahminler yapabilmek için artan miktarda kişisel veriye dayanarak önemli gizlilik sorunları yaratmaktadır. Yapay zekânın yaygınlaşması gizlilik korumasına yönelik yeni zorluklar getirirken sosyal bilimciler ve hukukçular ise veri gizliliği konusundaki tartışmalara giderek daha fazla kişisel veri mülkiyeti, özerklik ve veri kullanımına ilişkin kontrol gibi kavramları dahil etmektedir. Bu yaklaşımın temelinde, bireylerin kişisel verilerini kendi kimliklerinin bir uzantısı olarak görmeleri ve gizliliğin ihlali durumlarını kişisel sınırların ihlali olarak algılayabilecekleri fikri yatmaktadır. Bu nedenle, kişisel verilerin korunması yalnızca teknik bir mesele değil, aynı zamanda bireylerin mahremiyetine ve kişisel alanlarına saygı gösterilmesi gereken bir etik sorundur (Martin ve Zimmermann, 2024).

Yapay zekânın avantaj ve dezavantajlarının ardından, diş hekimliği alanındaki kullanımlarının verilmesi, yapay zekâ uygulamalarının anlaşılabilirliğinin sağlanması açısından son derece önemlidir.

1.2. Yapay Zekânın Diş Hekimliğinde Kullanım Alanları

Gelişmeye hızla devam eden yapay zekâ uygulamaları birçok alanda olduğu gibi diş hekimliğinde de ilerlemeye çok açıktır. Yapay zekâ uygulamaları diş numaralandırma sistemleri, dental anomali tespiti, çürük teşhisi, çeşitli patolojilerin saptanması, ortodontik tedavi uygulamalarının planlanması ve sonuçların önceden görülebilmesi, robotik cerrahi ile dental implant uygulanması ve dental plak tespitine kadar değişen alanlarda kullanılmaktadır (Özkesici ve Yılmaz, 2021). Yapay zekâ modüllerinin görüntü işleme teknikleriyle olan uyumluluğu sayesinde, diş hekimliğinde radyoloji çalışmaları oldukça ön plana çıkmıştır. İki ya da üç boyutlu radyolojik teknikler üzerinden dişlerin sınıflandırılması, gruplara ayrılması, periodontal hastalıkların teşhisi ve riskli grupların değerlendirilmesi, anatomik yapıların tespit edilerek işaretlenmesi ve bu yolla sefalometrik analizlerin gerçekleştirilmesi bu alandaki güncel çalışmaların örnekleri olarak gösterilebilir (Hwang vd., 2019; Özkesici ve Yılmaz, 2021).

Yapay zekânın tıbbi radyoloji alanındaki entegrasyonu, hasta sonuçlarında ve tanı süreçlerinin doğruluğunda çığır açıcı gelişmeler sağlayabilecek bir potansiyele sahiptir. Hastalıkların teşhis ve tedavisinde tıbbi radyoloji hayati öneme sahip bir alandır ve yapay zekâ uygulamaları, bu alanda önemli gelişmeler ve iyileştirmeler sağlama potansiyeline sahiptir. Günümüzde tıbbi görüntüleme teknikleri, hastalıkların teşhisinde vazgeçilmez bir araç haline gelmiştir. Ancak, görüntülerin doğru bir şekilde yorumlanması zaman alıcı ve insan hatasına açık olabilmektedir. Yapay zekâ teknolojilerinin devreye girmesiyle bu süreçlerin daha hızlı, daha güvenilir ve daha verimli hale getirebileceği düşünülmektedir (Dave ve Patel, 2023).

Yapay zekânın tıbbi radyolojiye en büyük katkılarından biri, tıbbi görüntülerin analiz edilmesidir. X-ray, MR (Manyetik Rezonans) ve BT (Bilgisayarlı Tomografi) gibi görüntüleme teknikleri, hastalıkların teşhisinde büyük öneme sahiptir. Yapay zekâ sistemleri, bu görüntüleri inceleyerek olası anormallikleri belirleyebilmekte ve farklı tıbbi durumların teşhis sürecine destek sağlayabilmektedir. Bu yalnızca tanı hızını artırmakla kalmamakta, aynı zamanda tanılarının doğruluğunu da önemli ölçüde artırabilmektedir. Böylece, hastalara daha

erken müdahale edilerek tedavi sürecinde olumlu sonuçlar elde edilebilmektedir (Dave ve Patel, 2023).

Bununla birlikte, yapay zekâ algoritmaları tıbbi görüntülerde lezyonları otomatik olarak tespit edebilme yeteneğine de sahiptir. Lezyonların manuel olarak tespit edilmesi, her zaman hatasız olamayabilmekte ve bazı durumlarda gözden kaçan tanılar ortaya çıkabilmektedir. Yapay zekâ, bu süreçleri optimize ederek yanlış tanı riskini azaltma ve hasta güvenliğini artırabilme özelliklerine sahiptir. Yapay zekânın sunduğu bir diğer yenilik, tıbbi görüntüleme verilerini analiz ederek hastalıkların ilerlemesini öngörme yeteneğidir. Özellikle kanser gibi hastalıkların seyri, hastanın yaşam süresi ve kalitesi açısından kritik öneme sahiptir. Yapay zekânın, bu hastalıkların ilerleyişini tahmin ederek kişiselleştirilmiş tedavi planlarının oluşturulmasına katkı sağlayabileceği düşünülmektedir (Dave ve Patel, 2023). Bu bağlamda, yapay zekâ teknolojilerinin tıbbi radyolojide kullanımı, daha hızlı ve doğru tanı, erken müdahale fırsatları ve kişiselleştirilmiş tedavi yaklaşımları sunarak sağlık hizmetlerini bir adım öteye taşımaktadır. Yapay zekânın bu alandaki potansiyeli, gelecekte hasta bakımını iyileştirme yolunda önemli bir kilometre taşı olma niteliği taşımaktadır (Dave ve Patel, 2023).

Yapay zekânın diş hekimliğinde en yoğun kullanım şansı bulunduğu alanlardan biri de dental radyografik görüntülemelerdir. Dental radyografik görüntülerin analizi günlük klinik uygulamada teşhis sürecinin önemli bir parçasıdır. Yapay zekânın dental uygulamalardaki ilk kullanımı Mol ve Van Der Stelt (1992) tarafından gerçekleştirilmiş olup, periapikal kemik lezyonlarının dental radyografiler üzerinden teşhisi sağlanmıştır. Bu tarz çalışmalarda, yapay zekânın çalışma prensibi görüntü yorumlama ve bunu öğrenme prensibine dayanmaktadır (Mol ve Van Der Stelt, 1992; Özkesici ve Yılmaz, 2021).

Diş hekimliğinde radyografik yöntemlerin çoğu zaman klinik işlem öncesi klinisyene tanı ve tedavi planlaması ile ilgili veri sağlaması nedeniyle, çoğu yapay zekâ çalışması da teşhis modeli oluşturmaya yönelik kurgulanmıştır. Belirtilen yapay zekâ teşhis modelleri proksimal çürük teşhisi, kök kanal girişlerinin tespit edilmesi ya da kök kırıklarının teşhisi gibi birçok tanısal süreçte yardımcı olmaktadır (Johari vd., 2017; Saghiri vd., 2012). Diş çürüğünün doğru teşhisi, doğru bir tedavi prosedürü için şarttır. Yapay zekâ, diş hekimlerine radyografiler üzerinden çürük lezyonlarını teşhis etmede yardımcı olabilir. Bu konuda metodolojilerinde farklılıklar olsa da literatürde birçok çalışma tespit etmek mümkündür. Ancak, bu çalışmaların

büyük çoğunluğunun daimi dentisyonu kapsadığı, süt dişlenme ile ilgili verilerin oldukça sınırlı olduğu görülmektedir.

Yapay zekâ çürük teşhisi alanında da sıklıkla kullanılmaktadır. Konvansiyonel radyografilerde kavitasyon izlenemeyen olgularda ya da minenin dış üçte birlik kısmının demineralize olduğu arayüz çürüklerinde radyografik bulgulara rastlamak her zaman mümkün olmayabilir (Akpata vd., 1996). Bu nedenle bu lezyonların erken tanısı için, demineralize olan alanları tespit eden bilgisayar destekli analizlere olan talep son yıllarda artış göstermiştir (Heaven vd., 1994). Falk Schwendicke vd. (2021), evrişimli sinir ağı tabanlı yapay zekâ modelini kullanarak gerçekleştirdikleri çalışmalarında, bu modelin %80 oranında doğru tahmin sergilediğini belirtmiştir (Falk Schwendicke vd., 2021). Buna benzer bir çalışmada bitewing radyografiler üzerinde gerçekleştirilen çürük teşhisinde, diş hekimleri %71 oranında doğru tahminde bulunurken, yapay zekâ modeli %80 doğruluk oranı sunmuştur (Cantu vd., 2020).

Yapay zekânın hekimin bile tespit edemediği lezyonları teşhis etmesi, çürük lezyonların erken teşhisinde umut verici bir araç olarak kullanılabileceğinin bir göstergesidir. Bayraktar ve Ayan (2022), dijital bitewing radyografiler üzerinde interproksimal çürük lezyonlarının tespitinde derin evrişimli sinir ağının etkinliğini incelemeyi amaçlamıştır. “Yolo” (You Only Look Once) olarak bilinen bir evrişimli sinir ağı modeli, bitewing radyografilerinde çürük lezyonlarını tespit etmek için modifiye edilmiş ve eğitilmiştir. Bu sinir ağı modelinin bitewing radyografilerde çürük lezyonların tanısında yüksek etkinlik gösterdiği bildirilmiştir (Bayraktar ve Ayan, 2022).

Lian vd. (2021) yaptığı çalışmada ise, çürük lezyonlarını saptamak, panoramik filmlerdeki farklı radyografik uzantıları sınıflandırmak ve sınıflandırma sonuçlarını uzman diş hekimleri ile karşılaştırmak için derin öğrenme yöntemlerini kullanmayı amaçlamıştır. Çalışmaya toplam 1160 dental panoramik film dahil edilmiş ve bu görüntüler 3 uzman diş hekimi tarafından analiz edilmiştir. Filmlerdeki tüm çürük lezyonları etiketlenerek, çürük lezyonlarını tespit etmek için U-Net adı verilen evrişimli bir sinir ağı kullanılmıştır. Sonuç olarak, derin öğrenme yönteminin performansı uzman diş hekimleri ile benzer düzeyde bulunmuştur (Lian vd., 2021).

Lee vd. (2018), 3000 periapikal film kullanılarak gerçekleştirilen çalışmada, molar ve premolar dişlerdeki çürüklerin teşhis edilmesi hedeflenmiş ve başarılı sonuç alınmıştır (Lee vd., 2018). Yazarların, 2021 yılında yaptıkları çalışmada ise bitewing radyografilerde çürük tespiti için U-Net kullanan bir evrişimli sinir ağı modeli geliştirmişler ve bu modelin klinisyenlerin performansını iyileştirip iyileştiremeyeceğini araştırmışlardır. Toplamda, geliştirilen evrişimli sinir ağı modelinin eğitimi için 304 bitewing radyografi ve performans değerlendirmesi için 50 radyografi kullanılmıştır. Özellikle, başlangıç ve orta düzeydeki çürüklerde anlamlı farklılık tespit edilen çalışma sonucunda yapay zekânın klinisyenlerin diş çürüklerini daha doğru teşhis etmesine yardımcı olabileceği ve başlangıç düzeyindeki çürüklerin gözden kaçmasının önüne geçebileceği vurgulanmıştır (Lee vd., 2021).

Moran vd. (2021), bitewing radyografiler üzerinde aproksimal diş çürüklerini belirlemek ve bu çürükleri lezyon şiddetine göre sınıflandırmak amacıyla, görüntü işleme teknikleri ile evrişimli sinir ağlarını bir araya getiren yeni bir yöntem geliştirmiştir. Bu amaçla, çalışmaya 112 adet bitewing radyografi dahil edilmiş olup, her radyografik imajdan ayrı ayrı diş görüntüleri çıkarılmış ve elde edilen görüntüler evrişimli sinir ağı modellerini eğitmek için kullanılmıştır. Radyografik görüntüler önceden tanımlanmış sınıfları belirtmek için uzmanlar tarafından etiketlenmiştir. Eğitim sürecinin sonunda en etkin sonuçlar, test setindeki doğruluğu %73,3 olan Inception modeli tarafından elde edilmiştir. Sonuçlar umut verici olarak kabul edilebilir olup, önerilen yöntemin diş hekimlerine bitewing görüntülerinin değerlendirilmesinde, lezyon şiddetinin ve uygun tedavilerin tanımlanmasında yardımcı olmak için kullanılabileceğini düşündürmektedir (Moran vd., 2021).

Yapay zekâ tabanlı teşhis destek yazılımlarının çürük tespiti üzerindeki etkisini değerlendiren çalışmalar, klinik karar süreçlerinde bu teknolojilerin potansiyel faydalarını ortaya koymaktadır. Bu çalışmalardan biri, yapay zekânın bitewing radyograflarda proksimal çürük tespiti üzerindeki etkisini incelemeyi amaçlamıştır.

Çalışmada, evrişimli sinir ağı kullanan bir yapay zekâ yazılımı 22 diş hekimi tarafından rastgele olarak kullanılmıştır. Diş hekimleri, 140 bitewing radyograf içeren bir havuzdan rastgele seçilen 20 bitewing radyograf üzerinde çürük tespiti yapmış, bunlardan 10 tanesi yapay zekâ desteğiyle, diğer 10 tanesi ise herhangi bir yapay zekâ desteği olmadan değerlendirilmiştir. Çürükler mine, dentin ve derin dentin çürüğü olarak alt gruplara ayrılmış ve her lezyonun doğruluğu ile tedavi kararları analiz edilmiştir.

Sonuçlar, yapay zekâ kullanan diş hekimlerinin kullanmayanlara kıyasla anlamlı derecede daha yüksek ortalama teşhis doğruluğuna sahip olduğunu göstermiştir. Özellikle yapay zekâ desteği, diş hekimlerinin mine lezyonlarını tespit etme duyarlılıklarını önemli ölçüde artırmıştır. Ancak, dentin veya derin dentin çürüğü tespitinde bu fark gözlenmemiştir. Artan duyarlılığın bir yan etkisi olarak hem non-invaziv hem de invaziv tedavi kararlarında belirgin bir artış kaydedilmiştir (Mertens vd., 2021). Klinik anlamda, yapay zekâ desteği diş hekimlerinin özellikle mine lezyonlarını daha doğru bir şekilde tespit etmelerini sağlarken aynı zamanda invaziv tedavi kararlarını da artırabileceği göz önünde bulundurulmalıdır.

Bayrakdar vd. (2022) ise, tespit ve segmentasyon yöntemi kullanarak bitewing radyografiler üzerinde gerçekleştirdikleri çalışmada, derin evrişimli sinir ağlarının (VGG-16 ve U-Net) diş çürüklerini etkin bir şekilde teşhis ettiklerini bildirmiştir (Bayrakdar vd., 2022).

Yapay zekânın çürük teşhislerinde kullanılmasının maliyet üzerindeki etkilerinin değerlendirilmesinin amaçlandığı bir çalışmada, bitewing radyograflarda proksimal çürük tespitinde yapay zekâ destekli ve desteksiz tespitlerin klinik sonuçları ve maliyetleri incelenerek bir karşılaştırma yapılmıştır. Çalışma kapsamında, tam evrişimli bir sinir ağı (U-Net), bitewing radyografisi üzerinde eğitilmiş, doğrulanmış ve test edilmiştir. Lezyonlar, başlangıç lezyonları ve derin lezyonlar olarak iki ana grupta sınıflandırılmıştır. Başlangıç lezyonlarının tespit edilmesi durumunda çürük infiltrasyonu uygulanırken, ileri lezyonların tespiti durumunda restoratif tedavi uygulanmıştır. Çalışmada, doğru ve yanlış pozitif/negatif tespitlerin ve bu tespitlere dayalı alınan tedavi kararlarının hasta ömrü boyunca etkileri simüle edilmiştir. Maliyetler, 2020 yılı euro birimi üzerinden değerlendirilmiş ve Almanya'daki karma ödeme sistemine göre hesaplanmıştır. Sonuç olarak, yapay zekânın daha yüksek oranda doğru tespitler yaparken aynı zamanda maliyet tasarrufu sunduğu tespit edilmiştir (F. Schwendicke vd., 2021). Bu bulgular, yapay zekâ tabanlı karar destek sistemlerinin yalnızca tanısal doğruluğu artırmakla kalmayıp, sağlık sistemleri açısından ekonomik sürdürülebilirliğe de katkı sağlayabileceğini ortaya koymaktadır.

Derin öğrenme tabanlı yapay zekâ modellerinin farklı dişlenme dönemlerine sahip çocuklardan alınan panoramik radyograflarda diş çürüğünün tespitinde etkili bir araç olduğunu belirten bir çalışmada, 4 ile 14 yaş arasındaki çocuklardan alınan toplam 6075 adet panoramik radyografi kullanılarak bu radyografiler süt dişlenme dönemi (n: 1857), karışık dişlenme dönemi (n: 1406) ve daimi dişlenme dönemi (n: 2812) olmak üzere üç gruba ayrılmıştır.

Sonuçlar, yapay zekâ modellerinin her üç dişlenme döneminde de yüksek duyarlılık ve doğruluk oranları ile diş çürüğü teşhisinde önemli bir katkı sağlayabileceğini göstermektedir (Asci vd., 2024). Bu bulgular, diş hekimliği alanında yapay zekânın erken teşhis süreçlerine entegrasyonunun, klinik sonuçları iyileştirme potansiyelini ortaya koymaktadır.

Çocuklarda panoramik radyograflar üzerinden diş çürüğü teşhisinde geleneksel evrişimli sinir ağlarını iyileştirerek daha yüksek doğruluk elde etmeyi amaçlayan bir çalışmada, bir ya da daha fazla çürüğü bulunan 210 çocuk hastaya ve çürüğü olmayan 94 hastaya ait panoramik radyograflar kullanılmıştır. Çalışmada, toplamda 6028 diş üzerinde yapılan incelemede, 3039 dişte çürük tespit edilmiştir. Önerilen yöntem, özellikle süt ikinci azı dişlerindeki çürüklerin teşhisinde beş yıllık deneyime sahip iki hekimin performansını geride bırakmıştır. Çalışmanın sonuçları, evrişimli sinir ağı tabanlı derin öğrenme yöntemlerinin hastanelerde diş çürüğü teşhisinde diş hekimlerine önemli bir destek sunma potansiyelini göstererek, bu yöntemlerin klinik uygulamalarda teşvik edilmesi gerektiğini ortaya koymaktadır (Zhou vd., 2022).

Literatür taraması yapıldığında hem daimi dişlerde hem de süt dişlerde çürük teşhisi yapan ve bunları karşılaştıran bir çalışma bulunmaktadır. Bu çalışmada, 771 bitewing (554 yetişkin, 217 pediatrik) radyograf kullanılarak özellikle derin çürüklerin yetişkin ve pediatrik radyografilerde başlangıç çürüklerine kıyasla daha doğru tespit edildiği belirlenmiştir. Derin öğrenme modelleri, daimi ve süt dişlerindeki bitewing radyografilerinde ileri düzey çürük lezyonlarını başarılı bir şekilde tespit edebilmiştir. Ancak, modelin performansı açısından en büyük zorluk, başlangıç ve orta düzey çürük lezyonları arasında meydana gelen yanlış sınıflandırmalar olmuştur. Çalışma, derin öğrenme modellerinin çürük lezyonlarını doğru bir şekilde sınıflandırmada genel olarak etkili olduğunu ortaya koysa da, lezyonların derinliğini erken aşamalarda tam olarak yakalayamama ve bir lezyonu başka bir kategoride sınıflandırma gibi sorunlarla karşılaşmıştır (Azhari vd., 2023). Bu sonuçlar, yapay zekânın diş hekimliğinde teşhis süreçlerinde faydalı bir araç olarak kullanılabileceğini, ancak henüz iyileştirilmesi gereken alanlar bulunduğunu göstermektedir.

Literatürde bulunan çalışmalarda görüldüğü üzere, yapay zekâ modelleri ile tespit edilen çürüklerin belli bir sistematik sınıflandırma içinde olmadığı ve kullanılan radyografik görüntülerin çoğunlukla daimi dentisyonu kapsadığı dikkati çekmektedir. Bu kapsamda,

literatürde yapay zekâ tabanlı teşhis modellerinin süt dişlerindeki çürük lezyonların tanısına dair veri içeren çalışmalarda eksikliklerin olduğunu söylemek mümkün olacaktır.


1.3. Yapay Zekâ Tabanlı Çürük Tespiti ve Teşhisinin Gelecek Perspektifleri

Diş hekimliğinin geleceğine bakıldığında, yapay zekânın diş çürüğü tespiti ve teşhisindeki rolü umut vadeci görünmektedir. Şimdiden büyük miktarda veriyi hızlı ve doğru bir şekilde işleme yeteneğine kavuşan yapay zekâ, çürük teşhisini daha hızlı ve verimli hale getirmeye başlamıştır. Her yeni vaka ile öğrenme yeteneğini geliştiren yapay zekâ sistemlerinin gelecekte daha da gelişerek çok fazla alanda kullanılır hale geldiğini görebileğimiz düşünülmektedir. Yapay zekâ sistemleri daha kolay kullanılabilir ve erişilebilir hale geldikçe diş hekimlerinin bu sistemleri uygulamalarına dahil etmeleri yaygınlaşıp kolaylaşacaktır. Bu şekilde, yapay zekâ tabanlı teşhis günlük diş hekimliği uygulamalarına entegre olarak daha fazla diş kliniği, hastane ve eğitim kurumu bu teknolojileri benimseyebilecektir.

1.4. Yapay Zekâ ile İlişkili Kavramlar ve Çalışma Prensipleri

Son yıllarda yapay zekâ, bilim dünyasında popüler bir konu haline gelmiştir. Teknoloji tabanlı olan ve olmayan yayın organlarında yer alan çok sayıda bilimsel çalışma makine öğrenmesi, derin öğrenme ve yapay zekâ konularını kapsamaktadır. Buna karşın, bu fenomenler hakkında hala kesinlik kazanmamış olgular söz konusudur (Choi vd., 2020). Bu açıdan, yapay zekânın çalışma prensibini daha net kavrayabilmek için yapay zekâ ile ilişkili terimleri ve bunların çalışma prensipleri hakkında bilgi vermek faydalı olacaktır. Bu terimler arasında en önemlilerinden biri makine öğrenmesidir. Makine öğrenmesi, bir veri setine dayalı sonuçları tahmin etmek için algoritmalara dayanan bir olgudur (Saglam vd., 2021). Bir bilgisayarın elde ettiği deneyimlerden öğrenme ya da işlemlerini yeni edinilen bilgiler temelinde değiştirme yeteneği olarak tanımlanır. Başka bir deyimle, makine öğrenmesi algoritmaları elle girilmiş çok sayıda girdiyi analiz ederek ya da öğrenerek doğru ve net bir cevap vermek üzere tasarlanmıştır (Özkesici ve Yılmaz, 2021). Bu süreç, çeşitli veri türlerini işlerken insan beynini taklit eden derin öğrenme algoritmalarını kullanmak ve sinir yoluyla karar vermede kullanılmak üzere modeller oluşturmak ya da olaylar bütünü bir sonuca götüren “eğer-ise” gibi basit bir karar verme ağacı modeline dayanabilir. Basit bir şekilde ifade etmek gerekirse, derin öğrenme; bir algoritmanın kendisine sağlanan verileri (örneğin Excel

tabloları, görüntüler vb.) alıp, önceden belirlenmiş ve özel olarak tasarlanmış bir yol üzerinden (yapay sinir ağı) işleyerek istenen görevi çözmeye yönelik bir süreçtir. Yapay sinir ağı, belirli bir soruya yanıt üretebilmek için, algoritmanın eğitildiği bir eğitim veri kümesi kullanılarak oluşturulur. Bu eğitim verisi, doğru sonuçlar elde edebilmek için çözülmesi beklenen sorunun özelliklerini yansıtmalıdır (Mintz ve Brodie, 2019). Örnek vermek gerekirse, bir makine öğrenmesi algoritması, normal ya da anormal olarak etiketlenmiş bu tür binlerce radyolojik görüntüyü analiz ederek radyolog tarafından eğitilmiş ise, baş ve boyun bölgesine ait bir görüntüdeki lenf nodunu normal ya da anormal olarak tanıma ve algılama yeteneğine sahip olabilir (Özkesici ve Yılmaz, 2021).




Şekil 1.1. Klasik programlamaya karşı makine öğrenmesi paradigmasını gösteren şematik diyagram (a ve b). Klasik programlamada, bir bilgisayara bir veri kümesi ve bu veriler üzerinde nasıl işlem yapılacağını belirleyen bir algoritma verilir; bilgisayar, bu talimatlar doğrultusunda çıktılar üretir. Makine öğrenmesinde ise bilgisayara bir veri kümesi ile birlikte konuya ilişkin doğru çıktılar sağlanır. Bilgisayar, bu iki unsur arasındaki ilişkiyi kendisi öğrenir ve yeni bir algoritma geliştirir. Elde edilen bu algoritma, ileride karşılaşılabilecek veri kümeleri üzerinde çıkarım yapabilmek için kullanılır (Choi vd., 2020). (Görsel modifiye edilerek kullanılmıştır.).

Yapay zekâ ile ilişkili bir diğer terim de temsili öğrenmedir. Bilgisayar tabanlı algoritma sistemlerinin sağlanan verileri kategorize etmek için gerekli aşamalar üzerine çalıştığı bir makine öğrenmesi alt türüdür. Temsili öğrenme, makine öğrenmesi süreçlerinde olduğu gibi, verilerin sisteme elle girilmesini gerektirmemektedir. Bunun yerine, bilgisayar algoritmaları, sağlanan verileri sınıflandırmak için gereken özellikleri kendisi öğrenir (McCarthy vd., 2006; Özkesici ve Yılmaz, 2021). Dahası, yapay zekâ eğitimi için kullanılan veri miktarı, makine öğrenimi algoritmalarının yeterliliğini de etkilemektedir. Temsili öğrenme sisteminde, veri eklerken performans büyük ölçüde artırılır. Bunun bir sonucu olarak da çoklu miktarda veri


sağlandığında, temsili öğrenmeye dayalı sistemler, elle veri girişi gerektiren geleneksel makine öğrenmesi sistemlerine göre üstünlük sağlayabilir (McCarthy vd., 2006; Özkesici ve Yılmaz, 2021).

Yapay zekâ ile bağlantılı bir diğer önemli kavram ise derin öğrenmedir. Bu kavram, 2006 yılında Hinton'ın çok katmanlı yapay sinir ağlarının daha verimli bir biçimde eğitilebileceğini ifade etmesiyle ortaya çıkmıştır (Kaya vd., 2019). Derin öğrenme insan beyni gibi işlemeye benzer şekilde yapılandırılmış, aynı anda birden fazla veri kümesini dikkate alan, ikinci ve üçüncü farklı değerlendirmeler yapabilen bir modeldir. Derin öğrenmede her değerlendirme farklı bir katmanda yapılmaktadır. Bu nedenle, her bir sonraki değerlendirme bir önceki katmandan elde edilen çıktıya dayanır. Bu işlemde yer alan katmanlar, girdileri ve çıktıları doğrudan görülemediği için “gizli katmanlar” olarak adlandırılır (Özkesici ve Yılmaz, 2021).

Derin öğrenmede, geleneksel makine öğrenmesinden farklı olarak kodlanmış kurallar ile öğrenmek yerine, çeşitli imajlar, video, ses, metinler ve buna benzer verilerin simgelerinden otomatik olarak öğrenme söz konusudur (Kaya vd., 2019). Ham resim ya da metin verisi esnek yapıda olduğu için bu verilerden de öğrenme olabilmekte ve verinin büyüklüğüne göre tahmin doğrulukları da artabilmektedir. Ek olarak, derin öğrenme, örnekler üzerinden de öğrenme işlemini gerçekleştirebilmektedir (Buduma vd., 2022; Kaya vd., 2019). Derin öğrenmede makinenin çözmesi arzu edilen bir problem için kural seti kullanarak çözüm sağlamak yerine, örneklerin değerlendirilmesi ile probleme çözüm bulmak hakimdir. Bu nedenle, derin öğrenmede model seçimi problemin çözümünde etkin bir rol oynar (Kaya vd., 2019).



Şekil 1.2. Veri bilimi tekniklerinin şematik gösterimi. Veri bilimi yapay zekâyı, öğrenme modellerini ve yapay sinir ağlarını kapsamaktadır. Makine öğrenmesi ise, derin öğrenme ve yapay sinir ağları dahil olmak üzere birçok model ve yöntem içerir (Choi vd., 2020) (Görsel modifiye edilerek kullanılmıştır.).



Şekil 1.3. Yapay zekâ sistemlerinin şematik gösterimi (Nagi vd., 2020) (Görsel modifiye edilerek kullanılmıştır.).

Yapay zekâ konusunda bilinmesi gerekli kavramlardan biri de yapay sinir ağıdır. İnsan beyninin çalışma prensiplerinden ve düşünme yetisinden esinlenilerek geliştirilmiş bir bilgi işleme teknolojisi olarak tanımlanabilir. Başka bir ifadeyle yapay sinir ağı, biyolojik sinir ağlarının işleyişini model alan bilgisayar programlarıdır (Saglam vd., 2021). Bu ağların öğrenme yetenekleri, geleneksel yöntemlerle çözülmesi oldukça güç olan problemlere etkili çözümler üretebilmesine imkan tanımaktadır. Ayrıca öğrenme kabiliyeti sayesinde, bilinen örneklerden yola çıkarak daha önce karşılaşılmamış durumlar hakkında genelleme yapabilmektedir (Ağyar, 2015). Yalnızca sayısal verilerle çalışan bu sistemler; bilgiyi depolama, örneklerden öğrenme, yeni örnekler üzerinde çıkarım yapabilme, sınıflandırma ve şekil tamamlama gibi işlevlere sahiptir. Bu nedenle yapay sinir ağı, finansal işlemlerden mühendislik ve tıp alanındaki uygulamalara, üretim süreçlerinden arıza tespiti ve analizine kadar pek çok farklı sektörde yaygın biçimde kullanılmaktadır (Ağyar, 2015).

Öğrenme yeteneğine sahip bir yapay sinir ağı kullanılarak, bir sistemde ya da cihazda ortaya çıkabilecek arızaların tespit edilmesi mümkün hâle gelmektedir. Sinir ağı tıp ve diş hekimliğinde de birçok işlevi yerine getiren çeşitli özellikler içerir. Bunlar tanıdan tedavi sürecine, hatta takip aşamasına kadar olan tüm dönemleri içermektedir (Brickley vd., 1998; Saglam vd., 2021). Yapay sinir ağı, çoğunlukla tahmin yapma, sınıflandırma, veriler arasında ilişki kurma, veri analiz etme ve filtreleme gibi işlemlerde kullanılmaktadır (Ağyar, 2015).

Tahmin: Bu amaçla kullanılan yapay sinir ağı, girdileri değerlendirip bir çıktıyı tahmin etmek için kullanılır. Döviz kuru tahmini örnek olarak verilebilir (Ağyar, 2015).

Sınıflandırma: Bu amaçla kullanılan yapay sinir ağı, kendilerine verilen girdi değerlerini sınıflandırma işlevini yerine getirir. Örneğin, bir makinede meydana gelen hataların kategorilere ayrılması bu duruma örnek olarak gösterilebilir (Ağyar, 2015).

Veri İlişkilendirme: Bu amaçla eğitilen yapay sinir ağı, öğrenmiş oldukları verilerden yararlanarak eksik bilgileri tamamlayabilir. Örneğin, eksik parçaları bulunan bir görselin bütünlenmesi bu duruma örnek olarak verilebilir (Ağyar, 2015).

Veri Yorumlama: Bu yapay sinir ağıları, verilen girdileri inceleyip değerlendirir. Bir olayla ilgili toplanan örneklerden öğrenilen ve eğitim sürecinde oluşturulan bilgileri kullanarak, karşılaşılan yeni durumların yorumlanmasına olanak tanır (Ağyar, 2015).

Veri Filtreleme: Bu amaçla eğitilen ağılar, çok sayıda veri içerisinde en uygun olanları seçme işlevini üstlenir. (Ağyar, 2015).

Yapay zekâ ile ilişkili kavramlardan bir diğeri de evrişimli sinir ağıları olup, bu tipik olarak, verileri analiz etmek için birkaç gizli katmana sahip derin öğrenme algoritmalarına dayanan belirli bir yapay sinir ağı türüdür. “Evrişimsel” ifadesinden de anlaşılacağı gibi, katmanlar arasındaki ilişkiler oldukça karmaşıktır ve her evrişimli sinir ağında birden fazla gizli katman yer almaktadır. Katman sayısının artışı matematiksel hesaplama gücünü de artırdığından avantajlı bir durum içermektedir (Mintz ve Brodie, 2019).

Evrişimli sinir ağıları bağlamında kullanılan birçok farklı algoritma mevcuttur. Bunlardan en popülerlerinden biri olan U-Net mimarisi, biyomedikal segmentasyon uygulamalarında oldukça yüksek performans gösteren popüler bir derin öğrenme modelidir (Ronneberger vd., 2015). Mimari, aşağı örnekleme ve yukarı örnekleme yolları arasında atlama bağlantıları kullanarak, düşük çözünürlükteki öznitelikleri yüksek çözünürlükle birleştirir. Bu simetrik yapı bir “u” harfine benzediğinden ismi buradan gelmektedir. (Ozturk vd., 2020). Bu mimarinin temel konsepti, görüntülerin çözünürlüğünü önce düşürmek, ardından ilgilenilen yapıları belirleyip, bu yapıları takip ederken çözünürlüğü geri yüklemektir (Ronneberger vd., 2015). U-Net, özellikle biyomedikal görüntülerin hızlı ve hassas segmentasyonunu sağlamak amacıyla geliştirilmiş evrişimli (convolutional) bir ağı mimarisidir ve birçok çalışma, tıbbi görüntü veri setlerinde başarılı sonuçlar elde ettiğini vurgulamaktadır (Ronneberger vd., 2015). Ayrıca, U-Net mimarisi çok az sayıda eğitilmiş veriyle bile yüksek doğrulukla segmentasyon yapabilme yeteneğine sahiptir (Ronneberger vd., 2015).

Birçok biyomedikal uygulamada, yeterli sayıda eğitim görüntüsüne genellikle ulaşmak mümkün olmamaktadır. Ancak, U-Net mimarisi, çok az sayıda eğitim görüntüsü ile çalışarak daha hassas segmentasyon sağlamayı mümkün kılacak şekilde geliştirilmiştir (Çiçek vd., 2016). Bu, özellikle hacimsel (volumetrik) görüntülerde daha da belirginleşmektedir; çünkü bu tür görüntülerde tekrarlayan yapılar ve belirli varyasyonlar bulunduğundan, yalnızca birkaç görüntü ile eğitilmiş bir ağı, üçüncü bir görüntüye başarılı bir şekilde genelleme

yapabilmektedir (Çiçek vd., 2016). Bu özellik, U-Net'i biyomedikal görevlerde binlerce eğitim görüntüsüne ulaşamadığında bile etkili bir araç haline getirmektedir (Ozturk vd., 2020). U-Net mimarisi, biyomedikal görüntü segmentasyonunda yaygın olarak kullanılmasına rağmen, belirli sınırlamaları ve dezavantajları bulunmaktadır. Bu mimaride, sınıf etiket tahminlerinin yavaş olduğu ve sınıf etiketlerinin dengesizliği gibi sorunlarla karşılaşıldığı belirtilmiştir (Chen vd., 2023).

En sık kullanılan algoritmalarından bir diğeri de Yolo'dur. Yolo terimi, "You Only Look Once" ifadesinin kısaltması olup, Joseph Redmon, Santosh Divvala, Ross Girshick ve Ali Farhadi tarafından 2015 yılında geliştirilen gerçek zamanlı bir nesne algılama algoritmasını ifade eder. Bu algoritma, Coco veri kümesi üzerinde önceden eğitilmiş olup, bir görüntünün tamamını işlemek için tek bir sinir ağı kullanır. Görüntüyü belirli bölgelere ayırır ve her bölge için olasılıkları ile sınırlayıcı kutuları tahmin eder (Redmon vd., 2016). Diğer algoritmalarda nesne tespiti için görselin tamamını değerlendirirken, Yolo görüntüyü belirli parçalara ayırır ve her bir parçada bulunan nesneleri sınırlayıcı kutular (bounding box) çizerek işaretler. Bu kutular, nesnenin ilgili bölgede bulunma olasılığını belirler. Ayrıca her kutu için bir "güven skoru" hesaplanır; bu skor, nesnenin sınırlayıcı kutu içindeki kapsama oranı ile eğitilmiş nesne sınıfları arasındaki benzerlik düzeyini ifade eder (Yılmaz, 2023).

Yolo algoritmaları, görüntüyü yalnızca bir kez sinir ağına göndererek işler ve bu yaklaşım işlemin çok daha hızlı gerçekleştirilmesine imkan tanır. Sınırlayıcı kutular 3x3, 5x5 veya 7x7 gibi farklı boyutlarda oluşturulabilir ve bu kutular, ilgili bölgede bir nesnenin bulunup bulunmadığını belirlemek için kullanılır. Daha sonra nesnenin konumunun değerlendirilmesi için kutunun merkez noktası ile nesnenin konumu karşılaştırılır. Yolo, her sınırlayıcı kutu için ayrı bir değerlendirme vektörü üretir ve bu vektör kutunun uzunluğunu, yüksekliğini ve ait olduğu sınıfı tanımlar (Yılmaz, 2023).

Güven skoru, tahmin edilen bağıl sınıf olasılığı ile "kutu güven skoru"nın çarpımı sonucunda elde edilir. Bu işlem, nesnenin belirlenen sınırlayıcı kutu içerisinde bulunduğu durumlarda uygulanır. Bir kutuda birden fazla nesnenin yer alması durumunda ise, bu sorun "çapa kutusu" (anchor box) yöntemiyle çözülerek her bir nesne için ayrı kutular oluşturulur. Bu kutuların değerleri hesaplanırken "IoU" (Intersection over Union) metriğinden yararlanılır (Altay ve Yılmaz, 2023). Ayrıca gerek olmayan kutuların ortaya çıkmasını engellemek amacıyla maksimum olmayanı bastırma (non-max suppression) algoritması devreye girer. Bu

algoritma, öncelikle düşük güven skoruna sahip kutuları eleyerek yalnızca en yüksek güven skoruna sahip kutuların sonuçta kalmasını sağlar. Temel olarak algoritma, giriş görüntüsünü farklı bölgelere ayırdıktan sonra güven puanı düşük olan çerçeveler, nesne içermediği kabul edilerek kaldırılır. Son aşamada ise, görüntü boyutu filtreler ve yüksek seviyeli özetleyici evrişim katmanları aracılığıyla küçültülür (Yılmaz, 2023).

Hızlı ve yüksek doğruluk oranına sahip olmasıyla bilinen Yolo, sağlık hizmetlerinden güvenlik gözetimine ve sürücüsüz araçlara kadar pek çok farklı alanda kullanılmaktadır. Yolo sağlık hizmetleri, güvenlik gözetimi ve sürücüsüz arabalar gibi birçok uygulamada kullanılmaktadır. Yolov5 bilgisayarlı görü modelleri ailesindeki bir modeldir. Dört ana versiyonu vardır: küçük (s), orta (m), büyük (l) ve ekstra büyük (x), her bir model bir öncekine göre kademeli biçimde daha yüksek doğruluk performansı sunar. Ayrıca her varyantın eğitilmesi için farklı bir süre gerekir. Hedef, çıkarım süresi (X eksen) ile performans (Y eksen) dengesi açısından mümkün olan en verimli nesne algılama modelini üretmektir. Yolov5 diğer son teknoloji tekniklere göre son derece iyi performans göstermektedir, özel veri kümeleri üzerinde eğitimi ve çıkarımı son derece kolay ve oldukça açık hale getirir. Doğru formatta hazır bir veri kümesi ile hızlı bir eğitim olanağı sağlar. Çok sayıda dışa aktarım seçeneği bulunmaktadır (Bochkovskiy vd., 2020; Khanam ve Hussain, 2024; Redmon vd., 2016).

Yolov5 deposu, varsayılan olarak TensorBoard ve Weights&Biases kayıt (Log) sağlar. Doğru kayıt (Log) için eğitime başlamadan önce bir Weights&Biases hesabı oluşturabilir ve API kimlik bilgileri ile bağlantı kurulabilir. Tüm doğrulama (validation) tahminleriyle birlikte her ölçümü (metric), kaybı (loss) ve görüntüyü içeren TensorBoard kayıtları (Log) mevcuttur. Bu durum, bir modeli eğittikten sonra herhangi bir noktada performans ölçütlerine göz atılmasını da kolaylaştırır (Abadi vd., 2016; Jocher vd., 2020).

Birçok nesne algılama modeli, Coco veri kümesine göre önceden tanımlanmış çapa kutuları (predefined anchor boxes) kullanırken, Yolov5, bağlantı kutularını oluşturmak için genetik bir algoritma kullanır. Varsayılan olanlar iyi değilse, bağlantı kutularını verilere uyacak şekilde yeniden hesaplayan bu işleme otomatik çapa (autoanchor) adı verilir. Bu yöntem, k-Means algoritması ile birlikte kullanılarak daha gelişmiş çapa kutularının (anchor boxes) oluşturulmasını sağlar. YOLOv5 ise mozaik veri artırma tekniğini kullanarak, modelin farklı ve karmaşık görsellerle başa çıkma yeteneğini geliştirmek amacıyla dört ayrı görüntüyü

tek bir karede birleştirir. Mozaik büyütme ile birlikte diğer büyütme tekniklerini de kullanır (Bochkovskiy vd., 2020; Jocher vd., 2020).

Yolov5 modelini kendisi dışındaki Yolo sürümlerinden ayıran en önemli özellik, geliştirmiş olduğu kütüphanedir. Nesne algılamada Yolo mimarisi başarılı olmaktadır. Bunun nedeni, Yolo algoritmasının regresyon tabanlı bir yapıya sahip olmasıdır; bu sayede görüntünün yalnızca belirli bölgelerini seçmek yerine, algoritma tek bir işlemde tüm görüntü için sınıf ve sınırlayıcı kutu tahminlerini gerçekleştirir (Redmon vd., 2016). Yolo ağı aşağıda açıklamaları bulunan üç ana parçadan oluşmaktadır:

Omurga (Backbone): Görüntüdeki özellikleri farklı ayrıntı seviyelerinde toplayıp işleyen yapı, bir evrişimli sinir ağıdır. Bir ağın omurgası, görüntüden özellik çıkarma sürecini üstlenir. Bu omurga, görüntüler için zengin özellik temsilleri üretmek amacıyla kullanılan önceden eğitilmiş bir ağıdır. Bu yapı, görüntünün uzamsal çözünürlüğünü azaltırken aynı zamanda kanal (özellik) çözünürlüğünü artırmaya katkı sağlar. Modelin boyun kısmı ise, çıkarılan bu özelliklerden piramit yapıları üretmek için kullanılır. Bu, modelin farklı boyut ve ölçeklerdeki nesnelere genelleştirilmesine olanak sağlar (He vd., 2016; Lin vd., 2017; Redmon vd., 2016).

Boyun (Neck): Görüntü özelliklerini tahmin katmanına aktarmadan önce onları karıştırıp birleştiren katmanlar bütünüdür ifade eder. Ağın boyun bölümü, omurga (özellik çıkarma katmanı) ile kafa (karar verme katmanı) arasında konumlanır. Bu yapı, omurga tarafından çıkarılan özelliklerin baş katmanına ulaşmadan önce rafine edilmesine ve daha işlenebilir hâle getirilmesine katkı sağlar (Lin vd., 2017; Liu vd., 2018).

Baş (Head): Boyundan özellikleri tüketir ve kutu ve sınıf tahmin adımlarını gerçekleştirir. Model kafası, son aşamadaki işlemleri gerçekleştirmek için kullanılır. Özellik haritalarına bağlantı kutuları uygular ve sınıflar, nesnellik puanları ve sınırlayıcı kutular gibi nihai çıktıyı oluşturur (Bochkovskiy vd., 2020; Redmon vd., 2016).

Yolov5 modelin boynuna iki büyük değişiklik getirmiştir. İlk olarak Uzamsal Piramit Havuzlamanın bir çeşidi kullanılmış ve Yol Toplama Ağı, BottleNeckCSP'nin mimarisine dahil edilmesiyle değiştirilmiştir. Yolov5, Yolov3 ve Yolov4 ile aynı kafayı kullanmakta olup, sınırlayıcı kutuların konumunu (x, y, yükseklik, genişlik), puanları ve nesne sınıflarını tahmin

eden üç evriřim katmanından oluřmaktadır (Bochkovskiy vd., 2020; Jocher vd., 2020; Redmon vd., 2016).

1.5. Yapay Zekâ Tabanlı Modellerde Eđitim, Validasyon ve Test Ařamaları

Yapay zekâ tabanlı derin öğrenme modellerinin klinik uygulamalarda güvenle kullanılabilmesi için eđitim, validasyon (dođrulama) ve test ařamalarının titizlikle bilinmesi ve uygulanması önemlidir.

1.5.1. Eđitim Ařaması

Eđitim ařaması, model parametrelerinin (örneğin sinir ađı) optimize edildiđi ana safhadır. Burada amaç, modelin etiketli eđitim verisi üzerinde örüntüleri öğrenmesini sađlamaktır. Derin öğrenme başarıları, genellikle büyük, kaliteli ve çeřitliliđe sahip eđitim veri setleri ile mümkündür (LeCun vd., 2015). Bu ařamada kullanılan veri miktarı genellikle toplam setin %70-80'i kadardır (Lee vd., 2021). Tıbbi görüntü analizinde, örneđin U-Net tabanlı segmentasyon kullanıldığında bile, küçük veri setleri belirli augmentasyon teknikleriyle desteklenerek etkili çalışmalar yapılabilmektedir (Shorten vd., 2021).

1.5.2. Validasyon Ařaması

Modelin eđitim süreci sırasında, validasyon seti eđitim verilerinden bađımsız olarak ayrılır ve modelin genel performansının deđerlendirilmesinde kullanılır (Goodfellow vd., 2016). Bu ařama, modelin sadece eđitim verisine deđil, yeni verilere de ne derece genellenebileceđini göstermek açısından kritiktir (Refaeilzadeh vd., 2009). Özellikle tıbbi görüntü analizinde, validasyon verileri ile modelin sürekli izlenmesi, klinik geçerliliđin sađlanması açısından hayati öneme sahiptir (Litjens vd., 2017). Uygun řekilde yapılandırılmıř bir validasyon süreci, modelin eđitim sürecinde öğrendiđi bilgiyi tekrar eden örneklerden genelleyip genellemediđini ölçmemize olanak tanır (Zhou, 2021).

1.5.3. Test Aşaması

Test seti, modelin eğitimi ve validasyonu sırasında hiç kullanılmamış verilerden oluşur ve bu sayede modelin nihai performansının objektif bir şekilde değerlendirilmesini sağlar (Beam ve Kohane, 2018). Bu aşama, modelin gerçek dünyadaki klinik senaryolara ne kadar uygun olduğunun anlaşılabilmesi açısından son derece önemlidir (Rajpurkar vd., 2018). Test seti üzerinde hesaplanan metrikler (örneğin doğruluk, F1 skoru, duyarlılık, özgüllük), modelin genellenebilirliğini sayısal olarak özetler (Saito ve Rehmsmeier, 2015). Derin öğrenme sistemlerinde özellikle tıbbi tanı problemlerinde bu metrikler, insan uzmanlarla karşılaştırmalar yapılmasına imkân tanıyarak yapay zekâ sistemlerinin klinik karar destek aracı olarak kullanılabilirliğini ortaya koyar (Esteva vd., 2019). Ayrıca test verisiyle yapılan değerlendirmeler, modelin nadir görülen örnekler veya düşük örneklem büyüklüğüne sahip sınıflar karşısındaki dayanıklılığını da gözler önüne serer (Zhang ve Yang, 2021).

1.6. Çalışmanın Gerekçesi ve Amaç

Yapay zekâ tabanlı çürük tespiti ve teşhisinin geleceği umut vadetmekte olup, bu konudaki çalışmaların sayısı hızla artış göstermektedir. Yapay zekâ; doğruluğu artırma, verimliliği geliştirme ve bakım süreçlerini kişiselleştirme potansiyeli sayesinde diş hekimliğinde devrim niteliğinde yenilikler sunma imkanına sahiptir. Bununla birlikte, bu geleceğin etik, yasal ve teknik zorlukların dikkatli bir şekilde ele alınmasını gerektirdiği de unutulmamalıdır. Bu zorluklarla etkin biçimde başa çıkıldığında, yapay zekânın gücünden yararlanarak ağız sağlığını iyileştirmek ve diş bakımının geleceğini yeniden şekillendirmek mümkün olacaktır.

Yapay zekâ sistemlerinin pediatrik dental radyolojideki uygulama alanı giderek genişlemekte olup, bu teknolojiler, çürük lezyonlarının otomatik tespitinde umut verici sonuçlar sunmaktadır. Ancak literatürdeki çalışmaların büyük çoğunluğu daimi dişlere odaklanmakta, erken yaş grubundaki süt dişlerinde çürük teşhisine yönelik araştırmalar ise sınırlı kalmaktadır. Süt dişlerinde çürüğün daha hızlı ilerlemesi, minenin ve dentinin yapısal özelliklerinden kaynaklanan savunmasızlıkla birlikte değerlendirildiğinde, erken ve doğru tanının önemi daha da belirginleşmektedir. Ayrıca çocuk hastalarda iş birliğinin sınırlı düzeyde olması, geleneksel tanı yöntemlerinin etkinliğini azaltmakta ve diş çürüklerinin geç fark edilmesine neden olabilmektedir. Bu durum hem tedavi sürecini zorlaştırmakta hem de

invaziv müdahalelerin gerekliliğini artırmaktadır. Bu bağlamda, çocuk hastalara yönelik tanı süreçlerinde zaman kazandırabilecek ve doğruluğu artırabilecek teknolojilere duyulan ihtiyaç her geçen gün artmaktadır. Bu noktada, bu çalışmada hem süt hem de daimi dişlerden elde edilen radyografiler kullanılarak geliştirilen yapay zekâ modelinin performansının karşılaştırılması, söz konusu ihtiyaca yönelik somut bir katkı sağlamayı hedeflemektedir. Farklı dentisyon dönemlerine ait verilerle yapılacak karşılaştırmalı analizler, yaşa ve diş tipine özgü tanısal zorlukların yapay zekâ sistemleri tarafından nasıl yönetilebileceğine ışık tutabilecektir. Bu sayede, çocuk diş hekimliği pratiğinde kullanılabilecek güvenilir ve etkili dijital teşhis destek araçlarının geliştirilmesine yönelik önemli veriler sunulması önemlidir. Bu tür çalışmalar ile elde edilecek sonuçların, çocuk diş hekimliğinde yapay zekâ tabanlı çözümlerin entegrasyonu açısından literatürdeki boşluğu doldurması beklenmektedir.

Belirtilen ön bilgilerden hareketle, bu tez çalışmasının amacı, derin öğrenme tabanlı bir yapay zekâ algoritması olan Yolov5x mimarisini kullanarak, süt ve daimi dişlere ait bitewing radyografilerde yer alan arayüz çürüklerinin otomatik olarak teşhisine yönelik geliştirilen modelin tanısal performansını değerlendirmektir.

2. GEREÇ ve YÖNTEM

Yolov5x olarak adlandırılan derin öğrenme tabanlı mimari/modelinin süt ve daimi dişlerin arayüz çürüklerini teşhis etmedeki performansının araştırıldığı bu tez çalışmasına ait çalışma tasarımı, izlenen kılavuz ve yönergeler, etik kurul onayı ve çalışma prosedürü ile ilgili diğer tüm metodolojik adımlar aşağıda detaylı bir biçimde sunulmuştur.

2.1. Çalışma Tasarımı ve Rehber Alınan Kılavuzlar

Bu tez çalışması dental radyografik imajlar üzerinde gerçekleştirilmiş olup, retrospektif bir tasarıma sahiptir. Çalışma kapsamında Yolov5x algoritmasıyla geliştirilen modelin süt ve daimi dişlerin arayüzlerinde konumlanan çürükleri teşhis etme performansı değerlendirilmiştir.

Çalışmamızda yer alan aşamalar ve prosedürler, medikal ve dental görüntüleme alanında kullanılan yapay zekâ bazlı algoritmaların çalışıldığı bilimsel araştırmalar için şeffaflık, tekrarlanabilirlik ve güvenilirlik standartlarının sağlanabilmesi amacıyla 2024 yılında güncel hali yayımlanan “Checklist for Artificial Intelligence in Medical Imaging (CLAIM) (Tejani vd., 2024)” kılavuzu baz alınarak yürütülmüştür. Bu nedenle, bu tez çalışmasında yapay zekâ destekli dental radyografi analizlerinin bilimsel geçerliliğini ve güvenilirliğini artırmak amacıyla, CLAIM 2024 güncellemesinde belirtilen kapsamlı kontrol listesine, çalışmamız için uygun olan adımlar özelinde uygunluk sağlanmıştır. Bu kapsamda, tez çalışmamıza dahil edilen veri kaynaklarının tanımlanması, etiketleme (labelling) süreçlerinin şeffaf şekilde tamamlanması ve raporlanması, kullanılan yapay zekâ bazlı modelin eğitim süreçlerinin gerçekleştirilmesi, test protokolleri ve test süreci sonunda performans metriklerinin ve konfüzyon matrislerinin açıklanması şeklindeki basamaklar, CLAIM kılavuzunda yer alan kontrol listesindeki ilgili maddeler doğrultusunda gerçekleştirilmiştir. Bu yönergeler sayesinde, çalışmamıza dahil edilen yapay zekâ algoritmasının doğruluğu kadar, araştırmanın metodolojik bütünlüğü de sağlanmaya çalışılmıştır.

2.2. Etik Kurul Onayı ve Etik İlkeler

Çalışmamız için gerekli etik onay, T.C. Ankara Üniversitesi Diş Hekimliği Fakültesi Klinik Araştırmalar Etik Kurulu'ndan alınmıştır (Tarih: 06.11.2023, Karar No: 12/11). Ayrıca, bu çalışmadaki araştırma protokolü Dünya Tıp Birliği Helsinki Bildirgesi'nde belirtilen etik ilkeler gözetilerek uygulanmıştır (Shrestha ve Dunn, 2019).

2.3. Araştırmanın Fonlanması ve Giderlerin Karşlanması

Bu tez çalışmasının maddi giderleri, Ankara Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından karşılanmıştır (Proje ID: 3520, Proje Kodu: TDK-2024-3520).

2.4. Görüntü Verilerinin Sağlanması

Tez çalışmasına dahil edilen bitewing radyografik görüntüler, Ankara Üniversitesi Diş Hekimliği Fakültesi Çocuk Diş Hekimliği Anabilim Dalı Kliniği ve Ankara Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı Kliniklerinde, daha önceden farklı endikasyonlar gerekliliği dahilinde, hasta/velilerinin onamı sonrasında alınarak, hastane bünyesinde çalışan “Görüntü Arşivleme ve İletişim Sistemi (PACS sistemi)” uygulamasına kaydedilen görüntüler içinden seçilmiştir. Çalışmaya dahil edilen tüm bitewing radyografiler, yüksek frekanslı DC sistemine sahip olan Belmont Phot-X II (Belmont Takara Company, Japonya) cihazı ile elde edilmiştir. Dijital sensör (GENDEX GX PS-500, Gendex Dental Sistemler, Hatfield, PA, ABD) kullanılarak alınmış olan radyografik görüntülemeler sırasında çocuk hastalara özel düşük doz protokolleri uygulanmış olup; tüp voltajı 60-70 kV, tüp akımı ise 4-5 mA olarak ayarlanmıştır. Pozlama süreleri ise 0.10-0.25 saniye arasında olacak şekilde belirlenmiştir. Bu doğrultuda daha önceden alınmış olan radyografik görüntülerin çalışmamıza dahil edilme kriterleri aşağıda yer almaktadır.

2.5. Dahil Edilme Kriterleri

- Hem süt hem de daimi diş bitewing radyografileri için, daha önceden alınmış, en az bir arayüzde (distal ve/veya mesial) radyografik olarak tespit edilebilir diş çürüğü bulunması

- Süt dişlerinin bulunduğu, süt veya karışık dişlenme döneminde elde edilmiş bitewing radyografiler için ilgili hasta yaşının 4-9 aralığında olması
- Daimi dişlenmeye ait olan ve sadece daimi dişlerin bulunduğu bitewing radyografiler için ilgili hasta yaşının 12-30 aralığında olması

2.6. Hariç Tutulma Kriterleri

- Hem süt hem de daimi diş bitewing radyografilerinde arayüzde (distal ve/veya mesial) radyografik olarak tespit edilebilir diş çürüğü bulunmaması
- Süt dişlerinin bulunduğu, süt veya karışık dişlenme döneminde elde edilmiş bitewing radyografiler için ilgili hasta yaşının 4-9 aralığı dışında olması
- Daimi dişlenmeye ait olan ve sadece daimi dişlerin bulunduğu bitewing radyografiler için ilgili hasta yaşının 12-30 aralığı dışında olması
- Herhangi bir radyografi artefaktı bulunması
- Özellikle diş kuronu ve köklü ilgilendiren dental anomali bulunması

2.7. Çalışma Grupları ve Dahil Edilen Radyografik Görüntülerin Dağılımı

Çalışmamıza süt dişlerini ve daimi dişleri içeren radyografik görüntüler dahil edilmiş olup, bu gruplara ilişkin özellikler aşağıda sunulmuştur.

2.7.1. Süt Dişi Radyografik Görüntüleri


Bu gruba süt ya da karışık dişlenme döneminde olan ve 4-9 yaş aralığındaki hastalardan daha önceden farklı endikasyonlar nedeniyle çekilmiş toplam 1000 görüntü dahil edilmiştir. Bu gruptaki radyografik görüntülerde daimi dişlerin de görüntüde mevcut olması durumunda, işlemler sadece görüntülerdeki süt dişleri bazında gerçekleştirilmiştir. Dahil edilen 1000

radyografik görüntünün; 800'ü eğitim, 100'ü validasyon ve 100'ü test veri seti olacak şekilde dağılımı planlanmıştır.

2.7.2. Daimi Diş Radyografik Görüntüleri

Bu gruba daimi dişlenme döneminde olan ve 12-30 yaş aralığındaki hastalardan daha önceden farklı endikasyonlar nedeniyle çekilmiş toplam 1000 görüntü dahil edilmiştir. Bu gruptaki radyografik görüntülerde, işlemler tüm daimi dişleri dahil edecek şekilde gerçekleştirilmiştir. Dahil edilen 1000 radyografik görüntünün; 800'ü eğitim, 100'ü validasyon ve 100'ü test veri seti olacak şekilde dağılımı planlanmıştır.

Çalışmamıza dahil edilen veri setine ait süt ve daimi diş bitewing radyografik görüntülerine ait örnekler Şekil 2.1.'de sunulmuştur.



Şekil 2.1. Kullanılan veri setine ait süt dişi (a ve b) ve daimi dişi (c ve d) bitewing radyografik görüntüleri

2.8. Görüntü Anonimizasyonu ve Veri Güvenliği

Tez çalışmamıza dahil edilen tüm dijital radyografik görüntüler, Görüntü Arşivleme ve İletişim Sistemi üzerinden, görüntü ile kişisel kimlik bilgilerinin birbiri ile ilişkilendirilemeyeceği şekilde anonimize edilmiştir. Bu kapsamda, görüntü imajları üzerinden hastanın adı ve soyadı, hastane sistemine ilişkin protokol numarası, doğum tarihi ve benzeri

kişisel tanımlayıcı bilgiler silinmiştir. Anonimize edilen bitewing radyografiler, yalnızca araştırmacılar tarafından erişilebilen ve diğer kişilerin erişimine kapalı olan bir bilgisayarda şifre korumalı olarak saklanmıştır.


2.9. Görüntü Ön İşleme

Yapay zekâ eğitim ve test sürecinden önce, çalışma prosedürlerine dahil edilen tüm görüntüler .jpeg dosya formatına dönüştürülmüştür. Bunun haricinde, görüntüler üzerinde veri artırma (augmentation) teknikleri, yatay döndürme, parlaklık ayarı ve bulanıklaştırma işlemleri uygulanmamıştır.

2.10. Etiketleme Süreci

Çalışmada kullanılan hem süt dişlerinin bulunduğu hem de daimi dişlenmeye ait olan tüm dijital bitewing radyografik görüntülerde, arayüz çürüklerinin saptanması amacıyla manuel olarak etiketlenme prosedürleri tamamlanmıştır. Etiketleme süreci, radyografik görüntülerde yer alan tüm dişlerdeki tüm arayüz çürük lezyonlarını kapsayacak şekilde yapılmıştır. Bu kapsamda, süt ya da karışık dişlenmedeki bitewing radyografilerde görüntüye daimi dişler dahil olsa da, etiketleme işlemleri sadece süt dişleri için yapılmış, bu görüntülerdeki daimi dişler çalışma kapsamı dışında bırakılmıştır. Bununla birlikte, daimi dişlenmeye ait bitewing radyografilerdeki tüm daimi dişler etiketlenme prosedürüne dahil edilmiştir.

Radyograflar Craniocatch (Eskişehir/Türkiye) etiketleme modülüne yüklenerek her bir görüntüdeki çürük lezyonunun sınırları, poligonal segmentasyon yöntemiyle manuel olarak belirlenmiştir. Bu işlem sonucunda, yapay zekâ modelinin eğitimine uygun veri formatında çıktı dosyaları elde edilmiştir. Segmentasyon sonuçları, her görüntü için ilgili sınıf etiketlerini ve yapıların segmentasyon koordinatlarını içerecek şekilde kaydedilmiştir. Etiketleme süreci boyunca, görüntüler rastgele bir sırada işlenmiş olup bu yaklaşım, modelin değerlendirme aşamasında sistematik önyargıdan etkilenmemesini sağlamak amacıyla benimsenmiştir. Çalışmada gerçekleştirilen etiketleme prosedürlerine ait örnekler Şekil 2.2.'de sunulmuştur.



Şekil 2.2. Süt dişi (a) ve daimi diş (b) bitewing radyografik görüntülerine ait arayüz çürük lezyonlarını etiketleme süreçlerini gösteren görüntüler

2.11. Çalışma Prosedürü ve Veri Setleri

Bu tez çalışmasında kullanılan Yolov5x mimarisi için 3 adet veri seti oluşturulmuştur. Çalışma özelinde kullanılan veri setleri; eğitim veri seti, validasyon (doğrulama) veri seti ve test veri setinden oluşmuştur. Veri setlerinin dağılım oranları hem süt hem de daimi diş bitewing radyografik görüntüleri için; %80 eğitim (her grup için 800 görüntü), %10 validasyon (her grup için 100 görüntü) ve %10 test (her grup için 100 görüntü) olacak şekilde ayrılmıştır. Bu kapsamda, çalışmaya ait eğitim, validasyon ve test aşamalarına ilişkin prosedürler aşağıda detaylı olarak sunulmuştur.

Çalışmamıza dahil edilen süt ve daimi diş bitewing radyografi grupları için eğitim, validasyon ve test veri kümelerine ilişkin radyografi sayıları ve etiket sayıları Çizelge 2.1. ve 2.2.'de detaylı bir biçimde gösterilmiştir.

Çizelge 2.1. Eğitim, validasyon ve test veri setleri ile ilişkili radyografik görüntü sayıları

Veri Seti	Süt Dişi Görüntüleri	Daimi Diş Görüntüleri	Toplam
Eğitim	800	800	1600
Validasyon	100	100	200
Test	100	100	200
Toplam	1000	1000	2000

Çizelge 2.2. Eğitim, validasyon ve test veri setleri ile ilişkili etiket sayıları

Veri Seti	Süt Dişi Etiketleri	Daimi Diş Etiketleri	Toplam
Eğitim	2371	2281	4652
Validasyon	271	263	534
Test	259	259	518
Toplam	2901	2803	5704

2.12. Yapay Zekâ Eğitim Aşamaları

Sürecin ilk aşaması olan eğitim prosedürü ve bu sürece ait veri seti, yapay zekâ modelinin çürük teşhisi ve segmentasyonu konusundaki eğitimi için kullanılmıştır. Bu doğrultuda hem süt hem de daimi diş bitewing radyografileri için 800'er radyografi eğitim veri setine randomize olacak şekilde atanmıştır. Buna göre, çalışmamıza dahil edilen Yolov5x olarak adlandırılan derin öğrenme tabanlı yapay zekâ mimarisinin eğitim süreci için toplamda 1600 bitewing radyografi görüntüsü (800 süt, 800 daimi diş görüntüleri için) kullanılmış olup, yapay zekâ modeli toplam 4652 etiket (2371 süt, 2281 daimi diş görüntüleri için) ile süt ve daimi dişlerde çürük tespiti için ayrı ayrı eğitilmiştir. Eğitim aşamasının ardından validasyon sürecine geçilmiştir.

2.13. Kullanılan Yapay Zekâ Modeli

Bu çalışmada, dijital bitewing radyografilerde arayüz çürüklerinin tespiti ve teşhis performansını değerlendirmek amacıyla geliştirilen Yolov5 mimarisinin genişletilmiş varyantı olan Yolov5x modeli kullanılmıştır. Yolov5x, daha derin ve geniş katman yapısı sayesinde küçük ve belirsiz nesnelerin daha başarılı tespitini hedefleyen bir derin öğrenme modelidir.

Model eğitimi, Ultralytics YOLOv5 PyTorch kütüphanesi kullanılarak gerçekleştirilmiştir. Eğitim sürecinde kullanılan temel hiperparametrelerden epoch sayısı 800, öğrenme oranı ise 0,01'dir.

2.14. Model Validasyon (Doğrulama) Aşaması

Çalışmamızda kullanılan YOLOv5x mimarisinin optimizasyonu ve hiperparametre ayarlarının gerçekleştirilmesi adına hem süt hem de daimi diş bitewing radyografik görüntüleri için, 100'er radyografik görüntüden (toplam veri setinin %10'u) oluşan bir veri kümesi validasyon amacıyla kullanılmıştır. Bu veri seti, modelin eğitimi sırasında öğrenme performansının izlenmesi ve aşırı öğrenmenin (overfitting) önlenmesi için kullanılmıştır. Buna göre, çalışmamıza dahil edilen YOLOv5x olarak adlandırılan derin öğrenme tabanlı yapay zekâ mimarisinin validasyon süreci için toplamda 200 bitewing radyografi görüntüsü (100 süt, 100 daimi diş görüntüleri için) kullanılmış olup, yapay zekâ modeli toplam 534 etiket (271 süt, 263 daimi diş görüntüleri için) ile valide edilmiştir.

YOLOv5x derin öğrenme tabanlı yapay zekâ modelinin eğitimi boyunca her epoch sonunda doğrulama seti üzerindeki kayıp ve performans metrikleri takip edilmiştir. Bu noktada, erken durdurma stratejisi uygulanarak, doğrulama kaybında belirli sayıda art arda iyileşme gözlenmemesi durumunda eğitim sonlandırılmıştır. Doğrulama aşamasında elde edilen en iyi model ağırlıkları, test seti üzerinde nihai değerlendirme amacıyla saklanmış ve sadece bu “en iyi doğrulama skoru” gösteren model kullanılarak performans ölçümleri gerçekleştirilmiştir. Bu sayede model seçimi, eğitim ve test verilerinin ayrımına sadık kalınarak nesnel biçimde yapılmıştır. Hiperparametre optimizasyonu, başlangıçta deneysel denemelerle belirlenen bir grid üzerinden gerçekleştirilmiş ve eğitim doğrulama dengesine göre en uygun konfigürasyon seçilmiştir. Validasyon aşamasının ardından modelin performansının ölçüldüğü test sürecine geçilmiştir.

2.15. Model Test Aşaması

Süreç açısından, bu aşamalar içindeki son veri seti olan test veri seti ise, yapay zekâ mimarisinin daha önce görmediği etiketler üzerinde, modelin performansını tarafsız ve objektif biçimde değerlendirmek amacıyla kullanılan izole bir veri kümesidir. YOLOv5x yapay zekâ mimarisinin test aşamasında hem süt hem de daimi diş bitewing radyografik görüntüleri

için, 100'er radyografik görüntüden (toplam veri setinin %10'u) oluşan bir veri kümesi kullanılmıştır. Buna göre, çalışmamıza dahil edilen Yolov5x olarak adlandırılan derin öğrenme tabanlı yapay zekâ mimarisinin test süreci için toplamda 200 bitewing radyografi görüntüsü (100 süt, 100 daimi diş görüntüleri için) kullanılmış olup, yapay zekâ modeli toplam 518 etiket (259 süt, 259 daimi diş görüntüleri için) ile test edilmiştir. Çalışmamıza dahil edilen yapay zekâ mimarisi olan Yolov5x modelinin eğitimi, değerlendirilmesi, doğruluk analizleri, sonuçların görselleştirilmesi ve analiz edilmesi için Pytorch kütüphanesi kullanılmıştır.

2.16. Sonuçların Yorumlanması ve Performans Değerlendirme Metrikleri

Çalışmamızda hem süt hem de daimi diş bitewing radyografik görüntülerinde yer alan arayüz çürüklerinin yapay zekâ modeli tarafından teşhis edilme performansına ilişkin sonuçlar bir konfüzyon matrisi ile değerlendirilmiştir. Bu bağlamda, validasyon ve test sürecindeki performans araştırmacının (H.S.G.) belirlemiş olduğu sınırlayıcı kutuları altın standart olarak kabul etmektedir. Sonuçların değerlendirilmesinde kullanılan konfüzyon matrisi gerçek durum ile tahmin edilen durum arasındaki ilişkiyi ortaya koymaktadır. Bu bağlamda, Yolov5x yapay zekâ modelinin performansını değerlendirmek için temel anlamda test veri setinin konfüzyon matrisi baz alınmıştır. Yolov5x modelinin başarısını değerlendirmek amacıyla kullanılan metrikler aşağıda maddeler halinde özetlenmiştir.

2.16.1. Doğru Pozitif (DP)

Yapay zekâ modelinin çürük lezyonunu doğru bir şekilde tahmin ettiği durumları tanımlamaktadır. Farklı bir ifadeyle, gerçekten çürük olan ve yapay zekâ modelinin çürük olarak tahmin ettiği alanları göstermektedir (Yılmaz, 2023).

2.16.2. Yanlış Pozitif (YP)

Yapay zekâ modelinin çürük lezyonunu yanlış bir şekilde pozitif olarak (varmış gibi) tahmin ettiği durumları tanımlamaktadır. Gerçekte negatif olan durumlar pozitif olarak hatalı tespit edilir. Farklı bir ifadeyle, gerçekte çürük olmayan, ancak yapay zekâ modelinin çürük olarak tahmin ettiği alanları göstermektedir (Yılmaz, 2023).

2.16.3. Yanlış Negatif (YN)

Yapay zekâ modelinin çürük lezyonunu yanlış bir şekilde negatif olarak tanımladığı durumları ifade etmektedir. Gerçekte çürük olan alanlar model tarafından gözden kaçırılır ve negatif olarak tespit edilir (Yılmaz, 2023).

Çalışmamız özelinde DP, YP ve YN değerleri kullanılarak aşağıdaki metrikler hesaplanmış ve performans değerlendirilmesinde kullanılmıştır.

2.16.4. Kesinlik (Precision)

Kesinlik tahmin edilen sonuçların ne kadar doğru olduğunu ölçen bir terimdir. Kullanılan yapay zekâ modeli tarafından pozitif olarak tahmin edilen örnekler içerisinde kaç tanesinin gerçekten pozitif olduğunu göstermektedir. Farklı bir ifadeyle, bu çalışma özelinde, yapay zekâ modelinin çürük olarak tahmin ettiği alanların ne kadarının gerçekten çürük olduğunu göstermektedir. Bu bağlamda, yüksek tespit edilmiş bir kesinlik değeri, az sayıda YP sonucunu ifade etmektedir. Kesinlik, $\frac{DP}{DP+YP}$ formülasyonu ile hesaplanmaktadır (Yılmaz, 2023).

2.16.5. Duyarlılık (Recall ya da Sensitivity)

Yapay zekâ modelinin doğru bir şekilde pozitif olarak tanımladığı gerçek pozitif vakaların oranını temsil etmektedir. Çalışmamız özelinde, gerçek çürük alanlarının ne kadarının model tarafından doğru tespit edildiğini göstermektedir. Bu bağlamda, yüksek tespit edilmiş bir duyarlılık değeri, yapay zekâ modelinin çürükleri kaçırma oranının düşük olduğunu göstermektedir. Duyarlılık, $\frac{DP}{DP+YN}$ formülasyonu ile hesaplanmaktadır (Yılmaz, 2023).

2.16.6. F1 Skoru

Kesinlik ve duyarlılık değerlerinin harmonik ortalaması olan bu skor, bu değerlerin aralarındaki dengeyi ifade etmektedir. Bu bağlamda, kesinlik ve duyarlılık arasında bir denge varsa F1 skoru da yüksek olarak tespit edilmektedir. Ek olarak, yüksek F1 skoru gerçek

pozitifleri tespit etme ile yanlış pozitifleri önleme arasında iyi bir dengeye sahip bir modele işaret etmektedir. F1 skoru, $\frac{2 \times \text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}}$ formülasyonu ile hesaplanır (Yılmaz, 2023).

2.16.7. Güven Skoru Eğrileri

Ek olarak, modelin genel performansının, farklı güven skoru (confidence) eşik değerlerine göre nasıl değiştiğini değerlendirmek amacıyla “F1- Güven Skoru Eğrisi” oluşturulmuştur. Bu eğri, modelin hem doğruluk hem de duyarlılık arasında kurduğu dengeyi temsil eden F1 skorunu, farklı güven aralıklarında göstermektedir. Ek olarak kesinlik ve duyarlılık için de güven skoru eğrileri değerlendirmelerde kullanılmıştır (Chicco ve Jurman, 2020; Saito ve Rehmsmeier, 2015).

2.16.8. ROC Eğrisi ve AUC

Modelin genel sınıflandırma performansını değerlendirmek amacıyla Alıcı İşlem Karakteristik Eğrisi (Receiver Operating Characteristic Curve, ROC) analizi gerçekleştirilmiştir. ROC eğrisi, modelin farklı eşik değerlerinde elde ettiği doğru pozitif oranı (True Positive Rate, TPR) ile yanlış pozitif oranı (False Positive Rate, FPR) arasındaki ilişkiyi göstermektedir. Çalışmamızda bunlara ilave olarak modelin ROC eğrisi altında kalan alan (Area Under the Curve, AUC) değeri de hesaplanmıştır. Bu değer, modelin pozitif ve negatif sınıfları ayırt etme kapasitesinin yüksek olduğunu ve genel performansının başarılı düzeyde olduğunu göstermektedir. AUC değerinin 1 değerine yakın olması, modelin tüm pozitif örnekleri eksiksiz şekilde doğru tespit ettiği ve yanlış pozitif oranının minimum olduğu ideal bir senaryoyu temsil ederken, 0,5 değeri ise modelin rastgele tahmin yaptığını ifade etmektedir (Fawcett, 2006; Hanley ve McNeil 1982).

3. BULGULAR


Bu tez çalışmasında, süt ve daimi diş bitewing radyografileri kullanılarak geliştirilen Yolov5x tabanlı derin öğrenme modelinin arayüz çürüklerini teşhis etme performansı değerlendirilmiştir. Modelin segmentasyon odaklı teşhis yeteneği sayesinde arayüzde konumlanmış çürük lezyonlarının sınırlarının piksel düzeyinde doğru şekilde belirlenmesi hedeflenmiştir.

Çalışmamız kapsamında, her iki diş grubuna ait bitewing radyografiler üzerinde modelin kesinlik, duyarlılık, F1 skoru ve ROC-AUC gibi temel performans metrikleri detaylı bir biçimde analiz edilmiştir. Ayrıca test aşamasına ait konfüzyon matrisleri ve güven skoru eğrileri kullanılarak modelin sınıflandırma kabiliyeti kapsamlı biçimde ortaya konulmuştur.

Çalışmamız dahilinde elde ettiğimiz bulgular, “Süt Dişi Radyografik Görüntüleri” ve “Daimi Diş Radyografik Görüntüleri” olmak üzere iki ayrı başlık altında sunulmuştur.

3.1. Süt Dişi Radyografik Görüntüleri

Süt dişi bitewing radyografilerinin test aşamasında, Yolov5x modeli tarafından teşhis edilen arayüz çürükleri, ilgili bölgelerde segmentasyon maskeleriyle birlikte işaretlenmiştir. Görsellerde, modelin hem tekil hem de çoklu lezyonları yüksek doğrulukla tanımlayabildiği gözlenmektedir (Şekil 3.1).



Şekil 3.1. Süt dişi bitewing radyografilerinde Yolov5x modelinin test aşamasında arayüz çürüklerinin teşhisine ilişkin örnek görüntüler. Kırmızı bölgeler, modelin segmentasyon tabanlı olarak işaretlediği çürük alanlarını göstermektedir.

Süt dişi radyografik görüntüleri için gerçekleştirilen segmentasyon tabanlı analizlerde, Yolov5x modelinin arayüzde konumlanmış çürük lezyonların test aşamasındaki teşhisine ait DP tespit sayısı 202, YP tespit sayısı 52 ve YN tespit sayısı ise 57 olarak belirlenmiştir.

Bu sonuçlara göre bu grup için Yolov5x modelinin;

Kesinlik değeri: 0,80

Duyarlılık değeri: 0,78


F1 skoru: 0,79 olarak hesaplanmıştır.

Ayrıca modelin ROC analizinde hesaplanan alan altındaki değer ise (AUC) 0,87 şeklinde tespit edilmiştir (Çizelge 3.1).

Çizelge 3.1. Yolov5x modelinin süt dişi radyografilerindeki performans metrikleri


Metrik	Değer
DP	202
YP	52
YN	57
Kesinlik	0,80
Duyarlılık	0,78
F1 Skoru	0,79
AUC (ROC)	0,87

Süt dişi radyografik görüntüleri için elde edilen konfüzyon matrisi, modelin klinik kullanıma yönelik sınıflandırma kabiliyetini görsel olarak da desteklemektedir (Şekil 3.2).



Şekil 3.2. Süt dişi radyografik görüntüleri için elde edilen konfüzyon matrisi (DP=202, YP=52 ve YN=57)


Modelin genel test seti üzerindeki F1 skoru 0,79 olarak hesaplanmıştır. Süt dişi radyografileri üzerinde oluşturulan F1-Güven Skoru eğrisi ve buna ilişkin analizde ise, modelin farklı güven skoru eşik değerlerinde gösterdiği genel performansı değerlendirmek amacıyla uygulanmış ve analiz sonucunda, Yolov5x modelinin maksimum F1 skoru 0,73 olarak hesaplanmış ve bu değere 0,376 güven skorunda ulaşılmıştır (Şekil 3.3). Bu sonuç, modelin yaklaşık %37 güven eşiğinde kesinlik ve duyarlılık arasındaki optimal dengeyi kurabildiğini göstermektedir. Bu durum, test seti skorları ile eğri üzerinde elde edilen maksimum skorun farklı ölçütler temsil ettiğini ve eşik değeri optimizasyonunun model performansını önemli ölçüde etkileyebileceğini göstermektedir. Bu bağlamda, eşik değeri yükseldikçe kesinlik değeri artmakta, ancak buna bağlı olarak duyarlılık değeri de azaldığı için F1 skoru düşüş göstermektedir. Bu bulgu, modelin klinik uygulamalarda hangi güven skoru aralığında kullanılmasının uygun olacağına dair önemli bir referans sunmaktadır (Şekil 3.3).



Şekil 3.3. Süt dişi radyografileri için segmentasyon bazlı F1-Güven Skoru eğrisi (maksimum F1 skoru: 0,73; güven skoru: 0,376).


Süt dişi radyografileri için oluşturulan kesinlik-güven skoru analizi, Yolov5x modelinin farklı güven skoru eşik değerlerindeki kesinlik performansını değerlendirmek amacıyla yapılmış olup, bu analiz sonucunda, modelin maksimum kesinlik değeri 1,00 olarak belirlenmiş ve bu değere 0,798 güven skorunda ulaşılmıştır. Bu bulgu, modelin yaklaşık %80

güven eşik değeri uygulandığında işaretlediği tüm bölgelerde arayüz çürüğü bulunma olasılığının oldukça yüksek olduğunu belirtmektedir (Şekil 3.4).



Şekil 3.4. Süt dişi radyografileri için segmentasyon bazlı Kesinlik-Güven Skoru Eğrisi (maksimum kesinlik: 1,00; güven skoru: 0,798).


Süt dişi radyografileri için oluşturulan Duyarlılık-Güven Skoru eğrisi, modelin farklı güven skoru eşik değerlerinde gösterdiği duyarlılık performansını ortaya koymak amacıyla yapılmış olup, analiz sonucunda, modelin maksimum duyarlılık değeri 0,85 olarak hesaplanmış ve bu değere 0,00 güven skorunda ulaşılmıştır. Bu sonuç, en düşük güven eşiği uygulandığında modelin tüm olası çürükleri maksimum düzeyde yakalama eğiliminde olduğunu göstermektedir (Şekil 3.5).



Şekil 3.5. Süt dişi radyografileri için segmentasyon bazlı Duyarlılık-Güven Skoru Eğrisi (maksimum duyarlılık: 0,85; güven skoru: 0,00).

3.2. Daimi Diş Radyografik Görüntüleri

Daimi diş bitewing radyografilerinin test aşamasında, Yolov5x modeli tarafından teşhis edilen arayüz çürükleri, ilgili bölgelerde segmentasyon maskeleriyle birlikte işaretlenmiştir. Görsellerde, modelin hem tekil hem de çoklu lezyonları yüksek doğrulukla tanımlayabildiği gözlenmektedir (Şekil 3.6).



Şekil 3.6. Daimi diş bitewing radyografilerinde Yolov5x modelinin test aşamasında arayüz çürüklerinin teşhisine ilişkin örnek görüntüler. Kırmızı bölgeler, modelin segmentasyon tabanlı olarak işaretlediği çürük alanlarını göstermektedir.

Daimi diş radyografik görüntüleri için gerçekleştirilen segmentasyon tabanlı analizlerde, Yolov5x modelinin arayüzde konumlanmış çürük lezyonların teşhisine ait DP tespit sayısı 193, YP tespit sayısı 54 ve YN tespit sayısı ise 66 olarak belirlenmiştir.

Bu sonuçlara göre bu grup için Yolov5x modelinin;

Kesinlik değeri: 0,78

Duyarlılık değeri: 0,75


F1 skoru: 0,76 olarak hesaplanmıştır.

Ayrıca modelin ROC analizinde hesaplanan alan altındaki değer ise (AUC) 0,88 şeklinde tespit edilmiştir (Çizelge 3.2).

Çizelge 3.2. Yolov5x modelinin daimi diş radyografilerindeki performans metrikleri


Metrik	Değer
DP	193
YP	54
YN	66
Kesinlik	0,78
Duyarlılık	0,75
F1 Skoru	0,76
AUC (ROC)	0,88

Daimi diş radyografik görüntüleri için elde edilen konfüzyon matrisi, modelin klinik kullanıma yönelik sınıflandırma kabiliyetini görsel olarak da desteklemektedir (Şekil 3.7).




Şekil 3.7. Daimi diş radyografik görüntüleri için elde edilen konfüzyon matrisi (DP=193, YP=54 ve YN=66)

Modelin daimi diş radyografilerindeki genel test seti üzerindeki F1 skoru 0,77 olarak hesaplanmıştır. Daimi diş radyografileri üzerinde gerçekleştirilen F1–Güven Skoru Eğrisi ve buna ilişkin analizde ise, modelin farklı güven skoru eşiklerinde sergilediği genel performansı değerlendirmek amacıyla yapılmış olup, analiz sonucunda, modelin maksimum F1 skoru 0,66 olarak belirlenmiş ve bu değere 0,364 güven skorunda ulaşılmıştır. Bu bulgu, modelin yaklaşık %36 güven eşiğinde kesinlik ve duyarlılık arasında en uygun dengeyi kurabildiğini göstermektedir (Şekil 3.8).




Şekil 3.8. Daimi diş radyografileri için segmentasyon bazlı F1-Güven Skoru Eğrisi (maksimum F1 skoru: 0,66; güven skoru: 0,364).

Daimi diş radyografileri için oluşturulan kesinlik-güven skoru analizi, Yolov5x modelinin farklı güven skoru eşik değerlerindeki kesinlik performansını değerlendirmek amacıyla yapılmış olup, bu analiz sonucunda, modelin maksimum kesinlik değeri 1,00 olarak belirlenmiş ve bu değere 0,819 güven skorunda ulaşılmıştır. Bu bulgu, modelin yaklaşık %80 güven eşik değeri uygulandığında işaretlediği tüm bölgelerde arayüz çürüğü bulunma olasılığının oldukça yüksek olduğunu belirtmektedir (Şekil 3.9).



Şekil 3.9. Daimi diş radyografileri için segmentasyon bazlı kesinlik-güven skoru eğrisi (maksimum kesinlik: 1,00; güven skoru: 0,819).

Daimi diş radyografileri için oluşturulan duyarlılık-güven skoru eğrisi, modelin farklı güven skoru eşik değerlerinde gösterdiği duyarlılık performansını ortaya koymak amacıyla yapılmış olup, analiz sonucunda, modelin maksimum duyarlılık değeri 0,84 olarak hesaplanmış ve bu değere 0,00 güven skorunda ulaşılmıştır. Bu sonuç, en düşük güven eşiği uygulandığında modelin tüm olası çürükleri maksimum düzeyde yakalama eğiliminde olduğunu göstermektedir (Şekil 3.10).



Şekil 3.10. Daimi diş radyografileri için segmentasyon bazlı duyarlılık-güven skoru eğrisi (maksimum duyarlılık: 0,84; güven skoru: 0,00).

4. TARTIŞMA

Popölasyonda en sık görölen hastalıklar arasında yer alan diş çürüğü, fermente olabölen karbonhidratları metabolize edebölen bakterilerin ürettiğı asitlerin diş sert dokularında oluşturduğu karmaşık etkileşimler sonucunda meydana gelen ve şiddeti çeşitli faktörler ile değışiklik gösteren multifaktöriyel bir hastalıktır (Bordoni vd., 2021; Machiulskiene vd., 2020; Pitts vd., 2021; Selwitz vd., 2007). Kavitasyonsuz demineralize lezyonların tedavi edilmemesi durumunda, oral floradaki karyojenik bakterilerin neden olduğı asit üretim artışı, bu asitlerin diş yüzeyini demineralize etmesi ve bunun sonucunda mine yüzeyinin bütönlüğünün bozulmasıyla oluşın lezyonlar kavitasyonlu çürük lezyonları olarak adlandırılmaktadır (Iannucci ve Radiography, 2017). Bununla birlikte, ilerlemiş olgularda görölen ve tedavi edilmemiş kavitasyonlu diş çürükleri şiddetli ağrı ve dental apse gelişimi gibi çeşitli fiziksel semptomların oluşmasına ve ayrıca psikolojik semptomların ortaya çıkmasına ve bunun sonucunda da yaşam kalitesinin değışen derecelerde düşmesine neden olmaktadır (Bordoni vd., 2021; Machiulskiene vd., 2020; Pitts vd., 2021; Selwitz vd., 2007; Zaror vd., 2022).

Diş çürüğü çocuklarda sadece fiziksel sağık parametreleri ve sonuçları ile sınırlı olmayan, aynı zamanda çocukların psikolojik ve sosyal gelişimlerine de önemli zararlar verebilen bir hastalıktır (Corrêa-Faria vd., 2020; Fernandez vd., 2022; Zaror vd., 2022). Nitekim, Filstrup vd. (2003), yaptıkları bir çalışmada, diş çürüğüne sahip olan çocukların gülümsemekten kaçındığı ve genel sağık kalitelerinin azaldığı, dolayısıyla da diş çürüğünden etkilenen çocukların sosyal ve psikolojik yönden olumsuz deneyimler yaşadığı ortaya konulmuştur (Filstrup vd., 2003). Bu konuda yapılan başka bir çalışmada ise Jackson vd. (2011), ağız ve diş sağığı yetersiz seviyede olan çocukların okul başarılarının daha düşük düzeyde olduğı sonucuna varmıştır (Jackson vd., 2011). Diğer yandan, Cunnion vd. (2010), gerçekleştirdiğı araştırmada, erken dönemde uygulanan dental tedavilerin çocuklarda diş çürüğü kaynaklı ağrı düzeylerinin azaltılması, uyku ve beslenme düzenlerinin sağılanması gibi olumlu sonuçlar sunduğı ve bu fiziksel çıktıları ek olarak çocukların psikolojik ve sosyal gelişimlerinin de olumlu etkilendiğı vurgulanmıştır (Cunnion vd., 2010).

Diş çürüğü sadece bireyleri değil aynı zamanda bireylerin dahil olduğı toplum ekonomilerini de olumsuz yönde etkilemektedir. Righolt vd. (2018), bu konu ile ilgili yaptıkları çalışmada artın diş çürüğü oranlarının tedavileri daha karmaşık hale getirdiğini ve

maliyet açısından ülkelerin sağlık sistemleri üzerinde artan bir finansal yük oluşturduğunu ortaya koymuştur. Aynı çalışmada, çürüğün erken tespitinin ve teşhisinin ve hastalığın erken evrelerinde uygulanacak tedavilerin uzun vadede tedavi maliyetlerini düşürerek ülkelere ekonomik anlamda önemli kazanımlar sağlayacağını belirtmiştir (Righolt vd., 2018). Tüm bu bulgular diş çürüğünün multifaktöriyel doğası gereği etkin önleme ve tedavi stratejilerinin geliştirilmesinin son derece önemli olduğu gerçeğini desteklemektedir.

Çürüğün erken teşhisinin tedavinin daha etkin şekilde sağlanabilmesi adına son derece önemli olduğu gerçeğinden hareketle, çürük teşhis yöntemleri ve klinik etkinlikleri de uygulamada önem kazanmaktadır. Günümüzde, geleneksel çürük teşhis yöntemleri içerisinde yer alan görsel ve dokunsal muayene yöntemleri ile radyolojik muayene standart çürük teşhis yöntemleri olarak rutin klinik pratikte sıklıkla tercih edilmektedir (Gomez, 2015; Selwitz vd., 2007). Görsel muayene diş çürüğü bazlı lezyonların tespitinde en sık kullanılan yöntemdir (Gomez, 2015; Pitts, 1993). Görsel muayene yönteminin sağlıklı yüzeylerin doğru bir şekilde tanımlanmasında etkili olduğu, ancak çürük lezyonlarının doğru şekilde tespit edilmesinde duyarlılığının düşük olduğu bildirilmektedir (Bader vd., 2002). Mialhe vd. (2003), yaptıkları çalışmada, daimi dişlerde görsel muayene yöntemiyle tespit edilen arayüz çürük lezyonlarının duyarlılık oranları %30 olarak belirtilmiştir (Mialhe vd., 2003). Novaes vd. (2009) ise süt molar dişlerin arayüzeylerinde yer alan kavitasyonlu çürük lezyonlarının saptamasında benzer duyarlılık değerleri elde etmişlerdir (Novaes vd., 2009). Bu çalışmalar yalnızca görsel muayene ile yapılan değerlendirmelerin sınırlılıklarını ortaya koymuştur.

Görsel muayenenin yanında yapılan dokunsal değerlendirmeler genellikle bir dental sond yardımıyla uygulanmakta olup, sond kullanımına ilişkin bazı sınırlılıklar da mevcuttur. Sond ile yapılan fiziksel muayene sırasında uygulanan mekanik kuvvet diş yüzeylerinde remineralize olabilme şansı olan alanlarda yapısal bozulmaya neden olabilmektedir (Gomez, 2015; Nickerson ve Orton, 1997). Ayrıca, sondun diş yüzeyinde hareket ettirilmesi karyojenik bakterilerin bir yüzeyden diğer yüzeye taşınmasına neden olarak, çürük gelişimini hızlandırmakta ve invaziv tedavi gereksinimi arttırmaktadır (Gomez, 2015; Nickerson ve Orton, 1997). Ek olarak Ismail (2004), yaptığı bir çalışmada görsel muayene ve sond muayenesinin özellikle aproksimal bölgelerde ve okluzal fissürlerde yer alan çürük lezyonlarını saptamada yetersiz kaldığını ortaya koymuştur (Ismail, 2004). Bu bakımdan arayüz çürüklerinin erken aşamada ve etkin şekilde tespiti oldukça önemlidir (Gomez, 2015).

Görsel ve dokusal muayeneye ek olarak uygulanan radyografik muayeneler diş çürüklerinin tespitinde tanısal güvenilirliği artırmaktadır (Dayo vd. 2021; Gomez, 2015; Zandoná ve Zero, 2006). Özellikle görsel muayenenin yetersiz kaldığı bölgelerde radyolojik muayene var olan çürük lezyonlarının teşhisini kolaylaştırmaktadır, ancak radyografik muayene ile çürük lezyonlarının tespitinin sağlanabilmesi için diş dokusunda %30-40 oranında mineral kaybının oluşması gerekmektedir. Bununla birlikte, çürüğün aktif ya da inaktif olması gibi ayrımlar da tek başına radyografik muayene yöntemleri ile tespit edilememektedir (White ve Pharoah, 2014).

Panoramik radyografiler ise genel ağız içi değerlendirmede ve ön tanı aşamasında önemli bir tanısal araç olarak kullanılmaktadır. Düşük radyasyon düzeyi, kısa çekim süresi ve hasta tarafından iyi tolere edilebilmesi gibi avantajlara sahiptir (Jeon vd., 2020; Flint vd., 1998). White ve Pharoah (2014), yaptıkları bir çalışmada panoramik radyografilerin avantajlarının yanı sıra, ayrıntı çözünürlüklerinin yetersizliği, premolar bölgelerde sık sık radyografik süperpozisyonların oluşması ve geometrik distorsiyon gibi dezavantajlara sahip olduğunu da ortaya koymuştur (White ve Pharoah, 2014). Bu dezavantajları nedeniyle tanının netleştirilmesi ve detaylı değerlendirme yapılabilmesi için panoramik radyografilere ek periapikal ve bitewing radyografilerin kullanımı yaygın bir klinik uygulama haline gelmiştir (Bozdemir ve Yarbaşı, 2019). Wenzel (2004), çalışmasında görsel muayeneye ek olarak bitewing radyografilerin kullanımının çürük lezyonlarının tespiti sırasında yalnızca klinik muayeneye dayalı değerlendirmelere kıyasla daha güvenilir ve objektif sonuçlar elde edildiğini ortaya koymuştur. Buna karşın, bitewing radyografilerde de çürük lezyonun aktif ya da inaktif olduğu belirlenememekte, çürük lezyonun derinliği olduğundan daha sık görülebilmekte ve mine yüzeyindeki erken evre çürük lezyonu tek başına radyografik görüntüleme ile hassas bir şekilde değerlendirilememektedir (Wenzel, 2004). Belirtilen tüm bu dezavantajlara karşın, radyografik muayene çürük teşhisinde destekleyici bir yöntem olarak değerlendirildiğinde önemli bir yere sahiptir. Özellikle bitewing radyografiler hem okluzal hem de aproksimal yüzeylerde klinisyenlerin doğru tedavi kararı verebilmesinde önemli klinik katkılar sağlamaktadır (Pitts, 1996).

Panoramik, periapikal ve bitewing gibi radyografik araçlar ile dental sond kullanımı gibi klinik uygulamalar, diş çürüklerinin tanısında yaygın biçimde başvurulmuş ve yüksek derecede güvenilirliği kabul gören yöntemler arasında yer alsa da bu tanı araçlarının doğruluğu ve etkinliği, klinisyenin mesleki deneyimi ve zihinsel/fiziksel yorgunluk düzeyine bağlı olarak değişkenlik gösterebilmektedir (Azhari vd., 2023). Bu bağlamda, geleneksel çürük teşhis

yöntemlerine ek olarak günümüzde çürük tanısına yönelik gelişmiş teknolojiler ön plana çıkmakta olup, bu yöntemler sunduğu objektivite sayesinde klinisyene bağlı değişkenlikleri de elimine edebilmektedir (Abogazalah ve Ando 2017; Group vd., 1996; Lara-Capi vd., 2017). Bu yöntemler arasında; dijital radyografi, lazer floresan sistemleri, FOTI ve QLF gibi yöntemler bulunmakta olup, bu yöntemler çürük lezyonlarının derinliğini, yayılımını ve aktivitesini objektif ve hassas biçimde değerlendirme imkânı sunmaktadır (Abogazalah ve Ando 2017; Group vd., 1996; Lara-Capi vd., 2017).

Son yıllarda diş hekimliğinde tanı ve tedavi planlamasının oluşturulmasında teknolojik gelişmeler klinisyene rehber olmaktadır. Özellikle mühendislik bilimleri ve yazılım sektörü ile diş hekimliği alanları birlikte çalışmakta, bunun sonucu olarak da insana ve iş gücüne bağımlılık zamanla azalmaktadır. Bu kapsamda, birçok alanda olduğu gibi diş hekimliğinde de popülerlik kazanmaya başlayan fenomenlerden biri de yapay zekâ ve yapay zekâ ile ilişkili diğer yöntemlerdir (Ahmed vd., 2021; Bonny vd., 2023; Özkesici ve Yılmaz, 2021; Schwendicke vd., 2020).

Yapay zekâ bir bilgisayarın, başka bir deyişle de bilgisayar destekli bir makinenin genellikle insan davranışlarını taklit etme, probleme çözüm üretme, anlama, bir olgu oluşturma, genelleme ve daha önceki deneyimlerden öğrenme gibi mantıksal süreçlerle ilgili görevleri gerçekleştirme yeteneği olarak tanımlanmaktadır (Ahmed vd., 2021; Bonny vd., 2023; Nabiye, 2012; Özkesici ve Yılmaz, 2021; Schwendicke vd., 2020). Özkesici ve Yılmaz (2021), yaptıkları çalışmada yapay zekâ uygulamalarının dental anomali tespitinde, çürük teşhisinde, çeşitli patolojilerin saptanmasında, dental plak tespitinde, robotik cerrahi ile dental implant uygulamalarında ve ortodontik tedavi uygulamalarının planlamasında kullanılabildiğini ortaya koymuştur (Özkesici ve Yılmaz, 2021).

Yapay zekâ destekli tıbbi görüntüleme yöntemlerinin daha hızlı, daha güvenilir ve daha verimli sonuçlar ortaya koyabileceği belirtilmektedir. Bu sayede, yapay zekânın tıbbi radyolojide kullanımının erken müdahale fırsatı ve kişiselleştirilmiş tedavi yaklaşımları sunarak sağlık hizmetlerine önemli katkılar sağlayacağını belirtilmiştir (Dave ve Patel, 2023). Yapay zekânın diş hekimliği alanında en yoğun kullanım bulunduğu alan ise dental radyografik görüntülemelerdir. Mol ve Van Der Stelt (1992), yaptıkları çalışmada yapay zekâyı ilk kez dental radyoloji alanında kullanarak periapikal kemik lezyonlarının dental radyografiler üzerindeki teşhisini sağlamıştır (Mol ve Van Der Stelt, 1992). Saghiri vd. (2012) ise yaptıkları

çalışmada yapay zekâ bazlı teşhis modelleri kullanarak kök kırıklarının teşhisi üzerine, benzer şekilde Johari vd. (2017) ise yapay zekâ teşhis modelleri kullanarak kök kanal girişlerinin tespit edilmesi üzerine öncül çalışmalar üretmiştir (Johari vd., 2017; Saghiri vd., 2012). Bu bağlamda, geçmişten günümüze değin yapay zekâ ve ilişkili yöntemlerin diş hekimliğindeki kullanımlarına yönelik çok sayıda çalışma güncel literatürün kapsamını oluşturmaktadır (Ahmed vd., 2021; Bonny vd., 2023; Özkesici ve Yılmaz, 2021; Schwendicke vd., 2020).

Asci vd. (2024), yaptıkları bir çalışmada 4 ila 14 yaş arasındaki çocuklarda süt, karışık ve daimi dişlenme dönemi olmak üzere her üç dişlenme döneminde de yapay zekâ modellerinin panoramik radyografiler üzerinde diş çürüğünün tespitinde yüksek duyarlılık ve doğruluk oranlarına sahip olarak diş çürüğü teşhisine önemli bir katkı sağlayacağını ortaya koymuştur (Asci vd., 2024). Diğer bir çalışmada Zhou vd. (2022), çocuklarda panoramik radyografiler üzerinde diş çürüğü teşhisinde geleneksel evrişimli sinir ağlarını iyileştirerek evrişimli sinir ağı tabanlı derin öğrenme yöntemlerinin hastanelerde diş çürüğü teşhisinde diş hekimlerine önemli bir destek sunma potansiyeli gösterebileceği sonucuna varmıştır (Zhou vd., 2022). Azhari vd. (2023) ise, çalışmalarında bitewing radyografiler üzerinde hem daimi dişlerde hem de süt dişlerinde çürük teşhisi yapan ve bunları karşılaştıran bir araştırma tasarlayarak, derin öğrenme modellerinin daimi ve süt dişlerindeki ileri düzey çürük lezyonlarını etkin bir şekilde tespit edebildiğini, ancak başlangıç ve orta düzey çürük lezyonları arasında meydana gelen yanlış sınıflandırmaların bulgulandığını ortaya koymuştur (Azhari vd., 2023). Belirtilen bu çalışmalar yapay zekâ ve yapay zekâ bazlı yöntemlerin diş hekimliğinde özellikle teşhis süreçlerinde faydalı bir araç olarak kullanılabileceğini, ancak henüz iyileştirilmesi gereken alanlar olduğunu ve pedodonti alanında eksiklikler bulunduğunu göstermektedir. Diğer bir çalışmada ise Lian vd. (2021), üç uzman diş hekimi ile nnU-Net adı verilen evrişimli sinir ağının çürük lezyonlarını tespit etme kapasitelerini 1160 dental panoramik radyografi üzerinde karşılaştırmış ve uzman diş hekimleri ile derin öğrenme yönteminin performansının benzer düzeyde olduğunu sonucuna varmışlardır (Lian vd., 2021).

Bu ön bilgilerden hareketle, bu tez çalışması diş çürüğünün erken ve doğru teşhisini desteklemek amacıyla yapay zekâ tabanlı görüntü analizlerinin klinik karar sürecine entegre edilmesini hedeflemektedir. Özellikle arayüzlerde konumlanan diş çürüklerinin konvansiyonel yöntemlerle tanı edilmesinde karşılaşılan klinik ve radyolojik zorluklar ve limitasyonlar ve bu bölgelere ait lezyonların sıklıkla geç evrede fark edilmesi, alternatif teknolojik çözümlere olan ihtiyacı da artırmaktadır. Bitewing radyografiler, arayüzde konumlanan çürük lezyonlarının değerlendirilmesinde en etkili radyografik araçlardan biri

olsa da bu görüntülerin yorumlanması klinisyenin deneyimine ve dikkat düzeyine bağlı olarak değişkenlik gösterebilmektedir. Bu bağlamda, görüntü analizinde yüksek doğruluk ve hız sunan yapay zekâ mimarileri hem süt hem de daimi dişlere ait bitewing görüntülerinde çürük tespiti açısından umut vadetmektedir. Ancak, bu konuda diş hekimliği literatüründe tespit edilebilir çok az sayıda çalışma ve sonuçlarının olması, bu alanda daha fazla çalışma yapılmasını gerekli kılmaktadır.

Literatürde yapay zekâ sistemlerinin dental radyolojideki kullanımı hızla artmakla birlikte, mevcut çalışmalar çoğunlukla daimi dişlere odaklanmakta, erken dönemde süt dişlerinde ortaya çıkan çürüklerin otomatik tespitine dair araştırmalar ise sınırlı kalmaktadır. Ancak süt dişlerinde çürüğün hızlı progresyon göstermesi ve çocuk hastalarda iş birliğinin kısıtlı olması, bu yaş grubunda doğru ve zamanında teşhisi daha da kritik hale getirmektedir. Bu çalışmada hem süt hem de daimi dişlere ait bitewing radyografiler üzerinden yapay zekâ temelli çürük tanı modelinin performansının karşılaştırmalı olarak değerlendirilmesi amaçlanmış, böylece iki farklı dentisyon dönemine özgü tanısal zorlukların yapay zekâ sistemleri tarafından nasıl ele alınabileceğinin ortaya konulması hedeflenmiştir. Elde edilen bulguların, yapay zekâ destekli tanı araçlarının klinik kullanımı konusunda çocuk diş hekimliği alanına önemli katkılar sunacağı da öngörülen çıktılar arasındadır.

Yapay zekâ destekli görüntü işleme teknikleri, diş çürüklerinin otomatik olarak tespiti amacıyla panoramik, bitewing ve periapikal radyografiler üzerinde başarıyla uygulanmaktadır (Kamburoğlu vd., 2012; Lee vd., 2018; Lian vd., 2021; Moran vd., 2021). Yapay zekâ bazlı çalışmalarda kullanılan radyografi tipinde bir standart bulunmamakla birlikte, arayüzde konumlanan çürük lezyonlarının teşhisinde daha etkin bir yöntem olması bakımından, mevcut tez çalışmasına süt ve daimi dişler için alınmış bitewing radyografilerin dahil edilmesi planlanmıştır.

Diş hekimliği literatürü incelendiğinde, diş çürüğü tespitinde ve teşhisinde kullanılabilecek çok çeşitli özelliklerde yapay zekâ mimarileri bulunmaktadır. Lee vd. (2018), gerçekleştirdikleri çalışmalarında bitewing radyografilerin değerlendirilmesi için U-Net kullanan bir evrişimli sinir ağı modeli geliştirmiş ve özellikle başlangıç ila orta düzeydeki çürüklerin tespitinde anlamlı performans farklılıkları tespit etmişlerdir (Lee vd., 2018). Yapılan diğer kapsamlı bir çalışmada Moran vd. (2021), bitewing radyografilerde arayüz çürük lezyonlarını tanımlamak ve bunları lezyon şiddetlerine göre sınıflandırabilmek için

görüntü işleme tekniklerini ve evrişimli sinir ağını birleştiren yeni bir yöntem önermiştir. Elde edilen veriler önerilen yöntemin diş hekimlerine bitewing görüntülerinin değerlendirilmesinde, lezyon şiddetinin ve uygun tedavilerin tanımlanmasına yardımcı olabilmek için kullanılabileceğini düşündürmektedir (Moran vd., 2021). Bayrakdar vd. (2022) ise, yaptıkları çalışmada derin evrişimli sinir ağlarının (VGG-16 ve U-Net) diş çürüklerini etkin bir şekilde teşhis ettiklerini bildirmiştir (Bayrakdar vd., 2022). Bu tez çalışmasında ise Yolo olarak adlandırılan yapay zekâ bazlı aileye ait algoritmaların beşinci versiyonu olan Yolov5x'in çalışma prosedürlerine dahil edilmesi tercih edilmiştir. Yolov5x, gerçek zamanlı nesne tanıma görevlerinde yüksek doğruluk ve hız performansı sunan, optimize edilmiş bir derin öğrenme modelidir (Redmon vd., 2016). Modelin küçük boyutlarda bile etkili sonuçlar sunabilmesi, farklı çözünürlüklerdeki dental radyografilerde kullanılabilmeye son derece elverişli olması ve eğitim sürecinde parametrik esneklikler sağlaması, mevcut çalışmanın amacıyla uyumlu hale gelmesini olanaklı kılmıştır. Ayrıca Yolov5x yapay zekâ tabanlı nesne tespit mimarisinin klinik uygulanabilirliğini artıran hızlı karar verme kabiliyeti ve performansı, onu çocuk hastalarda hızlı ve güvenilir teşhis ihtiyacını karşılamada güçlü bir aday haline getirmiştir (Redmon vd., 2016). Bununla birlikte, son yıllarda diş çürüğü teşhisini konu alan birçok bilimsel çalışmada Yolo tabanlı algoritmaların başarıyla kullanılmış olması da bu çalışmada söz konusu yapay zekâ modelinin tercih edilmesinde etkili bir etmen olmuştur (Bayraktar ve Ayan, 2022; Pérez de Frutos vd., 2024).

Yapay zekâ bazlı teşhis çalışmalarında çalışma prosedürlerine dahil edilen örneklemin büyüklüğü oldukça önemlidir. Belirtildiği şekilde, literatürde daimi dişlere ait bitewing radyografiler üzerinde yapılan çeşitli yapay zekâ temelli çalışmalarda farklı derin öğrenme mimarileri ve veri seti büyüklükleri/genişliği kullanılmıştır. Moran vd. (2021), ResNet mimarisi ile gerçekleştirdikleri çürük tespiti analizinde 112 adet daimi diş bitewing görüntüsü kullanmıştır (Moran vd., 2021). Lee vd. (2021), 304 adet daimi diş bitewing radyografi ile çalışırken; Bayrakdar vd. (2022) 621 bitewing radyograf kullanarak aproksimal çürüklerin tespiti üzerine odaklanmıştır. (Bayrakdar vd., 2022; Lee vd., 2021). Chen vd. (2022), konvolüsyonel sinir ağı tabanlı bir yöntem kullanarak toplam 978 bitewing radyografiyi incelemiştir (Chen vd., 2022). Panyarak vd. (2023), Yolov3 modeliyle 994 bitewing görüntüsü üzerinde çalışmış; Bayraktar ve Ayan (2022) ise yine Yolov3 algoritmasıyla 1000 adet daimi diş bitewing radyografi içeren bir veri seti kullanmışlardır (Bayraktar ve Ayan, 2022; Panyarak, Suttapak, vd., 2023). Çalışmamızda ise daha geniş çaplı veri seti dahil edilmesi bakımından 1000 adet daimi diş bitewing radyografisi kullanılmış olup, bu sayı literatürde yer alan benzer çalışmalara kıyasla oldukça yüksek bir örneklem büyüklüğünü temsil etmektedir.

Süt dişlerine yönelik çalışmaların sayısı daimi dişlere oranla çok daha sınırlı olmakla birlikte, çocuk hastaların radyografik görüntülerinin analizine odaklanan araştırmalar özellikle son yıllarda artış göstermektedir. Örneğin, Gonzalez vd. (2024), 100 adet süt dişi bitewing radyografisi kullanarak gerçekleştirdikleri çalışmalarında, derin öğrenme algoritmalarını kullanarak çürük teşhisi gerçekleştirmiş ve modelin erken lezyonları saptamadaki potansiyelini ele almıştır (Gonzalez vd., 2024). Öte yandan Lee vd. (2021), 304 adet bitewing görüntüsünden oluşan bir veri setiyle geliştirdikleri U-Net tabanlı konvolüsyonel sinir ağı modelini kullanarak çürük tespiti çalışması gerçekleştirmiştir (Lee vd., 2021). Bu tez çalışmasına da 1000 adet süt dişi bitewing radyografisi dahil edilmiştir. Bu bağlamda özellikle süt dişleri için kullanılan örneklem büyüklüğünün, literatürdeki çalışmalara kıyasla oldukça yüksek düzeyde olduğu söylenebilir. Bu durum modelin genelleme kapasitesini artırmak açısından önemli bir avantaj sağlamaktadır. Yapay zekâ destekli çürük teşhisinin doğruluğu, birçok etkene bağlı olarak önemli ölçüde değişkenlik gösterebilmektedir. Ammar ve Kühnisch (2024), yapmış oldukları sistematik bir derlemede bitewing radyografilerde çürüklerin tespiti ve sınıflandırılmasına yönelik yapay zekâ modellerinin tanısallık doğruluğunu değerlendirmiştir. 2010 yılı sonrası yayımlanmış çalışmalar 5 farklı veri tabanında taranmış ve dahil edilme kriterlerini karşılayan 14 makale incelenmiştir. Kullanılan veri setlerinin büyüklüğü 112 ile 3686 arasında değişmekte olup, yalnızca iki çalışma dışında tamamı görüntüler için uygunluk kriterlerini ayrıntılı şekilde raporlamıştır (Ammar ve Kühnisch, 2024). Bu açıdan bakıldığında, tez çalışmamızda kullanılan radyografi sayısı önceki literatür ile tutarlılık göstermektedir. Ayrıca radyografiler için tanımlanan dahil edilme ve dışlanma kriterleri açıkça belirtilmiştir.

Ammar ve Kühnisch (2024), raporladıkları sistematik derlemeye çok sayıda farklı yapay sinir ağı mimarisi dahil edilmiş ve bunlar arasında en sık tercih edilen U-Net mimarisi olmuştur. Dahil edilen çalışmaların %79'u daimi dişlere ait bitewing radyografi veri seti kullandığını belirtirken, kalan çalışmalarda diş tipine dair bilgi sunulmamıştır. Referans veri setlerinin anotasyonu genellikle ortalama iki diş hekimi tarafından yapılmış, iki çalışmada ise yalnızca bir klinisyenin anotasyon sürecine katıldığı bildirilmiştir. Bu klinisyenlerin mesleki deneyimi 3 ila 25 yıl arasında değişmekte olup, dahil edilen çalışmaların yaklaşık yarısında çürük lezyonları yalnızca “var” ya da “yok” şeklinde kategorik olarak ikili sınıflandırma ile değerlendirilmiştir. İncelenen çalışmaların %86'sı en az %80 doğruluk oranına sahip modeller rapor etmiştir; ancak büyük bir kısmında yanlışlık riski belirsiz ya da yüksek olarak belirtilmiştir. Mevcut tez çalışmamızda ise Yolov5 mimarisi kullanılmış olup, mevcut literatürden farklı olarak, yalnızca daimi değil hem süt hem de daimi dişlere ait bitewing radyografiler değerlendirmeye alınmış ve anotasyonlar, ikili sınıflandırma yöntemi yerine,

segmentasyon yöntemi ile çürük lezyonlarının anatomik sınırları detaylı şekilde belirlenerek tek bir araştırmacı tarafından yapılmıştır. Bu yönüyle çalışmamız, anotasyon kalitesi ve çeşitliliği açısından mevcut literatüre göre daha özgün ve güçlü bir metodoloji sunmaktadır.

Sonuç olarak, elde edilen doğruluk oranları, literatürde bildirilen sonuçlarla genel olarak uyumlu olmakla birlikte, çalışmamızın yapısal farklılıkları tanılayıcı başarının artırılmasında etkili olmuştur.

Bu tez çalışması kapsamında, Yolov5x segmentasyon aracı kullanılarak süt dişlerini içeren 1000 adet bitewing radyografi ile daimi dişleri içeren 1000 adet bitewing radyografide arayüz çürüklerinin teşhisine ait performans değerlendirmesi hedeflenmiş ve model performansı detaylı metriklerle ele alınmıştır. Her iki grupta toplam 5704 işaretleme yapılmıştır. Çalışmamızda daha önceden de belirtildiği üzere metodolojik olarak performans değerlendirme aşamasında bir dizi farklı metrik ve konfüzyon matrisi kullanılmıştır. Modelin duyarlılığı, gerçek pozitif vakaları ne ölçüde doğru şekilde tanıyabildiğini ifade ederken; kesinlik ise pozitif olarak tahmin edilen vakaların ne kadarının gerçekten doğru olduğunu ortaya koymaktadır. Genellikle bu iki ölçüt arasında bir denge söz konusu olup, bir metriğin artışı, diğerinin azalmasına neden olabilmektedir. Bu nedenle, model performansı değerlendirilirken bu dengenin dikkate alınması büyük önem taşır (Buckland ve Gey, 1994; Yılmaz, 2023). Öte yandan, çürük tespitine yönelik bir yapay zekâ mimarisinin yüksek duyarlılığa sahip olması, mevcut lezyonların kaçırılmadan doğru bir şekilde teşhis edilmesini sağlarken, yüksek kesinlik değeri, belirtildiği üzere teşhis edilen çürük lezyonlarının büyük ölçüde gerçek çürükleri temsil ettiğini gösterir. Bu da hem yanlış negatif (gerçek çürüklerin gözden kaçırılması) hem de yanlış pozitif (sağlıklı dişlerin yanlışlıkla çürük olarak tanımlanması) sonuçların en aza indirildiği anlamına gelmektedir (Ferreira Zandoná vd., 1998; Yılmaz, 2023). Ayrıca bu tür modellerin genel başarımını daha dengeli ve nesnel biçimde ölçmek amacıyla sıklıkla kullanılan F1 skoru ise, duyarlılık ve kesinliğin harmonik ortalamasını temsil etmektedir. Özellikle medikal ve dental tabanlı çalışmalarda sıklıkla karşılaşılan sınıf dengesizliği durumlarında, F1 skoru modelin hem doğru pozitifleri yakalama hem de yanlış pozitifleri azaltma yeteneğini tek bir ölçüm altında toplamakta olup, araştırmacılara bütünsel bir değerlendirme imkanı sunar. Bu özelliği sayesinde F1 skoru, sağlık alanında geliştirilen yapay zekâ modellerinin performans değerlendirmesinde güvenilir ve kapsamlı bir ölçüt olarak öne çıkar (DeVries vd., 2021). Bu doğrultuda, mevcut tez çalışmamızın ana bulguları ise, süt dişlerinde 0,80 kesinlik, 0,78 duyarlılık ve 0,79 F1 skoru şeklinde iken, daimi dişlerde ise bu oranlar sırasıyla 0.78, 0.75 ve 0.76 şeklinde bulgulanmıştır.

Bu sonuçlar arada küçük bir fark olsa da, bu tez çalışmasında ele alınan yapay zekâ bazlı nesne tespit mimarisinin süt dişleri ve daimi dişlere ait bitewing radyografilerdeki arayüz çürüklerini benzer bir performans ile teşhis ettiğine işaret etmektedir.

Bu tez çalışmasının sonuçları ile diş hekimliği literatüründe yer alan önceki çalışmaların sonuçları arasında bazı alanlarda benzerlik saptanırken, bazı alanlarda gerek farklı yapay zekâ modelleri kullanılması gibi metodolojik farklılıklardan kaynaklı olarak, gerekse de çalışmaya dahil edilen örneklem özellikleri ve karakteristikleri bakımından farklılıklar bulunmaktadır. Ying vd. (2024) gerçekleştirdiği çalışmada, diş çürüğü teşhisine yönelik Yolov5, Trans-UNet, DETR ve U-Net gibi farklı derin öğrenme modellerinin performansları karşılaştırılmıştır. Elde edilen bulgulara göre, Yolov5 modeli %87 F1 skoru, %82 duyarlılık ve %94 özgüllük ile diğer algoritmalar arasında en yüksek tanısallık başarıyı göstermiştir. Trans-UNet modeli ise %86 F1 skoru, %81 duyarlılık ve %92 özgüllük ile benzer ancak daha düşük bir performans sergilemiştir. Ayrıca, tanı performansını duyarlılık ve özgüllüğün kombinasyonu şeklinde ifade eden Youden indeksi açısından da Yolov5 en yüksek değere (%76) ulaşarak çürük tespiti açısından en başarılı model olarak öne çıkmıştır (Ying vd., 2024).

Benzer şekilde, Frutos vd. (2024) tarafından gerçekleştirilen bir çalışmada, AI-Dentify adlı derin öğrenme sistemi, bitewing radyografilerde aproksimal çürüklerin tespiti amacıyla geliştirilmiştir. Bu çalışmada, altı deneyimli diş hekimi tarafından işaretlenen toplam 13.887 adet bitewing görüntüsü kullanılmıştır. Görseller RetinaNet, Yolov5 ve EfficientDet modellerinin eğitilmesinde kullanılmış, elde edilen sonuçlara göre Yolov5, %54,8 F1 skoru ile en yüksek tanısallık doğruluğa ulaşmıştır. RetinaNet ve EfficientDet modelleri ise göreceli olarak daha düşük performans sergilemiştir. Bu bulgulardan hareketle, Yolov5 algoritmasının büyük ölçekli, uzman etiketli veri setlerinde bile yüksek doğrulukla çalışabildiği ve dental görüntü analizinde güvenilir bir tercih olduğu belirtilmiştir (Pérez de Frutos vd., 2024). Panyarak ve Wantanajittikul (2023) ise, 2575 adet bitewing görüntüsüyle gerçekleştirdikleri karşılaştırmalı çalışmada, Yolov3 ve Yolov7 modellerini değerlendirmiş ve F1 skorlarını sırasıyla 0.375 ve 0.555 olarak bildirmiştir (Panyarak, Wantanajittikul, vd., 2023). Bu tez çalışmasında da Yolov5x modeli daimi dişler için %76, süt dişleri için %79 düzeyinde F1 skoru bulgulanmış olup; önceki çalışmalar ile olan farklılıkların metodolojik tasarım özelliklerine, kullanılan radyografik görüntülerin özelliklerine ve eğitim ve validasyon aşamalarında kullanılan radyografilerin karakterine bağlı olabileceği düşünülmektedir. Her ne kadar çalışmamıza tespit edilebilir bir radyografik artefaktı olan görüntü dahil edilmese de yetişkin hastalara kıyasla özellikle çocuk hastalardan radyografi alınması sırasında

yaşanabilecek kooperasyon kaybı bile sonuçların daha farklı olmasına neden olabilmektedir. Genel bir değerlendirme yapıldığında, bu tez çalışmasında birçok güncel çalışmanın üzerinde bir performans düzeyi saptanmış olup, Yolov5 mimarisinin çürük tespitinde güçlü bir alternatif olabileceği düşünülmektedir. Ayrıca, bu başarı oranı modelin hem duyarlılık hem özgüllük açısından dengeli bir performans sergilediğini ve eğitim veri setinin yapay zekâ sistemine önemli ölçüde katkı sağladığını göstermektedir.

Literatürde yapılmış önceki çalışmalar incelendiğinde, Yolo ailesine ait alt algoritmaların da başarılarının birbirleri ile kıyaslandığı ve bu bağlamda sonuçların rapor edildiği izlenmektedir. Ayhan vd. (2025), yürüttüğü bir çalışmada toplam 2150 adet daimi dişe ait bitewing radyografi toplanarak analiz edilmiştir (Ayhan vd., 2025). Araştırmanın temel amacı, yaygın olarak kullanılan 11 farklı Yolo modeli (Yolov5n, Yolov5s, Yolov5m, Yolov5l, Yolov7-t, Yolov9-t, Yolov9-s, Yolov9-m, Yolov9-c, Yolov9-f) ile bitewing radyografilerden mine ve dentin çürüklerini otomatik olarak teşhis edebilme yeteneklerini karşılaştırmalı olarak değerlendirmektir. Geliştirilen Yolov9-c modeli, en yüksek duyarlılık (recall) ve F1 skoru değerlerine ulaşmış; bu değerler sırasıyla 0.727 ve 0.687 olarak raporlanmıştır. Mevcut çalışmamızda ise Yolov5x modeli ile bu değerlere kıyasla daha yüksek duyarlılık ve F1 skoru elde edilmiştir. Bu farkın, Yolov9-c modelinin yeni geliştirilmiş bir mimari olması nedeniyle optimizasyon sürecinin henüz tamamlanmamış olmasına bağlı olabileceği düşünülmektedir. Ayrıca, farklı veri setlerinin kullanılması, anotasyon kalitesi ve model eğitimi sırasında kullanılan parametreler de performans farklarına katkı sağlayan faktörler arasında değerlendirilebilir. Benzer şekilde yine Yolo ailesinin diğer üyelerini dahil eden başka bir çalışmada, Yavsan vd. (2025), 415 periapikal radyografiden oluşan bir veri seti kullanarak arayüz çürüklerinin tespiti amacıyla, en güncel sürümler dahil olmak üzere toplam 13 farklı Yolo algoritmasını (Yolov4, Yolov5s, Yolov5m, Yolov5l, Yolov5x, Yolov6s, Yolov7x, Yolov8n, Yolov8s, Yolov8m ve Yolov8x) aynı koşullar altında eğitmiş ve bu algoritmaların performanslarını doğruluk temelinde karşılaştırmıştır (Yavsan vd., 2025). Yapılan değerlendirmeler sonucunda, en yüksek doğruluk oranı %90,8 ile Yolov5s algoritmasında elde edilmiştir. Bu model, ayrıca %90,24 F1 skoru ile de yüksek tanı başarısı sunmuştur. Elde edilen bulgular, Yolov5s algoritmasının periapikal radyografilerde arayüz çürüklerinin teşhisi açısından etkili, güvenilir ve klinik uygulamalara entegre edilebilecek düzeyde başarılı bir yapay zekâ çözümü olduğunu göstermektedir. Buna karşılık, bizim çalışmamızda Yolov5x sürümü tercih edilmiş olup, Yavsan vd. (2025) kullandığı periapikal radyografilerden farklı olarak, çürük tespitinde altın standart olarak kabul edilen bitewing radyografiler kullanılmıştır. Bu fark, özellikle aproksimal çürüklerin tanısal belirginliği açısından önem arz etmektedir.

Bununla birlikte, çalışmamızda kullanılan veri seti örneklem büyüklüğü ve anotasyon sayısı açısından daha geniş kapsamlıdır ve bu durum modelin genellenebilirliği ve tanı başarısına olumlu katkı sağlamaktadır. Yolov5x mimarisinin yüksek çözünürlüklü detayları daha etkin işleyebilme kapasitesi sayesinde, özellikle klinik uygulamalarda tutarlı sonuçlar üretebilme potansiyeli daha da artmıştır. Ayrıca, Kunt vd. (2023) tarafından yürütülen bir çalışmada, daimi dişleri içeren toplam 3989 bitewing radyografiden oluşan kapsamlı bir veri seti oluşturulmuş ve bu görüntüler, çeşitli nesne tespiti yapabilen evrimsel sinir ağı mimarilerinin eğitimi amacıyla kullanılmıştır (Kunt vd., 2023). Değerlendirilen modeller arasında Yolov5, Faster R-CNN, RetinaNet ve EfficientDet gibi güncel ve etkin mimariler yer almıştır. Modellerin başarısı, F1 skoru gibi çeşitli performans metrikleriyle değerlendirilmiştir. Bu çalışmada test edilen 12 farklı mimarinin F1 skorları 0.72 ile 0.76 aralığında raporlanmıştır. Bu sonuçların çalışmamız ile yaklaşık benzer nitelikte olduğu görülmektedir.

Süt dişlerine yönelik gerçekleştirilen yapay zekâ destekli çürük tespiti çalışmaları, sınırlı sayıda olmakla birlikte giderek artan bir ilgi görmektedir. Gonzalez vd. (2024), 100 adet süt dişi bitewing radyografisi kullanarak kodsuz (no-code) bir yapay zekâ platformu aracılığıyla çürük tespiti gerçekleştirmiş ve bu modelin F1 skorunu 0,95 olarak bildirmiştir (Gonzalez vd., 2024). Bu yüksek başarı, veri setinin kalitesi ve sınırlı örneklemdeki kontrollü koşullarla ilişkilendirilebilir. Bu çalışma, süt dişlerinde aproksimal çürük tespiti için derin öğrenme uygulamalarının uygulanabilirliğini göstermektedir. Ancak model mimarisi, etiketleme yöntemi, örneklem büyüklüğü ve veri çeşitliliği gibi faktörlerin sonuçlar üzerinde belirleyici etkileri olduğu atlanmamalıdır. Bu bağlamda, çalışmamızda Yolov5 mimarisi kullanılarak 1000 adet süt dişine ait bitewing radyografi üzerinde gerçekleştirilen analiz sonucunda elde edilen 0,79 F1 skoru, mevcut literatürdeki çalışmalarla karşılaştırıldığında hem örneklem büyüklüğü hem de model başarısı açısından dikkat çekici bir düzeydedir. Bu sonuç, Yolov5'in süt dişi çürüklerinin tespitinde de güçlü bir tanısal performansa sahip olduğunu ortaya koymaktadır.

Çalışmamız özelinde, daimi diş radyografileri ile aralarında minör bir farklılık olsa da, süt dişlerinde modelin daha iyi performans göstermesinin çeşitli fizyolojik ve radyografik nedenlerinin olabileceği düşünülmektedir. Öncelikle, süt dişlerinin mine ve dentin tabakaları daha incedir ve bu durum, çürüğün dentine ulaşmasıyla birlikte radyografide daha yüksek kontrastlı lezyonlar oluşturmaya neden olmaktadır (Wenzel, 2004). Bu kontrast artışı, derin öğrenme tabanlı modellerin görsel örüntüleri daha rahat ayırt edebilmesine olanak sağlamaktadır. Ayrıca, çocuklarda çürük progresyonu genellikle daha hızlı olup, bu durum

lezyonların daha net sınırlı ve geniş alanlara yayılmış şekilde izlenmesine de neden olur (Lippert vd., 2004). Bu morfolojik belirginlik, Yolov5 gibi hızlı nesne tanıma ve segmentasyon algoritmaları için avantaj sağlamaktadır. Ayrıca, çocuk hastalara ait görüntülerde diş yapılarının daha az aşınmış olmasının, lezyon-kontrast oranını artırarak yapay zekâ modelinin karar verme sürecini kolaylaştırmış olabileceği de olası nedenler arasındadır. Bununla birlikte, anotasyon sürecinde çocuk diş hekimliği alanında çalışan bir araştırmacının görev alması, etiketleme ve anotasyon kalitesini artırarak model eğitiminin doğruluğuna katkı sağlamış olabilir. Öte yandan, modelin daimi dişlerde az seviyede de olsa nispeten daha düşük performans göstermesi, bu dişlerdeki çürüklerin başlangıç aşamalarında radyografide nispeten belirgin olmayan yapıda olmasıyla ilişkilendirilebilir. Ayrıca yaşça daha büyük hastalardaki diş taşı birikimi veya overlapping gibi görüntü artefaktları daha sık izlenebilmekte olup, bu durum modelin segmentasyon başarısını olumsuz etkileyebilir. Bununla birlikte, daimi dişlerde proksimal alanların daha sıkışık olması nedeniyle çürük konturlarının ayırt edilmesi, özellikle sınırlı anotasyonlarla eğitilmiş bir model için zorluk yaratmaktadır. Belirtilen bu durumların, Yolov5x modelinin süt ve daimi dişlerdeki arayüz çürüklerini teşhis etme performansındaki minör farklılıklara neden olan olası faktörler olduğu düşünülmektedir.

Her yapay zekâ çalışmasında olduğu gibi çalışmamızın bazı sınırlılıkları da dikkate alınmalıdır. İlk olarak, modelin eğitildiği veri seti tek merkezli olup, bu durum modelin genellenebilirliğini belirli ölçüde sınırlandırabilir. Bununla ilintili olarak, bu durum her ne kadar metodolojik standardizasyonlar için anlamlı olsa da farklı klinik ortamlar ve görüntüleme cihazlarıyla oluşabilecek çeşitlilik sonuçlara yansıtamayabilir. Öte yandan, model yalnızca çürük lezyonuna odaklanmış olup; pulpal lezyonlar, fissür çürükleri veya restorasyonlar gibi diğer klinik parametreler değerlendirme dışı bırakılmıştır. Gelecekteki çalışmaların çok sınıflı modeller kullanarak teşhis tiplerini detaylandırması ve multimodal veri (örneğin klinik muayene, hasta geçmişi) ile desteklenmesi önerilmektedir.

Sonuç olarak, mevcut çalışmamız Yolov5x mimarisinin hem süt hem daimi dişlerde yüksek performans gösterdiğini ve literatürdeki benzer çalışmalarla karşılaştırılabilir sonuçlar elde ettiğini ortaya koymaktadır. Bu bulgular, yapay zekâ destekli radyografik tanı sistemlerinin klinik pratiğe entegrasyonu açısından önemli bir adım niteliğindedir. Özellikle pedodontik vakalarda yapay zekâ tabanlı sistemlerin, klinik tanı kararlarını destekleyecek düzeyde güvenilir çıktılar sunabileceği ve ağız sağlığı taramalarında ikinci görüş aracı olarak kullanılabileceği düşünülmektedir. Ancak genel sonuçların geçerliliği için çok merkezli, prospektif ve dış doğrulamalı çalışmalara ihtiyaç devam etmektedir. Bu bağlamda, gelecekteki

alıřmalar, yařa gre dengelenmiř ve ok merkezli veri setleriyle desteklenmeli; st ve daimi diřlerin ayrı modellerde ya da diř tipi farkını dođrudan ieren ok giriřli mimarilerle eđitilmesi arařtırılmalıdır. Ayrıca, kk lezyonları daha isabetli tespit edebilecek segmentasyon mimarileri ile karřılařtırmalı analizler planlanması tanısal bařarıyı daha da artırma potansiyeline sahip giriřimler arasındadır.



5. SONUÇ ve ÖNERİLER

Bu tez çalışmasında, araştırmanın tüm sınırlılıkları dahilinde, Yolov5x mimarisi kullanılarak geliştirilen derin öğrenme tabanlı bir modelin, süt ve daimi dişlere ait bitewing radyografiler üzerinde arayüz çürüklerini tespit etmedeki performansı değerlendirilmiştir. Bu doğrultuda aşağıda yer alan çıkarımlar yapılabilir.

- 1- Geliştirilen model, özellikle süt dişlerine ait görüntülerde az farkla da olsa daha yüksek F1 skoru ve doğruluk oranları ile başarılı sonuçlar sergilemiş; segmentasyon tabanlı yaklaşımın çürük teşhisinde etkili bir yöntem olduğunu ortaya koymuştur. Süt ve daimi dişler arasında gözlenen performans farklılıkları, anatomik yapı, mineralizasyon düzeyi ve radyografik kontrast gibi faktörlerle açıklanabilir.
- 2- Modelin elde ettiği metrikler, özellikle erken dönem çürük teşhisinde yardımcı bir klinik karar destek sistemi olarak kullanılabilme potansiyelini ortaya koymaktadır. Ancak, mevcut model yalnızca radyografik görüntülere dayalı olarak eğitildiğinden, gerçek klinik senaryolarda kullanılmadan önce multimodal veri (klinik muayene, klinik anamnez bulguları vb.) entegrasyonu ile desteklenmesi önerilmektedir. Ayrıca, yanlış pozitif/negatif oranlarının klinik karar sürecini olumsuz etkileyebileceği unutulmamalı; bu nedenle modelin eşik değer seçimi dikkatle yapılmalıdır.
- 3- Gelecekte, daha büyük ve çeşitlendirilmiş çok merkezli veri setleriyle eğitilmiş, farklı yaş gruplarını da kapsayan modellerin geliştirilmesi, bu tür yapay zekâ sistemlerinin genellenebilirliğini ve güvenilirliğini artıracaktır. Ayrıca, gerçek zamanlı klinik karar destek uygulamalarının geliştirilmesinin, bu teknolojilerin rutin diş hekimliği pratiğine entegre edilmesini mümkün kılabileceği de düşünülmektedir.

KAYNAKLAR

- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., Devin, M., Ghemawat, S., Irving, G., & Isard, M. (2016). {TensorFlow}: a system for {Large-Scale} machine learning. 12th USENIX symposium on operating systems design and implementation (OSDI 16).
- Abogazalah, N. and Ando, M. (2017). Alternative methods to visual and radiographic examinations for approximal caries detection. *Journal of oral science*, 59(3), 315-322.
- Acs, G., Lodolini, G., Kaminsky, S., & Cisneros, G. J. (1992). Effect of nursing caries on body weight in a pediatric population. *Pediatr Dent*, 14(5), 302-305.
- Ağyar, Z. (2015). Yapay sinir ağlarının kullanım alanları ve bir uygulama. *Mühendis ve Makine*, 56(662), 22-23.
- Ahmed, N., Abbasi, M. S., Zuberi, F., Qamar, W., Halim, M. S. B., Maqsood, A., & Alam, M. K. (2021). Artificial intelligence techniques: analysis, application, and outcome in dentistry—a systematic review. *BioMed research international*, 2021(1), 9751564.
- Akpata, E., Farid, M., Al-Saif, K., & Roberts, E. (1996). Cavitation at radiolucent areas on proximal surfaces of posterior teeth. *Caries research*, 30(5), 313-316.
- Altay, A. and Yılmaz, S. (2023). YOLO Algoritması Kullanılarak T Hücrelerinin Sınıflandırılması. *İleri Mühendislik Çalışmaları ve Teknolojileri Dergisi*, 3(2), 66-81.
- Ammar, N. and Kühnisch, J. (2024). Diagnostic performance of artificial intelligence-aided caries detection on bitewing radiographs: a systematic review and meta-analysis. *Jpn Dent Sci Rev*, 60, 128-136. <https://doi.org/10.1016/j.jdsr.2024.02.001>
- Asci, E., Kilic, M., Celik, O., Cantekin, K., Bircan, H. B., Bayrakdar İ, S., & Orhan, K. (2024). A Deep Learning Approach to Automatic Tooth Caries Segmentation in Panoramic Radiographs of Children in Primary Dentition, Mixed Dentition, and Permanent Dentition. *Children (Basel)*, 11(6). <https://doi.org/10.3390/children11060690>
- Ayhan, B., Ayan, E., Karadağ, G., & Bayraktar, Y. (2025). Evaluation of Caries Detection on Bitewing Radiographs: A Comparative Analysis of the Improved Deep Learning Model and Dentist Performance. *J Esthet Restor Dent*, 37(7), 1949-1961. <https://doi.org/10.1111/jerd.13470>
- Ayhan, H., Suskan, E., & Yildirim, S. (1996). The effect of nursing or rampant caries on height, body weight and head circumference. *J Clin Pediatr Dent*, 20(3), 209-212.
- Azhari, A. A., Helal, N., Sabri, L. M., & Abduljawad, A. (2023). Artificial intelligence (AI) in restorative dentistry: Performance of AI models designed for detection of interproximal carious lesions on primary and permanent dentition. *Digit Health*, 9, 20552076231216681. <https://doi.org/10.1177/20552076231216681>
- Bader, J. D., Shugars, D. A., & Bonito, A. J. (2002). A systematic review of the performance of methods for identifying carious lesions. *J Public Health Dent*, 62(4), 201-213. <https://doi.org/10.1111/j.1752-7325.2002.tb03446.x>
- Bayrakdar, I. S., Orhan, K., Akarsu, S., Çelik, Ö., Atasoy, S., Pekince, A., Yasa, Y., Bilgir, E., Sağlam, H., Aslan, A. F., & Odabaş, A. (2022). Deep-learning approach for caries detection and segmentation on dental bitewing radiographs. *Oral Radiology*, 38(4), 468-479. <https://doi.org/10.1007/s11282-021-00577-9>

- Bayraktar, Y. and Ayan, E. (2022). Diagnosis of interproximal caries lesions with deep convolutional neural network in digital bitewing radiographs. *Clin Oral Investig*, 26(1), 623-632. <https://doi.org/10.1007/s00784-021-04040-1>
- Beam, A. L. and Kohane, I. S. (2018). Big Data and Machine Learning in Health Care. *Jama*, 319(13), 1317-1318. <https://doi.org/10.1001/jama.2017.18391>
- Bhbosale, S., Pujari, V., & Multani, Z. (2020). Advantages and disadvantages of artificial intelligence. *Aayushi International Interdisciplinary Research Journal*, 77, 227-230.
- Bochkovskiy, A., Wang, C.-Y., & Liao, H.-Y. M. (2020). YOLOv4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv:2004.10934*.
- Bonny, T., Al Nassan, W., Obaideen, K., Al Mallahi, M. N., Mohammad, Y., & El-Damanhoury, H. M. (2023). Contemporary role and applications of artificial intelligence in dentistry. *F1000Research*, 12, 1179.
- Bordoni, N. E., Salgado, P. A., & Squassi, A. F. (2021). Comparison between indexes for diagnosis and guidance for treatment of dental caries. *Acta Odontológica Latinoamericana*, 34(3), 289.
- Bozdemir, E. and Yarbaşı, Ö. (2019). Tanıda sadece panoramik radyografi ne kadar güvenli? *Selcuk Dental Journal*, 6(4), 100-103.
- Brickley, M., Shepherd, J., & Armstrong, R. (1998). Neural networks: a new technique for development of decision support systems in dentistry. *Journal of dentistry*, 26(4), 305-309.
- Buckland, M. and Gey, F. (1994). The relationship between recall and precision. *Journal of the American society for information science*, 45(1), 12-19.
- Buduma, N., Buduma, N., & Papa, J. (2022). *Fundamentals of deep learning*. " O'Reilly Media, Inc."
- Bughin, J., Hazan, E., Sree Ramaswamy, P., DC, W., & Chu, M. (2017). Artificial intelligence the next digital frontier.
- Cantu, A. G., Gehrung, S., Krois, J., Chaurasia, A., Rossi, J. G., Gaudin, R., Elhennawy, K., & Schwendicke, F. (2020). Detecting caries lesions of different radiographic extension on bitewings using deep learning. *Journal of dentistry*, 100, 103425.
- Celtikci, E. (2018). A systematic review on machine learning in neurosurgery: the future of decision-making in patient care. *Turk Neurosurg*, 28(2), 167-173.
- Chen, G., Li, L., Zhang, J., & Dai, Y. (2023). Rethinking the unpretentious U-net for medical ultrasound image segmentation. *Pattern Recognition*, 142, 109728.
- Chen, X., Guo, J., Ye, J., Zhang, M., & Liang, Y. (2022). Detection of Proximal Caries Lesions on Bitewing Radiographs Using Deep Learning Method. *Caries Res*, 56(5-6), 455-463. <https://doi.org/10.1159/000527418>
- Chicco, D. and Jurman, G. (2020). The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC genomics*, 21(1), 6.
- Choi, R. Y., Coyner, A. S., Kalpathy-Cramer, J., Chiang, M. F., & Campbell, J. P. (2020). Introduction to Machine Learning, Neural Networks, and Deep Learning. *Transl Vis Sci Technol*, 9(2), 14. <https://doi.org/10.1167/tvst.9.2.14>
- Corrêa-Faria, P., Viana, K. A., Raggio, D. P., Hosey, M. T., & Costa, L. R. (2020). Recommended procedures for the management of early childhood caries lesions—a scoping review by the

Children Experiencing Dental Anxiety: Collaboration on Research and Education (CEDACORE). *BMC Oral Health*, 20(1), 75.

- Cunnion, D. T., Spiro, A., 3rd, Jones, J. A., Rich, S. E., Papageorgiou, C. P., Tate, A., Casamassimo, P., Hayes, C., & Garcia, R. I. (2010). Pediatric oral health-related quality of life improvement after treatment of early childhood caries: a prospective multisite study. *J Dent Child (Chic)*, 77(1), 4-11.
- Çiçek, Ö., Abdulkadir, A., Lienkamp, S. S., Brox, T., & Ronneberger, O. (2016). 3D U-Net: learning dense volumetric segmentation from sparse annotation. Medical Image Computing and Computer-Assisted Intervention–MICCAI 2016: 19th International Conference, Athens, Greece, October 17-21, 2016, Proceedings, Part II 19,
- Dave, M. and Patel, N. (2023). Artificial intelligence in healthcare and education. *Br Dent J*, 234(10), 761-764. <https://doi.org/10.1038/s41415-023-5845-2>
- Dayo, A. F., Wolff, M. S., Syed, A. Z., & Mupparapu, M. (2021). Radiology of dental caries. *Dental Clinics*, 65(3), 427-445.
- DeVries, Z., Locke, E., Hoda, M., Moravek, D., Phan, K., Stratton, A., Kingwell, S., Wai, E. K., & Phan, P. (2021). Using a national surgical database to predict complications following posterior lumbar surgery and comparing the area under the curve and F1-score for the assessment of prognostic capability. *The spine journal*, 21(7), 1135-1142.
- Ekstrand, K., Qvist, V., & Thylstrup, A. (1987). Light microscope study of the effect of probing in occlusal surfaces. *Caries Res*, 21(4), 368-374. <https://doi.org/10.1159/000261041>
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118. <https://doi.org/10.1038/nature21056>
- Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristo, M., Chou, K., Cui, C., Corrado, G., Thrun, S., & Dean, J. (2019). A guide to deep learning in healthcare. *Nat Med*, 25(1), 24-29. <https://doi.org/10.1038/s41591-018-0316-z>
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern recognition letters*, 27(8), 861-874.
- Fernandez, M. d. S., Pauli, L. A., da Costa, V. P. P., Azevedo, M. S., & Goettems, M. L. (2022). Dental caries severity and oral health-related quality-of-life in Brazilian preschool children. *European Journal of Oral Sciences*, 130(1), e12836.
- Ferreira Zandoná, A., Analoui, M., Beiswanger, B., Isaacs, R., Kafrawy, A., Eckert, G., & Stookey, G. (1998). An in vitro comparison between laser fluorescence and visual examination for detection of demineralization in occlusal pits and fissures. *Caries research*, 32(3), 210-218.
- Filstrup, S. L., Briskie, D., da Fonseca, M., Lawrence, L., Wandera, A., & Inglehart, M. R. (2003). Early childhood caries and quality of life: child and parent perspectives. *Pediatr Dent*, 25(5), 431-440.
- Flint, D. J., Paunovich, E., Moore, W. S., Wofford, D. T., & Hermes, C. B. (1998). A diagnostic comparison of panoramic and intraoral radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol Endod*, 85(6), 731-735. [https://doi.org/10.1016/s1079-2104\(98\)90043-9](https://doi.org/10.1016/s1079-2104(98)90043-9)
- Ghahramani, Z. (2015). Probabilistic machine learning and artificial intelligence. *Nature*, 521(7553), 452-459.

- Gift, H. (1997). Oral health outcomes research-challenges and opportunities. *Measuring oral health and quality of life*, 25-46.
- Gomez, J. (2015). Detection and diagnosis of the early caries lesion. *BMC Oral Health*, 15(Suppl 1), S3.
- Gonzalez, C., Badr, Z., Güngör, H. C., Han, S., & Hamdan, M. D. (2024). Identifying Primary Proximal Caries Lesions in Pediatric Patients From Bitewing Radiographs Using Artificial Intelligence. *Pediatr Dent*, 46(5), 332-336.
- Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). *Deep learning* (Vol. 1). MIT press Cambridge.
- Group, C. O. H., Walsh, T., Macey, R., Riley, P., Glenney, A.-M., Schwendicke, F., Worthington, H. V., Clarkson, J. E., Ricketts, D., & Su, T.-L. (1996). Imaging modalities to inform the detection and diagnosis of early caries. *Cochrane Database of Systematic Reviews*, 2021(12).
- Hamet, P. and Tremblay, J. (2017). Artificial intelligence in medicine. *Metabolism*, 69s, S36-s40. <https://doi.org/10.1016/j.metabol.2017.01.011>
- Hanley, J. A. and McNeil, B. J. (1982). The meaning and use of the area under a receiver operating characteristic (ROC) curve. *Radiology*, 143(1), 29-36.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Heaven, T., Weems, R., & Firestone, A. (1994). The use of a computer-based image analysis program for the diagnosis of approximal caries from bitewing radiographs. *Caries research*, 28(1), 55-58.
- Hwang, J.-J., Jung, Y.-H., Cho, B.-H., & Heo, M.-S. (2019). An overview of deep learning in the field of dentistry. *Imaging science in dentistry*, 49(1), 1-7.
- Iannucci, J. and Radiography, H. D. (2017). Principles and Techniques, St Louis Missouri. In: Elsevier.
- Ismail, A. I. (2004). Visual and visuo-tactile detection of dental caries. *J Dent Res*, 83 Spec No C, C56-66. <https://doi.org/10.1177/154405910408301s12>
- Jackson, S. L., Vann, W. F., Jr., Kotch, J. B., Pahel, B. T., & Lee, J. Y. (2011). Impact of poor oral health on children's school attendance and performance. *Am J Public Health*, 101(10), 1900-1906. <https://doi.org/10.2105/ajph.2010.200915>
- Jeon, K. J., Han, S.-S., Lee, C., Choi, Y. J., Jung, H. I., & Kim, Y. H. (2020). Application of panoramic radiography with a multilayer imaging program for detecting proximal caries: a preliminary clinical study. *Dentomaxillofacial Radiology*, 49(8), 20190467.
- Jocher, G., Chaurasia, A., & Qiu, J. Y. (2020). Ultralytics. *YOLOv5: PyTorch Implementation of Object Detection Models*. *GitHub Repository*.
- Johari, M., Esmaeili, F., Andalib, A., Garjani, S., & Saberhari, H. (2017). Detection of vertical root fractures in intact and endodontically treated premolar teeth by designing a probabilistic neural network: an ex vivo study. *Dentomaxillofacial Radiology*, 46(2), 20160107.
- Jordan, M. I. and Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.

- Kamburoğlu, K., Kolsuz, E., Murat, S., Yüksel, S., & Özen, T. (2012). Proximal caries detection accuracy using intraoral bitewing radiography, extraoral bitewing radiography and panoramic radiography. *Dentomaxillofacial Radiology*, 41(6), 450-459.
- Kaya, U., Yılmaz, A., & Dikmen, Y. (2019). Sağlık alanında kullanılan derin öğrenme yöntemleri. *Avrupa Bilim ve Teknoloji Dergisi*(16), 792-808.
- Khanam, R., & Hussain, M. (2024). What is YOLOv5: A deep look into the internal features of the popular object detector. *arXiv preprint arXiv:2407.20892*.
- Khanzode, K. C. A. and Sarode, R. D. (2020). Advantages and disadvantages of artificial intelligence and machine learning: A literature review. *International Journal of Library & Information Science (IJLIS)*, 9(1), 3.
- Kunt, L., Kybic, J., Nagyová, V., & Tichý, A. (2023). Automatic caries detection in bitewing radiographs: part I-deep learning. *Clin Oral Investig*, 27(12), 7463-7471. <https://doi.org/10.1007/s00784-023-05335-1>
- Lara-Capi, C., Cagetti, M. G., Lingström, P., Lai, G., Cocco, F., Simark-Mattsson, C., & Campus, G. (2017). Digital transillumination in caries detection versus radiographic and clinical methods: an in-vivo study. *Dentomaxillofacial Radiology*, 46(4), 20160417.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
- Lee, J. H., Kim, D. H., Jeong, S. N., & Choi, S. H. (2018). Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *J Dent*, 77, 106-111. <https://doi.org/10.1016/j.jdent.2018.07.015>
- Lee, J. H., Yu, H. J., Kim, M. J., Kim, J. W., & Choi, J. (2020). Automated cephalometric landmark detection with confidence regions using Bayesian convolutional neural networks. *BMC Oral Health*, 20(1), 270. <https://doi.org/10.1186/s12903-020-01256-7>
- Lee, S., Oh, S. I., Jo, J., Kang, S., Shin, Y., & Park, J. W. (2021). Deep learning for early dental caries detection in bitewing radiographs. *Sci Rep*, 11(1), 16807. <https://doi.org/10.1038/s41598-021-96368-7>
- Lian, L., Zhu, T., Zhu, F., & Zhu, H. (2021). Deep learning for caries detection and classification. *Diagnostics*, 11(9), 1672.
- Lin, T.-Y., Dollár, P., Girshick, R., He, K., Hariharan, B., & Belongie, S. (2017). Feature pyramid networks for object detection. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Lippert, F., Parker, D. M., & Jandt, K. D. (2004). Susceptibility of deciduous and permanent enamel to dietary acid-induced erosion studied with atomic force microscopy nanoindentation. *Eur J Oral Sci*, 112(1), 61-66. <https://doi.org/10.1111/j.0909-8836.2004.00095.x>
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J., van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88. <https://doi.org/10.1016/j.media.2017.07.005>
- Liu, S., Qi, L., Qin, H., Shi, J., & Jia, J. (2018). Path aggregation network for instance segmentation. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Low, W., Tan, S., & Schwartz, S. (1999). The effect of severe caries on the quality of life in young children. *Pediatr Dent*, 21(6), 325-326.

- Machiulskiene, V., Campus, G., Carvalho, J. C., Dige, I., Ekstrand, K. R., Jablonski-Momeni, A., Maltz, M., Manton, D. J., Martignon, S., & Martinez-Mier, E. (2020). Terminology of dental caries and dental caries management: consensus report of a workshop organized by ORCA and cariology research group of IADR. *Caries research*, 54(1), 7-14.
- Martin, K. D. and Zimmermann, J. (2024). Artificial intelligence and its implications for data privacy. *Curr Opin Psychol*, 58, 101829. <https://doi.org/10.1016/j.copsyc.2024.101829>
- McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI magazine*, 27(4), 12-12.
- Mertens, S., Krois, J., Cantu, A. G., Arsiwala, L. T., & Schwendicke, F. (2021). Artificial intelligence for caries detection: Randomized trial. *J Dent*, 115, 103849. <https://doi.org/10.1016/j.jdent.2021.103849>
- Mialhe, F. L., Pereira, A. C., Pardi, V., & de Castro Meneghim, M. (2003). Comparison of three methods for detection of carious lesions in proximal surfaces versus direct visual examination after tooth separation. *J Clin Pediatr Dent*, 28(1), 59-62. <https://doi.org/10.17796/jcpd.28.1.g121387868676514>
- Mintz, Y. and Brodie, R. (2019). Introduction to artificial intelligence in medicine. *Minim Invasive Ther Allied Technol*, 28(2), 73-81. <https://doi.org/10.1080/13645706.2019.1575882>
- Mol, A. and Van Der Stelt, P. (1992). Application of computer-aided image interpretation to the diagnosis of periapical bone lesions. *Dentomaxillofacial Radiology*, 21(4), 190-194.
- Moran, M., Faria, M., Giralaldi, G., Bastos, L., Oliveira, L., & Conci, A. (2021). Classification of Approximal Caries in Bitewing Radiographs Using Convolutional Neural Networks. *Sensors (Basel)*, 21(15). <https://doi.org/10.3390/s21155192>
- Nabiyev, V. V. (2012). *Yapay zeka: insan-bilgisayar etkileşimi*. Seçkin Yayıncılık.
- Nagi, R., Aravinda, K., Rakesh, N., Gupta, R., Pal, A., & Mann, A. K. (2020). Clinical applications and performance of intelligent systems in dental and maxillofacial radiology: A review. *Imaging Sci Dent*, 50(2), 81-92. <https://doi.org/10.5624/isd.2020.50.2.81>
- Neuhaus, K., Ellwood, R., Lussi, A., & Pitts, N. (2009). Traditional lesion detection aids. *Detection, assessment, diagnosis and monitoring of caries*, 21, 42-51.
- Nickerson, A. and Orton, G. (1997). Enhancing Caries detection. *J Practical Hygiene*, 21-26.
- Novaes, T. F., Matos, R., Braga, M. M., Imparato, J. C., Raggio, D. P., & Mendes, F. M. (2009). Performance of a pen-type laser fluorescence device and conventional methods in detecting approximal caries lesions in primary teeth--in vivo study. *Caries Res*, 43(1), 36-42. <https://doi.org/10.1159/000189705>
- Ozturk, O., Sarıtürk, B., & Seker, D. Z. (2020). Comparison of fully convolutional networks (FCN) and U-Net for road segmentation from high resolution imageries. *International journal of environment and geoinformatics*, 7(3), 272-279.
- Özkesici, M. Y. and Yılmaz, S. (2021). Oral ve Maksillofasiyal Radyoloji’de Yapay Zeka. *Sağlık Bilimleri Dergisi*, 30(3), 346-351.
- Panyarak, W., Suttapak, W., Wantanajittikul, K., Charuakkra, A., & Prapayasatok, S. (2023). Assessment of YOLOv3 for caries detection in bitewing radiographs based on the ICCMS™ radiographic scoring system. *Clin Oral Investig*, 27(4), 1731-1742. <https://doi.org/10.1007/s00784-022-04801-6>

- Panyarak, W., Wantanajittikul, K., Charuakkra, A., Prapayasatok, S., & Suttapak, W. (2023). Enhancing Caries Detection in Bitewing Radiographs Using YOLOv7. *J Digit Imaging*, 36(6), 2635-2647. <https://doi.org/10.1007/s10278-023-00871-4>
- Peers, A., Hill, F. J., Mitropoulos, C. M., & Holloway, P. J. (1993). Validity and reproducibility of clinical examination, fibre-optic transillumination, and bite-wing radiology for the diagnosis of small approximal carious lesions: an in vitro study. *Caries Res*, 27(4), 307-311. <https://doi.org/10.1159/000261556>
- Pérez de Frutos, J., Holden Helland, R., Desai, S., Nymoen, L. C., Langø, T., Remman, T., & Sen, A. (2024). AI-Dentify: deep learning for proximal caries detection on bitewing x-ray - HUNT4 Oral Health Study. *BMC Oral Health*, 24(1), 344. <https://doi.org/10.1186/s12903-024-04120-0>
- Pitts, N. B. (1993). Current methods and criteria for caries diagnosis in Europe. *J Dent Educ*, 57(6), 409-414.
- Pitts, N. B. (1996). The use of bitewing radiographs in the management of dental caries: scientific and practical considerations. *Dentomaxillofac Radiol*, 25(1), 5-16. <https://doi.org/10.1259/dmfr.25.1.9084279>
- Pitts, N. B., Twetman, S., Fisher, J., & Marsh, P. D. (2021). Understanding dental caries as a non-communicable disease. *British dental journal*, 231(12), 749-753.
- Rajpurkar, P., Irvin, J., Ball, R. L., Zhu, K., Yang, B., Mehta, H., Duan, T., Ding, D., Bagul, A., Langlotz, C. P., Patel, B. N., Yeom, K. W., Shpanskaya, K., Blankenberg, F. G., Seekins, J., Amrhein, T. J., Mong, D. A., Halabi, S. S., Zucker, E. J., . . . Lungren, M. P. (2018). Deep learning for chest radiograph diagnosis: A retrospective comparison of the CheXNeXt algorithm to practicing radiologists. *PLoS Med*, 15(11), e1002686. <https://doi.org/10.1371/journal.pmed.1002686>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Refaeilzadeh, P., Tang, L., & Liu, H. (2009). Cross-validation. In *Encyclopedia of database systems* (pp. 532-538). Springer.
- Righolt, A. J., Jevdjevic, M., Marcenes, W., & Listl, S. (2018). Global-, Regional-, and Country-Level Economic Impacts of Dental Diseases in 2015. *J Dent Res*, 97(5), 501-507. <https://doi.org/10.1177/0022034517750572>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. Medical image computing and computer-assisted intervention–MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18,
- Safdar, N. M., Banja, J. D., & Meltzer, C. C. (2020). Ethical considerations in artificial intelligence. *European journal of radiology*, 122, 108768.
- Saghiri, M. A., Asgar, K., Boukani, K., Lotfi, M., Aghili, H., Delvarani, A., Karamifar, K., Saghiri, A., Mehrvarzfar, P., & Garcia-Godoy, F. (2012). A new approach for locating the minor apical foramen using an artificial neural network. *International endodontic journal*, 45(3), 257-265.
- Saglam, H., Tuğba, A., Bayrakdar, İ. Ş., Bilgir, E., Uğurlu, M., Çelik, Ö., & Orhan, K. (2021). Diş Hekimliğinde Yapay Zeka: Artificial Intelligence In Dentistry. *Sağlık Bilimlerinde Yapay Zeka Dergisi (Journal of Artificial Intelligence in Health Sciences)* ISSN: 2757-9646, 1(2), 26-33.

- Saito, T. and Rehmsmeier, M. (2015). The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PLoS One*, 10(3), e0118432.
- Schwendicke, F., Golla, T., Dreher, M., & Krois, J. (2019). Convolutional neural networks for dental image diagnostics: A scoping review. *J Dent*, 91, 103226. <https://doi.org/10.1016/j.jdent.2019.103226>
- Schwendicke, F., Rossi, J. G., Göstemeyer, G., Elhennawy, K., Cantu, A. G., Gaudin, R., Chaurasia, A., Gehrung, S., & Krois, J. (2021). Cost-effectiveness of Artificial Intelligence for Proximal Caries Detection. *Journal of Dental Research*, 100(4), 369-376. <https://doi.org/10.1177/0022034520972335>
- Schwendicke, F. a., Samek, W., & Krois, J. (2020). Artificial intelligence in dentistry: chances and challenges. *Journal of dental research*, 99(7), 769-774.
- Selwitz, R. H., Ismail, A. I., & Pitts, N. B. (2007). Dental caries. *The Lancet*, 369(9555), 51-59.
- Sheiham, A. (2006). Dental caries affects body weight, growth and quality of life in pre-school children. *Br Dent J*, 201(10), 625-626. <https://doi.org/10.1038/sj.bdj.4814259>
- Shorten, C., Khoshgoftaar, T. M., & Furht, B. (2021). Text Data Augmentation for Deep Learning. *J Big Data*, 8(1), 101. <https://doi.org/10.1186/s40537-021-00492-0>
- Shrestha, B. and Dunn, L. (2019). The declaration of Helsinki on medical research involving human subjects: a review of seventh revision. *Journal of Nepal Health Research Council*, 17(04), 548-552.
- Tejani, A. S., Klontzas, M. E., Gatti, A. A., Mongan, J. T., Moy, L., Park, S. H., Kahn Jr, C. E., & Panel, C. U. (2024). Checklist for artificial intelligence in medical imaging (CLAIM): 2024 update. *Radiology: Artificial Intelligence*, 6(4), e240300.
- Wenzel, A. (2004). Bitewing and digital bitewing radiography for detection of caries lesions. *J Dent Res*, 83 Spec No C, C72-75. <https://doi.org/10.1177/154405910408301s14>
- White, S. and Pharoah, M. (2014). Oral radiology: principles and interpretation: Elsevier Health Sciences; 2013. In: Dec.
- Yavsan, Z. S., Orhan, H., Efe, E., & Yavsan, E. (2025). Diagnosis of approximal caries in children with convolutional neural networks based detection algorithms on radiographs: A pilot study. *Acta Odontol Scand*, 84, 18-25. <https://doi.org/10.2340/aos.v84.42599>
- Yilmaz, S. (2023). Beyin Tümörü Tanıları İçin YOLOv7 Algoritması Tabanlı Karar Destek Sistemi Tasarımı. *Kocaeli Üniversitesi Fen Bilimleri Dergisi*, 6(1), 47-56.
- Ying, S., Huang, F., Shen, X., Liu, W., & He, F. (2024). Performance comparison of multifarious deep networks on caries detection with tooth X-ray images. *J Dent*, 144, 104970. <https://doi.org/10.1016/j.jdent.2024.104970>
- Zandoná, A. F. and Zero, D. T. (2006). Diagnostic tools for early caries detection. *The Journal of the American Dental Association*, 137(12), 1675-1684.
- Zaror, C., Matamala-Santander, A., Ferrer, M., Rivera-Mendoza, F., Espinoza-Espinoza, G., & Martínez-Zapata, M. J. (2022). Impact of early childhood caries on oral health-related quality of life: A systematic review and meta-analysis. *International journal of dental hygiene*, 20(1), 120-135.

Zhang, Y. and Yang, Q. (2021). A survey on multi-task learning. *IEEE transactions on knowledge and data engineering*, 34(12), 5586-5609.

Zhou, X., Yu, G., Yin, Q., Liu, Y., Zhang, Z., & Sun, J. (2022). Context Aware Convolutional Neural Network for Children Caries Diagnosis on Dental Panoramic Radiographs. *Comput Math Methods Med*, 2022, 6029245. <https://doi.org/10.1155/2022/6029245>

Zhou, Z.-H. (2021). *Machine learning*. Springer nature.



EKLER

EK-1. Etik Kurul Onayı



T.C.
ANKARA ÜNİVERSİTESİ
Diş Hekimliği Fakültesi
Klinik Araştırmalar Etik Kurulu



Konu : Etik Kurul Hk.
Sayı : 36290600/ 58/2023

06.11.2023

Sayın Doç. Dr. Akif DEMİREL
Ankara Üniversitesi Diş Hekimliği Fakültesi
Pedodonti Anabilim Dalı
Öğretim Üyesi

Doç. Dr. Akif DEMİREL danışmanlığında ve Dt.Hatice Selin YAZICI tarafından yürütülecek olan “Süt ve Daimi Dişlerde Arayüz Çürüklerinin Teşhisinde Yapay Zekanın Etkinliğinin Değerlendirilmesi” konulu çalışma Etik Kurulumuz tarafından incelenmiş ve araştırma etiği açısından UYGUN bulunmuştur.

Bilgilerinizi saygılarımla rica ederim.

Eki: 3 sayfa

	KLİNİK ARAŞTIRMALAR ETİK KURULU KARAR FORMU	
		Sayfa Sayısı: 1/1

ARAŞTIRMANIN AÇIK ADI	Süt ve Daimi Dişlerde Arayüz Çürüklerinin Teşhisinde Yapay Zekanın Etkinliğinin Değerlendirilmesi

ETİK KURUL BİLGİLERİ	ETİK KURULUN ADI	ANKARA ÜNİVERSİTESİ DİŞ HEKİMLİĞİ FAKÜLTESİ
	AÇIK ADRESİ:	A.Ü. DİŞ HEKİMLİĞİ FAKÜLTESİ BEŞEVLER / ANKARA
	TELEFON	2965695
	FAKS	
	E-POSTA	

BAŞVURU BİLGİLERİ	KOORDİNATÖR/SORUMLU ARAŞTIRMACI UNVANI/ADI/SOYADI	DOÇ. DR. AKİF DEMİREL			
	KOORDİNATÖR/SORUMLU ARAŞTIRMACININ UZMANLIK ALANI	ANKARA ÜNİV. DİŞ HEKİMLİĞİ FAKÜLTESİ PEDODONTİ ANABİLİM DALI			
	KOORDİNATÖR/SORUMLU ARAŞTIRMACININ BULUNDUĞU MERKEZ	ANKARA			
	VARSA İDARİ SORUMLU UNVANI/ADI/SOYADI				
	DESTEKLEYİCİ				
	PROJE YÜRÜTÜCÜSÜ UNVANI/ADI/SOYADI (TÜBİTAK vb. gibi kaynaklardan destek alanlar için)				
	DESTEKLEYİCİNİN YASAL TEMSİLCİSİ				
	ARAŞTIRMANIN FAZİ VE TÜRÜ	FAZ 1	☐		
		FAZ 2	☐		
		FAZ 3	☐		
		FAZ 4	☐		
		Gözlemsel ilaç çalışması	☐		
		Tıbbi cihaz klinik araştırması			
		İn vitro tıbbi tanı cihazları ile yapılan performans değerlendirme çalışmaları	☐		
		İlaç dışı klinik araştırma	☒		
	Diğer ise belirtiniz ☐				
ARAŞTIRMAYA KATILAN MERKEZLER	TEK MERKEZ ☒	ÇOK MERKEZLİ	ULUSAL	ULUSLARARASI ☐	

Not: Etik kurul başkanı, imzasının yer almadığı her sayfaya imza atmalıdır.

	KLİNİK ARAŞTIRMALAR ETİK KURULU KARAR FORMU	
		Sayfa Sayısı: 1/2

ARAŞTIRMANIN AÇIK ADI	Süt ve Daimi Dişlerde Arayüz Çürüklerinin Teşhisinde Yapay Zekânın Etkinliğinin Değerlendirilmesi

DEĞERLENDİRİLEN BELGELER	Belge Adı	Tarihi	Versiyon Numarası	Dili			
	ARAŞTIRMA PROTOKOLÜ	01.11.2023	1	Türkçe ☐	İngilizce ☐	Diğer ☐	
	BİLGİLENDİRİLMİŞ GÖNÜLLÜ OLUR FORMU			Türkçe ☐	İngilizce ☐	Diğer ☐	
	OLGU RAPOR FORMU			Türkçe ☐	İngilizce ☐	Diğer ☐	
	ARAŞTIRMA BROŞÜRÜ			Türkçe ☐	İngilizce ☐	Diğer ☐	
DEĞERLENDİRİLEN DİĞER BELGELER	Belge Adı	Açıklama					
	SİGORTA	☐					
	ARAŞTIRMA BÜTÇESİ	☐					
	BİYOLOJİK MATERYEL TRANSFER FORMU	☐					
	İLAN	☐					
	YILLIK BİLDİRİM	☐					
	SONUÇ RAPORU	☐					
	GÜVENLİLİK BİLDİRİMLERİ	☐					
KARAR BİLGİLERİ	Karar No: 12/11	Tarih: 06.11.2023					
	Yukarıda bilgileri verilen başvuru dosyası ile ilgili belgeler araştırmanın/çalışmanın gerekçe, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiş ve uygun bulunmuş olup araştırmanın/çalışmanın başvuru dosyasında belirtilen merkezlerde gerçekleştirilmesinde etik ve bilimsel sakınca bulunmadığına toplantıya katılan etik kurul üye tam sayısının salt çoğunluğu ile karar verilmiştir. İlaç ve Biyolojik Ürünlerin Klinik Araştırmaları Hakkında Yönetmelik kapsamında yer alan araştırmalar/çalışmalar için Türkiye İlaç ve Tıbbi Cihaz Kurumu'ndan izin alınması gerekmektedir.						

KLİNİK ARAŞTIRMALAR ETİK KURULU	
ETİK KURULUN ÇALIŞMA ESASI	İlaç ve Biyolojik Ürünlerin Klinik Araştırmaları Hakkında Yönetmelik, İyi Klinik Uygulamaları Kılavuzu
BAŞKANIN UNVANI / ADI / SOYADI:	Prof. Dr. Şaziye SARI

Unvanı/Adı/Soyadı	Uzmanlık Alanı	Kurumu	Cinsiyet	Araştırma ile ilişki	Katılım *	İmza
Prof. Dr. Şaziye SARI	Pedodonti	Ankara Üniv. Diş Hek. Fakültesi	E ☐ K ☒	E ☐ H ☐	E ☐ H ☒	
Prof. Dr. Sadullah ÜÇTAŞLI	Protetik Diş Tedavisi	Ankara Üniv. Diş Hek. Fakültesi	E ☒ K ☐	E ☐ H ☐	E ☐ H ☐	
Prof. Dr. Elif ÜNSAL	Periodontoloji	Ankara Üniv. Diş Hek. Fakültesi	E ☐ K ☒	E ☐ H ☐	E ☐ H ☐	
Prof. Dr. Ufuk TOYGAR MEMİKOĞLU	Ortodonti	Ankara Üniv. Diş Hek. Fakültesi	E ☐ K ☒	E ☐ H ☐	E ☐ H ☐	

Not: Etik kurul başkanı, imzasının yer almadığı her sayfaya imza atmalıdır.

	KLİNİK ARAŞTIRMALAR ETİK KURULU KARAR FORMU			
				Sayfa Sayısı: 1/3

ARAŞTIRMANIN AÇIK ADI	Süt ve Daimi Dişlerde Arayüz Çürüklerinin Teşhisinde Yapay Zekanın Etkinliğinin Değerlendirilmesi

Unvanı/Adı/Soyadı	Uzmanlık Alanı	Kurumu	Cinsiyet		Araştırma ile ilişki		Katılım *		İmza
Prof. Dr. Meltem DARTAR ÖZTAN	Endodonti	Ankara Üniv. Diş Hek. Fakültesi	E ☐	K ☒	E ☐	H ☐	E ☐	H ☐	
Doç. Dr. Mehmet Hakan KURT	Ağız Diş ve Çene Radyolojisi	Ankara Üniv. Diş Hek. Fakültesi	E ☒	K ☐	E ☐	H ☐	E ☐	H ☐	
Doç. Dr. Mehmet Emre YURTTUTAN	Ağız Diş ve Çene Cerrahisi	Ankara Üniv. Diş Hek. Fakültesi	E ☒	K ☐	E ☐	H ☐	E ☐	H ☐	
Dr. Öğr. Üyesi Mert OCAK	Temel Bilimler	Ankara Üniv. Diş Hek. Fakültesi	E ☒	K ☐	E ☐	H ☐	E ☐	H ☐	
Prof. Dr. Sevil ÖZGER İLHAN	Farmakoloji	Gazi Üniv. Tıp Fakültesi	E ☐	K ☒	E ☐	H ☐	E ☐	H ☐	
Yrd. Doç. Dr. Sevilay KARAHAN	Biyostatistik	Hacettepe Üniv. Tıp Fakültesi	E ☐	K ☒	E ☐	H ☐	E ☐	H ☐	
Doç. Dr. Nadire ÖZDEMİR	Hukuk	Ankara Üniv. Hukuk Fakültesi	E ☐	K ☒	E ☐	H ☐	E ☐	H ☐	
Ahmet Ferhat ÖZDEMİR	Memur	Ankara Üniv. Diş Hek. Fakültesi	E ☒	K ☐	E ☐	H ☐	E ☐	H ☐	

*
:Toplantıda Bulunma

Not: Etik kurul başkanı, imzasının yer almadığı her sayfaya imza atmalıdır.