



T. C.

GAZİANTEP ÜNİVERSİTESİ

DİŞ HEKİMLİĞİ FAKÜLTESİ

**DERİN ÖĞRENME YÖNTEMİ KULLANILARAK KARIŞIK DİŞLENME
DÖNEMİNDE ALINAN PERİAPİKAL RADYOGRAFİLERDE DİŞLERİN
NUMARALANDIRILMASI VE DENTAL RESTORASYONLARIN
SINIFLANDIRILMASI**

Büşra YÜCETÜRK

UZMANLIK TEZİ

ÇOCUK DİŞ HEKİMLİĞİ ANABİLİM DALI

DANIŞMAN

Dr. Öğr. Üyesi Zehra GÜNER

Gaziantep

2025

BEYAN

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

28.02.2025

Büşra YÜCETÜRK



İÇİNDEKİLER

| | |
|---|------------|
| SİMGE VE KISALTMALAR | iii |
| ŞEKİLLER LİSTESİ | iv |
| TABLolar LİSTESİ | vi |
| ÖZET | 1 |
| ABSTRACT | 2 |
| 1. GİRİŞ VE AMAÇ | 3 |
| 2. GENEL BİLGİLER | 5 |
| 2.1. Diş Çürüğü | 5 |
| 2.2. Çürük Teşhis Yöntemleri | 6 |
| 2.2.1. Geleneksel Çürük Teşhis Yöntemleri | 7 |
| 2.2.2. Görsel ve Görsel-Dokunsal Yöntem | 7 |
| 2.2.3. Radyografik Yöntem..... | 7 |
| 2.2.3.1. Panoramik Radyografi..... | 8 |
| 2.2.3.2. Periapikal Radyografi | 9 |
| 2.2.3.3. Bite-wing Radyografi..... | 11 |
| 2.3. Diş Çürüğü Tedavi Planı..... | 11 |
| 2.4. Dişlerin Sınıflandırılması | 14 |
| 2.4.1. Zsigmondy Numaralandırma Sistemi..... | 14 |
| 2.4.2. Palmer Numaralandırma Sistemi | 15 |
| 2.4.3. Universal Numaralandırma Sistemi (Cunningham Sistemi)..... | 16 |
| 2.4.4. FDI (International Federation of Dentistry) Numaralandırma Sistemi | 16 |
| 2.5. Yapay Zeka (YZ) | 17 |
| 2.5.1. Makine Öğrenimi | 18 |
| 2.5.2. Yapay Sinir Ağları (YSA) | 18 |
| 2.5.3. Derin Öğrenme..... | 21 |
| 2.5.3.1. Evrişimli Sinir Ağları (Convolutional Neural Network | 22 |

| | |
|--|-----------|
| 2.5.3.2. Tekrarlayan Sinir Ağı (Recurrent Neural Network) | 23 |
| 2.5.3.3. Uzun Kısa Süreli Hafıza Ağları (LSTM) | 23 |
| 2.5.3.4. Sınırlı Boltzman Makineleri (RBM) | 23 |
| 2.5.3.5. Derin İnanç Ağları (DBN) | 24 |
| 2.5.3.6. Derin Otokodlayıcılar | 24 |
| 2.5.4. Derin Öğrenmede Görüntü Segmentasyonu | 24 |
| 2.5.5. Kodlayıcı- Kod çözücü Modeller | 25 |
| 2.5.6. Derin Öğrenme Yöntemlerinin Nesne Tespitinde Kullanılması | 25 |
| 2.5.7. Derin Öğrenme Kütüphaneleri..... | 28 |
| 2.6. Derin Öğrenme ve Diş Hekimliği | 28 |
| 2.6.1. Çocuk Diş Hekimliğinde Yapay Zeka..... | 30 |
| 3. GEREÇ VE YÖNTEM | 33 |
| 3.1. Dişlerin Etiketlenmesi | 33 |
| 3.2. Veri Setinin Oluşturulması | 35 |
| 3.3. Model Eğitimi ve Geliştirilmesi | 36 |
| 3.4. Performans Değerlendirme Metrikleri..... | 37 |
| 4. BULGULAR..... | 41 |
| 4.1. Veri Seti Dağılımı | 41 |
| 4.2. Dişlerin Numaralandırılması Performans Sonuçları | 42 |
| 4.3. Restorasyonların Tespiti Performans Sonuçları | 47 |
| 5. TARTIŞMA | 52 |
| 6. SONUÇ VE ÖNERİLER | 65 |
| 7. KAYNAKLAR | 66 |

SİMGE VE KISALTMALAR

| | |
|-------------|---|
| AUC | Alıcı İşletim Karakteristik Eğrisi |
| DBN | Derin İnanç Ağları |
| ESA | Evrişimli Sinir Ağları |
| FN | Yanlış Negatif |
| FP | Yanlış Pozitif |
| LTSM | Uzun Kısa Vadeli Hafıza Ağları |
| mAP | Genel ortalama kesinlik-Mean average precision |
| IoU | Birleşim Üzerinden Ortalama Kesişim-Intersection over Union |
| RBM | Sınırlı Boltzman Makineleri |
| RNN | Tekrarlayan Sinir Ağı |
| ROC | İşletim Karakteristik Eğrisi |
| SDD | Single Shot Multi Box Detector |
| TP | Doğru Pozitif |
| TN | Doğru Negatif |
| YOLO | You Only Look Once |
| YSA | Yapay Sinir Ağları |
| YZ | Yapay Zeka |

ŞEKİLLER LİSTESİ

| | |
|--|----|
| Şekil 2. 1. Diş çürük lezyonu oluşumunda patolojik ve koruyucu faktörlerin dengesi (17) | 5 |
| Şekil 2. 2. Zsigmondy daimi dişlenme numaralandırma sistemi (71) | 15 |
| Şekil 2. 3. Zsigmondy süt dişlenme numaralandırma sistemi (71) | 15 |
| Şekil 2. 4. Palmer daimi dişlenme numaralandırma sistemi (71) | 15 |
| Şekil 2. 5. Palmer süt dişlenme numaralandırma sistemi (71) | 15 |
| Şekil 2. 6. Universal daimi dişlenme numaralandırma sistemi (71) | 16 |
| Şekil 2. 7. Universal süt dişlenme numaralandırma sistemi (71) | 16 |
| Şekil 2. 8. FDI daimi dişlenme numaralandırma sistemi (71) | 17 |
| Şekil 2. 9. FDI süt dişlenme numaralandırma sistemi (71) | 17 |
| Şekil 2. 10. Yapay zeka alt gruplarının şematik görüntüsü (80) | 18 |
| Şekil 2. 11. Tek katmanlı algılayıcı modeli (89) | 19 |
| Şekil 2. 12. Çok katmanlı algılayıcı modeli (88) | 20 |
| Şekil 2. 13. İleri beslemeli ağ yapısı (88) | 20 |
| Şekil 2. 14. Geri beslemeli ağ yapısı (88) | 21 |
| Şekil 2. 15. YOLO nesne tespit aşamaları | 27 |
| Şekil 3. 1. Süt ve daimi dişlerinin etiketlenmesi | 34 |
| Şekil 3. 2. Restorasyonların etiketlenmesi: (A) yeşil: amputasyon, pembe: dolgu, koyu yeşil: taşkın dolgu, koyu mavi: kök kanal tedavisi (B) Mavi: sabit yer tutucu restorasyonu | 35 |
| Şekil 3. 3. IoU Değerinin Hesaplanması (151) | 37 |
| Şekil 4. 1. Dişlerin numaralandırılması için veri dağılımı ve korelogram gösterimi | 41 |
| Şekil 4. 2. Restorasyonların tespiti için veri dağılımı ve korelogram gösterimi | 42 |
| Şekil 4. 3. YOLOv8 Modelinin Dişlerin Numaralandırılması için Karmaşıklık Matrisi | 43 |
| Şekil 4. 4. Dişlerin Numaralandırılması Kesinlik-Güven Eğrisi | 44 |
| Şekil 4. 5. Dişlerin Numaralandırılması Duyarlılık-Güven Eğrisi | 44 |

| | |
|---|----|
| Şekil 4. 6. Dişlerin Numaralandırılması Kesinlik-Duyarlılık Eğrisi..... | 45 |
| Şekil 4. 7. Dişlerin Numaralandırılması F1-Güven Eğrisi..... | 45 |
| Şekil 4. 8. Dişlerin Numaralandırılması Epoch İlerleyişi ve Performans Grafikleri | 46 |
| Şekil 4. 9. YOLOv8 modelinin dişlerin numaralandırılması için doğru pozitif, yanlış pozitif ve yanlış negatif tespiti..... | 47 |
| Şekil 4. 10. YOLOv8 Modelinin Restorasyonların Tespiti için Karmaşıklık Matrisi | 48 |
| Şekil 4. 11. Restorasyonların Tespiti Kesinlik-Güven Eğrisi..... | 49 |
| Şekil 4. 12. Restorasyonların Tespiti Duyarlılık-Güven Eğrisi | 49 |
| Şekil 4. 13. Restorasyonların Tespiti Kesinlik-Duyarlılık Eğrisi | 50 |
| Şekil 4. 14. Restorasyonların Tespiti F1-Güven Eğrisi | 50 |
| Şekil 4. 15. Restorasyonların Tespiti için Epoch İlerleyişi ve Performans Grafikleri..... | 51 |
| Şekil 4. 16. YOLOv8 modelinin dişlerdeki restorasyonların doğru pozitif, yanlış pozitif ve yanlış negatif tespiti | 51 |
| Şekil 5. 1. Diş eksikliği durumunda modelin başarılı bir şekilde numaralandırma yaptığı örnek periapikal radyografiler..... | 58 |

TABLULAR LİSTESİ

| | |
|--|----|
| Tablo 3. 1. Dişlerin numaralandırılması veri seti sınıflandırılması | 36 |
| Tablo 3. 2. Restorasyonların tespiti veri seti sınıflandırılması | 36 |
| Tablo 3. 3. Karmaşıklık matrisi | 38 |
| Tablo 4. 1. Dişlerin numaralandırılması için TP, FP, FN ve Doğruluk Değerleri..... | 42 |
| Tablo 4. 2. Dişlerin Numaralandırılması Performans Skorları | 43 |
| Tablo 4. 3. Restorasyonların Tespiti için TP, FP, FN ve Doğruluk Değerleri..... | 47 |
| Tablo 4. 4. Restorasyonların Tespiti Performans Skorları..... | 48 |

ÖZET

DERİN ÖĞRENME YÖNTEMİ KULLANILARAK KARIŞIK DIŞLENME DÖNEMİNDE ALINAN PERIAPİKAL RADYOGRAFİLERDE DIŞLERİN NUMARALANDIRILMASI VE DENTAL RESTORASYONLARIN SINIFLANDIRILMASI

Büşra YÜCETÜRK

ÇOCUK DIŞ HEKİMLİĞİ ANABİLİM DALI

Dr. Öğr. Üyesi Zehra GÜNER

Şubat 2025, Sayfa 79

Bu çalışmada derin öğrenme tabanlı yapay zeka modelleri ile karışık dişlenme döneminde alınan periapikal radyografiler üzerinden dişlerin doğru numaralandırılması ve farklı türdeki restorasyonların tespit etkinliğinin değerlendirilmesi amaçlanmaktadır. Bu bağlamda karışık dişlenme döneminde periapikal radyografilerdeki dişlerin doğru bir şekilde numaralandırılması ve restorasyonların tespit edilmesi, tedavi planlanması sürecinde kritik öneme sahiptir. Ayrıca derin öğrenme modellerinin kullanımı, erken teşhis sürecini otomatikleştirerek tedavi süreçlerinin hızını ve doğruluğunu iyileştirmektedir. Bu çalışmaya 6-12 yaş aralığında çeşitli tanısal amaçlarla alınmış süt ve daimi dişlerin numaralandırılması amacıyla 1504, restorasyonların otomatik tespit etkinliğinin değerlendirilmesi için 1599 periapikal radyografi dahil edildi. Periapikal radyografiler Gaziantep Üniversitesi Diş Hekimliği Fakültesi Çocuk Diş Hekimliği Anabilim Dalı arşivinden elde edildi. Python programlama dili ve Opencv-Pytorch-Numpy-Pandas-Torch-Vision-Torch, Tensorboard-Seaborn kütüphaneleri ile YOLOv8 modeli kullanıldı. Model performans başarısı, karmaşıklık matrisi kullanılarak değerlendirildi. Dişlerin numaralandırılması için karmaşıklık matrisi kullanarak hesaplanan duyarlılık, kesinlik ve F1-skor değerleri sırasıyla 0,915, 0,979, 0,946 olarak tespit edildi. Restorasyonların tespiti için duyarlılık, kesinlik ve F1-skor değerleri sırasıyla 0,954, 0,871, 0,911 olarak hesaplandı. Sonuç olarak bu çalışma, derin öğrenme tabanlı yapay zeka tabanlı algoritmalarının karışık dişlenme dönemindeki çocuklardan elde edilen periapikal radyografilerde süt ve daimi dişlerin numaralandırılması ve restorasyonların tespitini amaçlayan bu çalışmanın sonuçları umut vaat etmektedir.

Anahtar Sözcükler: Derin öğrenme, karışık dişlenme, periapikal radyografi, yapay zeka, YOLO

ABSTRACT

NUMBERING OF TEETH AND CLASSIFICATION OF DENTAL RESTORATIONS IN PERIAPICAL RADIOGRAPHS TAKEN DURING THE MIXED DENTITION PERIOD USING DEEP LEARNING METHOD

Büşra YÜCETÜRK

Specialization Thesis Department of Pediatric Dentistry

Supervisor: Assistant Professor Zehra GÜNER

February 2025, Pages 79

This study aims to evaluate the accuracy of tooth numbering and the detection efficiency of various restorations on periapical radiographs taken during the mixed dentition period using deep learning-based artificial intelligence models. Accurate tooth numbering and restoration detection on periapical radiographs are critical for effective treatment planning. The use of deep learning models enhances the speed and precision of treatment processes by automating the early diagnosis process. In this study, 1504 periapical radiographs of primary and permanent teeth from children aged 6 to 12 years were included for numbering in various diagnostic procedures, along with 1599 periapical radiographs to assess the effectiveness of automated restoration detection. These radiographs were obtained from the archives of the Department of Pediatric Dentistry, Faculty of Dentistry, Gaziantep University. The Python programming language, along with libraries such as OpenCV, PyTorch, Numpy, Pandas, TorchVision, and TensorBoard, was used with the YOLOv8 model. Model performance was assessed using a confusion matrix, with sensitivity, precision, and F1-score for tooth numbering calculated as 0,915, 0,979, and 0,946, respectively. For restoration detection, the sensitivity, precision, and F1-score were 0,954, 0,871, and 0,911, respectively. The results of this study suggest that deep learning algorithms are effective in accurately numbering teeth and detecting restorations on periapical radiographs of children in the mixed dentition period, demonstrating promising outcomes for clinical applications.

Keywords: Artificial intelligence, deep learning, mixed dentition, periapical radiography, YOLO

1. GİRİŞ VE AMAÇ

Diş çürükleri, şeker kaynaklı, biyofilm aracılı ve çok faktörlü olup, diş sert dokularının demineralizasyon ve remineralizasyon süreçlerini takip eden dinamik bir hastalıktır (1). Diş çürükleri, genellikle yavaş ilerler ancak zamanında müdahale edilmediği takdirde ağrı, enfeksiyon ve diş kayıplarına neden olabilen ciddi bir sağlık sorunu haline gelebilmektedir (2). Bu yüzden çürük lezyonlarının doğru ve erken tespiti, uygulanacak tedavi yönteminin belirlenmesinde kritik bir aşama olarak kabul edilmektedir (3). Tedavi süreci başlıca, klinik değerlendirme, çürük risk değerlendirilmesi, kesin tanının konulması, en uygun tedavi planının geliştirilmesi ve alternatif tedavi seçeneklerinin sunulmasını kapsamaktadır (4).

Diş hekimliğinde klinik ve görsel değerlendirmenin yanında yardımcı yöntem olarak radyolojik inceleme sıklıkla kullanılmaktadır (5). Tanıda görüntüleme tekniklerinden olan panoramik, periapikal ve bite-wing radyografiler kullanılmaktadır. Periapikal radyografilerde diş, alveoler kemik ve periodontal dokular görüntülenmektedir (6). Esas olarak pulpa ve kök kanal morfolojisinin değerlendirilmesi, periapikal patolojinin tespiti, kuron/kök kırıkları, restorasyonların incelenmesi, dental çürük lezyonların saptanması, tedavi öncesi değerlendirilme ve tedavi sonrası iyileşmenin izlenmesi için kullanılmaktadır (7). Diş hekimleri iyi bir eğitim almış olsalar da radyografik teknik hataları, kontrasttaki değişimler ve büyüme gibi bazı faktörler radyografilerin yorumlanması sırasında yanlış teşhislere neden olabilmektedir. Ayrıca diş hekiminin tecrübesi, bilgi birikimi ve radyografilerin değerlendirilmesi sürecindeki yorgunluk radyografik değerlendirmeyi etkileyebilecek diğer etmenler arasında yer almaktadır. Bu nedenle periapikal radyografilerde tanı ve tedavi planı sürecine katkıda bulunacak yapay zeka tabanlı otomatik tespit yönteminin geliştirilmesi, diş hekimleri için büyük bir önem taşımaktadır (8).

Yapay zeka, ilk defa 1950'lerde ortaya atılmıştır. Nesnelere ve kelimelere tanıma, problem çözme, karar verme gibi insan zekasının gerektirdiği karmaşık işlevleri taklit etmeye çalışan bir makinenin biyolojik olmayan yeteneği olarak nitelendirilmektedir (9,10). Makine öğrenimi, kendiliğinden öğrenebilen, bilgisayarlara insan müdahalesi olmadan otomatik öğrenme yeteneği sağlayan, algoritmalar oluşturmak için eğitim veri kümelerini kullanan bir yapay zeka alt grubudur (11). Makine öğrenimi birden fazla alt gruba

sahiptir. Bu alt gruplardan günümüzde en popüler olanı derin öğrenme algoritmalarıdır (12). Günümüzde, yapay zeka ve alt grubundaki derin öğrenme ve evrişimli sinir ağı (ESA) kullanılarak tıp ve diş hekimliği alanında tanı, görüntü tanıma, görüntü işleme ile ilgili yapılan araştırmalar giderek artmaktadır (13). Arşivlenmiş çok sayıda dijital görüntü, yapay zeka değerlendirmesi için radyolojinin veri sağlamasını kolaylaştırırken; yapay zeka algoritmaları, hastalıkların tespit edilmesinde giderek daha fazla uygulanmaktadır (8).

Diş hekimliğinde YZ, algoritmalar aracılığıyla manuel süreçleri otomatikleştirerek röntgen, ağız içi görüntüler ve bilgisayarlı tomografi taramaları gibi tanısal görüntüleri analiz ederek diş sorunlarını tanımlamaktadır (14,15). Son yıllarda yapay zeka algoritmaları, sefalometrik radyografilerde landmark tespiti, alveolar kemik kaybının değerlendirilmesi, kök morfolojisinin incelenmesi, üç ve iki boyutlu radyografilerde diş tespiti ve numaralandırılması, restorasyonların tespiti, dikey kök kırıklarının ve diş ve çene patolojilerinin tespiti, osteoporoz ve maksiller sinüzit değerlendirilmesi, diş çürükleri ve periapikal patolojilerin belirlenmesi gibi pek çok alanda kullanılabilmektedir (16).

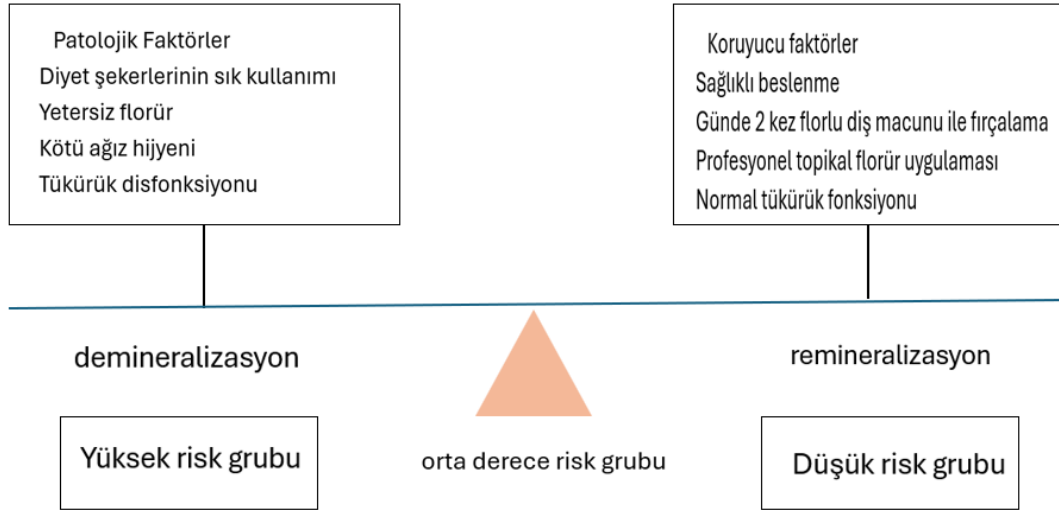
Bu çalışmanın amacı, karışık dişlenme dönemindeki çocuklardan alınan periapikal radyografilerde görüntülenen dişleri numaralandırmak ve farklı türdeki restorasyonların tespitinin etkinliğini derin öğrenme tabanlı yapay zeka modelleri ile değerlendirmektir.

2. GENEL BİLGİLER

2.1. Diş Çürüğü

Diş çürükleri, diş sert dokularının yapısı, diş yüzeyinde meydana gelen mikrobiyal biyofilm, diyet karbonhidratları (esas olarak şekerler), genetik etkiler ve tükürük arasındaki etkileşimleri içeren çok faktörlü dinamik bir hastalıktır. Dinamik diş çürük süreci, diş demineralizasyonu ve remineralizasyonunun hızla değişen dönemlerinden oluşur ve yeterli süre zarfında demineralizasyon daha fazla gerçekleşirse, dişin anatomik olarak çürüğe yatkın bölgelerinde çürük lezyonlarının oluşması başlayabilmektedir. (17).

Diş çürüğünün oluşumu ve ilerlemesini etkileyen koruyucu ve patolojik faktörleri dengelemek önemlidir. Koruyucu faktörler remineralizasyonu destekleyerek ve diş çürük lezyonunun durmasını teşvik ederken, patolojik faktörler dengeyi diş çürüğü başlangıcı ve çürük lezyonunun ilerlemesi yönünde kaydırmaktadır (17) (Şekil 2.1).



Şekil 2. 1. Diş çürük lezyonu oluşumunda patolojik ve koruyucu faktörlerin dengesi (17)

Dişler, oral mikrobiyotanın dişlere bağlanmasını kolaylaştıran ve glikoprotein ve proteinlerden oluşan bir tükürük zarı tabakasıyla kaplıdır. Dişlerin yüzeylerini kaplayan bu yapıya dental biyofilm denilmektedir. Biyofilm, mine yüzeyinin tükürük ve ağız boşluğu ile temasını engelleyerek diş yüzeyinde korumalı bir mikro ortam meydana getirir (18).

Biyofilm çok sayıda bakteri ve yan ürünleri içerebilir ve biyofilmin çürük oluşumu için kritik bileşeni Mutans Streptokok türleridir. Bu bakteriler karbonhidratları ve diğer şekerleri fermente ederek laktik asit ve benzeri asidik ürünleri oluşturmaktadır. Bu asitler diş sert dokularındaki minerallerin çözünmesine ve opak beyaz veya kahverengi alanların diş yüzeyinde oluşmasına neden olmaktadır (19). Mine yüzeyinde görülen opak beyaz nokta lezyonları, diş çürüğünün başlangıç aşamasında en erken belirtisidir. Opak beyaz nokta lezyonları tedavi edilmezse ve demineralizasyon devam ederse, bu lezyonlar mine yüzeyinde kavite oluşturarak boşluk oluşturmaktadırlar (20).

Opak beyaz nokta lezyonları geri dönüşümlüdür ve biyofilmin yeterli miktarda azaltılmasıyla herhangi bir aşamada minede kavitasyon gözlemlendiğinde bile durdurabilmektedir. Diş çürükleri, uzun süre tedavi edilmediği durumlarda çürüğün yapısına bağlı olarak pulpal enfeksiyonlarına yol açarak apikal periodontitis, periapikal apse, periapikal granülom, periapikal kist, selülit, osteomyelit gibi çeşitli patolojilere neden olabilmektedir (21,22).

2.2. Çürük Teşhis Yöntemleri

Diş hekimliğinde başarılı etkin bir tedavinin birinci aşaması, çürüğün doğru ve kesin teşhisinin yapılmasıyla olmaktadır (3). Çürük lezyonunun ideal tespitinde yöntemin; uygulaması basit, güvenilir, girişimsel olmayan ve özgül olması gerektiği savunulmuştur (23). Teknolojinin ilerlemesiyle çürük lezyonlarının tespiti için kullanılan yöntemlerin sayısı artmıştır ve giderek artmaya devam etmektedir (24,25).

Günümüzde yapılan araştırmalarda yapay zekaya dayalı çürük lezyonun teşhis ve tespit yöntemleri ilgi çeken bir konu olmaya başlamıştır (26,27). Çürük lezyonunun tespit yöntemleri, çürüğün daha erken belirlenmesini kolaylaştırarak veya varlığının objektif bir şekilde saptanmasını sağlayarak teşhis sürecini geliştirmeyi amaçlamaktadır (28).

Çürük lezyonun tespiti için kullanılan yöntemler; geleneksel ve güncel çürük tespit yöntemleri olarak değerlendirilmektedir.

2.2.1. Geleneksel Çürük Teşhis Yöntemleri

Çürük lezyonunun teşhisinde geleneksel yöntem, ilk olarak görsel muayene ile beraber sondla dokunma hissinin değerlendirilmesi ve radyografilerle desteklenmesiyle yapılmaktadır. Klinisyenler uzun yıllardır dental sond ve bite-wing radyografiler kullanarak renk değişikliğini, yüzeyin pürüzlülüğünü ve lokalizasyonunu değerlendirerek çürük lezyonunun varlığını subjektif olarak tespit etmektedir (22). Geleneksel çürük teşhis yöntemleri düşük sensitivite gösterdiğinden genellikle çürük lezyonlarının gözden kaçırılmasına neden olmaktadır (29).

2.2.2. Görsel ve Görsel-Dokunsal Yöntem

Çürük lezyonun görsel muayenesinde yalnızca iyi bir dental ışık altında göz ile tespiti yapılmaktadır. Görsel-dokunsal muayenede ise, iyi bir dental ışık altında dental plağın temizlenmiş olduğu diş yüzeylerinde pamuk rulolar ve hava su spreyi ile izolasyon sağlanarak dental sond ve ayna yardımı ile çürük lezyonunun tespiti yapılmaktadır (30). Fakat bu yöntem çürük lezyonunun büyüklüğü hakkında kesin bilgi sağlamamakta ve çürük lezyonunun teşhisi ve tespitinde yetersiz kalmaktadır (31).

Çürük lezyonunun değerlendirilmesi ve sonuçlarının standardizasyonu için Nyvad, Uluslararası Görsel Skorlama Sistemi (UniViSS), Uluslararası Çürük Teşhis ve Değerlendirme Sistemi (ICDAS) ve ICDAS II gibi çeşitli sistemler geliştirilmiştir (32–34).

Dental plakla kaplı diş yüzeyinde kullanılan ve keskin uçlu bir sond ile değerlendirme yapan sistem Nyvad iken; ICDAS II, dental plak bulunmayan diş yüzeylerinde kuru ve nemli koşullarda, yuvarlak uçlu bir sond kullanılarak değerlendirme yapan bir sistemdir (35).

2.2.3. Radyografik Yöntem

Radyografik yöntem çürük lezyonunun tespitinde en yaygın kullanılan yöntemlerden biridir. Temel çalışma prensibi, çürük lezyonu ilerledikçe mine ve dentinde görülen demineralizasyon sonucunda dişlerden geçen X ışını miktarının artması esasına

dayanmaktadır. Bu durum da görüntü reseptörüne radyografik yoğunluğun artması olarak kaydedilmektedir (36). Çürük lezyonunun radyografide belirlenebilmesi için demineralizasyonun yaklaşık %30-40 oranında gerçekleşmesi gerekmektedir (37).

Düz yüzeylerde kavite oluşturmuş çürük lezyonların teşhisinde gözle muayene etkili olmasına rağmen, kavitasyon oluşturmamış oklüzal ve ara yüzlerdeki çürük lezyonların tespitinde yetersiz kalmaktadır. Radyografik yöntem ise şüphelenilen bölgelerin değerlendirilmesinde avantaj sağlamaktadır (29).

Film bazlı geleneksel radyografiler, karanlık oda varlığını ve temizlenmesini, kimyasal banyo aşamalarını ve sınırlı saklama koşullarını gerektirmektedir. Bu dezavantajların sonuçları dijital radyografilerin ortaya çıkmasıyla aşılmıştır (7). Dijital radyografiler, hastaya veya uygulayan kişiye ek bir radyasyon maruziyeti oluşturmamaktadır ve alınan görüntüde densite, kontrast, görüntü yönü değiştirme gibi işlemlere izin vermektedir. Bunlara ek olarak radyasyon dozu daha düşüktür. Ayrıca görüntünün hızlı elde edilmesi, kolaylıkla bilgisayarda saklanabilmesi ve yönlendirilebilmesi dijital radyografilerin hızla popüler hale gelmesine neden olmuştur (38).

Fiyat olarak geleneksel radyografilere kıyasla pahalı olması, çözünürlüklerinin daha düşük olması, alveol kavsi dar olan ve rubber-dam altında tedavi yapılan hastalarda sensörün zor yerleştirilmesi dijital radyografilerin dezavantajlarından (39).

2.2.3.1. Panoramik Radyografi

Panoramik radyografi, maksillofasiyal iskelet sistemleri, dişleri ve dişleri destekleyen anatomik yapıları iki boyutlu gösteren ve en yaygın kullanılan ekstraoral radyografi tekniğidir. Kavisli yüzey yapıların tomografik görüntülerinin iki boyutlu yorumlanmasıdır. Dişlerin, maksiller sinüsün önemli bir kısmı dahil olmak üzere maksillanın, mandibular kemiğin, sert damağın ve her iki temporomandibular eklemin görüntülenmesini kolaylaştırır (40).

Diş hekimliğinde panoramik radyografiler; dental dokuların, patolojilerin (kist, enfeksiyon, tümör vb.) ve çene-yüz bölgesi kemiklerde oluşan travma yaralanmalarının incelenmesinde, tam dişsiz veya dişli hastalarda dentisyonun teşhis ve tedavi aşamalarında, süt ve daimi dentisyonun gelişiminin izlenmesinde, bulantı refleksi bulunan ve intraoral radyografi alınamayan yetişkin ve çocuk hastalarda,

temporomandibular eklem rahatsızlıklarında ön tanı konulmasına yardımcı olması amacıyla kullanılmaktadır (41).

Maksilla ve mandibulanın tek bir film aracılığıyla görüntülenmesi, hastanın daha az radyasyona maruz kalması, pozisyon kolaylığı ve zamandan tasarruf sağlaması, kısıtlı ağız açıklığı bulunan hastalarda kolaylıkla uygulanabilir olması ve uygulanması kolay olduğundan hastaların eğitimine kolaylık sağlaması panoramik radyografinin avantajlarından biridir. Panoramik radyografinin dezavantajlarından birkaçı ise; detay net değildir ve başlangıç çürük lezyonlarının ve periodontal hastalıkların tespit edilmesi zordur. Alınan görüntülerde magnifikasyon, büyüme, artefakt ve hayalet görüntü oluşumu gözlenmektedir ve alınan görüntüler geometrik distorsiyonlar içermektedir. İmaj tabakasının şekline uymayan ve fasiyal asimetrisi bulunan hastalardan alınan görüntülerde distorsiyon olması görüntünün çoğu zaman tek başına teşhiste yeterli olamamasına neden olmaktadır (41).

2.2.3.2. Periapikal Radyografi

Periapikal radyografi dişin kökle beraber çevre kemik anatomisini içeren intraoral radyografi tekniğidir (42). Bu radyografiler esas olarak pulpa ve kök kanal morfolojilerin değerlendirilmesinde, kuron ve kök kırığının tespitinde, alveoler kemik morfolojisinin izlenmesinde, tedavi öncesi planlamada, tedavi sonrası iyileşme ve takibinde kullanılırlar (7). Diş çürüklerinin tespitinde, pulpa dokusu ve uygulanan tedavi işlemlerinde, periodontal ligament, lamina dura devamlılığının ve dentin kalınlığındaki değişimlerin değerlendirilmesinde, çekim öncesinde ve endodontik tedaviler sırasında kök morfolojisinin incelenmesinde, dişlere ve çevresindeki anatomik yapılara gelen travma ve implant cerrahisinde periapikal radyografilerden yararlanılır. Küçük çocuklarda makroglossi varlığında, sığ damak yapısında, kısıtlı ağız açıklığına sahip hastalarda, periapikal radyografik muayene sırasında bazı zorluklar yaşanmaktadır. Bu nedenlerden dolayı çoğu hasta intraoral film/sensör yerleştirilmesini tolere edememektedir (43).

Periapikal radyografilerin alınması sırasında standardizasyonu sağlamak amacıyla aşağıdaki aşamalar uygulanmalıdır:

- 1) Hastanın film alınırken başı desteklenmeli ve dik pozisyonda oturması sağlanmalıdır.
- 2) Hastadan bir film alınacak olsa bile mutlaka kurşun önlük giydirilerek alınmalıdır.

- 3) X-ışını cihazı uygun kVp, mA ve yeterli ışınlama süresiyle ayarlanmalıdır.
- 4) İstenilen lokalizasyon bölgesine göre ışınlama süresi ayarlanmalıdır.
- 5) Reseptörün intraoral yerleştirilmesinden önce, dişlerin aksiyal eğimleri değerlendirilmelidir.
- 6) Reseptörün intraoral yerleştirilmesi sırasında görüntüyü değiştirebilecek toruslara, dişlerdeki çapraşıklıklara vb. dikkat edilmelidir.
- 7) Reseptörün intraoral yerleştirilmesinden sonra konumlandırmanın kolayca yapılabilmesi için tüp başlığı doğru pozisyonda konumlandırılmalıdır.
- 8) Reseptör, oral kavite içine doğru apikal taraf öncülüğünde konumlandırılmalıdır (44).

Periapikal radyografilerin sekonder çürük lezyonu tespitinde kullanıldığı bildirilmiştir (45). Talaipour, Nemati, Anaraki, Golpasha ve Heidarhan Tehrani yaptıkları araştırmada sekonder çürük lezyonlarının tespitinde periapikal radyografilerin etkili bir yöntem olduğu gösterilmiştir (46).

Periapikal radyografilerin iki boyutlu olması, tanı koymayı zorlaştıracak şekilde anatomik yapıların üst üste binmesi gibi sınırlamaları mevcuttur. Bunun yanında periapikal lezyonların görüntüsü, periodontal ligament aralığının genişliği ve alveoler kemik kalınlığı gibi anatomik yapıların bireysel varyasyonlarına bağlı olarak etkilenebilir (47).

Periapikal radyografiler, panoramik radyografilere göre daha detaylı görüntü elde etmektedirler (48). Periapikal lezyon tespitinde periapikal ve panoramik radyografiye kıyasla konik ışınlı bilgisayarlı tomografilerin daha net ve yüksek doğruluk oranlı görüntüye sahip olduğu bildirilmektedir. Periapikal radyografilerin ise panoramik radyografilerden daha net görüntüleme ve doğruluk sunduğu gösterilmiştir (49).

Periapikal radyografiler çekilirken 2 farklı teknik kullanılmaktadır. Birinci teknik paralel teknik, ikinci teknik ise açığortay tekniğidir. Paralel teknik aynı zamanda uzun kon tekniği ya da dik açı tekniği olarak da bilinmektedir. Bu tekniğin uygulama prensipleri; odak noktası küçük olmalı, diş ile reseptör paralel olmalı, ışınlar reseptöre ve dişe dik olarak gelmeli, odakla diş arası mesafe uzun olmalı, diş ile film arası mesafe olabildiğince kısa olmalıdır (42). Diş reseptör paralellliğini sağlayan paralel film tutucular, akrilik stentler, ısırma blokları bu teknikte kullanılabilir. Periapikal teknik standardizasyonunda x-ışını tüpü ile diş ve reseptör aynı düzlemde olduğundan her çekimde aynı görüntü elde

edilmektedir. Alveoler kemikteki küçük deęişimlerin deęerlendirilmesinde, endodontik kanal tedavisinde kk boyunun doęru saptanabilmesinde ve periodontal tedavi sonrası takibin yapılabilmesinde paralel teknik kullanılması nerilmektedir (44).

Aıortay teknięinin temel prensipleri; fokal spot kçük, fokal spot ile obje arası mesafe fazla, objenin film ile mesafesi mmkn olduęunca kısa olmalıdır. Bu teknikte film, alt enede aęız tabanına, st enede ise damaęa temas etmektedir. Dişlerin lingual/palatinal yzeylerine deęecek Őekilde intraoral yerleřtirilmelidir (44).

2.2.3.3. Bite-wing Radyografi

İntraoral bite-wing radyografi interproksimal alanda grlen ve klinikte zor tespit edilen rk lezyonlarının tespit edilmesinde en sık kullanılan radyografik tekniktir (50). Bununla birlikte tek seferde tm aęzın grntlenememesi dolayısıyla rk tespitinde aęzın her kadranından tek tek bite-wing radyografi alınması bu radyografinin dezavantajlarındanır (51).

Bite-wing Radyografi Tanı Hedefleri;

- Klinik olarak interproksimal rkleri grsel muayenede belirgin hale gelmeden tespit etmek,
- Dişlerdeki restorasyonların altında oluřan sekonder rkleri tespit etmek,
- Furkasyon ve interdental alandaki kemik kaybını deęerlendirmektir (44).

2.3. Diş rę Tedavi Planı

Diş rę tedavi planlaması patojenik risk faktrlerinin ortadan kaldırılmasını ve mevcut rk lezyonun tedavi edilmesini saęlayan iřlevsel srdrlebilir bir sretir. Bařlıca tedavi sreci, klinik muayene, rk risk deęerlendirilmesi, kesin tanı, en uygun tedavi planı geliřtirilmesi ve alternatif tedavi planlarının sunulmasını ierir. Bunların yanında uygulanacak tedavi planına hastanın da aktif olarak katılması saęlanmalıdır. Tedavi planı yapılırken teřhis srecine rk Őiddetinin deęerlendirilmesi (kavitasyonlu veya kavitasyonsuz vb.) ve rk aktivitesi de eklenmelidir. Aynı zamanda da teřhis ve tedavi planı ařamalarında bireyin rk risk deęerlendirilmesi dikkate alınmalıdır (4). rk lezyonunun prognozu hastanın genel sistemik hastalıkları ve oral unsurlarla yakından iliřkilidir.

Çürük yönetim sistemi 3 aşamadan oluşmaktadır.

- Bireyin çürük risk düzeyini belirleyerek çürük risk faktörlerini kontrol etmek,
 - Bireysel lezyonlara bağlı çürük tedavisi,
 - Çürük lezyon tedavisi zorluk değerlendirilmesi (52).
- **Çürük risk düzeyine göre çürük tedavisi**

Tedavi planı öncesi ve sonrasında çürük risk değerlendirilmesi yapılmalıdır. Çürük yönetimi boyunca da bu risk değerlendirilmesi göz önünde bulundurulmalıdır. Hastanın çürük risk tayini, hem mevcut durumdan ne kadar etkilendiğini yansıttığı için hem de ileri dönemde çürükten etkilenme derecesini tahmin ettiği için tedavi yapıldıktan sonra da koruyucu uygulamalarla ve hastanın kontrolleriyle beraber tüm süreci içermelidir. Örneğin CAMBRA' ya göre çürük risk sınıflamasına göre tedavi planı değişmektedir (53). Hastaların yapılan tedavilerden sonra 3, 6, 12. aylarda kontrollere çağrılmasıyla beraber yapılan tedaviler tekrar değerlendirilerek çürük risk yönetimi güncellenebilir (54). Tedavi planlaması, yüksek çürük riskli hastalarda düşük riskli hastalardakine göre farklılıklar içermelidir. Bu hastalarda diğer etiyolojik faktörler ve ağız hijyeninin yetersiz olması göz önüne alındığında yapılacak tedavilerin başarısı etkilenmektedir. Bu yüzden tedavi planlaması sırasında doğru teşhis konulması, restoratif tedavilerin yapılması ve kontrollerinin gerçekleştirilmesi, etiyolojik faktörlerin belirlenmesi ve ayrılması, koruyucu uygulamaların gerçekleştirilmesi gerekmektedir (55).

- **Bireysel lezyonlara bağlı çürük tedavisi**

Klinik muayenede aktif çürük lezyonlarının belirlenmesi, tedavi öncesi ve kontrollerinde tedavi planına doğrudan yardımcı olmaktadır. Durgun çürük lezyonları temel koruyucu faktörler (florürlü diş macunu kullanma) dışında invaziv bir müdahale gerektirmez. Girişimsel olmayan bu tedavinin tüm çürük lezyonlarını kontrol edebileceği doğrulanmıştır (56). Aktif çürük lezyonlarında ise kaviteye meydana geldiği zaman restoratif tedavilerin uygulanması gerekmektedir. Yani kaviteye oluşmamış inaktif çürük lezyonlarının invaziv bir tedaviye ihtiyacı yokken aktif çürük lezyonların çürüğün lokalizasyonuna bağlı, uygun restoratif tedavilerinin yapılması gerekmektedir. Çürük lezyonunun aktivitesinde, lezyonun kendiliğinden temizlenebilir bir yüzeyde olması,

tükürük ve remineralize ajanların kullanılması aktif lezyonların inaktif lezyona dönüşümünü mümkün kılmaktadır (57).

Restoratif tedaviler uygulanırken çürük lezyonun derinliğine (mine, dentin, sementi içermesine) lokalizasyonuna (oklüzal, aproksimal, kök) göre farklı yaklaşımlar uygulanmaktadır. Amerikan Diş Hekimleri Birliği'nin (ADA) 2018 yılında yayınladığı kılavuza göre kavitasyon oluşmamış pit ve fissür çürüklerinde fissür örtücü uygulamaları önerilmiştir. Kavitasyonlu pulpaya ulaşmayan çürük lezyonlarında estetik ve fonksiyonel ihtiyaçlar göz ardı edildiği durumlarda gümüş diamin florür ile restoratif olmayan tedaviler yapılabilmektedir. Yapılan çalışmalar, 6-12 ayda bir gümüş diamin florür uygulanan tedavinin aktif çürük lezyonunu durdurabildiğini göstermektedir (58,59).

Restoratif tedavi endikasyonu, kavitasyon oluşmuş çürük lezyonu temizlenemez ya da örtülenemez olduğu durumlarda konulmaktadır. Restoratif tedavi, dentin-pulpa kompleksini korumayı, çürük lezyon aktivitesini durdurmayı, fonksiyon, estetik, fonasyona katkı sağlamayı, biyofilmi kontrol altına almayı hedefleyen müdahale stratejisidir (52). Minimal invaziv tedavi yaklaşımlarında temel yaklaşım kavitasyon oluşmuş çürük lezyonlarında enfekte dentinin uzaklaştırılması ve etkilenmiş dentinin remineralizasyonu sağlayan restoratif materyalle kapatılmasıdır (60).

Çürük lezyon tedavisinde farklı restoratif tedavi yöntemleri kullanılmaktadır. Çocuk hastalarda yapılan bu tedaviler, diş dolgusu, amputasyon ve kanal tedavisi, yer tutucular olarak örneklendirilebilmektedir. Dolgu, çürük veya kırılmış dişlere uygulanan restoratif tedavidir. Kanal tedavisi, diş çürüğünün ilerlemesiyle dişin enfekte olması sonucunda uygulanan tedavi yöntemidir. Tedavide kök kanalları içerisinde bulunan diş siniri çıkartılmakta ve kök kanalları temizlenmektedir. Kök kanallarının yeniden doldurulmasıyla kanal tedavisi bitirilmektedir (61). Amputasyon tedavisi koronal pulpanın enfekte kısmı çıkarıldıktan sonra kalan kök pulpasının bakterisid bir materyalle kapatılmasıyla fonksiyonun sürdürülmesi yöntemidir (62). Çürüyen dişin çekilmesiyle oklüzyonun üzerindeki istenmeyen yükleri en aza indirmek ve boşluğu korumak amacıyla yer tutucular uygulanmaktadır (63).

- **Çürük lezyon tedavisi zorluk değerlendirilmesi**

Çürük lezyon tedavisinde zorluk değerlendirilmesi için temel faktörler; sistemik ve oral faktörleri, çürüğe karşı kişinin hassasiyeti, teknik duyarlılık, geçmiş tedavi deneyimi ve bazı destekleyici faktörleri içermektedir (64). Tedavide yapılan işlemler zorluk kademesine göre üçe ayrılmaktadır (65). Birinci derece düşük veya orta çürük risk grubu, ikinci derece yüksek çürük risk grubu, üçüncü derece aşırı yüksek çürük risk grubu olarak sınıflandırılmaktadır. Tedavinin zorluk sınıflandırılması ayrıca diş yüzeyindeki lokalizasyonuna, çürük lezyon derinliğine, tedavi tekniğine, restorasyonun durumuna, faringeal refleks veya dental fobiye, ağız açıklığı durumuna, tükürük sekresyonuna göre değişmektedir (52).

2.4. Dişlerin Sınıflandırılması

İnsanlarda süt ve daimi dişlenme olmak üzere iki çeşit dişlenme dönemi vardır. Her iki dişlenme döneminde de dişlerin farklı işlevleri ve morfolojileri vardır (66). Dişlerin bu karmaşık özellikleri, her dişin kadranına, türüne, maksilla ya da mandibulada olma durumuna göre sistematik olarak tanımlanma ihtiyacını doğurmuş ve bu yüzden dişlerin sınıflandırma sistemlerinin geliştirilmesine yol açmıştır. Diş çizelgesi ve numaralandırılması rutin klinik uygulamalarda bir bütünlük sağlamaktadır (67).

Her dişin arktaki yerini belirlemek amacıyla harf, sayı veya semboller kullanılarak diş sınıflandırması veya diş formülasyonu yapılmaktadır. Diş antropolojisinde ve diş hekimliğinde kullanılmak üzere en az on farklı diş sınıflandırılması geliştirilmiştir. Diş kayıtlarında Zsigmondy, Palmer, Universal ve FDI numaralandırma sistemleri yaygın olarak kullanılmaktadır (66,68).

2.4.1. Zsigmondy Numaralandırma Sistemi

Adolph Zsigmondy tarafından oluşturulmuş ilk sınıflama sistemidir. Daimi ve süt dişleri bu sistemde orta hattan arkaya doğru numaralandırılarak gösterilmektedir. Daimi dişler 1'den 8'e (1. kesicilerden 3. molar) kadar numaralandırılırken süt dişleri de I'den V'e Roma rakamlarıyla gösterilmektedir (66,69,70) (Şekil 2.2, Şekil 2.3).

| | | |
|-----|-----------------|-----------------|
| ÜST | 8 7 6 5 4 3 2 1 | 1 2 3 4 5 6 7 8 |
| ALT | 8 7 6 5 4 3 2 1 | 1 2 3 4 5 6 7 8 |

Şekil 2. 2. Zsigmondy daimi dişlenme numaralandırma sistemi (71)

| | | |
|-----|----------------|---------------|
| ÜST | V IV III III I | I II III IV V |
| ALT | V IV III III I | I II III IV V |

Şekil 2. 3. Zsigmondy süt dişlenme numaralandırma sistemi (71)

2.4.2. Palmer Numaralandırma Sistemi

Zsigmondy sisteminin bir modifikasyonudur. Mandibula ve maksilla kadranslara ayrılır ve daimi dişlenmede sağ maksillada son dişten başlanarak 1'den 32'ye kadar numaralandırma yapılır. Süt dişlenme döneminde ise her kadranda orta hattın başlayarak arkaya doğru A harfinden başlanıp E harfine doğru sıralama yapılır (70,72) (Şekil 2.4, Şekil 2.5).

| | | |
|-----|-------------------------|-------------------------|
| ÜST | 1 2 3 4 5 6 7 8 | 9 10 11 12 13 14 15 16 |
| ALT | 32 31 30 29 28 27 26 25 | 24 23 22 21 20 19 18 17 |

Şekil 2. 4. Palmer daimi dişlenme numaralandırma sistemi (71)

| | | |
|-----|-------|-------|
| ÜST | EDCBA | ABCDE |
| ALT | EDCBA | ABCDE |

Şekil 2. 5. Palmer süt dişlenme numaralandırma sistemi (71)

2.4.3. Universal Numaralandırma Sistemi (Cunningham Sistemi)

Dişleri numaralandırmak amacıyla kullanılan bu sistem Parreidt tarafından 1882 yılında teklif edilmiş ve Cunningham tarafından 1883 yılında kullanılmaya başlanmıştır. Daimi dişlenmede dişler sağ maksilla son diştten başlanarak saat yönünde 1'den 32'ye kadar numaralandırma yapılmaktadır. Süt dişlenme döneminde ise sağ maksilla son diştten başlanarak saat yönünde A ile T arasındaki harfler kullanılmaktadır (66,69,70) (Şekil 2.6, Şekil 2.7).

| | | | | | | | | | | | | | | | | | | |
|-----|-----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|---|
| R | ÜST | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | L |
| ALT | | 32 | 31 | 30 | 29 | 28 | 27 | 26 | 25 | 24 | 23 | 22 | 21 | 20 | 19 | 18 | 17 | |

Şekil 2. 6. Universal daimi dişlenme numaralandırma sistemi (71)

| | | | | | | | | | | |
|-----|---|---|---|---|---|---|---|---|---|---|
| ÜST | A | B | C | D | E | F | G | H | I | J |
| ALT | T | S | R | Q | P | O | N | M | L | K |

Şekil 2. 7. Universal süt dişlenme numaralandırma sistemi (71)

2.4.4. FDI (International Federation of Dentistry) Numaralandırma Sistemi

1987 yılında kullanılmaya başlanan bu sistem 1971 yılında Uluslararası Diş Hekimliği Federasyonu'nun bir toplantısında önerilmiştir. Bu sistemde mandibula ve maksilla kadranslara ayrılmıştır ve her bir çene için orta hatttan başlanarak diş numaraları sıralanmıştır. Dişlerin hangi tarafta olduğunu belirtmek için de daimi dişlenmede 1'den 4'e kadar süt dişlenme ise 5'den 8'e kadar çenenin sağ tarafından başlanarak sayılar sıralanmıştır. Günümüzde en çok kullanılan diş numaralandırma sistemidir (66,69,71,73) (Şekil 2.8, Şekil 2.9).

| | | |
|-----|-------------------------|-------------------------|
| ÜST | 18 17 16 15 14 13 12 11 | 21 22 23 24 25 26 27 28 |
| ALT | 48 47 46 45 44 43 42 41 | 31 32 33 34 35 36 37 38 |

Şekil 2. 8. FDI daimi dışlenme numaralandırma sistemi (71)

| | | |
|-----|----------------|----------------|
| ÜST | 55 54 53 52 51 | 61 62 63 64 65 |
| ALT | 85 84 83 82 81 | 71 72 73 74 75 |

Şekil 2. 9. FDI süt dışlenme numaralandırma sistemi (71)

2.5. Yapay Zeka (YZ)


Yapay zeka teriminin ilk kez ortaya çıkışı Dortmund Konferansı'nda 1956 yılında John McCarthy tarafından gerçekleştirilmiştir. McCarthy tarafından yapay zekanın tanımı “Zekanın ve öğrenmenin özellikleri en ince ayrıntılarıyla tanımlanırsa, bilgisayarlar bunları canlandırabilir ve insana benzer düşünebilir” şeklinde ifade edilmiştir (74). Alan Turing'in makine zeka testini yapmasıyla gerçek anlamda YZ ortaya çıkmıştır. Turing adı verilen bu zeka testi, bilgisayarla insan arasındaki etkileşimde, insan ve bilgisayar farkı ayırt edilemiyorsa o bilgisayarın insan kadar akıllı sayılması gerektiğini kabul etmektedir (75). Bu test ayrıca “Makineler düşünebilir mi?” sorusunu da ortaya çıkarmıştır (76).

Bir sorunu çözen makinelerin belirlenen bazı görevlerini, veri setlerini kullanarak yerine getiren ve veriler aracılığıyla öğrenebilen, insanın bilişsel davranışlarını ve zekasını taklit edebilen teknoloji YZ olarak tanımlanmaktadır (77).

1950'lerde ilk kez ortaya atılan YZ teriminin üzerine 1980'lerde makine öğrenimi terimi ve sonrasında derin öğrenme ve yapay sinir ağları (YSA) terimleri ortaya çıkmıştır (78).

Yapay karmaşık nöral bağlantı ağlarından meydana gelen sayısal metotlar bütününe YSA denilmektedir. Derin öğrenme ise karmaşık veri setlerini öğrenmek ve bu veri setlerinden çıkarım yapmak için çok daha fazla alt grupla beraber matematiksel işlemleri kullanan

bir yapay zeka sinir ağıdır (79). Venn diyagramı YZ ve alt gruplarının ilişkisini göstermektedir (80) (Şekil 2.10).



Şekil 2. 10. Yapay zeka alt gruplarının şematik görüntüsü (80)

2.5.1. Makine Öğrenimi

Makine öğrenimi algoritmaları, bilgisayar sistemlerinin tecrübelerinden öğrenmelerine izin vererek karmaşık veri setlerini algılama ve belirsiz durumların üstesinden gelme yeteneklerini yükseltir. Bu algoritmalar çok miktarda veri setini işleyebilir, karmaşık desenleri bulabilir ve bu desenleri esas alarak yeni bilgiler üretebilir. Gelişen öğrenme algoritmalarıyla beraber sistemler zamanla performanslarını artırabilir ve belirsiz durumlara uyum sağlayabilir. Ayrıca bu algoritmalar, günümüz yapay zeka sistemlerinin temelini meydana getirir ve uygulama alanları arasında doğal dil işleme, görüntü ve konuşma tanıma, öneri sistemleri gibi birçok konu bulunmaktadır (81).

2.5.2. Yapay Sinir Ağları (YSA)

İnsan beyni nöron yapısının modellenmesi 1943 yılında McCulloch ve ark. tarafından yapılmış ve insan beynine benzeyen bir şekilde bu modellemeden de yararlanılarak yapay sinir ağları (YSA) tasarlanmıştır. Yapay sinir ağları, insan beyninin nöronal yapısından esinlenerek ve matematiksel modellemeden oluşan nöronları birleştirerek bir ağ oluşturur (79,82). İnsan beynindeki bilgiyi depolama, kullanma, veri işleme, veri setlerini analiz etme ve yorumlama gibi işlevlerini taklit eden ve insana benzer kararlar alan akıllı sistemler oluşturmayı amaçlamaktadır (83,84).

Yapay sinir ağıları insan beynini taklit ederek benzer şekillerde regresyon, sınıflandırma ve kümeleme gibi işlevleri kolaylıkla öğrenebilmektedir. Makine öğrenme algoritmalarının yalnız başına çözemeyeceği sorunların üstesinden YSA gelebilmektedir (85). Yapay sinir ağlarının temel prensibi; verilen örneklerden bilgi toplayıp genellemeler yaparak öğrenme sürecini gerçekleştirmek ve ilk kez karşılaştığı örnekler hakkında öncesinde öğrenilen bilgilerden yararlanarak karar verebilmektir. Bu ağların en büyük üstünlüğü ve yeniliği olarak gösterilen öğrenebilme ve genelleme özellikleri sonucunda çağımızda birçok bilim alanında sıkça kullanılmaktadır ve karmaşık sorunları yüksek başarı derecesiyle çözebilmektedir (86).


Yapay sinir ağları genellikle sınıflandırma, tahmin, veri seti yorumlama, veri ilişkilendirme ve veri filtreleme gibi birçok işlevde kullanılmaktadır (87). Ayrıca yapay sinir ağlarının doğrusal olmama, paralel çalışma, uyarlanabilirlik, öğrenme, çok sayıda değişken ve parametre kullanma, genelleme, hata toleransı ve esneklik, eksik verilerle çalışma gibi birçok özelliği bulunmaktadır (88).

Yapay sinir ağı modelleri 4 grup altında değerlendirilmektedir. Bu gruplar:

- Tek katmanlı algılayıcılar
- Çok katmanlı algılayıcılar
- İleri beslemeli yapay sinir ağları
- Geri beslemeli yapay sinir ağları

Tek Katmanlı Algılayıcılar

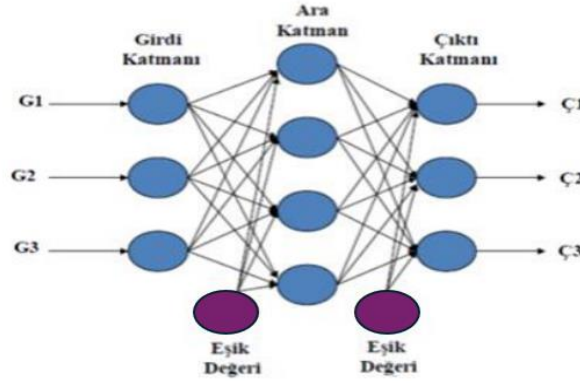
Tek katmanlı yapay sinir algılayıcılar sadece girdi ve çıktıdan oluşmaktadır ve çıktı fonksiyonu doğrusal olup en basit sinir ağı modelidir (Şekil 2.11) (89).



Şekil 2. 11. Tek katmanlı algılayıcı modeli (89)

Çok Katmanlı Algılayıcılar


Çok katmanlı yapay sinir algılayıcıları, aktivasyon fonksiyonu doğrusal olmayan birçok nöronun birbirleriyle bağlı olduğu yapıya denir (88) (Şekil 2.12).



Şekil 2. 12. Çok katmanlı algılayıcı modeli (88)

İleri Beslemeli Yapay Sinir Ağları

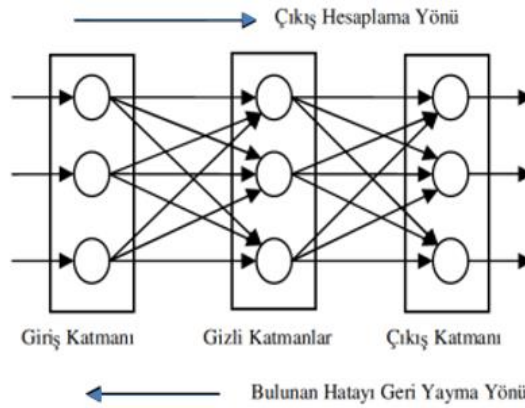
Bilgi akışının ileriye doğru tek yönlü ilerlediği yapay sinir ağı mimarisine ileri beslemeli sinir ağları adı verilmektedir. Bu ağlar girdi katmanından başlayarak veriyi katmanlar boyunca işler ve sonrasında çıktı katmanından varsayım ve netice üretir. Yapay sinir ağları özellikle doğal dil işleme, görüntü ve ses tanıma, regresyon, sınıflandırma gibi birçok uygulama alanında yarar sağlamaktadır (88) (Şekil 2.13).



Şekil 2. 13. İleri beslemeli ağ yapısı (88)

Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli ağlar hem ileriye hem de geriye veri akışı aktarabilmektedir. Bu yapı, doğrusal olmayan dinamik bir ağ modeli sergilemektedir. Temel prensibi, önceki adımlardan gelen bilgiyi belleklerinde saklayarak sonraki adımlarda kullanabilmektir. Bu ağlar, çoklu bağlantı kurabilme kabiliyeti sayesinde karmaşık ve çözümü sıkıntılı sorunların ve denklemlerin çıkış yolunda sıklıkla faydalanılan bir yol olarak ön plana çıkmaktadır (89) (Şekil 2.14).



Şekil 2. 14. Geri beslemeli ağ yapısı (88)

2.5.3. Derin Öğrenme

İnsan beynindeki nöronal yapıyı taklit eden yapay sinir ağları, daha çok veri ile daha karışık problemleri çözebilmek için derin öğrenme kavramına 21. yüzyılda evrilmiştir. Hilton'un 2006 yılında, çok katmanlı yapay sinir ağlarını daha etkin bir şekilde eğitebileceğini ifade etmesiyle derin öğrenme kavramı ortaya çıkmıştır (90). Çok fazla katmana sahip klasik sinir ağlarıyla kurulamayan yapay sinir ağları, modern hesaplama yöntemlerindeki hızlı ilerlemeler sayesinde derin öğrenme metodu ile kurulabilmektedir. Bu sayede derin öğrenme yöntemleri veri setlerindeki doğrusal olmayan ve çok karışık modelleri meydana getirebilmektedir. Çağımızdaki veri hacmi artışı ve karmaşıklığın büyümesiyle derin öğrenme yöntemlerinin popülaritesi artmıştır. Derin öğrenme yöntemi, ses tanıma, görüntü ve doğal dil işleme gibi birçok alanda başarıya sahiptir. Plaka tanıma, parmak izi okuyucuları, yüz tanıma, sürücüsüz araçlar, iris okuyucuları, istenmeyen posta/reklam belirleme ve tıpta teşhis-tedavi öneri sistemlerinin ilerlemesi gibi pek çok alanda kullanılmaktadır (91).

Derin öğrenme, veri temsillerinin geleneksel makine öğrenimindeki elle oluşturma gerekliliğini ortadan kaldırmıştır. Bu yöntemde veriler, sırasıyla katmanlarda işlenerek gitgide artan bir şekilde daha etkili temsiller meydana getirmektedir. Derin öğrenmenin popüleritesinin en önemli nedenlerinden birisi, özellik çıkarım görevini ağ içinde otomatik olarak yapabilmesidir. Günümüzde derin öğrenme yöntemi ile ilgili araştırmalar artan bir şekilde devam etmektedir (92).

Çeşitli derin öğrenme metotları bulunmakta ve bu metotların çözeceği problemlerin türüne ve boyutuna göre derin öğrenme algoritmaları değiştirilebilmektedir (93). Bu algoritmalar arasında evrişimli sinir ağı (ESA), uzun kısa vadeli hafıza (Long Short-Term Memory-LTSM), tekrarlayan sinir ağı (Recurrent Neural Network-RNN), sınırlı boltzman makineleri (RBM), derin inanç ağları (Deep Belief Network-DBN) ve derin otokodlayıcılar yer almaktadır (94).

2.5.3.1. Evrişimli Sinir Ağları (Convolutional Neural Network)

Yaygın olarak Evrişimli Sinir Ağları (ESA) ConvNet olarak bilinmektedir ve özellikle nesne belirleme ve görüntü işlemek amacıyla kullanılan güçlü sinir ağı çeşididir (95). Bu güçlü sinir ağı ileri beslemeli ve çok katmanlı bir yapıya sahiptir ve derin öğrenme metotları arasında en sık kullanılan sinir ağlarıdır. Daha çok sınıflandırma ve tespit işlevlerinde kullanılmaktadır. Evrişimli sinir ağları 17 sinir ağı içerisinde birden fazla aktivasyon katmanı, havuzlama katmanı, evrişim katmanı, tam bağlı katman, sınıflandırma katmanı ve bu katmanlara ek katmanlar yer almaktadır. Sınıflandırılacak öğelere ait özellikler tespit edilerek sınıflandırma katmanı ile öğelerin sınıflandırılması bu katmanlarda gerçekleştirilir. Sınıflandırma katmanında, her katman kendi işlevini gerçekleştirdikten sonra sonuçlandırılmaktadır (96).

Derin öğrenmenin eşsiz bir parçası sinir ağlarının eğitilmesidir. ESA'lar eğitilirken;

- Katman sayısı belirlenir ve sıralanarak ilk önce yapay zeka modelleri oluşturulur.
- Başlangıç değişkenleri belirlenir.
- Girdi verisi olarak bir görüntü eğitim setinden modele devredilir. İşlenen veriler her katmandan sıradaki katmana aktarılır. Bu katmanlar arasındaki aktarıma ileri besleme denir.
- İleri besleme basamağında veri setleri sinir ağına giriş yapar ve bu veriler işlenerek ağırlıklar hesaplanır. Bu işlemin yapılabilmesi için bütün katmanlardaki

nöronlara baştan sona doğru veri aktarımı olmalıdır. Böylelikle bütün veriler tüm ağ yapısı boyunca ilerler. (97)

Evrişimli sinir ağından elde edilen sonuç, amaçlanan sonuçtan farklı olduğu zaman meydana gelen hata (kayıp) bağlantı noktalarına gönderilerek geri besleme yapılmaktadır. Makinenin sağladığı sonucun iyi veya kötü olma hususu hata miktarı ölçülerek değerlendirilmektedir. Bulunan hata miktarı tersine doğru çıktıdan girdiye hareket etmektedir. Bu duruma da geri besleme denilmektedir. Bütün nöronlara hata sinyali dağılarak hatanın toplam değeri belirlenmekte ve bu sinyal katmanlar boyunca bütün nöronlara yayılarak sürmektedir (98).

2.5.3.2. Tekrarlayan Sinir Ağı (Recurrent Neural Network)

Tekrarlayan sinir ağlarının en çarpıcı özelliği, hafızaya sahip olma becerisidir. Bu ağlar, birimler arasında ilişkiler kurabildiği için zaman serilerine dayalı ve sıralı prosedürlerde başarılı sonuçlar sağlayan sinir ağı modelini temsil etmektedir. Her bir basamak işleminin bir önceki çıktıya bağlı olduğu bir çalışma prosedürüne dayanan sinir ağlarıdır. Özellikle görüntü işleme uygulamalarında her birimdeki bilgilerin kullanılabilir olması yüksek doğruluk sağlamaktadır. Bu durum ileri beslemeli ağlara göre tekrarlayan sinir ağlarının önemli bir avantajıdır (99).

2.5.3.3. Uzun Kısa Süreli Hafıza Ağları (LSTM)

Uzun vadeli bağımlılıkları ele almak üzere Hochreiter ve Schmidhuber tarafından 1997 yılında özel bir RNN olan LSTM tasarlanmıştır. Makine çevirisi, hisse senedi ücreti tahmini, resim yazısı, konuşma ve el yazısı tanıma ve rüzgâr hızı gibi pek çok alanda zaman serilerinin yeniden oluşturulması ve öngörülmesinde kullanılmaktadır. Yapılan birçok çalışmada derin ileri beslemeli sinir ağlarından ve diğer son teknoloji makine öğrenimi algoritmalarından daha iyi performans gösterdiği vurgulanmıştır (100).

2.5.3.4. Sınırlı Boltzman Makineleri (RBM)

Sınırlı Boltzman Makineleri, sınıflandırma, modelleme, regresyon ve boyutsallık azaltma gibi pek çok alanda kullanılabilen derin öğrenme metodudur (101). Sınırlı Boltzmann Makineleri iki katmanı içerir. Bu katmanlar, giriş verilerini kapsayan görünür katman ve bu verileri simgeleyen gizli katmandır. Bu iki katman arasındaki ilişkilerin ağırlıklarını

(güçlerini) öğrenerek veri üzerinde niteliklerin temsilini öğrenmeyi amaçlamaktadır (102).

2.5.3.5. Derin İnanç Ağları (DBN)

Geoffrey Hinton tarafından ortaya atılan DBN, arka arkaya eklenen Sınırlı Boltzman Makinelerinden oluşmaktadır. Her RBM katmanı kendinden önceki ve sonraki katmanla ilişki kurarak çalışmaktadır. Ancak herhangi bir katmanın düğümleri kendileriyle yatay olarak iletişim kurmazlar. Softman katmanı son katman olarak bulunmaktadır ve denetimsiz öğrenme ve sınıflandırma için kümeleme kabiliyeti bulunmaktadır. DBN' ler ayrıca görüntü üretme ve tanıma gibi alanlarda fayda sağlamaktadır (102).

2.5.3.6. Derin Otokodlayıcılar

Derin otokodlayıcılar sıklıkla kodlayıcı, kod çözücü ve kod olmak üzere üç temel bileşenden oluşmaktadır. Bu sistem girdileri çeşitli gösterimle değiştirebilecek şekilde tasarlanmıştır. Bu kodlayıcılar boyutunu küçülterek ve girdiyi kodlayarak gerçek girdiyi kopyalama gayesi gütmektedir. Ancak görüntü düzgün görünmüyorsa, yorumlama için bir sinir ağına aktarılmaktadır. Netleştirilmiş görüntü daha sonra yeniden oluşturulmuş görüntü olarak isimlendirilmektedir. Bu görüntü de önceki görüntü kadar uygun olabilmektedir (103).

2.5.4. Derin Öğrenmede Görüntü Segmentasyonu

Yapay zeka üç farklı teknik kullanarak görüntü üzerinde analiz yapar. Bunlar sınıflandırma, nesne algılama ve segmentasyon tekniğidir (104).

- **Sınıflandırma:** Görüntüdeki bir ögenin hangi sınıfa uygun olduğunu tahmin etmeyi belirtmektedir. Tüm görüntünün “insanlar”, “hayvanlar” veya “açık hava” gibi sınıflara ayrılması örnek olarak verilebilmektedir (105,106).
- **Nesne algılama:** Bir görüntüdeki nesnelere algılama ve ilgili nesnelere etrafına dikdörtgen çerçeve çizmeyi ifade etmektedir (örneğin bir koyun veya bir kişi) (106,107).
- **Segmentasyon:** Görüntüdeki bir yapıyı geri kalan unsurlardan ayırmayı ifade etmektedir. Görüntünün sınırlarıyla beraber hangi nesneye uygun olduğunu belirtmektedir (Örneğin bir organın sınırlarının ve bilgisayarlı tomografide pulmoner embolinin tespiti) (106,108). Bu teknikte nesne parçalarını ve nesnelere

“süper pikseller” meydana getirmektedir. Segmentasyon tekniği tek tek pikselleri gözlem birimleri olarak ele almak yerine daha büyük bileşenler üzerinde çalışmayı hedeflemektedir (109).

Tam evrişimli ağlar, çok ölçekli ve piramit ağ tabanlı modeller, grafik modellenmiş evrişimli modeller, bölgeye dayalı evrişimli sinir ağı tabanlı modeller, tekrarlayan sinir ağı tabanlı modeller, genişletilmiş evrişimli modeller, aktif kontur modeller, dikkat tabanlı modelleri ile kodlayıcı-kod çözücü tabanlı modeller, evrişimli modeller derin öğrenme tabanlı segmentasyon modellerine örnek verilebilmektedir (104).

2.5.5. Kodlayıcı- Kod çözücü Modeller

Kodlayıcı- kod çözücü modeller görüntü segmentasyonunda sıklıkla kullanılan modellerdir. Bu kodlayıcılar pek çok derin öğrenme tabanlı segmentasyon çalışmalarında kullanılmıştır. U-Net ve V-Net en iyi bilinen derin öğrenme mimarileri arasında bulunmaktadır (104,109,110).

U-Net tıbbi görüntü analizi için geliştirilen, sınırlı miktarda veri seti kullanarak görüntüleri hassas bir şekilde kısımlara ayırabilen, ESA tabanlı görüntü segmentasyon tekniğidir. Genişletilebilir, basit, esnek bir yapıdadır ve piksel düzeyinde yüksek nitelikte bölütleme sonuçları aktarmaktadır. Bu özelliklerinden dolayı tıbbi görüntüleme yüksek bir başarı sağladıklarından U-Net ve varyasyonları yaygın olarak kullanılmaktadır. U-Net'in tıp ve çeşitli alanlarda kullanım potansiyeli her geçen gün artmaktadır. MR taramaları, bilgisayarlı tomografi taramaları, X ışınları ve mikroskopiye kadar pek çok görüntü alanında faydalı sonuçlar vermektedir (111).

U-Net mimarisi medikal görüntüler üzerinde görüntü segmentasyonunda en başarılı ESA yöntemlerinden biri olarak öne çıkmaktadır. Bu mimari kod çözme ve kodlama kısımlarından meydana gelmektedir. Kodlama işlemi VGG tarzı bir ESA modelinden oluşmaktadır ve özellik kanallarının yukarı evrişim yinelenmesiyle kod çözme işlemi gerçekleşmektedir (112,113).

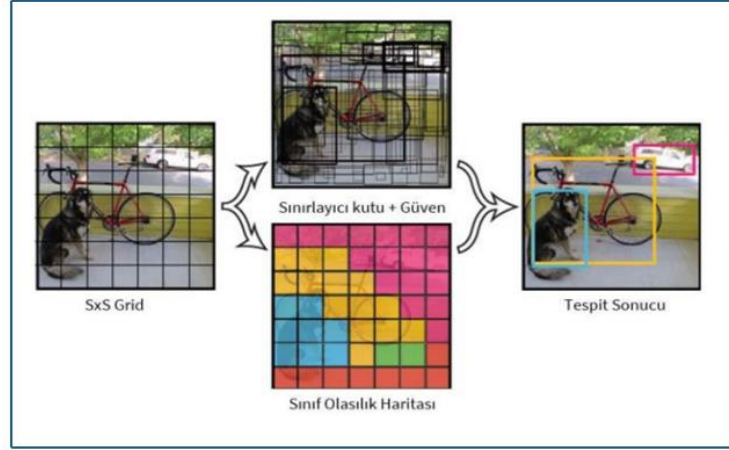
2.5.6. Derin Öğrenme Yöntemlerinin Nesne Tespitinde Kullanılması

Evrişimli sinir ağlarının planlanması, farklı ölçeklerdeki görüntüler üstünde pek çok görsel sorunların çözülmesi hedefini taşımaktadır (114). Bu sorunların çözülmesinde nesne tespiti yapan, ESA mimarisi içeren nesne belirleme

dedektörlerinin yeniden boyutlandırıldığı girdi bölümü, veri setinin özellik haritalarını bulundurduğu omurga bölümü, özellik haritalarının bir arada bulunduğu boyun bölümü ve nesne belirleme dedektörünün öngördüğü çıktıları bulundurduğu baş bölümü bulunmaktadır (115). Fast R-CNN, Faster R-CNN, R-CNN, YOLO (You Only Look Once), SSD (Single Shot Multi Box Detector), ESA tabanlı ve nesne belirlemede başarılarını kanıtlamış derin öğrenme algoritmalarındandır (116,117).

Fast R-CNN, R-CNN algoritmalarının negatif özelliklerinin iyileştirilmesi ve model tahmin hızını arttırarak verimi yükseltmek amacıyla tasarlanmıştır (116,118). Faster R-CNN, iki basamaklı, Fast R-CNN ve tümü ESA mimarisinden oluşan bölge öneri ağından meydana gelmektedir (119). R-CNN algoritmaları ile nesne belirlemenin zor ve yavaş olmasının sebebi, her bölge için ayrı ESA kullanılması ve görüntüde izlenen ve belirlenen nesnelerin bölgelere ayrılmasıdır. Bu algoritma ayrıca ESA tabanlı nesne belirlemede kullanılan ilk yöntemdir (120). SSD tek bir evrişimli sinir ağından meydana gelmektedir ve çok daha yüksek hızlarda tahmin yapabilmektedir (117).

YOLO, nesne belirlemede başarı ve hızı yüksek olan ESA tabanlı bir tekniktir. Görüntüde izlenen nesnelerin tahminlerini gerçek zamanlı yapabilen, tek bir evrişimli sinir ağı içeren, sade ve hızlı bir nesne tespit dedektörüdür (120). YOLO algoritması, insan görüntü sisteminin, görüntüdeki nesnelerin birbirlerini nasıl etkilediklerini ve nerede bulunduğunu eş zamanlı olarak algılayabilmesinden esinlenerek geliştirilmiştir (121). YOLO algoritması, görüntüdeki belirli bölgeleri seçmek yerine, görüntüyü analiz ederek bölgeleri tanımlamakta ve görüntü etrafına sınırlayıcı kutular çizebilmek için görüntünün tamamına sinir ağı uygulamaktadır (122). Diğer derin öğrenme yöntemleri, genellikle görüntü üzerinde nesnelerin bulunma olasılığı yüksek alanları tespit edip, ardından sınıflandırıcılarla nesnelere belirlemeye çalışırken, YOLO bu işlemi tek adımda gerçekleştirebilmektedir (107) (Şekil 2.15).



Şekil 2. 15. YOLO nesne tespit aşamaları

YOLO, Redmon ve arkadaşları tarafından 2016 yılında yayımlanmış gerçek zamanlı bir algoritmadır. Nesne algılamada, sınırlayıcı kutu konumları, görüntü pikselleri ve olasılık sınıflarını tek bir regresyon problemi olarak çözümlenmektedir. 2017 yılında algoritmasının hızını, duyarlılık ve doğruluk oranını iyileştiren YOLOv2 yayımlanmıştır. 2018 yılında, algoritmanın nesne algılama performansını daha da geliştirerek küçük, yoğun ve üst üste çakışan nesnelere algılama yeteneği olan YOLOv3 yayımlanmıştır. 2020 yılında çok daha hızlı ve doğru sonuç veren YOLOv4 geliştirilmiştir (123). YOLOv5, 2020 yılında YOLOv4'ten birkaç ay sonra yayımlanmıştır ve Pytorch'ta geliştirilmiştir (124). Eylül 2022'de YOLOv6 ve Temmuz 2022'de YOLOv7 geliştirilmiştir. YOLOv8, Ultralytics tarafından Ocak 2023'te yayımlanmıştır (125).

YOLO mimarisinin en son versiyonlarından olan YOLOv8, pek çok önemli değişim sunmakta ve son işlem teknikleriyle donatılmaktadır. YOLOv8, FPN ve PAN modüllerini entegre ederek çalışmaktadır. FPN, özellik kanallarının sayısını artırıp giriş görüntüsünün çözünürlüğünü aşamalı olarak azaltmaktadır. Bu durum çeşitli ölçek ve farklı çözünürlüklerdeki nesnelere tanımlayabilen özellik haritalarının meydana gelmesini sağlamaktadır. PAN modülü ise ağırlıklı farklı katmanlarından özellikleri toplayarak, çeşitli şekil ve boyutlardaki nesnelere doğru bir şekilde tanımlama yeteneğini arttırmaktadır (126). YOLO modülleri boyutlarına göre nano (n), küçük (s), orta (m), büyük (l), ekstra büyük (x) olarak düzenlenmiştir. Daha küçük modeller daha hızlı yürütme süresi ve daha düşük doğruluk oranı sunarken, daha büyük modeller daha yavaş yürütme süresi ve daha yüksek doğruluk oranı sunmaktadır (127).

2.5.7. Derin Öğrenme Kütüphaneleri

Derin öğrenme mimarilerini ve yapay sinir ağlarını eğitmek ve geliştirmek için kullanılan yazılım metotları derin öğrenme kütüphaneleridir. Derin öğrenme kütüphaneleri büyük veri setlerinden örüntüler elde etmek ve derin öğrenme mimarilerinin işlevlerini uygulamak için geliştirilmiştir (78).

PyTorch: Facebook tarafından geliştirilen bir başka açık kaynaklı derin öğrenme kütüphanesidir. Esnek bir kullanım ve dinamik hesaplama grafikleri oluşturma yeteneği sunmaktadır (78).

TensorFlow: Google tarafından geliştirilen bu açık kaynaklı derin öğrenme kütüphanesinde, grafik tabanlı bir hesaplama modeli kullanılmaktadır ve geniş bir topluluk desteği bulunmaktadır (78).

Keras: UC Berkeley tarafından geliştirilen ve genellikle bilgisayar görüşü uygulamalarında kullanılan hızlı bir derin öğrenme kütüphanesidir (78).

MXNet: Apache MXNet, esnek, ölçeklenebilir ve birden fazla dilde destek sağlayan derin öğrenme kütüphanesidir. Dağıtılmış eğitim kabiliyeti sunmaktadır (128).

Bu kütüphaneler, farklı ihtiyaçlara ve seçimlere sahip geliştiriciler için çeşitli avantajlar sağlamaktadır. Derin öğrenme kütüphanesinin hangisinin seçileceği projenin ihtiyaçlarına, geliştirme deneyimine ve topluluk desteğine bağlıdır (128).

2.6. Derin Öğrenme ve Diş Hekimliği

Yapay zeka tabanlı sistemler, hızlı bir şekilde gelişmekte ve pek çok alanda olduğu gibi diş hekimliği alanında da son yıllarda etkili olup sıklıkla kullanılmaya başlanmıştır (129). Günümüz çağında internetin ve bilgisayarların gelişimi, kolay erişilebilirliği ve diş hekimliği alanında YZ ile işlenebilecek veri setlerinin varlığı bu gelişmeleri artırıcı bir etki niteliğindedir. Diş hekimliğinde hem hasta klinisyen iletişimi aşamalarında hem de pek çok klinik prosedürlerde teknolojik gelişmeler büyük önem taşımaktadır (130). Yapay zeka tabanlı algoritmalar dental asistanlarla beraber hasta randevuları düzenlemekte ve böylece hasta belgelerinin yönetimi daha kolay ve verimli olmaktadır (131). Bunlara ek olarak hastaların tıbbi ve dental anamnezi kaydedilmekte, alkol ve sigara kullanımı gibi kötü alışkanlıkları öğrenilerek hekimler bilgilendirilmektedir.

Böylece aynı zaman sürecinde eşsiz veri tabanı sayesinde hasta için oluşturulmuş süreç hızlanmakta ve hasta takibi daha kolay hale gelmektedir (130). Tüm bunların sayesinde insan gücü ve vaktinden tasarruf edilmekte, insan kaynaklı hatalar minimuma indirilmekte, maaliyetler azaltılmaktadır (78).

Diş hekimliğinde YZ, teşhis sürecini daha doğru ve verimli hale getirerek tedavinin en iyi sonucunu elde etmek amacıyla kullanılmaktadır. Teşhis koymak ve en uygun tedaviye karar vermek için diş hekimlerinin sahip oldukları tüm bilgileri etkili bir şekilde kullanmaları gerekmektedir. Ancak bazen sınırlı bir süre zarfında doğru klinik kararı vermek zor olabilmektedir. Yapay zeka mimarileri daha doğru kararlar alabilmeleri için diş hekimlerine rehber görevi görebilmektedir (78).

Yapay zeka algoritmaları, otomatik diş tespiti ve doğrulanması için panoramik filmlerde bulunan ayırt edici etkenlerden faydalanabilmektedir. Ek olarak sadece dişlerin ve çevresindeki anatomik yapıların ayrıntılı görüntüsünü sunan periapikal filmler, yapay zeka tabanlı diş numaralandırma sistemlerinin hassasiyetini arttırmaktadır. Periapikal filmlerin alınması, diş morfolojisindeki küçük değişikliklerin ayırt edilmesini ve kesin tanımlanmasını kolaylaştırmaktadır. Doğru diş segmentasyonu ve tanımlanmasının, teşhis konulmasından tedavi planlanmasına kadar etkili klinik kullanımları bulunmaktadır. Yapay zeka tabanlı segmentasyonun fayda sağladığı 3 boyutlu bilgiler, diş hekimliği prosedürlerinin etkinliğini artırarak diş hekimlerin karmaşık anatomik yapıları daha yüksek hassasiyetle tanımlamasına olanak sağlamaktadır (132). Son dönemlerde yapay zeka tabanlı algoritmalar kullanılarak konik ışınli bilgisayarlı tomografi görüntüleri ile dişlerin otomatik tespiti ve sınıflandırılması arařtırmaları da bulunmaktadır (133).

Ağız, diş ve çene radyolojisi alanında sefalometrik radyografilerde landmark tespiti, alveolar kemik kaybı tespiti, kök morfolojisinin incelenmesi, üç ve iki boyutlu radyografilerde diş tespiti ve numaralandırılması, dişlerde çürük ve periapikal patoloji tespiti gibi pek çok alanda kullanılabilir (134,135). Ayrıca yapay zeka modelleri, ağız hastalıklarının teşhisinde, ağız kanserleri ve ağız kanserleri gelişme riski taşıyan hastaların belirlenmesinde, ortodontide büyüme ve gelişimin izlenmesinde, kemik yaşının el-bilek radyografileriyle yorumlanmasında, dişlerin nasıl ve ne kadar hareket ettirilmesi gerektiğinin belirlenmesinde ve uygulanması gereken basınç miktarının ölçülmesinde kullanılmaktadır (16). Evrişimli sinir ağı tabanlı yapay zeka algoritmaları

dikey kök kırıklarını, diş ve çene patolojilerini, osteoporozu ve maksiller sinüziti değerlendirmek için kullanılmaktadır (136).

2.6.1. Çocuk Diş Hekimliğinde Yapay Zeka

Çocuk diş hekimliği, diş hekimliğinin bütün alanlarını içeren, çocuklar ve ergenler için hem tedavi edici hem de koruyucu tedavileri sağlayan yaşa özelleşmiş geniş tedavi alanı bulunan bilim dalıdır (137). Günümüzde çocuk diş hekimliğinde davranış yönlendirme tekniklerinde kayda değer önemli ilerlemeler meydana gelmiştir. Çocuklarda gözlenen kaygıyı azaltmak, iş birliğini teşvik etmek, ağız sağlığının olumlu sonuçlarını güçlendirmek için geleneksel yöntemler yenilikçi yaklaşımlarla iyileştirilmiştir (138).

Yapay zeka algoritmaları ile özellikle ağrı kontrolü, hasta ve ebeveyn eğitimi ve davranış yönlendirme teknikleri gibi pek çok alanda çalışmalar yapılmaktadır (139). Yapay zekanın gerçek zamanlı duygu tanıma yeteneği, diş hekimlerinin bir çocuğun kaygı seviyesindeki değişiklikleri izlenmesine ve bu değişikliklere uygun şekilde, rahatlatıcı veya duraklatıcı tepkiler vermelerine olanak sağlamaktadır (138).

Çocukların ağız sağlığının doktorlar tarafından değerlendirilmesi, tedaviye olan ihtiyaçlarının belirlenmesi için çok önemlidir. Bununla birlikte klinik tanı her durumda evrensel olarak uygulanabilir olmayabilir ve tedaviye olan erişimi çeşitli faktörlere bağlı olarak değişkenlik gösterebilir (9). Wang ve arkadaşları, sosyodemografik faktörleri kullanarak çocukların ağız sağlığı ve tedavi ihtiyaçlarını değerlendirmek için bir algoritma oluşturduğu çalışmada hem çocuklara hem de ebeveynlere yönelik anket ile veri toplamıştır. Bu yöntemin diş profesyonellerine erişimin olmadığı bölgelerde ebeveynler ve okul personelleri için kullanılabilir olduğunu öne sürmektedirler (140).

Park ve arkadaşları erken çocukluk çağı çürüklerinin tespiti amacıyla şeker tüketimi ve alerjik hastalık gibi risk faktörlerini incelediği, 4195 çocuğun verilerinin makine öğrenmesine dayalı analizinde erken çocukluk çağı çürüğünün yüksek risk gruplarını tahmin etmede olumlu sonuçlar verdiğini göstermiştir (141).

Yapay zeka, derin öğrenme modelleri kullanarak mesiodenslerin teşhisinde faydalı olabilmektedir. Panoramik radyografilerde süpernumerer dişlerin gözden kaçırılması genellikle genç ve deneyimsiz diş hekimlerinin tarama performansına bağlı olmaktadır. Ayrıca pek çok genel diş hekimi, çocuklardaki karışık dişlenmeyi doğru teşhis etmede

zorlanmaktadır. Bu zorlukların üstesinden gelmek için ESA tabanlı derin öğrenme, süpernumerer dişlerin tespiti konusunda etkili bir çözüm sunabilmektedir. Ahn ve arkadaşları (142), mesiodenslerin tespiti için kullandıkları derin öğrenme modelinin, sınırlı deneyime sahip klinik uzmanların daha doğru teşhisler koymalarına yardımcı olabileceğini ifade etmişlerdir. Ayrıca mesiodenslerin sınıflandırılmasında daha derin ağlar kullanılarak daha yüksek doğruluk elde edilmiştir. Bazı derin öğrenme modellerinin, insan değerlendirilmesine kıyasla daha hızlı sonuçlar ürettiği fakat doğruluk oranlarının biraz daha düşük kaldığı görülmüştür (143). Kim ve arkadaşları da mesiodenslerin tespiti için derin öğrenme modelleri kullanmışlardır ve araştırmalarında otomatik bir yöntemle tespitin mümkün olduğunu fakat mesiodensin sayısı ve tam pozisyonunun belirlenemediğini belirtmişlerdir (144).

Diş yaşının belirlenmesinde genellikle klinik ve pantomografik yöntemler kullanılır. Klinik yöntem uygulanması kolay ve hızlı sonuçlar sağlasa da sıklıkla yanlış sonuçlar verebilmektedir. Pantomografik yöntem ise diş tomurcuklarının mineralizasyon aşamasını değerlendiren daha hassas bir yaklaşımdır. Zaborowicz vd. (2021), dijital pantomografik görüntüler ve sinir modellemesi kullanarak 4-15 yaş aralığındaki çocukların kronolojik yaşını belirlemek için yeni bir yöntem geliştirmiştir. Bu yöntem basit olması, yüksek doğruluk sağlaması, pantomografik görüntülerde metrik yaş değerlendirmesi yapabilmesi nedeniyle kullanılan ilk yöntemlerden birisidir (145). Benzer şekilde Zaborowicz vd. (2022), yaptığı diğer çalışmada üç derin sinir ağı modeli ile 4-15 yaş arası çocuk ve ergenlerin diş ve kemik göstergelerini kullanarak biyolojik yaşı doğru bir şekilde belirleyebildiğini göstermiştir (146).

Hangi dişlerin diş hastalıklarından etkilenip etkilenmediğini belirleyen ve bunları tespit eden otomatik, karmaşık tespit sistemleri diş tanımlama sürecinin temelini oluşturmaktadır. Araştırmacılar, dişleri sınıflandırmak ve numaralandırmak için çeşitli teknikler geliştirmiştir (143). Evrişimli sinir ağları tabanlı algoritma, otomatik diş segmentasyonu konusunda daha yüksek doğruluk oranları sergilemektedir (147).

Kaya ve arkadaşları ESA tabanlı model olan YOLOv4 kullanarak otomatik diş tanıma için derin öğrenme sistemini kullanmıştır. YOLOv4 mimarisi ile hem süt dişleri hem de kalıcı dişleri tanımlayabilmiştir. YOLOv4, tek bir görüntüdeki nesnelere tanımlayabilen ve sınıflandırılabilen tek aşamalı bir dedektör mimarisidir. YOLO, gerçek zamanlı nesne

tanımlama yapabildiği ve çok farklı nesne sınıflamalarında ortalamanın üstünde sonuçlar verebildiği için diğer ESA algoritmalarından ayrılmaktadır (148).

Jagtap ve arkadaşlarının yaptığı araştırma, 18 yaş ve üzeri hastalardan alınan periapikal radyografilerde dişler, diş çürükleri, implantlar, restorasyonlar ve sabit protezlerin otomatik olarak tespit edilmesinde derin öğrenmeye dayalı YZ sistemlerinin potansiyelini ortaya koymaktadır (149). Başka bir çalışmada 18-65 yaş arası alınan bite-wing radyografilerinde sarkan diş restorasyonlarının tespiti ve teşhisinde yapay zekanın oldukça etkili olduğunu göstermektedir (150).

Yetişkin hastalardaki restorasyonları ve başarısızlıklarını tahmin etmek ve dişleri numaralandırmak için yapay zeka algoritmalarının kullanımı son birkaç yılda giderek artmıştır, bu durum literatür taramamızda gözlemlenmiştir. Karışık dişlenme dönemine ait çocuklardan alınan radyografilerde bu çalışmaların yetersiz olduğu gözlenmektedir. Bu çalışmanın amacı, ESA tabanlı yapay zeka modelleri ile karışık dişlenme döneminde alınan periapikal radyografilerde dişlerin numaralandırılması ve dental restorasyonların otomatik tespit etkinliğinin değerlendirilmesidir.

3. GEREÇ VE YÖNTEM

Çalışma protokolü Gaziantep Üniversitesi Müdahalesiz Klinik Araştırmalar Etik Kurulu Başkanlığı'nın 11.09.2024 tarih ve 2024/324 sayılı kararı ile onaylanmıştır (EK-1). Çalışma, Gaziantep Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından DHF.UT.24.13 numaralı proje ile desteklendi ve çalışma Gaziantep Üniversitesi Çocuk Diş Hekimliği Anabilim Dalı'nda yürütüldü.

Bu çalışmada 2018-2024 yılları arasında 6-12 yaş aralığında çeşitli tanısal amaçlarla alınmış periapikal radyografiler Gaziantep Üniversitesi Diş Hekimliği Fakültesi Çocuk Diş Hekimliği Anabilim Dalı arşivinden kullanılmıştır. Periapikal radyografiler isim, cinsiyet gibi bilgiler dikkate alınmadan anonim olarak taranmıştır ve JPEG formatında kaydedilerek çalışmaya dahil edilmiştir.


Bu çalışmaya karışık dişlenme dönemine ait süt ve daimi dişlerin numaralandırılması amacıyla 1504, restorasyonların otomatik tespit etkinliğinin değerlendirilmesi için 1599 periapikal dahil edilmiştir. Alınan periapikal radyografiler ProX periapikal X-ışını ünitesi (Planmeca, Helsinki, Finlandiya) kullanılarak dijital olarak elde edilmiştir.

Dahil edilme kriterleri arasında hastaların 6-12 yaş aralığında bulunması, hastaya ait periapikal radyografinin yeterli netlikte görüntü kalitesine sahip olması, görüntü yoğunluğunun normal olması yer almaktadır. Restorasyonların tespit etkinliğinin değerlendirildiği radyografilerde sabit yer tutucu, dolgu, kanal tedavisi veya amputasyon gibi restorasyonlardan en az bir tanesinin bulunması gerekmektedir. Çalışmadan hariç tutulma kriterleri arasında ise görüntünün kalitesinin yeterli olmadığı (pozisyon hataları, artefaktlar, süperpozisyonlar, kontrast hataları vb.) ve dental anomalisi bulunan hastalardan alınan periapikal radyografiler yer almaktadır.

3.1. Dişlerin Etiketlenmesi

Etiketleme işlemi, görüntülerde bulunan nesnelere nitelendirilmesi ve o nesnelere ait açıklamaların eklenmesidir. Bu adım derin öğrenme algoritmalarının işleyişi için önemlidir. Bu çalışmada periapikal radyografiler üzerindeki her bir diş ve restorasyon pedodonti alanında 2,5 yıllık deneyimli bir araştırma görevlisi ve çocuk diş hekimi uzmanı tarafından manuel olarak işaretlenmiştir. Veri setinde iki hekimin teşhisinin

eşleşmediği periapikal görüntüler çalışmaya dahil edilmemiştir. Web tabanlı CranioCatch anotasyon yazılımı (CranioCatch, Eskişehir, Türkiye) olan Label programına (<https://label.craniocatch.com/>) hazırlanan veri setleri yüklenerek proje dosyaları oluşturulup ve etiketleme işlemine hazır hale getirilmiştir. Süt ve daimi dişlerin sınırları poligon yöntemi ile işaretlenmiş ve her dişin numaralandırılması FDI numaralandırma sistemine göre yapılmıştır. Ayrıca bu dişlerde bulunan restorasyonların (dolgu, taşkın dolgu, amputasyon, endodontik kök kanal tedavisi, sabit yer tutucu) sınırları poligon yöntemi ile başka bir dosya içerisinde etiketlenmiştir. Etiketleme işlemi bittikten sonra görüntüler tüm diş boyutları dikkate alınarak 960 x 736 piksel boyutunda JSON formatında kaydedilerek output dosyaları oluşturulmuştur.



Şekil 3. 1. Süt ve daimi dişlerinin etiketlenmesi



Şekil 3. 2. Restorasyonların etiketlenmesi: (A) yeşil: amputasyon, pembe: dolgu, koyu yeşil: taşkın dolgu, koyu mavi: kök kanal tedavisi (B) Mavi: sabit yer tutucu

3.2. Veri Setinin Oluşturulması

YOLO mimarisinde veri setleri; modelin eğitimini ve optimizasyonunu sağlamak için kullanılan train (eğitim) veri seti, modelin performansını izlemek amacıyla kullanılan validasyon (doğrulama) veri seti ve çalışmanın sonunda modelin performansını raporlamak için kullanılan test veri setlerinden oluşur. Modelin tüm parametreleri sabitlendikten sonra test setinde performansı değerlendirilir.

Dişlerin numaralandırılmasında kullanılan 1504 periapikal radyografinin; 1204 radyografisi eğitim veri seti, 150 radyografisi doğrulama veri seti ve 150 radyografisi test veri seti oluşturmaktadır (Tablo 3.1). Restorasyonların tespiti için kullanılan 1599 periapikal radyografinin ise; 1281 radyografisini eğitim veri seti, 159 radyografisini doğrulama veri seti ve 159 radyografisini test veri seti oluşturdu (Tablo 3.2).

Tablo 3. 1. Dişlerin numaralandırılması veri seti sınıflandırılması

| Model İsmi | Eğitim Görüntü Sayısı | Eğitim Etiket Sayısı | Test Görüntü Sayısı | Test Etiket Sayısı | Doğrulama Görüntü Sayısı | Doğrulama Etiket Sayısı |
|---------------------------|-----------------------|----------------------|---------------------|--------------------|--------------------------|-------------------------|
| Periapikal Numaralandırma | 1204 | 7318 | 150 | 927 | 150 | 927 |

Tablo 3. 2. Restorasyonların tespiti veri seti sınıflandırılması

| Model İsmi | Eğitim Görüntü Sayısı | Eğitim Etiket Sayısı | Test Görüntü Sayısı | Test Etiket Sayısı | Doğrulama Görüntü Sayısı | Doğrulama Etiket Sayısı |
|---------------------|-----------------------|----------------------|---------------------|--------------------|--------------------------|-------------------------|
| Restorasyon Tespiti | 1281 | 2968 | 159 | 397 | 159 | 369 |

3.3. Model Eğitimi ve Geliştirilmesi

Modelin eğitim setindeki görüntüleri ezberleme ve test seviyesinde farklı kaynaktan gelen görüntüleri yanlış yorumlanma riskini en aza indirmek amacıyla data augmentation (veri arttırımı) metodu kullanıldı. Bu metot ile ezberlenen veri sayısı artırılıp çeşitlendirilerek modelin veri tanıma performansı iyileştirildi.

Bu çalışmada periapikal görüntüler HSV-Hue, Hue-Saturation, HSV-Value, Mosaic (Ton, Doygunluk, Değer) görüntü dönüştürme teknikleri uygulanarak işlendi. Bu işlemler <https://albumentations.ai/docs/> adresinde Python programlama dili ve Opencv-Pytorch-Numpy-Pandas-Torch-Vision-Torch, Tensorboard-Seaborn kütüphaneleri kullanılarak bir dizi oluşturuldu.

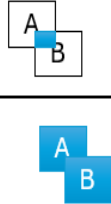
Dişlerin etiketlemesi ve dizin ayarlamalarından sonra model parametrelerinden olan epoch (eğitim adımı) sayısı, öğrenme oranı, batch size (örnek sayısı), optimizasyon

algoritması yazılarak modelin eğitim süreci uygulandı. Epoch toplam eğitim verilerinin bir ileri bir geri geçişini ifade etmektedir.

YOLOv8'in geniş versiyonu olan YOLOv8x modeli kullanılarak eğitim aşamasında her eğitim iterasyonunda 8 örneklilik bir grup kullanıldı. Öğrenme oranı (learning rate) 0.01 olarak belirlendi ve eğitim sürecinde her bir model için 500 epochla bir eğitim gerçekleştirildi. Optimizasyon algoritması olarak Adam optimizasyonu kullanıldı. Dışlerin numaralandırılması için en iyi model 292 epochta ve restorasyonların tespiti için 112 epochta kaydedildi.

3.4. Performans Değerlendirme Metrikleri

Nesne tespitinde modelin tahmin ederek oluşturduğu değer ile insan tarafından etiketlenme işleminin yapılmasıyla oluşan gerçek değer arasındaki örtüşme miktarı IoU (Intersection over Union- Birleşim Üzerinden Ortalama Kesişim) hesaplanarak elde edilir. IoU katsayısı modelin tahmin edilen sınırlayıcı kutucuğu (A) ile gerçekte etiketlenen kutucuğun (B) kesişim kümesinin, toplam birleşim kümesine olan oranıdır (Şekil 3.3). Bu değer yükseldikçe tespitin kesinliği de artmaktadır. IoU değerinin %50 olması, algoritmanın kabul edilebilir derecede başarılı olduğunu göstermektedir. IoU yüzdesi göz önünde bulundurularak kesinlik, duyarlılık gibi değerlerin hesaplanabilmesi için Gerçek Pozitif, Yanlış Pozitif, Gerçek Negatif, Yanlış Negatif değerlerin belirlenmesi gerekmektedir.

$$\text{IoU (Intersection over Union)} = \frac{\text{KESİŞİMALANI}}{\text{BİRLEŞİMALANI}}$$


Şekil 3. 3. IoU Değerinin Hesaplanması (151)

Gerçek Pozitif (TP): Gerçekte pozitif olan örneğin doğru tahmin edilmesine denir. (Restorasyonların ve numaralandırmanın doğru tespit edilmesi)

Yanlış Pozitif (FP): Gerçekte negatif olan verinin pozitif tahmin edilmesine denir. (Tespit edilen fakat numaralandırmanın ve restorasyonun yanlış belirlenmesi ya da dış dışında herhangi bir bölgenin tespit edilmesi)

Gerçek Negatif (TN): Gerçekte negatif olan verinin negatif tahmin edilmesine denir. Çalışmamızda periapikal radyografide olmayan bir nesnenin tahmin edilememesi mümkün olmadığı için bu değer kullanılmamaktadır.

Yanlış Negatif (FN): Gerçekte pozitif olan bir verinin negatif tahmin edilmesine denir. (Periapikal radyografi üzerinde bulunan fakat tespit edilemeyen diş ve restorasyon)

Model performansını değerlendirmek için, tahmin edilen ve gerçekleşen durumlar hakkında bilgi veren karmaşıklık matrisi kullanıldı. Bu matris modelin gerçek değerleri ile tahmin ettiği sonuçları karşılaştırarak, doğru ve yanlış tahminlerin değerini gösterir (Tablo 3.3). Elde edilen karmaşık matrisleri doğruluk, kesinlik (precision), duyarlılık (recall), F1-skor ve mAP değerleri ile modellerin performansları değerlendirilmiştir.

Tablo 3. 3. Karmaşıklık matrisi

| | | Tahmin Edilen Değer | |
|--------------|---------|---------------------|---------------------|
| | | pozitif | negatif |
| Gerçek Değer | pozitif | Gerçek Pozitif (TP) | Yanlış Negatif (FN) |
| | negatif | Yanlış Pozitif (FP) | Gerçek Negatif (TN) |

Doğruluk (Accuracy): Doğru tahminlerin toplam veri setine olan oranını gösterir. $TP+TN / (TP + TN + FP + FN)$ şeklinde matematiksel olarak hesaplanır (152).

Kesinlik (Precision): Pozitif tahmin edilen verilerin kaç tanesinin doğru olduğunu gösterir. $TP / (TP + FP)$ şeklinde matematiksel olarak hesaplanır (152).

Duyarlılık (Recall): Doğru olan pozitif ve yanlış negatif verilerin kaç tanesinin doğru pozitif olduğunu belirtir. $TP / (TP + FN)$ şeklinde matematiksel olarak hesaplanır (152).

Duyarlılık değerinin yüksek, kesinlik değerinin düşük olması işaretlenen tüm verilerin model tarafından tespit edildiğini gösterir. Ancak çoğunlukla tespitin doğru olmadığı yani yanlış pozitif değerinin fazla olduğunu anlaşılmaktadır. Duyarlılık değeri düşük olup kesinlik değeri yüksek olduğu durumda ise yanlış negatif değerin yüksek olduğu anlaşılmaktadır (153).

F1-skor: Kesinlik ve duyarlılık ölçümlerinin harmonik ortalamasıdır ve dengeli performans analizi sağlar. F1-skoru $2TP / (2TP + FP + FN)$ şeklinde matematiksel olarak hesaplanır (152).

Ortalama Kesinlik (Average Precision, AP): Kesinlik ve duyarlılık ölçümlerinin etkinliğinin bir arada değerlendirildiği metriktir. Kesinlik-duyarlılık eğrisinin altında kalan alan hesaplanarak bulunur.

Genel Ortalama Kesinlik (Mean Average Precision, mAP): Nesne algılama modellerinin değerlendirilmesinde kullanılır. Bu değer hesaplanırken karmaşıklık matrisi, IoU katsayısı, kesinlik ve duyarlılık değerleri kullanılmaktadır. mAP'nin iki farklı değerlendirme metriği bulunmaktadır. Bunlar mAP@0.5 ve mAP@0.5:0.95'tir. mAP@0.5 IoU eşiği 0.5 olduğu zaman ortalama hassasiyeti belirtir ve nispeten düşük tespit etkinliği olan değerlendirme metriğidir. mAP@0.5:0.95 ise birden fazla IoU eşiğinde hesaplanan ortalama hassasiyet değeridir (adım boyutu olarak 0.05'lik artışlarla 0.5'ten başlayıp 0.95'e kadar). mAP@0.5:0.95 daha yüksek tespit etkinliği olan değerlendirme metriğidir ve eşitli hassasiyet gereksinimleri varlığında modelin performansını daha kapsamlı değerlendirir (154).

Doğrulama verisindeki her bir periyodik görüntüden tespit edilen duyarlılık ve kesinlik değerleri yüzdesel olarak hesaplanır. Bu değerler kullanılarak kesinlik-duyarlılık (precision-recall) grafiği oluşturulmaktadır. Kesinlik-duyarlılık (precision-recall) grafikleri sınıf dağılımında ROC (İşletim Karakteristik Eğrisi) eğrisinin bir alternatifi olarak kullanılmıştır. Kesinlik-duyarlılık grafiğinin x ekseninde, ROC eğrisinin y ekseninde, doğru pozitif sayı değeri bulunmaktadır. Eğrinin veya grafiğin sol üst tarafa yaklaşması başarının arttığını gösterir (155).

Kayıp Fonksiyonu (Loss/Cost Function): Algoritmanın tahmininin gerçek değerden ne kadar uzak olduğunu ölçen bir metriktir. Algoritmanın hata miktarını değerlendirir (156).

Eđitim Kaybı (Train Loss): Derin öğrenme modelinin eğitim verilerine ne kadar iyi uyum gösterdiğini değerlendirir. Eğitim kaybı eğitim süresinde yapılan tüm hataların toplanmasıyla epochtan sonra hesaplanır.

Dođrulama Kaybı (Validation Loss): Doğrulama kaybı metriđi kullanılarak derin öğrenme modelinin doğrulama kümesinde ne kadar iyi verimlilik gösterdiğini ölçülür. Doğrulama kaybı ile eğitim kaybı karşılaştırılabilir. Bunun nedeni eğitim ve doğrulama kaybının doğrulama setine dahil edilen her veri setinde yapılan hataların hepsinin toplanmasıyla modeldeki hataları belirlemek için kullanılmasıdır. Doğrulama kaybı epochtan sonra modelin mükemmel olup olmadığını göstermek veya daha fazla ayarlama gerekip gerekmediğini değerlendirmek amacıyla kullanılır.

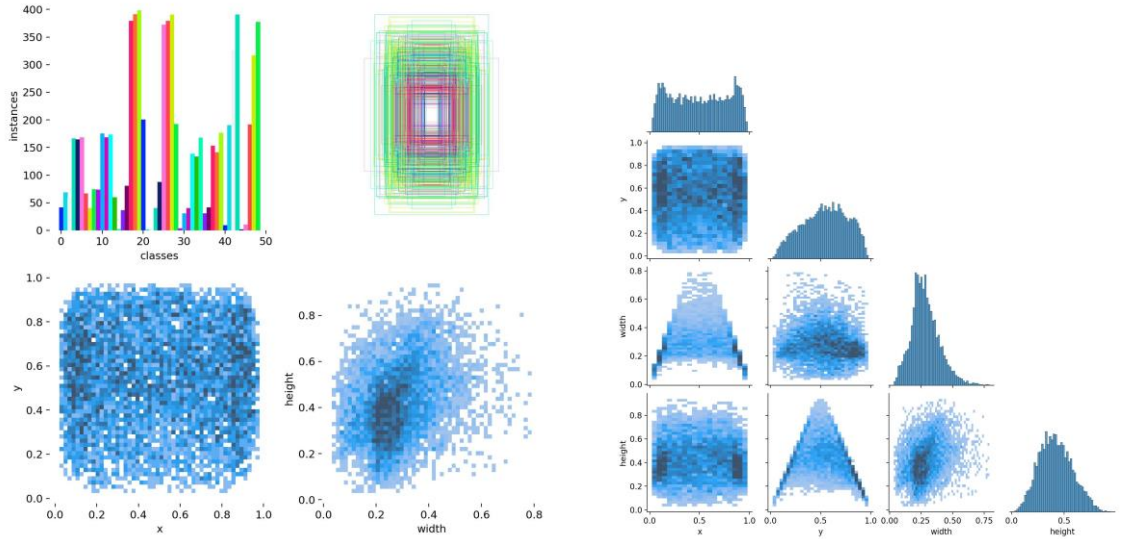


4. BULGULAR

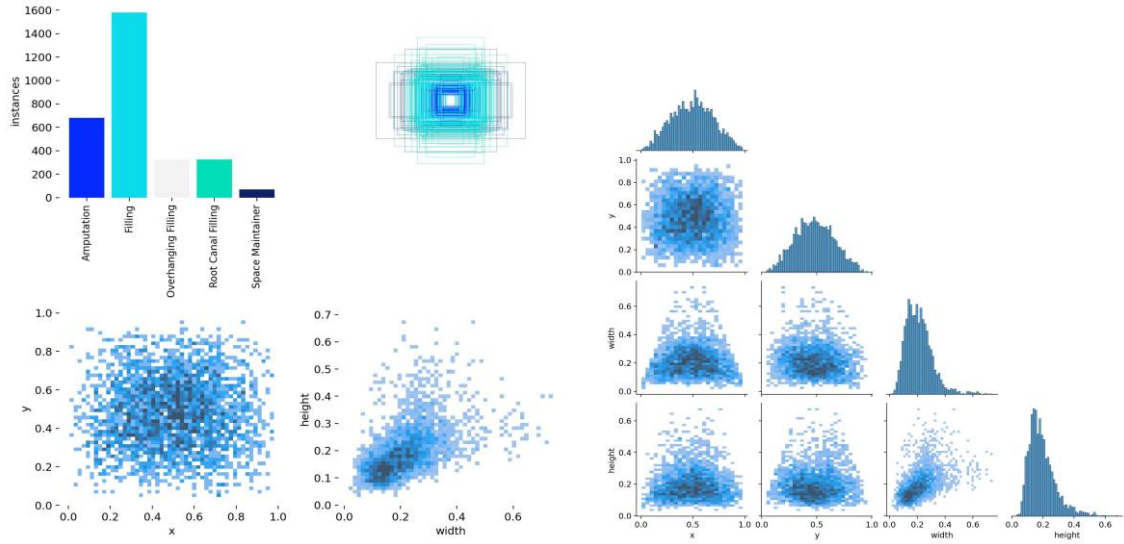
Bu tez çalışmasında YOLOv8x derin öğrenme algoritması kullanılarak periapikal radyografilerdeki dişlerin numaralandırılması ve restorasyonların otomatik tespit etkinliği incelenmiştir. Model performansını değerlendirmek amacıyla karmaşıklık matrisi, doğruluk, kesinlik, duyarlılık, F1- skor ve mAP değerleri kullanılmıştır.

4.1. Veri Seti Dağılımı

Verilerin görselleştirilmesi için 2D histogramlar olan korelogramlar kullanılır ve veri setine ve etiket dağılımına genel bir bakış sağlar. Bu çalışma, karışık dişlenme dönemine ait periapikal radyografilerden dişlerin numaralandırılması için 1504, restorasyonların otomatik tespit etkinliğinin değerlendirilmesi için 1599 periapikal radyografi içermektedir. Eğitim sonrası veri kümesindeki elde edilen etiket parametrelerin dağılımı ve korelasyon Şekil 4.1 ve Şekil 4.2’de gösterilmektedir. Bu şekilde her bir diş numarasına ait sütun farklı renklerle belirtilmiştir. Diş numara sayısı çok fazla olduğundan hangi rengin hangi numaralı dişe karşılık geldiği ayrıca belirtilememiştir.



Şekil 4. 1. Dişlerin numaralandırılması için veri dağılımı ve korelogram gösterimi



Şekil 4. 2. Restorasyonların tespiti için veri dağılımı ve korelogram gösterimi

4.2. Dişlerin Numaralandırılması Performans Sonuçları

YOLOv8 modeli karışık dişlenme dönemine ait süt ve daimi dişlerin numaralandırılması amacıyla yapılan tahmin etmedeki etiketlerin 849'unu gerçek pozitif, 18'ini yanlış pozitif, 78'ini yanlış negatif olarak değerlendirmiştir ve %89 doğruluk elde edilmiştir (Tablo 4.1). Bu sonuçlar IoU threshold değeri %50 belirlendiği zaman elde edilmiştir.

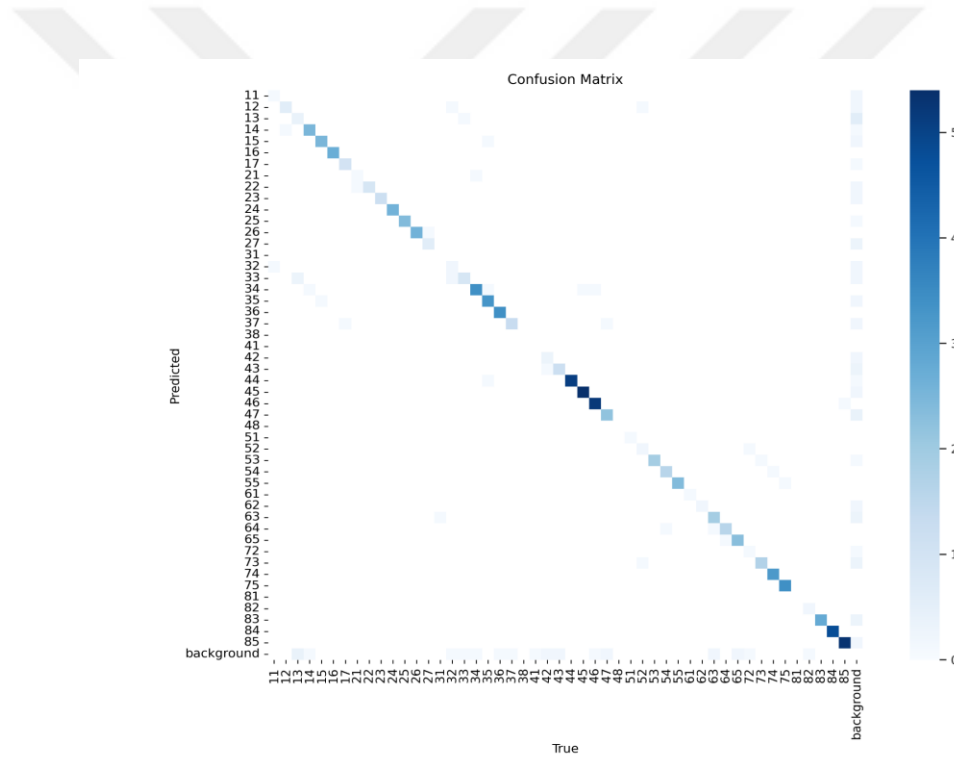
Tablo 4. 1. Dişlerin numaralandırılması için TP, FP, FN ve Doğruluk Değerleri

| | Gerçek Pozitif (TP) | Yanlış Pozitif (FP) | Yanlış Negatif (FN) | Doğruluk |
|--------------|--------------------------------|--------------------------------|--------------------------------|-----------------|
| Değer | 849 | 18 | 78 | 0,89 |

Karmaşıklık matrisi kullanarak hesaplanan değerleri Şekil 4.3 'te gösterilmektedir. Bu değerlendirme sonucu 0,979 kesinlik, 0,915 duyarlılık ve 0,946 F1 skoru elde edilmiştir (Tablo 4.2).


Tablo 4. 2. Dişlerin Numaralandırılması Performans Skorları

| Ölçü | Duyarlılık ($TP / (TP + FN)$) | Kesinlik ($TP / (TP + FP)$) | F1-skor ($2TP / (2TP + FP + FN)$) | mAP@50 | mAP@50-95 |
|-------|------------------------------------|----------------------------------|--|--------|-----------|
| Değer | 0,915 | 0,979 | 0,946 | 0.863 | 0.658 |



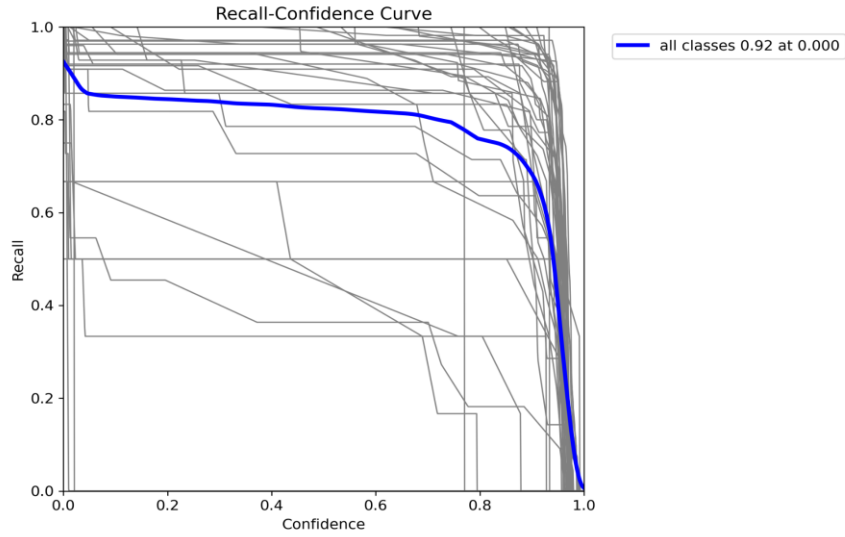
Şekil 4. 3. YOLOv8 Modelinin Dişlerin Numaralandırılması için Karmaşıklık Matrisi

YOLOv8 modelin tahminine duyulan güven ile bu tahminlerin kesinliği arasındaki bağlantıyı gösteren kesinlik-güven eğrisi Şekil 4.4'te gösterilmektedir. X eksenini 0.0 ile 1.0 arasındaki değişen güven değerini gösterirken y ekseninde 0.0 ile 1.0 arasındaki değişen kesinlik değerini göstermektedir. Bu eğride modelin güven aralığı genişledikçe kesinliğinin de arttığı gözlenmektedir.



Şekil 4. 4. Dişlerin Numaralandırılması Kesinlik-Güven Eğrisi

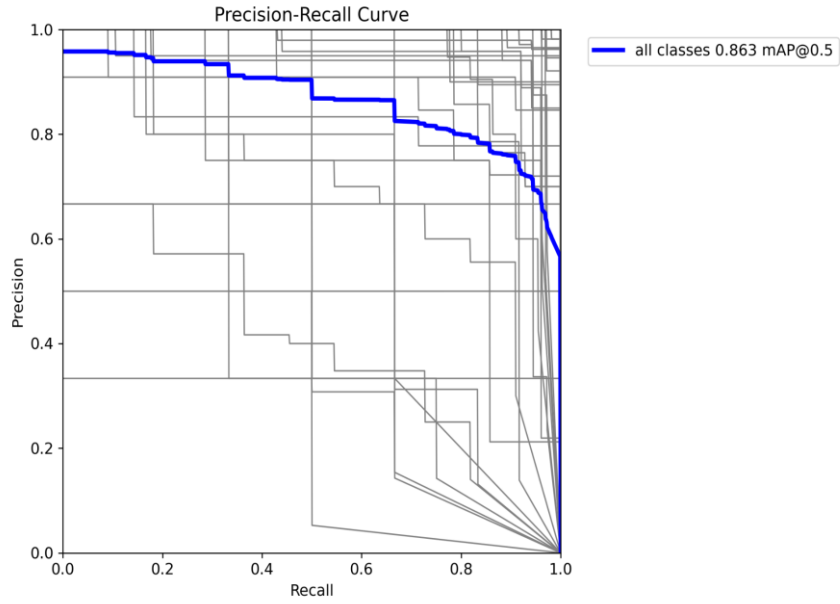
Duyarlılık-güven eğrisi, modelin tahminlerinin güven aralığı ile duyarlılık (gerçek pozitif oran) arasındaki bağlantıyı göstermektedir. Bu eğri Şekil 4.5’ te gösterilmektedir. X eksenini tespitlerin güven değerini gösterirken y eksenini tespit edilen gerçek pozitif örneklerin oranı olan duyarlılığı göstermektedir. Güven değeri arttıkça duyarlılık değeri azalır.



Şekil 4. 5. Dişlerin Numaralandırılması Duyarlılık-Güven Eğrisi


Kesinlik-duyarlılık eğrisi Şekil 4.6’da gösterilmektedir. Bu eğri kesinlik ile duyarlılık arasında istenen dengeyi sağlamak amacıyla uygun bir eşik değeri seçmek ve modelin etkinliğini görselleştirmek için kullanılabilir. Kesinlik değerinin yüksek olması model tarafından değerlendirilen pozitif tahminlerin çoğunun doğru olduğunu göstermektedir.

Duyarlılık değerinun yüksek olması ise model veri setindeki pozitif örneklerin çoğunun belirlendiğini göstermektedir.



Şekil 4. 6. Dişlerin Numaralandırılması Kesinlik-Duyarlılık Eğrisi

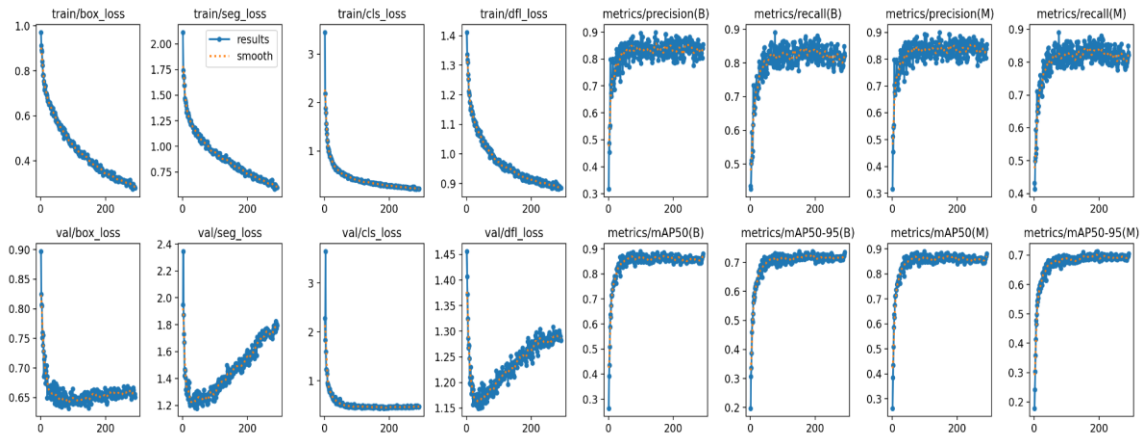
F1-güven eğrisi, güven aralığı ile yanlış pozitif oranı arasındaki bağlantıyı göstermektedir. Güven aralığı arttıkça yanlış pozitifler azalırken yanlış negatifler artar. F1-güven eğrisi farklı güven değerlerindeki kesinlik ve duyarlılık arasındaki dengeyi çözümlmek için incelenebilir. F1-güven eğrisi Şekil 4.7’de gösterilmektedir.




Şekil 4. 7. Dişlerin Numaralandırılması F1-Güven Eğrisi

YOLOv8 eğitilen modelinin performans grafiği Şekil 4.8’de gösterilmektedir. Bu grafik modelin etkinliğini değerlendirmek, herhangi bir sorunu tespit etmek, eğitim ilerlemesini izlemek için çok önemlidir. Özellikle eğitim aşaması süresince aşırı öğrenme veya düşük mAP değerleri gibi koşulların tanınmasına yardımcı olmaktadır ve modelin nesnelere algılama, bölümlere ayırma konusundaki yeterliliği hakkında bilgi vermektedir. Ayrıca modeli geliştirmek için ayarlamalar gerektiği zaman sinyal göndermektedir.

Bu grafik hem doğrulama hem de eğitim veri setleri için sınıf kaybı, kutu kaybı ve dfl kaybı gibi eğitim sürecinin farklı aşamalarına ilişkin kayıp değerlerini göstermektedir. Eğitim sürecinin epoch veya iterasyon sayısını X eksenini gösterir. Y eksenini ise doğrulama ve eğitim veri setleri için seg_loss, box_loss, cls_loss ve dfl_loss gibi kayıp metriklerinin ölçümlerini gösterir. Eğitim kaybının zamanla azaldığı bu grafiklerde görülmektedir. Bunu yanında grafiklerde kesinlik, duyarlılık ve mAP50 ve mAP50-90 gibi bazı performans metrikleri de gösterilmiştir. Epoch ilerleyişine göre performans ölçütlerinin hızla 1’e doğru yaklaşması, beklenen ve ileri sürülen grafiksel davranıştır.



Şekil 4. 8. Dişlerin Numaralandırılması Epoch İlerleyişi ve Performans Grafikleri



Şekil 4. 9. YOLOv8 modelinin dişlerin numaralandırılması için doğru pozitif, yanlış pozitif ve yanlış negatif tespiti

4.3. Restorasyonların Tespiti Performans Sonuçları

YOLOv8 modeli karışık dişlenme dönemine ait restorasyon bulunan etiketlerin 379'unu gerçek pozitif, 56'sını yanlış pozitif, 18'ini yanlış negatif olarak değerlendirmiştir ve %83 doğruluk elde edilmiştir (Tablo 4.3). Bu sonuçlar IoU threshold değeri %50 belirlendiği zaman elde edilmiştir.


Tablo 4. 3. Restorasyonların Tespiti için TP, FP, FN ve Doğruluk Değerleri

| | Gerçek Pozitif (TP) | Yanlış Pozitif (FP) | Yanlış Negatif (FN) | Doğruluk |
|--------------|------------------------|------------------------|------------------------|----------|
| Değer | 379 | 56 | 18 | 0,83 |

Karmaşıklık matrisi kullanarak hesaplanan değerleri Şekil 4.10'da gösterilmektedir. Bu değerlendirme sonucu 0,871 kesinlik, 0,954 duyarlılık ve 0,911 F1 skoru elde edilmiştir (Tablo 4.4).


Tablo 4. 4. Restorasyonların Tespiti Performans Skorları

| Ölçü | Duyarlılık ($TP / (TP + FN)$) | Kesinlik ($TP / (TP + FP)$) | F1-skor ($2TP / (2TP + FP + FN)$) | mAP@50 | mAP@50-95 |
|-------|------------------------------------|----------------------------------|--|--------|-----------|
| Değer | 0,954 | 0,871 | 0,911 | 0.881 | 0.626 |




Şekil 4. 10. YOLOv8 Modelinin Restorasyonların Tespiti için Karmaşıklık Matrisi


Restorasyonların tespiti için kesinlik-güven eğrisi Şekil 4.11’de duyarlılık-güven eğrisi Şekil 4.12’de, kesinlik-duyarlılık eğrisi Şekil 4.13 ‘te verilmiştir.



Şekil 4. 11. Restorasyonların Tespiti Kesinlik-Güven Eğrisi

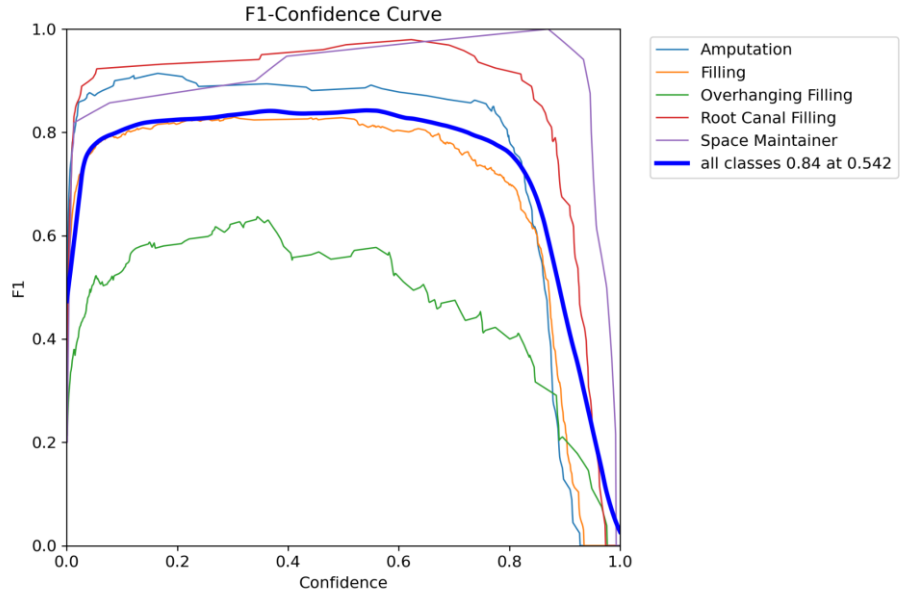


Şekil 4. 12. Restorasyonların Tespiti Duyarlılık-Güven Eğrisi



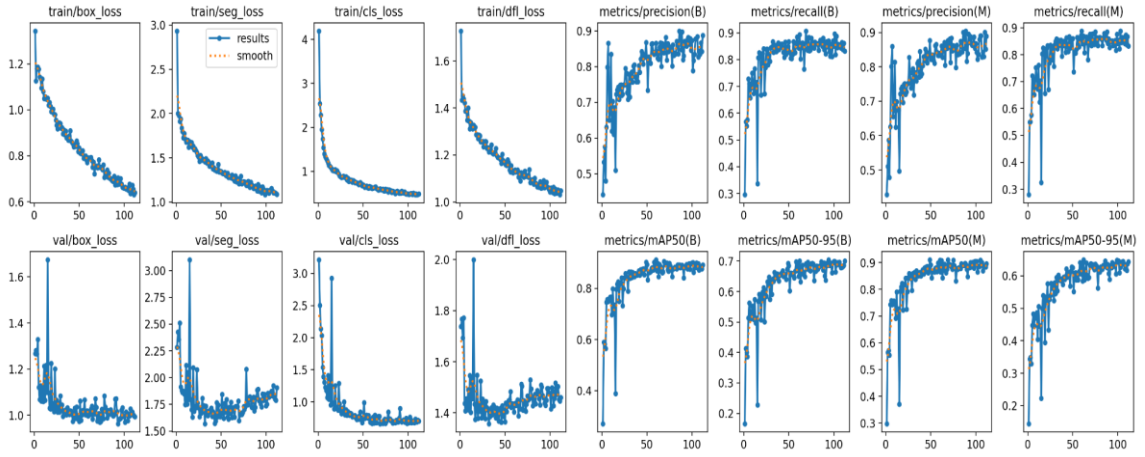
Şekil 4. 13. Restorasyonların Tespiti Kesinlik-Duyarlılık Eğrisi

Restorasyonların tespiti için F1-güven eğrisi Şekil 4.14'te gösterilmektedir.




Şekil 4. 14. Restorasyonların Tespiti F1-Güven Eğrisi

Restorasyonların tespiti için epoch ilerleyişine göre performans grafikleri Şekil 4.15’ te verilmiştir.



Şekil 4. 15. Restorasyonların Tespiti için Epoch İlerleyişi ve Performans Grafikleri



Şekil 4. 16. YOLOv8 modelinin dişlerdeki restorasyonların doğru pozitif, yanlış pozitif ve yanlış negatif tespiti

5. TARTIŞMA

Diş hekimliğinde diş çürük lezyonlarının kesin ve doğru teşhisinin yapılması başarılı ve etkin bir tedavi uygulamasının ilk adımını içermektedir. Diş çürüklerinin tanı yöntemleri de çürük lezyonunun erken teşhisini kolaylaştırarak ya da objektif değerlendirilmesini sağlayarak tanı sürecini iyileştirmeyi hedeflemektedir (3). Ayrıca diş çürüklerinin erken teşhisi hastalara koruyucu tedavilerin ve minimal invaziv yöntemlerin uygulanabilmesi için gereklidir. Dişlerde oluşan çürük lezyonları tedavi edilmediği takdirde mine, dentin ve pulpa dokusuna aşamalı yayılarak şiddetli ağrılara bunların sonucunda dişte fonksiyon kaybına hatta dişlerin çekilmesine neden olabilir. Dişlerin tespiti ve numaralandırılması basit olarak görünse de dişlerin numaralandırılması ve çürük lezyonlarının tespitinin kesinliği diş hekimlerinin sınırlı ve çeşitli bilgisinden etkilenmektedir. Bu durum aynı zamanda yetersiz tedavi yaklaşımlarına ve teşhislere neden olabilmektedir. Tüm bu zorlukların üstesinden gelebilmek, teşhis ve tedavi sürecini daha kolay hale getirebilmek amacıyla derin öğrenme yöntemlerine dayalı bilgisayar destekli sistemler kullanılabilmektedir (157,158). Derin öğrenme yöntemleri öncelikle teşhis konusunda diş hekimlerine yardımcı olurken aynı zamanda diş hekimlerinin üretkenliğini arttırmakla beraber doğruluğu ve hassasiyeti de iyileştirdiği iddia edilmektedir.

Diş hastalıklarının teşhis, tedavi planlaması ve yönetiminde radyografiler önemli rol oynamaktadır (149). Klinik muayenede kullanılan yaygın radyografiler arasında periapikal radyografiler, ısırma radyografileri ve panoramik radyografiler bulunmaktadır (159). Panoramik radyografiler diş hekimliğinde tanı ve tarama için yaygın olarak kullanılmaktadır. Fakat çocuk hastalarda yetişkin hastalara oranla radyasyon kaynaklı hasar riski iki ile üç kat daha fazla oluşmaktadır (160). Amerikan Diş Hekimleri Birliği'ne <https://www.fda.gov/media/84818/download> göre periapikal radyografiler bir rehber olarak seçilmektedir ve diş hekimleri de çocuk hastaları değerlendirmek için periapikal radyografileri panoramik radyografilere tercih etmektedir (161,162). Periapikal radyografiler, çürük lezyonlarının varlığı ve derinliği, dental restorasyonlar, interradiküler radyolüensiler, kök ve kanal morfolojileri, endodontik obturasyon uzunluğu ve yeterliliği, periodontal ligament aralığı, alveoler kemik seviyesi hakkında lokalize bilgi sağlamaktadır (163). Periapikal radyografiler, incelenen nesnelerin ayrıntılı görüntüsünü elde etme, üst üste binmeleri önlemek amacıyla odaklanmış bir alanda

gerçekleştirilme, yüksek çözünürlük, hastaları düşük radyasyona maruz bırakma ve iyi bir maaliyet etkinliği sağlaması yönünden çeşitli avantajlar sunmaktadır. Sonuç olarak diş hekimliği muayenelerinde periapikal radyografiler rutin olarak kullanılmaktadır. (41,164). Ancak tüm diş hekimleri bu radyografileri yorumlamada iyi eğitilmiş olsalar da büyütme hataları, kontrast, açılamadaki farklılıklar gibi bazı faktörler hatalı teşhislere yol açabilmektedir. Diş hekiminin deneyimi ve bilgisi ve radyografilerin incelenmesi sırasında yorgunluk yorumlamayı etkileyebilecek diğer faktörler arasında yer almaktadır (163). Bu zorlukların üstesinden gelmek için diş hekimlerine ek bir yardımcı olarak YZ sistemlerinin benimsenmesi radyografileri yorumlamada giderek daha önemli hale gelmektedir. Yapay zeka tabanlı gelişmiş yöntemler kullanılarak tedavi sonuçlarının daha doğru tahmin edilmesi, teşhis hassasiyetinin artması ve tedavi planlanmasında iyileşmelerin sağlanması beklenmektedir. Evrişimli sinir ağı tabanlı modeller özellikle çocuk diş hekimliğinde daha doğru ve daha hızlı teşhis için kullanılmaktadır (143). Çalışmamızda ESA tabanlı YOLOv8 mimarisi yöntemiyle karışık dişlenme döneminde alınan periapikal radyografilerde izlenen dişlerin numaralandırılması ve restorasyonların otomatik tespit etkinliği incelenmiştir.

Diş hekimliği alanında son yıllarda YZ teknolojisinin büyük ilerlemeler kaydetmesiyle beraber veri seti yönetimi ve teşhisi hızlandıran, basitleştiren yazılımlar tasarlanmıştır. Yapay zeka modelleri, diş hekimliğinde geliştirilen uygulamalarla beraber iş gücünü ve tekrarlayan rutin muayeneleri azaltmaktadır. Bununla beraber sağlık hizmetini daha geniş bir nüfusa daha düşük maliyetle sağlayabilmekte ve öngörücü, kişiselleştirilmiş ve daha etkileşimli uygulamaları destekleyerek, ağız ve diş sağlığı hizmetlerini daha hızlı ve düzenli hale getirmektedir (165).

Derin öğrenme modelleri görüntü alma ve sınıflama, segmentasyon, nesne algılama gibi pek çok alanda kullanılmaktadır (166). Derin öğrenme algoritmalarının kullanımı tıbbi durumların belirlenmesi, tedavi edilmesi ve tedavi sonrası izlenimde yaygınlaşmaktadır. Bu durum da tıbbi görüntüleme analizi alanında derin öğrenme mimarisinin kullanım sıklığını arttırmıştır (167). Derin öğrenme mimarileri, bilgisayarlı tomografi, ultrason görüntülerinin analizi ve manyetik rezonans görüntüleme (MRI) gibi çeşitli görüntüleme yöntemlerindeki görüntülerdeki anormallikleri ayırt edebilmekte ve kategorize edebilmektedir (168). Ayrıca akciğer hastalıkları, göz hastalıkları, ortopedi, travma ve meme kanseri gibi hastalıkların teşhisinde klinisyene yardımcı olmak için derin öğrenme

algoritma yöntemleri kullanılmaktadır (169). Literatürde diş hekimliği alanında yapılan araştırmalar incelendiğinde ise tanı koymaya yönelik pek çok yapay zeka tabanlı çalışmaların yapıldığı görülmektedir (170–172). 2021 yılında Khanagar ve ark. yaptığı sistematik bir derleme çalışmasında, literatürdeki 1268 araştırmayı tarayarak seçtikleri 43 çalışmayı değerlendirmişlerdir. Diş hekimliği alanında her branşı kapsayan çalışmaların değerlendirildiği bu çalışmada, periapikal radyografilerde çürük, dental restorasyon ve apikal patolojilerin tespiti, sefalometrik radyografilerde otomatik olarak anatomik noktaların analizleri, panoramik radyografiler üzerinde ise yirmilik dişlerin mandibular kanal ile ilişkisi, maksillofasiyal kistlerin incelenmesi, osteoporozun değerlendirilmesi gibi çeşitli çalışmalara değinmişlerdir. Ayrıca bu araştırma YZ teknolojisinin diş hekimliği alanında devrim yaptığını ve bu teknolojinin hekimlerin koydukları tanının doğruluğunu arttırarak hekimlerin hastalara en iyi seviyede tedavi sunmalarına yardımcı olabileceğini belirtmiştir (78).

Son yıllarda derin öğrenme yöntemlerinden biri olan YOLO nesne algılama modelleri, algılama sonuçlarının kalitesini düşürmeden gerçek zamanlı performansı amaçlayarak doğruluk ve hız arasında denge kurmaya odaklanmıştır. YOLO modeli nesne konumlarını ve sınıflarını giriş görüntüsünden doğrudan tahmin etmek için tek bir evrişimli sinir ağı uygulamış ve gerçek zamanlı işleme imkân tanımıştır (125). YOLO modelleri kullanılarak nesnelere algılamak için gereken sürenin kısaltılabileceği ileri sürülmüştür (173). YOLO ailesi sınırlamaları gidermek ve performansı artırmak için başlangıcından itibaren önceki sürümler üzerine geliştirilerek ve birden fazla yenilikten geçerek oluşturulmaktadır. YOLOv5'ten itibaren YOLO modelleri doğruluk ve hız arasındaki dengeyi hassas olarak düzenlemiş ve spesifik uygulamalara ve donanım ihtiyaçlarına uyacak şekilde çeşitli model ölçekleri sunmuştur. YOLOv8, YOLOv5'i geliştiren şirket tarafından 2023 yılının Ocak ayında yayınlanmıştır. YOLOv8, sınıflandırma, nesnellik, regresyon gibi faaliyetlerini bağımsız olarak işlemektedir. Bu model, her birimin kendi görevine odaklanmasını gerçekleştirmekte ve modelin genel doğruluğunu arttırmaktadır (125). Yapılan bu çalışmada da görüntülerin analizi için YOLOv8 modeli kullanılmıştır.

Derin öğrenme modelleri eğitilirken etiketli veriler kullanılır ve eğitim bittikten sonra istenilen görevi başarılı bir şekilde gerçekleştirmesi beklenir. Göreve bağlı olarak ilgili yapıyı veya patolojik alanı işaretleyen görüntüdeki etiketler oluşur. Modelin tahmin gücündeki artan iyileştirme, giriş görüntüsü spesifik bir etiketle eşlenene kadar tekrarlanır

(93). Bu tür eğitim sürecini ve etiket işlemini gerçekleştirebilmek için kontrol yani referans testi gereklidir. Bu test standartlar sağlanarak oluşturulabilir (174). Uzmanlar sınıflandırma ve ayırma işlevlerine bağlı olarak bir şeyin anatomik veya patolojik olup olmadığına, hangi pozisyonda ve şekle sahip olduğuna karar verebilirler (175). Bu tez çalışmasında veri setlerinin etiketleme işlemi 2.5 yıllık deneyimli bir araştırma görevlisi ve sekiz yıllık deneyimli bir çocuk diş hekimi uzmanı tarafından yapılarak doğruluk artırılmaya çalışılmıştır.

Derin öğrenme mimarisinin eğitim sürecinde veri sayısının artmasının veri tahmin analitiği sunmada daha başarılı sonuçlar verdiği bildirilmektedir (176). Bu tez çalışmasında dişlerin numaralandırılması için 1504, dental restorasyonların tespit için 1599 periapikal radyografi, 2018-2024 yılları arasında fakülte veri tabanından elde edilmiştir. Chen ve arkadaşlarının (2019) periapikal radyografiler kullanarak yaptığı çalışmada dişlerin tespit ve numaralandırılması için 1250 adet, Yasa ve arkadaşlarının (2021) bite-wing radyografiler kullanarak yaptığı diş tespit ve numaralandırma çalışmasında ise 1125 adet, Görürgöz ve arkadaşlarının (2022) periapikal radyografi kullanarak yaptığı diş tespit ve numaralandırma çalışmasında 1686 adet, Ayhan ve arkadaşlarının (2024) bite-wing radyografiler kullanarak yaptığı dişlerin numaralandırma ve çürük tespiti çalışmasında 1170 adet, Çelik ve arkadaşlarının (2022) panoramik radyografiler kullanarak yaptığı restorasyonların otomatik tespiti çalışmasında 684 adet, Ari ve arkadaşlarının (2022) periapikal radyografiler kullanarak yaptığı restorasyonların tespiti çalışmasında 1169 adet görüntüden oluşan veri seti kullanmışlardır (8,150,158,177–179).

Karmaşıklık matrisi veya hata matrisi, gerçek ve tahmin edilen değerleri ikili veya çoklu sınıflandırma sorunlarında grafik haline dönüştürerek görselleştiren ve performans metriklerinin kullanılarak istatistiksel değerlendirmesine olanak sağlayan bir tablodur. Performans değerlendirme metrikleri, eğitilen derin öğrenme teknolojisinin nesne algılama işlevinde ne kadar başarılı bir performans gösterdiğini değerlendirmek amacıyla kullanılan ölçü metrikleridir. Derin öğrenme modellerinin performansının değerlendirilmesinde farklı değerlendirme metrikleri kullanılmaktadır. İkili veya çoklu sınıflandırma için sıklıkla kullanılan performans değerlendirme metriklerinden bazıları kesinlik, duyarlılık, doğruluk, F1-skoru, IoU'dur (180). Yasa ve arkadaşları dişlerin numaralandırılması için yaptığı çalışmada otomatik bir algılama sistemi önermeyi

hedeflemişlerdir ve performans değerlendirilmesinde karmaşıklık matrisi kullanmışlardır. Çalışmalarında gerçek pozitif, yanlış pozitif, yanlış negatif metriklerini kullanıp, doğru negatif metriğini kullanmadan değerlendirme yapmışlardır (178). Bu çalışmada da dişlerin numaralandırılması ve restorasyonların tespiti için doğru negatif değeri kullanılmadan karmaşıklık matrisi kullanılmıştır ve kesinlik, duyarlılık, F1-skor ve mAP metrikleri ile performans değerlendirilmesi yapılmıştır.

Nesne algılama parametrelerinden olan duyarlılık ve kesinlik değerinin güvenirliliği doğruluk değerinin güvenirliliğinden daha yüksektir (181). Bu durum için örnek verirek 90 sağlıklı ve 10 hastanın olduğu veri setinde nesne algılama modelinin bütün verileri sağlıklı olarak belirlemesi durumunda doğruluk değeri %90 olarak hesaplanmaktadır. Bu durumda model başarısı hasta kişilerin değerlendirilmesi açısından bakıldığında hastaların hiçbirini tespit edemediğinden başarısız olarak görülmektedir. Dolayısıyla bu tez çalışmasında modelin performans değerlendirilmesinde duyarlılık, kesinlik, F1-skor metrikleri kullanılmıştır.

Literatürde, derin öğrenme tabanlı YZ yöntemleri kullanılarak dişlerin tespiti ve numaralandırılması için birçok çalışma bulunmaktadır. Fakat bu çalışmaların çoğunluğu daimi dişlenme dönemini içermektedir. Estai ve arkadaşları, dişlerin otomatik tespiti ve numaralandırılması çalışmasında ESA tabanlı üç aşamalı bir prosedür kullanmışlardır. 18 yaşından büyük hastalardan alınan 591 panoramik radyografi içermektedir. Bu çalışma ilk olarak U-Net modeli ile diş bölgelerinin ilgilenilen bölgeleri, ikinci olarak Faster R-CNN ile, U-Net tarafından tespit edilen ilgilenilen bölgeler içindeki her bir diş tanımlanmıştır. Son olarak VGG-16 modeli her bir dişi 32 kategoride diş numaralandırılması yapılmıştır. Diş tespiti modelinde, 0,99'luk bir duyarlılık ve 0,99'luk bir kesinlik, diş numaralandırma modelinde ise 0,98'lik bir duyarlılık, kesinlik ve F1 puanı elde edilmiştir (169).

Tekin ve arkadaşları 2022 yılında bite-wing radyografileri üzerinden evrişimli bir sinir ağı tipi olan Mask R-CNN kullanarak diş segmentasyonu ve numaralandırması çalışması yapmışlardır. Bu çalışmada da eğitim veri seti için 1000 radyografi ve test veri seti için 200 radyografi kullanılmıştır. Dişlerin numaralandırılması ve segmentasyonu amacıyla diş hekimleri tarafından yaygın olarak kullanılan FDI notasyonu kullanılmıştır. Dişlerin segmentasyonu için elde edilen deney sonuçları, %100 hassasiyet ve %97.49 mAP, 24 sınıflı diş numaralandırma modülünde ise %94.35 hassasiyet ve %91.51 mAP değerleri


elde edilmiştir (182). Özellikle dişlerin numaralandırılmasında elde edilen değerlerin bu tez çalışmasından daha yüksek olmasının nedeni, periapikal radyografi yönteminin bite-wing radyografi yöntemine göre diş kronlarının haricinde görüntüde daha fazla nesne içermesi ile bu durumun diş tespiti ve numaralandırma işlemini zorlaştırması olabilir. Ayrıca karışık dişlenme döneminde alınan radyografilerde gelişmekte olan daimi diş germeleri ve süt dişlerinde rezorpsiyonlar görülmesi görüntü netliğini olumsuz yönde etkilemiş olabilir.

Literatürde yapılan diğer benzer çalışmalar araştırıldığında, Chen ve arkadaşlarının dijitalize edilmiş periapikal radyografiler kullanılarak yaptıkları çalışmada Faster R-CNN mimarisi ile dişlerin tespiti ve numaralandırılması değerlendirilmiştir. Sonucunda dişlerin tespitinde 0,988 kesinlik ve 0,985 duyarlılık, dişlerin numaralandırmasında ise 0,917 kesinlik ve 0,914 duyarlılık değerlerini elde etmişlerdir (177). Yasa ve arkadaşları, bite-wing radyografiler kullanarak dişlerin tespiti ve numaralandırılması çalışmasında Faster R-CNN modeli ile iki farklı model arasında karşılaştırma yapmışlardır. İlk önce dişlerde sağ ve sol ayrımı yaparak, ikinci adımda ise sağ sol ayrımı yapmadan değerlendirme yapmışlardır. Çalışma 109 bite-wing veri setinin test verilerinden 715 dişten 697'sini doğru bir şekilde numaralandırmıştır. Kullanılan görüntülerde kronlar, köprüler, implantlar ve implant destekli restorasyonlar yoktur ve 12 radyografi eksik bir diş göstermiştir. Süt dişleri çalışmaya dahil edilmeyip sadece erişkin hastaların radyografileri dahil edilmiştir. Bu çalışmanın sonucunda 0,9748 duyarlılık, 0,9293 kesinlik ve 0,9515 F1-skor değerleri karmaşıklık matrisinden elde edilerek hesaplanmıştır (178). Bizim çalışmamıza ise dolgu, amputasyon, kök kanal tedavisi ve sabit yer tutucu gibi dental restorasyonların bulunduğu periapikal radyografiler dahil edilmiştir. Ayrıca daimi diş eksikliği bulunan radyografiler ve çekilmiş süt dişlerinin bulunduğu görüntüler de çalışmaya dahil edilmiştir.

Zhang ve arkadaşları, periapikal radyografiler üzerinde diş tespit ve numaralandırma çalışmasında etiket ağacı yöntemini kullanarak ESA tabanlı kademeli ağ modeli geliştirmişlerdir. Bu çalışmada veri kümesi eğitim için 800 periapikal radyografi ve test için 200 periapikal radyografi içermektedir. Tüm veriler 32 diş sınıflamasında sınırlayıcı kutular ve etiketler ile açıklanmıştır. Bu modelin diş tespit performans değerlendirme sonuçları 0,958 kesinlik ve 0,961 duyarlılık; dişlerin sınıflandırılmasında 0,803 kesinlik, 0,806 duyarlılık olarak gösterilmiştir. Sınırlı eğitim veri setine, çürük ve restorasyonlu

dişlerin varlığına, diş kaybı veya eksikliğine rağmen modelin oldukça iyi değerler sergilediği bildirilmiştir (183). Zhang ve arkadaşlarının periapikal radyografiler kullanarak yaptığı bu çalışmanın kesinlik ve duyarlılık değerlerinin bizim çalışmamızla karşılaştırıldığında daha düşük olduğu görülmüştür.

Tuzoff ve arkadaşlarının 1352 panoramik radyografi kullanarak diş tespiti ve numaralandırılması çalışmasında ESA tabanlı modellerin performansını uzman diş hekimleriyle karşılaştırmışlardır. Bu çalışmada diş tespiti için Faster R-CNN modeli ve diş numaralandırması için VGG-16 Net modeli kullanılmıştır. Yapılan bu çalışmada modelin uzman diş hekimleri ile kıyaslanabilir şekilde başarılı sonuçlar verdiği görülmektedir (184). Bununla beraber bu çalışmada diş eksikliğinin olduğu görüntülerde modelin yanlış numaralandırmalar yaptığı bildirilmiştir. Bizim çalışmamızda ise diş eksikliğinin veya kaybının olduğu görüntülerde bile geliştirilmiş YOLOv8 modelinin başarılı numaralandırma yaptığı Şekil 5.1’de gösterilmiştir.



Şekil 5. 1. Diş eksikliği durumunda modelin başarılı bir şekilde numaralandırma yaptığı örnek periapikal radyografiler

Çalışmamıza benzer olarak çocuklarda dişlerin numaralandırılması üzerine yapılan çalışmaları incelersek; Kılıç ve arkadaşları, panoramik radyografiler üzerinden süt dişlerinin otomatik tespit edilmesi ve numaralandırılması için Faster R-CNN modeli ile

yapay zeka algoritması uygulamışlardır. Bu model 5-7 yaş arası çocuklardan alınan 421 panoramik radyografi içermektedir. Geliştirilen algoritmanın sonuçları sırasıyla duyarlılık, kesinlik ve F1 skorları 0,9804, 0,9571 ve 0,9686 elde edilmiştir (134). Başka bir çalışmada otomatik daimi diş germi tespiti ve numaralandırılması için YOLOV4 modeli kullanılmıştır. 5-13 yaş arası çocuk hastalardan alınan 4518 panoramik radyografi algoritmanın eğitimi ve test edilmesi için kullanılmıştır. Bu modelin tespit doğruluğu gerçek pozitif, gerçek negatif, yanlış pozitif ve yanlış negatif değerlerine göre hesaplanmıştır. Performans değerlendirilmesi için kesinlik, duyarlılık, F1 skor ve mAP metrikleri kullanılmıştır. Modelin kesinlik, duyarlılık ve F1-skoru sırasıyla 0,89, 0,91 ve 0,9 olarak hesaplanmıştır (185).

Kaya ve arkadaşları, 4545 panoramik radyografi kullanarak diş tespiti ve numaralandırılması için yaptıkları çalışmada ESA tabanlı nesne algılama yöntemi kullanmışlardır. 5-13 yaş arası çocuklardan alınan görüntü YOLOv4 mimarisi kullanılarak değerlendirilmiştir. Değerlendirme sonucunda %94.44 ortalama duyarlılık değeri ve 0,91 ağırlıklı F1-skoru, %92.22 mAP değeri elde etmişlerdir (148). Bizim çalışmamızda ise YOLOv8 modeli ile 6-12 yaş arası çocuklardan alınan periapikal radyografiler kullanılarak süt ve daimi dişlerin numaralandırılması değerlendirilmiştir. YOLOv8 modelinin ve poligon etiketleme yönteminin kullanılması dişlerin daha hassas ve ayrıntılı bir şekilde belirlenmesini sağlamıştır. Her iki çalışmada da performans değerlendirilmesi için benzer metrikler kullanılmıştır.

Altuntaş ve arkadaşlarının panoramik radyografiler üzerinden dişlerin evrensel numaralandırma sistemine göre tespit edilmesi çalışmasında DENTEX Challenge 2023 ve Tufs Dental veri tabanında paylaşılan görseller kullanılmıştır. Bu çalışma süt dişlenme, karışık dişlenme ve daimi dişlenme dönemlerine ait 1684 panoramik radyografi içermektedir. Ayrıca kullanılan veri setinde 800 görüntüye veri artırma yöntemi uygulanıp veri sayısı 2434'e çıkarılmıştır. Çalışmanın sonucunda test veri setinde bulunan 365 adet süt dişlenme, daimi dişlenme ve karışık dişlenme döneminde alınan panoramik radyografide %92 doğruluk gösterdiği bildirilmiştir (186). Bu tez çalışmasında ise periapikal radyografiler kullanılarak dişlerin FDI numaralandırma sistemine göre sınıflandırılması yapılmıştır. Literatür tarandığı zaman çocuk hastalarda karışık dişlenme dönemini içeren periapikaller üzerinden dişlerin numaralandırılması

çalışmasına rastlanılmamıştır. Bu durum çalışmamıza farkındalık katarak ileriki dönemlerde yapılacak çalışmalara öncülük etmektedir.

2024 yılında Beşer ve arkadaşları, 3854 panoramik radyografi kullanarak diş tespiti ve numaralandırılması için yaptıkları çalışmada YOLOv5 modeli kullanmışlardır. 5-13 yaş arası çocuklardan alınan panoramik radyografilerde süt ve daimi dişlerin etiketlenmesi CranioCatch programı kullanılarak yapılmıştır. Çalışmanın sonucunda dişlerin tespitinde duyarlılık, hassasiyet, F1-skoru ve ortalama hassasiyet, mAP-0.5 değerleri sırasıyla 0,99, 0,99, 0,99 ve 0,98, dişlerin numaralandırılmasında duyarlılık, hassasiyet, F-1 skoru ve mAP-0.5 değerleri sırasıyla 0,98, 0,98, 0,98 ve 0,98 olarak bulunmuştur. Çalışmanın sonucunda YOLOv5 tabanlı modellerin, süt ve daimi dişleri doğru bir şekilde tespit etme ve numaralandırmada yüksek potansiyele sahip olduğu bildirilmiştir (187). Beşer ve arkadaşlarının yaptığı bu çalışmanın daha geniş bir diş tespit ve numaralandırma perspektifi sunduğu görülmektedir.

Yapılan literatür taramamızda dişlerdeki restorasyonların tespiti çalışmalarını inceleyerek; Ari ve arkadaşlarının derin öğrenme tabanlı algoritmalar kullanarak geliştirdikleri yapay zeka modelinde çürük lezyon, kron, diş pulpası, diş dolgusu, periapikal lezyon ve kök kanal dolgusu segmentasyonunun etkinliğini değerlendirmişlerdir. Bu çalışma CranioCatch yazılımında etiketlenmiş 1169 yetişkin periapikal radyografi içermektedir. PyTorch kütüphanesiyle U-Net modeli kullanılmıştır. Modelin eğitiminde yoğunluk normalizasyonu ve Kontrast Sınırlı Uyarlamalı Histogram Eşitleme gibi görüntü iyileştirme yöntemleri uygulanmıştır. Çalışmanın sonucunda çürük lezyon için kesinlik, duyarlılık ve F1 skorları sırasıyla 0,82, 0,82 ve 0,82; kron için kesinlik, duyarlılık ve F1 skoru sırasıyla 1, 1 ve 1 ; diş pulpası için kesinlik, duyarlılık ve F1 skoru sırasıyla 0,87, 0,97 ve 0,92; dolgu için kesinlik, duyarlılık ve F1 skoru sırasıyla 0,95, 0,95 ve 0,95; periapikal lezyon için kesinlik, duyarlılık ve F1 skoru sırasıyla 0,85, 0,92 ve 0,88; kök kanal dolgusu için kesinlik, duyarlılık ve F1 skoru sırasıyla 0,96, 1 ve 0,98 olarak bulunmuştur (8). Bu iki çalışmada benzer veri seti sayısı kullanıldığı ve performans başarısı elde edildiği görülmüştür. Ancak bizim çalışmamız karışık dişlenme döneminde bulunan hastalardan alınmış periapikal radyografileri içermektedir. Ayrıca multiclass (çoklu sınıflama) bir yöntem kullanılarak yapıldığı için dental restorasyonlar ayrı ayrı değerlendirilmemiştir.

Mao ve arkadaşları bite-wing radyografiler üzerinde yaptıkları çalışmada, çürük tespiti ve restorasyon için geliştirdikleri ESA tabanlı AlexNet derin öğrenme modelinin başarısını değerlendirmişlerdir. Bu çalışma, modelin ön işleme yöntemi, diş örneklerini tek tek ayırmak için segmentasyon yöntemi, çürükleri ve restorasyonları tanımlamak için kapsamlı bir model eğitimi sunmuştur. Daha iyi doğruluk değerlerine ulaşabilmek için üç adımdan oluşan görüntü ön işleme, kırpma, iyileştirme tekniklerini kullanmışlardır. Bu modelin sonucunda çürük tespiti için 0,903, restorasyon tespiti için 0,9556 doğruluk değerleri bulunmuştur. Bu tez çalışmasında derin öğrenme modeline uygun şekilde boyutlandırılmış görüntüler kullanılırken herhangi bir görüntü geliştirme ve kırpma tekniği kullanılmamıştır (188).

Engels ve arkadaşları 2022 yılında ağız içi fotoğraflar kullanarak yaptıkları çalışmada ESA tabanlı derin öğrenme metodu kullanarak farklı tipteki posterior restorasyonları değerlendirmişlerdir. 1761 görüntüden oluşan bu çalışma restorasyonları; restore edilmemiş diş yüzeyi, direkt kompozit dolgu, kalıcı veya geçici siman restorasyonları, amalgam dolgular, indirekt altın inleyler veya kronlar ve indirekt seramik kaplamalar veya kronlar olarak kategorize etmişlerdir. Eğitim tamamlandıktan sonra doğruluk değerleri restore edilmemiş dişler için %94.9, kompozitler için %92.9, simanlar için %98.3, amalgam restorasyonlar için %99.2, altın restorasyonlar için %99.4 ve seramik restorasyonlar için %97.8 olarak hesaplanmıştır (189).

Gardiyanoğlu ve arkadaşları 7696 panoramik radyografi dahil ederek tüm dişlerdeki restorasyonları tespit etmek için derin öğrenme tabanlı U-Net mimarisi kullanmışlardır. Tüm dişlerde bulunan; krun-köprü restorasyonları, kompozit-amalgam restorasyonlar, diş çürükleri, dental implantlar, rezidüel kökler ve kök kanal dolguları iki uzman tarafından manuel olarak segmentlere ayrılmıştır. Veri setindeki görseller 512 x 1280 piksel olarak yeniden boyutlandırılıp, Python programlama dilinde model oluşturulmuştur. Çalışmanın sonuçlarında hesaplanan doğruluk değerleri diş segmentasyonu için 0,95, diş çürükleri için 0,99, diş restorasyonları için 0,99, krun-köprü restorasyonları için 0,99, dental implantlar için 0,99, kök kanal dolguları için 0,99 ve rezidüel kökler için 0,99 olarak bulunmuştur (190).

Jagtap ve arkadaşlarının 18 yaş ve üstü bireylerden alınan periapikal radyografileri kullanarak yaptıkları çalışmada dişlerin, çürüklerin, implantların, sabit protezlerin otomatik tespiti değerlendirilmiştir. 500 yetişkin hastadan alınan 1000 periapikal

radyografi içeren veri seti oluşturulmuştur. ABD'nin Kaliforniya eyaletinde bulunan VELMENE Inc. tarafından geliştirilen ESA mimarisi kullanılarak iki oral ve maksillofasiyal radyolog tarafından karşılaştırma yapılmıştır. Yapay zeka modeli ile 1. gözlemci arasındaki anlaşma içi dolu siyah bir daire ile, 2. gözlemci arasındaki uyum boş bir kırmızı daire ile gösterilmiştir. Bu çalışma karşılaştırmalı yaklaşım kullanarak insan ile otomatik değerlendirmeler arasındaki tutarlılığı, doğrulamayı ve yapay zekanın dış anomalilerini belirlemedeki etkinliğini değerlendirmeyi amaçlamıştır. Çalışmadan elde edilen doğruluk değerleri çürük dişlerde 0,7-0,73, implantlarda 0,97-0,98, sabit protezli dişlerde 0,92-0,94, restore edilmiş dişlerde 0,85-0,89 olarak bulunmuştur. Yapay zeka algısı ile 1. ve 2. gözlemci arasında güçlü bir korelasyon gözlemlendiği belirtilmiştir (149).

Çelik ve arkadaşlarının 18-65 yaş arasında hastalardan alınan panoramik radyografilerle gerçekleştirdiği çalışmada restorasyonların tespiti değerlendirilmiştir. Toplam 684 nesne ile 123 panoramik radyografi dahil edilmiştir. Bu çalışma R-CNN, daha hızlı R-CNN, SSD, YOLOv3 ve RetinaNet dahil olmak üzere son teknoloji olan on farklı derin öğrenme algılama modeli kullanarak diş restorasyonlarının, protezlerin ve implantların otomatik tespiti amacıyla kapsamlı bir çözüm sunmaktadır. Modellerin geliştirilmesi için PyTorch kütüphanesi ve GoogleCoLab kullanılmıştır. Her model genel ortalama kesinlik (mAP), ortalama geri çağırma (AR) ve duyarlılık-geri çağırma eğrisi ile değerlendirilmiştir. Çalışmanın sonuçları incelendiğinde mAP değerlendirilen on model için 0,755 ile 0,973 arasında değişirken, AR değeri 0,605 ile 0,771 arasında değişmektedir. R-CNN RegnetX 0,771 AR ve 0,973 mAP değerleri ile en iyi algılama performansı göstermiştir. Bu bağlamda önerilen yapay zeka tabanlı modellerin panoramik radyografilerde diş restorasyonlarını, dental implantları ve protezi belirlemede başarılı performans ile güvenilir sonuçlar sunduğu gösterilmiştir (150).

Magat ve arkadaşlarının yaptıkları çalışmada 1159 bite-wing radyografiden oluşan veri seti kullanılmıştır. Evrişimli sinir ağı tabanlı olan YOLOv5 modeli taşkın restorasyonların tespiti ve segmentasyonu için eğitilmiştir. Eğitim süreci Python'daki PyTorch kitaplığı kullanılarak yürütülmüştür. Ayrıca eğitim Dental-AI Laboratuvarı'nda bulunan Dell PowerEdge T640 Hesaplama Sunucusu, Dell PowerEdge T640 GPU Hesaplama Sunucusu ve Dell PowerEdge R540 Depolama Sunucusu' nu içeren bilgisayar ekipmanları kullanılarak gerçekleştirilmiştir. Evrişimli sinir ağı modelinin etkinliğini değerlendirmek için doğruluk, duyarlılık, kesinlik, F1-skoru ve alıcı işletim karakteristik

eğrisi (AUC) altındaki alan metrikleri kullanılmıştır. Modelin duyarlılığı %90.9, F1-skoru %88.0 olarak hesaplanmıştır. Ayrıca modelin işletim karakteristik (ROC) eğrisinde AUC 0,859 olarak belirlenmiş ve 0.5 IoU eşliğindeki mAP 0,87 olarak kaydedilmiştir. Bu çalışma yapay zekanın performansını değerlendirirken aynı zamanda uzman dış hekimlerinin YZ ile karşılaştırmasını da içermektedir. Yapay zeka performans metrikleri 20'nin üzerinde bite-wing radyografi üzerinden değerlendirildiğinde hassasiyet ve F1-skoru açısından 4 ve 6 yıllık deneyime sahip bir uzmandan daha iyi sonuçlar elde ettiği görülmüştür. 4 ve 6 yıllık deneyime sahip uzman dış hekimleri ile yapay zeka modelinin AUC değerinin benzer olduğu görülmüştür. 10 yıllık deneyime sahip uzman dış hekimlerinin ise tüm performans değerlendirme metriklerinde yapay zeka modellerinden daha iyi performans gösterdiği bildirilmiştir (191).

Akgül ve arkadaşları 2024 yılında normal dolgu ve taşkın dolgu restorasyonlarını değerlendirdikleri çalışmada sırasıyla 2473 ve 1850 panoramik radyografi dahil etmişlerdir. Bu çalışmanın amacı panoramik radyografiler üzerinde ESA tabanlı derin öğrenme mimarisi kullanılarak normal ve taşkın dolguların yaygınlığını ve dağılımı değerlendirmektir. Toplam 10480 dolgu ve 2491 taşkın dolgu CranioCatch yazılımı ile etiketlenerek işlenmiştir. Karma dentisyona sahip hastalardan alınan panoramik radyografiler etiketleme sürecinde hatalara sebep olacağı düşünüldüğü için çalışmaya dahil edilmemiştir. YOLOv5x mimarisi yapay zeka modellerinin geliştirilmesinde kullanılmıştır. Model performans başarısını değerlendirmek amacıyla karmaşıklık matrisi kullanılarak duyarlılık, kesinlik ve F1 skor metrikleri hesaplanmıştır. Dolgu için kesinlik 0,97, duyarlılık 0,95 ve F1-skor 0,96; taşkın dolgu için kesinlik 0,89, duyarlılık 0,86, F1-skoru 0,87 olarak hesaplanmıştır. Bu çalışma ayrıca YOLOv5 modelinin görüntüleri verimli ve doğru bir şekilde segmentlere ayırma potansiyelini ve dolgu restorasyonlarını tespit etme ve ayırt etmede yeterliliğini göstermektedir (192).

Razaghi ve arkadaşları yaygın dış problemlerinin tespiti ve kategorilendirilmesi amacıyla yenilikçi bir yöntem geliştirmek üzere YOLOv8 derin öğrenme modelini kullanmışlardır. Bu çalışmanın odak noktası, bite-wing ve panoramik radyografilerden oluşan görüntüler değerlendirilerek oral ve dental hastalıkların incelenmesidir. Toplam 316 görüntüden oluşan veri seti, veri artırma yoluyla 1516 görüntüye çıkarılmıştır. Çeşitli YOLOv8 modelleri ile bu veri seti eğitilmiş 12 dış problemi sınıflandırılmıştır. Bu dış problemleri; diş çürüğü, kompozit rezin restorasyonu, amalgam restorasyonu, taşkınlık, gömülü diş,

kuron, marjinal boşluk, kalan kök, kök kanal tedavisi, periapikal lezyon, post, başarısız kanal tedavisi olarak sıralanmıştır. Ayrıca bu veri seti YOLOv8'in birden fazla modelini eğitmek amacıyla da kullanılmıştır. Çalışmanın sonucunda YOLOv8m eğitiminde en iyi performansın %90 geri çağırma, %90 kesinlik ve %71 mAP elde edildiği gösterilmiştir (127). Bizim çalışmamızda ise ekstra büyük model olan YOLOv8x modeli kullanılmıştır.

Bu tez çalışmasında her sınıflama için her bir grupta eşit sayıda veri seti bulunmamaktadır. Bu durumun nedeni, bazı tedavilerin daha yaygın uygulanmasıyla beraber periapikal görüntülerinin de daha fazla olmasıdır. Nadir görülen tedavilerdeki verilerin azlığı modelin daha düşük performans göstermesine yol açmış olabilir. Ayrıca kullanılan veri setlerinin göreceli olarak kısıtlı sayıda olması, elde edilen modelin başarısının daha iyi değerlendirilebilmesi için eğitim ve doğrulama süreçlerinde yapay zeka modellerinin hiç eğitilmediği görüntülerden yararlanılması önerilmektedir. Gelecekteki çalışmalarda, dengesiz veri seti ve her bir periapikalinden birden fazla restorasyon içerdiği göz önünde bulundurularak, belirli bir sınıfı artırmak için yeniden örnekleme yaparak ya da veri artırma yöntemlerini kullanarak bu durumun giderilebileceği düşünülmektedir.

Bu çalışmada veri setini oluşturmak için tek tip X-ray cihazı kullanılması, harici veri setinin kullanılmaması, periapikal standardizasyonunun farklı uygulayıcıların olması nedeniyle sağlanamaması ve farklı ESA modellerinin kullanılmaması gibi sınırlamaları bulunmaktadır. Yapılacak çalışmalar kapsamında, farklı görüntüleme cihazlarından elde edilen çeşitlendirilmiş verilerle oluşturulacak veri seti, yapay zeka modellerinin performansının artırılmasına katkı sağlayacaktır.

6. SONUÇ VE ÖNERİLER

Diş hekimliğinde klinik değerlendirmenin ilk aşaması dental radyografilerde dişlerin tespiti ve numaralandırılmasıdır. Bu işlemin yapay zeka tabanlı algoritmalar kullanılarak otomasyonunun sağlanması diş hekimlerinin klinikteki uygulamalarını kolaylaştıracaktır. Bu çalışmada, yapay zeka algoritmaları kullanılarak karışık dişlenme döneminde elde edilen görüntüler üzerinden dişlerin doğru bir şekilde numaralandırılması ve restorasyonların tespiti hedeflenmiştir. Geliştirilen yapay zeka tabanlı algoritma ile periapikal radyografilerde dişlerin numaralandırılmasında %89, restorasyonların tespitinde ise %83 doğruluk sonucuna ulaşılmıştır. Bu yüksek doğruluk değerleri, algoritmanın gelecek çalışmalar için umut vaat ettiğini göstermektedir. Özellikle modelin karışık dişlenme dönemindeki dişlerin doğru bir şekilde tanınmasında ve restorasyonların belirlenmesinde etkili olduğu gözlemlenmiştir.

Literatür taramamızda gözlemlediğimiz kadarıyla ilk kez yapılan ve öncü bir çalışma niteliğinde olan bu çalışma, yapay zeka modellerinin yoğun hasta potansiyeline sahip kliniklerde tanı ve tedavi süreçlerinde zaman ve iş gücü verimliliği açısından önemli faydalar sağlayacağına işaret etmektedir.

Sonuçlar değerlendirildiğinde modelin doğruluğunu artırmak için farklı hastalardan ve farklı cihazlardan elde edilen daha geniş veri setlerinin kullanılmasının faydalı olacağı, restorasyonların tespiti konusunda daha ayrıntılı etiketleme yapılarak modelin restorasyon türlerini daha hassas bir şekilde sınıflandırılacağı öngörülmektedir.

7. KAYNAKLAR

1. Pitts, N. B., Zero, D. T., Marsh, P. D., Ekstrand, K., Weintraub, J. A., Ramos-Gomez, F., & Ismail, A. Dental caries. *Nature reviews Disease primers. Dental caries.* 2017; 3(1), 1-16 (17030).
2. Mortensen D, Dannemand K, Twetman S, Keller MK. Detection of non-cavitated occlusal caries with impedance spectroscopy and laser fluorescence: an in vitro study. *Open Dent J.* 2014 Apr 4;8:28–32.
3. Gomez J. Detection and diagnosis of the early caries lesion. *BMC Oral Health.* 2015 Sep 15;15 Suppl 1(S1):S3.
4. Young DA, Featherstone JDB. Caries management by risk assessment. *Community Dent Oral Epidemiol.* 2013 Feb;41(1):e53–63.
5. Keenan JR, Keenan AV. Accuracy of dental radiographs for caries detection: Question: How accurate are dental radiographs for caries detection. *Evid Based Dent.* 2016 Jun;17(2):43.
6. White SC, Pharoah MJ. *Oral radiology: principles and interpretation.* Elsevier Health Sciences. 2013.
7. Shah N, Bansal N, Logani A. Recent advances in imaging technologies in dentistry. *World J Radiol.* 2014 Oct 28;6(10):794–807.
8. Ari T, Sağlam H, Öksüzoğlu H, Kazan O, Bayrakdar İŞ, Duman SB, Çelik Ö, Jagtap R, Gabka KF. Automatic feature segmentation in dental periapical radiographs. *Diagnostics (Basel).* 2022 Dec 7;12(12):3081.
9. Naeimi SM, Darvish S, Salman BN, Luchian I. Artificial intelligence in adult and pediatric dentistry: A narrative review. *Bioengineering (Basel).* 2024 Apr 27;11(5):431.
10. Reyes LT, Knorst JK, Ortiz FR, Ardenghi TM. Scope and challenges of machine learning-based diagnosis and prognosis in clinical dentistry: A literature review. *J Clin Transl Res.* 2021 Aug 26;7(4):523–39.
11. Hosny A, Parmar C, Quackenbush J, Schwartz LH, Aerts HJ. Artificial intelligence in radiology. *Nature Reviews Cancer.* 2018;18(8):500–10.
12. Hwang JJ, Jung YH, Cho BH, Heo MS. An overview of deep learning in the field of dentistry. *Imaging Sci Dent.* 2019 Mar;49(1):1–7.
13. Murata M, Arijji Y, Ohashi Y, Kawai T, Fukuda M, Funakoshi T. Deep-learning classification using convolutional neural network for evaluation of maxillary sinusitis on panoramic radiography. *Oral Radiol.* 2019 Sep;35(3):301–7.
14. Park W, Huh JK, Lee JH. Automated deep learning for classification of dental implant radiographs using a large multi-center dataset. *Sci Rep.* 2023 Mar

24;13(1):4862.

15. Mohammad-Rahimi H, Rokhshad R, Bencharit S, Krois J, Schwendicke F. Deep learning: A primer for dentists and dental researchers. *J Dent.* 2023 Mar;130(104430):104430.
16. BİÇER, A. G. Z., TEPE, Ö. G. H., ÇELİKSÖZ, Ö. G. Ö., & YAMAN, B. C. Yapay Zeka Ve Restoratif Diş Hekimliği. *TIP VE SAĞLIK BİLİMLERİNDE MULTİDİSİPLİNER BAKIŞ I.* 2023.
17. Pitts, N. B., & Zero, D. White paper on dental caries prevention and management. FDI World Dental Federation. 2016;3-9.
18. Wajs S. Dental caries. *Pieleg Polozna.* 1981;3(9):4-5.
19. United States. Public Health Service. Office of the Surgeon General, National Institute of Dental, & Craniofacial Research (US). Oral health in America: A report of the Surgeon General. National Institute of Dental and Craniofacial Research. 2000.
20. Tinanoff N. Dental Caries. In: Nowak AJ, Christensen JR, Mabry TR, Townsend JA, Wells MH, editors. *Pediatric Dentistry Elsevier.* 2019; p. 169-79.
21. Rathee M, Sapra A. Dental caries. In: *StatPearls. Treasure Island (FL). StatPearls Publishing.* 2024.
22. Selwitz RH, Ismail AI, Pitts NB. Dental caries. *Lancet.* 2007 Jan;369(9555):51-9.
23. Pitts NB. Diagnostic tools and measurements--impact on appropriate care. *Community Dent Oral Epidemiol.* 1997 Feb;25(1):24-35.
24. Korkut B, Tagtekin DA, Yanikoglu F. Early diagnosis of dental caries and new diagnostic methods: QLF, Diagnodent, electrical conductance and ultrasonic system. *EU Dishek Fak Derg.* 2011.
25. Özgür B, Ünverdi GE, Çehreliz A F E. Diş çürüğünün tespitinde geleneksel ve güncel yaklaşımlar. *Türkiye Klinikleri Journal of Pediatric Dentistry-Special Topics.* 2018;4(1):1-9.
26. Mohammad-Rahimi H, Motamedian SR, Rohban MH, Krois J, Uribe SE, Mahmoudinia E. Deep learning for caries detection: A systematic review. *J Dent.* 2022 Jul;122(104115):104115.
27. Zandoná AF, Zero DT. Diagnostic tools for early caries detection. *J Am Dent Assoc.* 2006 Dec;137(12):1675-84; quiz 1730.
28. Ekstrand KR, Ricketts DN, Kidd EA, Qvist V, Schou S. Detection, diagnosing, monitoring and logical treatment of occlusal caries in relation to lesion activity and severity: an in vivo examination with histological validation. *Caries Res.* 1998;32(4):247-54.
29. Gürses, M., & Ünlü, N. (2017). OKLUZAL ÇÜRÜK TEŞHİS YÖNTEMLERİNE

GÜNCEL BAKIŞ. Selcuk dental journal. 4(3), 153-161.

30. Kühnisch J, Ifland S, Tranaeus S, Hickel R, Stösser L, Heinrich-Weltzien R. In vivo detection of non-cavitated caries lesions on occlusal surfaces by visual inspection and quantitative light-induced fluorescence. *Acta Odontol Scand.* 2007 Jun;65(3):183–8.
31. Maupomé G, Pretty IA. A closer look at diagnosis in clinical dental practice: part 4. Effectiveness of nonradiographic diagnostic procedures and devices in dental practice. *J Can Dent Assoc.* 2004 Jul;70(7):470–4.
32. Kühnisch J, Goddon I, Berger S, Senkel H, Bücher K, Oehme T. Development, methodology and potential of the new Universal Visual Scoring System (UniViSS) for caries detection and diagnosis. *Int J Environ Res Public Health.* 2009 Sep;6(9):2500–9.
33. Nyvad B, Machiulskiene V, Baelum V. Reliability of a new caries diagnostic system differentiating between active and inactive caries lesions. *Caries Res.* 1999 Jul;33(4):252–60.
34. Pitts NB, Ekstrand KR, ICDAS Foundation. International Caries Detection and Assessment System (ICDAS) and its International Caries Classification and Management System (ICCMS)- methods for staging of the caries process and enabling dentists to manage caries. *Community Dent Oral Epidemiol.* 2013 Feb;41(1):e41–52.
35. Banting, D., Eggertsson, H., Ekstrand, K., Ferreira-Zandoná, A., Ismail, A., Longbottom, C., Zero, D. Rationale and evidence for the international caries detection and assessment system (ICDAS II). *Ann Arbor.*2005; 1001, 48109-1078.
36. Diniz MB, Rodrigues JA, Lussi A. Traditional and novel caries detection methods. *Contemporary approach to dental caries.* 2012;6:105–28.
37. Wenzel A. Bitewing and digital bitewing radiography for detection of caries lesions. *J Dent Res.* 2004 Jul;83(1_suppl):72–5.
38. Direkt Sistemler C C. İntraoral Dijital Görüntüleme Sistemleri: Direkt Sistemler, CCD, CMOS, Düz Panel Dedektörler, İndirekt Sistemler, Yarı Direkt Dijital Görüntüleme, Fosfor Plak Taramaları. *Türkiye Klinikleri J Oral Maxillofac Radiol-Special Topics.* 2016;2(2):4–9.
39. Yeler, D. Y., Taşveren, S. K., & Kaynar, O. Dişhekimliğinde dijital görüntüleme yöntemleri. *Atatürk Üniversitesi Diş hekimliği fakültesi dergisi,* 2006(Supplement 1).
40. Rózyło-Kalinowska, I. Panoramic radiography in dentistry. *Clinical Dentistry Reviewed.* 2021;5(1), 26.
41. White, S. C., & Pharoah, M. J. *Oral radiology: principles and interpretation.* Elsevier Health Sciences. 2013.
42. Iannucci, J., & Howerton, L. J. *Dental radiography-E-book: principles and*

techniques. Elsevier Health Sciences. 2016

43. Kumar R, Khambete N, Priya E. Extraoral periapical radiography: an alternative approach to intraoral periapical radiography. *Imaging Sci Dent*. 2011 Dec;41(4):161–5.
44. Mallya, S., & Lam, E. *White and Pharoah's oral radiology: principles and interpretation*. Elsevier Health Sciences. 2018.
45. Bicer, A. Z., & Unver, S. Etiology of secondary caries in prosthodontic treatments. *Dental Caries-Diagnosis, Prevention and Management*. 2018; 10, 35-54.
46. Talaiepour AR, Nemati Anaraki S, Heidarkhan Tehrani S, Golpasha M. In Vivo Diagnostic Accuracy of Digital Radiography in the Detection of Secondary Caries in Anterior Teeth. 2016; Available from: <https://jrdms.dentaliau.ac.ir/article-1-109-fa.html>
47. Patel S, Brown J, Pimentel T, Kelly RD, Abella F, Durack C. Cone beam computed tomography in Endodontics- a review of the literature. *Int Endod J*. 2019 Aug;52(8):1138–52.
48. Antony DP, Thomas T, Nivedhitha MS. Two-dimensional periapical, panoramic radiography versus three-dimensional cone-beam computed tomography in the detection of periapical lesion after endodontic treatment: A systematic review. *Cureus*. 2020 Apr 19;12(4):e7736.
49. Campello AF, Gonçalves LS, Guedes FR, Marques FV. Cone-beam computed tomography versus digital periapical radiography in the detection of artificially created periapical lesions: A pilot study of the diagnostic accuracy of endodontists using both techniques. *Imaging science in dentistry*. 2017;47(1):25–31.
50. Kasraei S, Shokri A, Poorolajal J, Khajeh S, Rahmani H. Comparison of cone-beam computed tomography and intraoral radiography in detection of recurrent caries under composite restorations. *Braz Dent J*. 2017 Jan;28(1):85–91.
51. Lian L, Zhu T, Zhu F, Zhu H. Deep learning for caries detection and classification. *Diagnostics (Basel)*. 2021 Sep 13;11(9):1672.
52. Yılmaz F. DİŞ ÇÜRÜKLERİ VE TEDAVİSİNE GÜNCEL YAKLAŞIMLAR. *SAĞLIK & BİLİM* 2023. *Odontoloji-I*. 2023;19.
53. Jenson L, Budenz AW, Featherstone JDB, Ramos-Gomez FJ, Spolsky VW, Young DA. Clinical protocols for caries management by risk assessment. *J Calif Dent Assoc*. 2007 Oct 1;35(10):714–23.
54. Hickel R, Roulet JF, Bayne S, Heintze SD, Mjör IA, Peters M. Recommendations for conducting controlled clinical studies of dental restorative materials. *Clin Oral Investig*. 2007 Mar;11(1):5–33.
55. Kavrik F, Savaş S, Küçükyılmaz E, Çelik EU. Yüksek çürük riskli adölesanlarda farklı tedavi yaklaşımları. *Türkiye Klinikleri Journal of Dental Sciences Cases*.

- 2016;2(1):35–43.
56. Kidd E, Fejerskov O, Nyvad B. Infected dentine revisited. *Dent Update*. 2015 Nov;42(9):802–6, 808–9.
 57. Fontana M. Nonrestorative management of cavitated and noncavitated caries lesions. *Dent Clin North Am*. 2019 Oct;63(4):695–703.
 58. Urquhart O, Tampi MP, Pilcher L, Slayton RL, Araujo MWB, Fontana. Nonrestorative treatments for caries: Systematic review and network meta-analysis. *J Dent Res*. 2019 Jan;98(1):14–26.
 59. Slayton RL, Urquhart O, Araujo MWB, Fontana M, Guzmán-Armstrong S, Nascimento MM. Evidence-based clinical practice guideline on nonrestorative treatments for carious lesions: A report from the American Dental Association. *J Am Dent Assoc*. 2018 Oct;149(10):837–49.e19.
 60. Frencken JE, Peters MC, Manton DJ, Leal SC, Gordan VV, Eden E. Minimal intervention dentistry for managing dental caries - a review: report of a FDI task group: Report of a FDI task group. *Int Dent J*. 2012 Oct;62(5):223–43.
 61. Ünsal Ü, Adem K. Diş görüntüleri üzerinde görüntü işleme ve derin öğrenme yöntemleri kullanılarak çürük seviyesinin sınıflandırılması. *Uluslararası Sivas Bilim ve Teknoloji Üniversitesi Dergisi*. 2022;2(2):30–53.
 62. Kaptan A, Çukurcu Ç. Süt Dişi Amputasyon Tedavilerinde Güncel Yaklaşımlar. *Türkiye Klinikleri Dishekimliği Bilimleri Dergisi*. 2020;26(1):122–32.
 63. Ds Özdemir MB. Çocuk Diş Hekimliğinde Yer Tutucu Uygulamaları. Available from: <https://www.bidgecongress.org/wp-content/uploads/2022/12/Dis-Hekimligi-Bilimlerinde-Guncel-Tartismalar-1-3.pdf#page=110>
 64. Xuedong Z, Junqi L, Jingping L, Jiyao L, Lei C, Qing Y. Difficulty influence factors of dental caries clinical treatment. *Hua Xi Kou Qiang Yi Xue Za Zhi*. 2017 Feb 1;35(1):1–7.
 65. Cheng L, Zhang L, Yue L, Ling J, Fan M, Yang D. Expert consensus on dental caries management. *Int J Oral Sci*. 2022 Mar 31;14(1):17.
 66. Yavuzylmaz, H. Diş morfolojisi-Fizyolojisi ve oklüzyon. Gazi Üniversitesi İletişim Fakültesi Basımevi, Ankara.2007
 67. Wood JD. Forensic dental identification in mass disasters: the current status. *J Calif Dent Assoc*. 2014 Jun;42(6):379–83.
 68. Sharma PS, Wadhwa P. Evaluation of the FDI two-digit system of designating teeth. *Quintessence Int Dent Dig*. 1977 Oct;8(10):99–101.
 69. Hillson, S. Sequense and timing of dental growth. *Dental anthropology*. 1996; 118-46.
 70. Clark, D. H. Dental record interpretation. *Practical forensic odontology*. Oxford:

Butterworth-Heinemann. 1992;101-110.

71. Yaşar ZF, Büken E. Tooth Coding Numbering Systems. *ADO Klinik Bilimler Dergisi*. 2012;6(2):1166–72.
72. Alt KW, Loring Brace C, Türp JC. The history of dental anthropology. In: *Dental Anthropology*. Vienna: Springer Vienna. 1998; p. 15–39.
73. Internationale, F. D. Two-digit system of designating teeth. *International Dental Journal*. 1971; 21, 104-106.
74. Alpaydın, E. *Yapay öğrenme (4. baskı)*. Boğaziçi Üniversitesi, 2013
75. Uzun T. Yapay zeka Ve Sağlık Uygulamaları. İzmir Katip Çelebi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi. 2020;3(1):80–92.
76. Avaner, E. B. Turing Testi Işığında Düşüncenin Multidisipliner İncelemesi III. *Türkiye Biyoetik Dergisi*, 2018;5(4), 183-192.
77. Putra RH, Doi C, Yoda N, Astuti ER, Sasaki K. Current applications and development of artificial intelligence for digital dental radiography. *Dentomaxillofac Radiol*. 2022 Jan 1;51(1):20210197.
78. Khanagar SB, Al-Ehaideb A, Maganur PC, Vishwanathaiah S, Patil S, Baeshen HA. Developments, application, and performance of artificial intelligence in dentistry - A systematic review. *J Dent Sci*. 2021 Jan;16(1):508–22.
79. Schwendicke F, Elhennawy K, Paris S, Friebertshäuser P, Krois J. Deep learning for caries lesion detection in near-infrared light transillumination images: A pilot study. *J Dent*. 2020 Jan;92(103260):103260.
80. Soffer S, Ben-Cohen A, Shimon O, Amitai MM, Greenspan H, Klang E. Convolutional neural networks for radiologic images: A radiologist's guide. *Radiology*. 2019 Mar;290(3):590–606.
81. Mahesh B. Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*[Internet]. 2020;9(1):381–6.
82. Nichols JA, Herbert Chan HW, Baker MAB. Machine learning: applications of artificial intelligence to imaging and diagnosis. *Biophys Rev*. 2019 Feb;11(1):111–8.
83. Atalay M, Çelik E. BÜYÜK VERİ ANALİZİNDE YAPAY ZEKÂ VE MAKİNE ÖĞRENMESİ UYGULAMALARI- ARTIFICIAL INTELLIGENCE AND MACHINE LEARNING APPLICATIONS IN BIG DATA ANALYSIS. *Mehmet akif ersoy üniv sos bilim enst derg*. 2017 Dec 31;155–72.
84. McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*. 1943 Dec;5(4):115–33.
85. Hao X, Zhang G, Ma S. Deep learning. *Int J Semant Comput*. 2016 Sep;10(03):417–39.

86. Ergezer H, Dikmen M, Özdemir E. Yapay sinir ağları ve tanıma sistemleri. *PiVOLKA*. 2003;2(6):14–7.
87. Ağyar Z. Yapay sinir ağlarının kullanım alanları ve bir uygulama. *Mühendis ve Makine*. 2015;56(662):22–3.
88. Öztürk K, Şahin ME. Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*. 2018;6(2):25–36.
89. Öztemel, E. *Yapay Sinir Ağları*, Papatya Yayıncılık, 2. Baskı, İstanbul, 2006: 29–57.
90. Kaya U, Yılmaz A, Dikmen Y. Sağlık Alanında Kullanılan Derin Öğrenme Yöntemleri. *Eur J Sci Technol*. 2019 Aug 31;(16):792–808.
91. KELEŞ, A. DERİN ÖĞRENME VE SAĞLIK ALANINDAKİ UYGULAMALARI. *Electronic Turkish Studies*, 2018: 13(21).
92. Elshawi R, Wahab A, Barnawi A, Sakr S. DLBench: a comprehensive experimental evaluation of deep learning frameworks. *Cluster Comput*. 2021 Sep;24(3):2017–38.
93. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015 May 28;521(7553):436–44.
94. Collobert R, Weston J, Bottou L, Karlen M, Kavukcuoglu K, Kuksa P. Natural language processing (almost) from scratch. *Journal of machine learning research*. 2011;12:2493–537.
95. Söylemez ÖF, Ergen B. Farklı Evrimsel Sinir Ağı Mimarilerinin Yüz İfade Analizi Alanındaki Başarılarının İncelenmesi. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*. 2020;11(1):123–33.
96. Doğan F, Türkoğlu İ. Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*. 2019;10(2):409–45.
97. Choi RY, Coyner AS, Kalpathy-Cramer J, Chiang MF, Campbell JP. Introduction to machine learning, neural networks, and deep learning. *Transl Vis Sci Technol*. 2020 Feb 27;9(2):14.
98. Kriegeskorte N, Golan T. Neural network models and deep learning. *Curr Biol*. 2019 Apr 1;29(7):R231–6.
99. Bae JH, Yeo D, Yim J, Kim NS, Pyo CS, Kim J. Densely distilled flow-based knowledge transfer in teacher-student framework for image classification. *IEEE Trans Image Process*. 2020 Apr 6;29:5698–710.
100. Somuncu E, Atasoy NA. Evrimsel tekrarlayan sinir ağı ile metin görüntüleri üzerinde karakter tanıma uygulaması gerçekleştirilmesi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*. 2022;37(1):17–28.
101. HCA Deekshith Shetty, MJ Varma, S Navi, MR Ahmed. Diving Deep into Deep

- Learning: History, Evolution, Types and Applications. 2020;
102. Hinton GE, Salakhutdinov RR. Reducing the dimensionality of data with neural networks. *Science*. 2006 Jul 28;313(5786):504–7.
 103. Voulodimos A, Doulamis N, Doulamis A, Protopapadakis E. Deep learning for computer vision: A brief review. *Comput Intell Neurosci*. 2018 Feb 1;2018:7068349.
 104. Minaee S, Boykov Y, Porikli F, Plaza A, Kehtarnavaz N, Terzopoulos D. Image segmentation using deep learning: A survey. *IEEE Trans Pattern Anal Mach Intell*. 2022 Jul;44(7):3523–42.
 105. Chollet F. Xception: Deep learning with depthwise separable convolutions. In: 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE; 2017. p. 1251–8.
 106. Yaji A, Prasad S, Pai A. Artificial intelligence in dento-maxillofacial radiology. *Acta Sci Dent Sci*. 2019;3(1):116–21.
 107. Redmon J, Farhadi A. YOLO9000: Better, faster, stronger. In: 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE; 2017. p. 7263–71.
 108. Chen LC, Papandreou G, Kokkinos I, Murphy K, Yuille AL. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs. *IEEE Trans Pattern Anal Mach Intell*. 2018 Apr;40(4):834–48.
 109. Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: *Lecture Notes in Computer Science*. Cham: Springer International Publishing; 2015; p. 234–41. (Lecture notes in computer science).
 110. Milletari, F., Navab, N., & Ahmadi, S. A. V-net: Fully convolutional neural networks for volumetric medical image segmentation. In 2016 fourth international conference on 3D vision (3DV). 2016; (pp. 565-571).
 111. Koç A, Akgün D. U-net Mimarileri ile Glioma Tümör Segmentasyonu Üzerine Bir Literatür Çalışması. *Eur J Sci Technol*. 2021 Jul 1;(26):407–14.
 112. Simonyan, K., & Zisserman, A. Very deep convolutional networks for large-scale image recognition. *arXiv 2014*. arXiv preprint arXiv. 2014;1409.1556, 1409.
 113. Livne M, Rieger J, Aydın OU, Taha AA, Akay EM, Kossen T. A U-net deep learning framework for high performance vessel segmentation in patients with cerebrovascular disease. *Front Neurosci*. 2019 Feb 28;13:97.
 114. Kim C, Kim D, Jeong H, Yoon SJ, Youm S. Automatic tooth detection and numbering using a combination of a CNN and heuristic algorithm. *Appl Sci (Basel)*. 2020 Aug 13;10(16):5624.
 115. Bochkovskiy, A., Wang, C. Y., & Liao, H. Y. M. Yolov4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv*. 2020;2004.10934.

116. Girshick, R. Fast r-cnn. arXiv preprint arXiv. 2015;1504.08083.
117. Kumar A, Srivastava S. Object detection system based on convolution neural networks using single shot multi-box detector. *Procedia Comput Sci.* 2020;171:2610–7.
118. Gkioxari G, Girshick R, Malik J. Contextual action recognition with R* CNN. In: 2015 IEEE International Conference on Computer Vision (ICCV). IEEE.2015; p. 1080–8.
119. Jiang H, Learned-Miller E. Face detection with the faster R-CNN. In: 2017 12th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2017). IEEE. 2017; p. 650–7.
120. Redmon, J. You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition.* 2016.
121. Jeong HJ, Park KS, Ha YG. Image preprocessing for efficient training of YOLO deep learning networks. In: 2018 IEEE International Conference on Big Data and Smart Computing (BigComp). IEEE; 2018; p. 635–7.
122. Liu, K., Tang, H., He, S., Yu, Q., Xiong, Y., & Wang, N. Performance validation of YOLO variants for object detection. In *Proceedings of the 2021 International Conference on bioinformatics and intelligent computing.* 2021, January; 239-243).
123. Şenkal, H., & Alaçam, S. (2022). Derin Öğrenmeye Dayalı Nesne Tanıma Modeli: Antik Yunan Sütunları. *Mimarlıkta Sayısal Tasarım XVI. Ulusal Sempozyumu (MSTAS)*, 22-26.
124. Jocher, G., Stoken, A., Borovec, J., Changyu, L., Hogan, A., Diaconu, L., Rai, P. ultralytics/yolov5: v3. 1-bug fixes and performance improvements. *Zenodo.*2020.
125. Terven J, Córdova-Esparza DM, Romero-González JA. A comprehensive review of YOLO architectures in computer vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *Mach Learn Knowl Extr.* 2023 Nov 20;5(4):1680–716.
126. Reis, D., Kupec, J., Hong, J., & Daoudi, A. Real-time flying object detection with YOLOv8. arXiv preprint arXiv. 2023;2305.09972.
127. Razaghi M, Komleh HE, Dehghani F, Shahidi Z. Innovative diagnosis of dental diseases using YOLO V8 deep learning model. In: 2024 13th Iranian/3rd International Machine Vision and Image Processing Conference (MVIP). IEEE. 2024; p. 1–5.
128. Gündüz G, Cedimoğlu İH. Derin öğrenme algoritmalarını kullanarak görüntüden cinsiyet tahmini. *Sakarya University Journal of Computer and Information Sciences.* 2019;2(1):9–17.
129. Ghods K, Azizi A, Jafari A, Ghods K. Application of Artificial Intelligence in clinical dentistry, a comprehensive review of literature. *J Dent (Shiraz).* 2023 Dec;24(4):356–71.

130. Mahdi SS, Battineni G, Khawaja M, Allana R, Siddiqui MK, Agha D. How does artificial intelligence impact digital healthcare initiatives? A review of AI applications in dental healthcare. *International Journal of Information Management Data Insights*. 2023 Apr;3(1):100144.
131. Khanna SS, Dhaimade PA. Artificial intelligence: transforming dentistry today. *Indian J Basic Appl Med Res*. 2017;6(3):161–7.
132. Hartoonian S, Hosseini M, Yousefi I, Mahdian M, Ghazizadeh Ahsaie M. Applications of artificial intelligence in dentomaxillofacial imaging: a systematic review. *Oral Surg Oral Med Oral Pathol Oral Radiol*. 2024 Nov;138(5):641–55.
133. Jang TJ, Kim KC, Cho HC, Seo JK. A fully automated method for 3D individual tooth identification and segmentation in dental CBCT. *IEEE Trans Pattern Anal Mach Intell*. 2022 Oct;44(10):6562–8.
134. Kılıc MC, Bayrakdar IS, Çelik Ö, Bilgir E, Orhan K, Aydın OB. Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs. *Dentomaxillofac Radiol*. 2021 Sep 1;50(6):20200172.
135. Krois J, Ekert T, Meinhold L, Golla T, Kharbot B, Wittemeier A. Deep learning for the radiographic detection of periodontal bone loss. *Sci Rep*. 2019 Jun 11;9(1):8495.
136. Orhan K, Bilgir E, Bayrakdar IS, Ezhov M, Gusarev M, Shumilov E. Evaluation of artificial intelligence for detecting impacted third molars on cone-beam computed tomography scans. *J Stomatol Oral Maxillofac Surg*. 2021 Sep;122(4):333–7.
137. Güler Ç, Alper ES. TÜRKİYE’DE PEDODONTİ (ÇOCUK DIŞ HEKİMLİĞİ) LİSANSÜSTÜ EĞİTİMİNDE TAMAMLANAN TEZLERİN İNCELENMESİ: METODOLOJİK BİR ÇALIŞMA. *Saglik Bilim Derg*. 2024 Jul 25;33(2):257–63.
138. Acharya S, Godhi BS, Saxena V, Assiry AA, Alessa NA, Dawasaz AA. Role of artificial intelligence in behavior management of pediatric dental patients—a mini review. *J Clin Pediatr Dent*. 2024;48(3):24–30.
139. Ekrem, E. C., & Daşkan, Z. Perinatal dönemde yapay zekâ teknolojisinin kullanımı. *Eurasian Journal of Health Technology Assessment*. 2021; 5(2), 147-162.
140. Wang Y, Hays RD, Marcus M, Maida CA, Shen J, Xiong D. Developing children’s oral health assessment toolkits using Machine Learning algorithm. *JDR Clin Trans Res*. 2020 Jul;5(3):233–43.
141. Park YH, Kim SH, Choi YY. Prediction models of early childhood caries based on machine learning algorithms. *Int J Environ Res Public Health*. 2021 Aug 15;18(16):8613.
142. Ahn Y, Hwang JJ, Jung YH, Jeong T, Shin J. Automated mesiodens classification system using deep learning on panoramic radiographs of children. *Diagnostics (Basel)*. 2021 Aug 15;11(8):1477.
143. Vishwanathaiah, S., Fageeh, H. N., Khanagar, S. B., & Maganur, P. C. Artificial intelligence its uses and application in pediatric dentistry: a review. *Biomedicines*.

2023;11(3), 788.

144. Kim J, Hwang JJ, Jeong T, Cho BH, Shin J. Deep learning-based identification of mesiodens using automatic maxillary anterior region estimation in panoramic radiography of children. *Dentomaxillofac Radiol.* 2022 Sep 1;51(7):20210528.
145. Zaborowicz K, Biedziak B, Olszewska A, Zaborowicz M. Tooth and bone parameters in the assessment of the chronological age of children and adolescents using neural modelling methods. *Sensors (Basel).* 2021 Sep 8;21(18):6008.
146. Zaborowicz M, Zaborowicz K, Biedziak B, Garbowski T. Deep learning neural modelling as a precise method in the assessment of the chronological age of children and adolescents using tooth and bone parameters. *Sensors (Basel).* 2022 Jan 14;22(2):637.
147. Lee JH, Han SS, Kim YH, Lee C, Kim I. Application of a fully deep convolutional neural network to the automation of tooth segmentation on panoramic radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol.* 2020 Jun;129(6):635–42.
148. Kaya E, Gunec HG, Gokyay SS, Kutal S, Gulum S, Ates HF. Proposing a CNN method for primary and permanent tooth detection and enumeration on pediatric dental radiographs. *Journal of Clinical Pediatric Dentistry.* 2022;46(4):293–8.
149. Jagtap, R., Samata, Y., Parekh, A., Tretto, P., Roach, M. D., Sethumanjusha, S., Suri, M. Clinical Validation of Deep Learning for Segmentation of Multiple Dental Features in Periapical Radiographs. *Bioengineering.* 2024; 11(10), 1001.
150. Çelik B, Çelik ME. Automated detection of dental restorations using deep learning on panoramic radiographs. *Dentomaxillofac Radiol.* 2022 Dec 1;51(8):20220244.
151. Padilla R, Netto SL, da Silva EAB. A survey on performance metrics for object-detection algorithms. In: 2020 International Conference on Systems, Signals and Image Processing (IWSSIP). IEEE. 2020;p. 237–42.
152. Hicks, S. A., Strümke, I., Thambawita, V., Hammou, M., Riegler, M. A., Halvorsen, P., & Parasa, S. On evaluation metrics for medical applications of artificial intelligence. *Scientific reports.*2022;12(1), 5979.
153. Metz CE. Basic principles of ROC analysis. *Semin Nucl Med.* 1978 Oct;8(4):283–98.
154. Zheng K, Liang H, Zhao H, Chen Z, Xie G, Li L. Application and analysis of the MFF-YOLOv7 model in underwater sonar image target detection. *J Mar Sci Eng.* 2024 Dec 18;12(12):2326.
155. Davis, J., & Goadrich, M. The relationship between Precision-Recall and ROC curves. In *Proceedings of the 23rd international conference on Machine learning.* 2006;pp. 233-240).
156. Koşan MA, Coşkun A, Karacan H. Yapay zekâ yöntemlerinde entropi. *Journal of Information Systems and Management Research.* 2019;1(1):15–22.

157. Schleyer TKL, Thyvalikakath TP, Spallek H, Torres-Urquidy MH, Hernandez P, Yuhaniak J. Clinical computing in general dentistry. *J Am Med Inform Assoc.* 2006 May;13(3):344–52.
158. Ayhan B, Ayan E, Bayraktar Y. A novel deep learning-based perspective for tooth numbering and caries detection. *Clin Oral Investig.* 2024 Feb 27;28(3):178.
159. Masthoff M, Gerwing M, Masthoff M, Timme M, Kleinheinz J, Berninger M. Dental Imaging - A basic guide for the radiologist. *Rofo.* 2019 Mar;191(3):192–8.
160. Sha X, Jin L, Han J, Li Y, Zhang L, Qi S. Comparison between periapical radiography and cone beam computed tomography for the diagnosis of anterior maxillary trauma in children and adolescents. *Dent Traumatol.* 2022 Feb;38(1):62–70.
161. An SY, Lee KM, Lee JS. Korean dentists' perceptions and attitudes regarding radiation safety and protection. *Dentomaxillofac Radiol.* 2018 Feb;47(3):20170228.
162. DENTAL RADIOGRAPHIC EXAMINATIONS: RECOMMENDATIONS FOR PATIENT SELECTION AND LIMITING RADIATION EXPOSURE, <https://www.fda.gov/media/84818/download>, Erişim tarihi: 2012
163. Singer M K H S. Challenges associated with digital radiology in dentistry. *EC Dental Science.* 2017;13:13–23.
164. Perschbacher S. Interpretation of panoramic radiographs: Interpretation of panoramic radiographs. *Aust Dent J.* 2012 Mar;57 Suppl 1:40–5.
165. Harorlı A, Akgül M, Yılmaz B, Bilge OM, Dağistan S, Çakur B. *Ağız, Diş ve Çene Radyolojisi.* 1. baskı İstanbul; Nobel Tıp Kitapevleri Tic. Ltd Şti. 2014;484–500.
166. Kaur R, Singh S. A comprehensive review of object detection with deep learning. *Digit Signal Process.* 2022 Dec;132(103812):103812.
167. Zhang Y, Gorriz JM, Dong Z. Deep learning in medical image analysis. *J Imaging.* 2021 Apr 20;7(4):74.
168. van der Velden BHM, Kuijf HJ, Gilhuijs KGA, Viergever MA. Explainable artificial intelligence (XAI) in deep learning-based medical image analysis. *Med Image Anal.* 2022 Jul;79(102470):102470.
169. Estai M, Tennant M, Gebauer D, Brostek A, Vignarajan J, Mehdizadeh M. Deep learning for automated detection and numbering of permanent teeth on panoramic images. *Dentomaxillofac Radiol.* 2022 Feb 1;51(2):20210296.
170. Hiraiwa T, Ariji Y, Fukuda M, Kise Y, Nakata K, Katsumata A. A deep-learning artificial intelligence system for assessment of root morphology of the mandibular first molar on panoramic radiography. *Dentomaxillofac Radiol.* 2019 Mar;48(3):20180218.
171. Fukuda M, Inamoto K, Shibata N, Ariji Y, Yanashita Y, Kutsuna S. Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic

- radiography. *Oral Radiol.* 2020 Oct;36(4):337–43.
172. Kuwada C, Arijji Y, Kise Y, Funakoshi T, Fukuda M, Kuwada T. Detection and classification of unilateral cleft alveolus with and without cleft palate on panoramic radiographs using a deep learning system. *Sci Rep.* 2021 Aug 6;11(1):16044.
 173. Wang CW, Huang CT, Lee JH, Li CH, Chang SW, Siao MJ. A benchmark for comparison of dental radiography analysis algorithms. *Med Image Anal.* 2016 Jul;31:63–76.
 174. Wenzel A, Hintze H. The choice of gold standard for evaluating tests for caries diagnosis. *Dentomaxillofac Radiol.* 1999 May;28(3):132–6.
 175. Schwendicke F, Golla T, Dreher M, Krois J. Convolutional neural networks for dental image diagnostics: A scoping review. *J Dent.* 2019 Dec;91(103226):103226.
 176. Chen XW, Lin X. Big data deep learning: Challenges and perspectives. *IEEE Access.* 2014;2:514–25.
 177. Chen H, Zhang K, Lyu P, Li H, Zhang L, Wu J. A deep learning approach to automatic teeth detection and numbering based on object detection in dental periapical films. *Sci Rep.* 2019 Mar 7;9(1):3840.
 178. Yasa Y, Çelik Ö, Bayrakdar IS, Pekince A, Orhan K, Akarsu S. An artificial intelligence proposal to automatic teeth detection and numbering in dental bite-wing radiographs. *Acta Odontol Scand.* 2021 May;79(4):275–81.
 179. Görürgöz C, Orhan K, Bayrakdar IS, Çelik Ö, Bilgir E, Odabaş A. Performance of a convolutional neural network algorithm for tooth detection and numbering on periapical radiographs. *Dentomaxillofac Radiol.* 2022 Mar 1;51(3):20210246.
 180. Lipton, Z. C., Elkan, C., & Narayanaswamy, B. (2014). Thresholding classifiers to maximize F1 score. *Stat.* 2014; 1050, 14.
 181. Yin, M., Wortman Vaughan, J., & Wallach, H. Understanding the effect of accuracy on trust in machine learning models. In *Proceedings of the 2019 chi conference on human factors in computing systems.* 2019, May;pp. 1-12.
 182. Yaren Tekin B, Ozcan C, Pekince A, Yasa Y. An enhanced tooth segmentation and numbering according to FDI notation in bitewing radiographs. *Comput Biol Med.* 2022 Jul;146(105547):105547.
 183. Zhang K, Wu J, Chen H, Lyu P. An effective teeth recognition method using label tree with cascade network structure. *Comput Med Imaging Graph.* 2018 Sep;68:61–70.
 184. Tuzoff DV, Tuzova LN, Bornstein MM, Krasnov AS, Kharchenko MA, Nikolenko SI. Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofac Radiol.* 2019 May;48(4):20180051.
 185. Kaya E, Gunec HG, Aydin KC, Urkmez ES, Duranay R, Ates HF. A deep learning approach to permanent tooth germ detection on pediatric panoramic radiographs.

Imaging Sci Dent. 2022 Sep;52(3):275–81.

186. Altuntaş AH, Küçükmanişa A, Urhan O. Numbering of teeth in the mixed dentition stage using deep learning. In: 2024 32nd Signal Processing and Communications Applications Conference (SIU). IEEE.2024; p. 1–4.
187. Beser B, Reis T, Berber MN, Topaloglu E, Gungor E, Kılıc MC. YOLO-V5 based deep learning approach for tooth detection and segmentation on pediatric panoramic radiographs in mixed dentition. BMC Med Imaging. 2024 Jul 11;24(1):172.
188. Mao YC, Chen TY, Chou HS, Lin SY, Liu SY, Chen YA. Caries and restoration detection using bitewing film based on transfer learning with CNNs. Sensors (Basel). 2021 Jul 5;21(13):4613.
189. Engels P, Meyer O, Schönewolf J, Schlickerrieder A, Hickel R, Hesenius M. Automated detection of posterior restorations in permanent teeth using artificial intelligence on intraoral photographs. J Dent. 2022 Jun;121(104124):104124.
190. Gardiyanoğlu E, Ünsal G, Akkaya N, Aksoy S, Orhan K. Automatic segmentation of teeth, crown-bridge restorations, dental implants, restorative fillings, dental caries, residual roots, and root canal fillings on orthopantomographs: Convenience and pitfalls. Diagnostics (Basel). 2023 Apr 20;13(8):1487.
191. Magat G, Altındag A, Pertek Hatipoglu F, Hatipoglu O, Bayrakdar İS, Celik O. Automatic deep learning detection of overhanging restorations in bitewing radiographs. Dentomaxillofac Radiol. 2024 Oct 1;53(7):468–77.
192. Akgül N, Yilmaz C, Bilgir E, Çelik Ö, Baydar O, Bayrakdar İŞ. A YOLO-V5 approach for the evaluation of normal fillings and overhanging fillings: an artificial intelligence study. Braz Oral Res. 2024 Sep 30;38:e098.