TÜRKİYE CUMHURİYETİ

KIRIKKALE ÜNİVERSİTESİ

DİŞ HEKİMLİĞİ FAKÜLTESİ

DERİN ÖĞRENME YÖNTEMİNE DAYALI YAPAY ZEKÂ ALGORİTMALARIYLA PANORAMİK RADYOGRAFİLERDE İNCELENEN SABİT PROTETİK RESTORASYONLAR ALTINDA OLUŞAN ÇÜRÜKLERİN TESPİTİ

Dt. Betül AYHAN

PROTETİK DİŞ TEDAVİSİ ANABİLİM DALI

UZMANLIK TEZİ

DANIŞMAN

Prof. Dr. Saadet SAĞLAM ATSÜ

KIRIKKALE-2023

TÜRKİYE CUMHURİYETİ
KIRIKKALE ÜNİVERSİTESİ
DİŞ HEKİMLİĞİ FAKÜLTESİ

DERİN ÖĞRENME YÖNTEMİNE DAYALI YAPAY ZEKÂ ALGORİTMALARIYLA PANORAMİK RADYOGRAFİLERDE İNCELENEN SABİT PROTETİK RESTORASYONLAR ALTINDA OLUŞAN ÇÜRÜKLERİN TESPİTİ

Dt. Betül AYHAN

PROTETİK DİŞ TEDAVİSİ ANABİLİM DALI

UZMANLIK TEZİ

DANIŞMAN
Prof. Dr. Saadet SAĞLAM ATSÜ

KIRIKKALE-2023

KIRIKKALE ÜNİVERSİTESİ DİŞ HEKİMLİĞİ FAKÜLTESİ

Protetik Diş Tedavisi Anabilim Dalı Diş Hekimliğinde Uzmanlık Programı çerçevesinde yürütülen bu çalışma aşağıdaki jüri üyeleri tarafından uzmanlık tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 13.07.2023

İmza

Prof. Dr. Saadet SAĞLAM ATSÜ

Kırıkkale Üniversitesi Diş Hekimliği Fakültesi

Jüri Başkanı

İmza

Prof. Dr. Perihan OYAR

Hacettepe Üniversitesi Sağlık Hizmetleri Meslek Yüksek Okulu Diş Protez Teknolojisi Programı

Üye

İmza

Doç. Dr. Melda MISIRLIOĞLU

Kırıkkale Üniversitesi Diş Hekimliği Fakültesi

Üye

İmza

Dr. Öğr. Üyesi Hamiyet GÜNGÖR ERDOĞAN

Lokman Hekim Üniversitesi Diş Hekimliği Fakültesi

Üye

İmza

Dr. Öğr. Üyesi Berkan ALTAY

Kırıkkale Üniversitesi Diş Hekimliği Fakültesi

Üye

İÇİNDEKİLER

İÇİNDEKİLER ii
ÖNSÖZ.....v
SİMGELER VE KISALTMALAR vi
ŞEKİLLER viii
ÇİZELGELER.....x
ÖZET xii
ABSTRACT xiii
1.GİRİŞ.....……...1

1.1. Sabit Protetik Restorasyon Tanımı…….3
1.2. Sabit Protetik Restorasyonların Başarısızlık Nedenleri……..4
1.3. Sabit Protetik Restorasyon Altında Çürük Oluşum Nedenleri……5
1.3.1 Sabit Protetik Restorasyonlarda Marjinal ve İnternal Uyumun Çürük ile İlişkisi……...….5
1.3.2. Protetik Materyal Seçimi ve Üretim Tekniğinin Çürük Üzerine Etkisi……..8
1.3.3. Siman Seçiminin Çürük Oluşumuna Etkisi……10
1.4.Sabit Protetik Restorasyon Altında Oluşan Çürüklerin Tespit Yöntemleri……13
1.4.1. Floresan Yöntemler……...14
1.4.2.Optik Koherens Tomografi……14
1.4.3. Radyografik Yöntemler…….15
1.4.3.1 Konik Işınlı Bilgisayarlı Tomografi (KIBT)……...15
1.4.3.2. Periapikal Radyografi…….16
1.4.3.3. Bite-wing Radyografi…….17
1.4.3.4. Panoramik Radyografi……17
1.5. Yapay Zekâ……...23
1.5.1. Yapay zekânın tarihçesi…….23
1.5.2.Makine Öğrenimi……...26

1.5.3. Yapay Sinir Ağları……28
1.5.3.1. Yapay Sinir Ağlarının Tarihçesi……28
1.5.3.2. Yapay Sinir Ağlarının Yapısı……..29
1.5.3.3. Yapay Sinir Ağlarının Eğitimi……30
1.5.4. Derin Öğrenme……..32
1.5.4.1. Derin Öğrenme Mimarileri……32
1.5.4.2. Derin Öğrenme Kütüphaneleri……...37
1.5.4.3. Derin Öğrenme ve Radyolojik Görüntü Analizi……38
1.5.4.4. Nesne Tespiti ve Derin Öğrenme Modelleri……...39
1.5.4.5. Derin Öğrenme ve Diş Hekimliği……...45
1.5.5. Protetik Diş Tedavisi Alanında Yapay Zekâ Uygulamaları……..46
1.6. Amaç……48
1.7. Hipotez……48
2. GEREÇ ve YÖNTEM.....……...……49
2.1. Panoramik Görüntülerin Toplanması……...49
2.2. Yöntem……49
2.2.1 SPR'lerin YOLOV7 ile Tespiti ve Kırpılması……50
2.2.1.1 Panoramik Radyografiler Üzerinde SPR'lerin Etiketlenmesi……..50
2.2.1.2 SPR'lerin Panoramik Radyografi Üzerinde YOLOV7 ile Tespit Edilmesi…50
2.2.1.3 SPR İçeren Alanların Otomatik Olarak Kırpılması……51
2.2.2 SPR Altındaki Çürüklerin Derin Öğrenme Modeli ile Tespiti……...52
2.2.2.1 Kırpılan Görüntüler Üzerinde Etiketleme Yapılması……..52
2.2.2.2 YOLOV7 Mimarisi Üzerinde Yapılan Geliştirmeler……...53
2.2.2.3 CBAM Modülü……54
2.2.2.4 Geliştirme Ortamı……55
2.2.2.5 SPR Altındaki Çürüklerin YOLOV7 ve YOLOV7+CBAM ile Tespiti……..55
2.2.3. İstatistiksel Analiz……56
2.2.3.1.Performans Metrikleri……56

3. BULGULAR……..61

3.1. Panoramik Radyografi Üzerinde SPR Tespit Eden Modelin Değerlendirmesi…61

3.2. SPR Altındaki Çürüklerin YOLOV7 ile Tespit Skorları……...62

3.3. SPR Altındaki Çürüklerin YOLOV7+CBAM ile Tespit Skorları……63

4.TARTIŞMA ve SONUÇ…….66

5. KAYNAKLAR……...79

ÖZGEÇMİŞ……106

ETİK KURUL ONAYI……...……...107

ÖNSÖZ

Uzmanlık eğitimimde ve tez sürecimde beni her daim destekleyen, yönlendiren ve bilgi birikimini benimle paylaşan değerli danışman hocam sayın Prof. Dr. Saadet SAĞLAM ATSÜ'ye,

Uzmanlık tezi olarak sunduğum bu çalışmada yardımlarını esirgemeyen, bilgi ve deneyimi ile büyük katkıları bulunan hocam sayın Dr. Öğr. Üyesi Enes AYAN'a,

Uzmanlık eğitim sürecime ilk başladığım yerde benden bilgi ve desteklerini esirgemeyen Atatürk Üniversitesi Protetik Diş Tedavisi Anabilim Dalı ailesindeki hocalarıma ve araştırma görevlisi arkadaşlarıma,

Uzmanlık eğitimim boyunca birlikte çalışmaktan büyük mutluluk duyduğum başta Dt. Özge ŞAHİN ve Dt. Sıla SUCUKA olmak üzere Kırıkkale Üniversitesi Protetik Diş Tedavisi Anabilim Dalı'ndaki hocalarıma, araştırma görevlisi arkadaşlarıma ve çalışanlarına,

Hayatımın her anında ve uzmanlık eğitimimin başladığı günden itibaren bu zorlu süreçte yanımda olan sevgili eşim Dt. Baturalp AYHAN'a ve kıymetli ailesine

Son olarak bugünlere gelmemde büyük emekleri olan babam Nejdet ARSLAN, annem Hatice ARSLAN ve abim Dr. Bahadır ARSLAN'a

Sonsuz teşekkürlerimi sunarım.

Dt. Betül AYHAN

SİMGELER ve KISALTMALAR

ALADA : As Low As Diagnostically Acceptable- Tanısal olarak kabul edilebilecek kadar düşük

ALARA : As Low As Reasonably Achievable- Makul olarak ulaşılabilecek kadar düşük

BT : Bilgisayarlı Tomografi

CAD : Computer Aided Design– Bilgisayar Destekli Tasarım

CAM : Computer Aided Manufacturing – Bilgisayar Destekli Üretim

CBAM : Convolutional Block Attention Module – Evrişimli Blok Dikkat Modülü

CBS : Convolutional Batch and SİLU Activation

CİS : Cam İyonomer Siman

DMAHDM : Dimetilaminoheksadesil metakrilat

DN : Doğru Negatif

DP : Doğru Pozitif

ESA : Evrişimli Sinir Ağları

FACE : Fluorescence Aided Caries Excavation- Floresan Yardımıyla Çürük Temizleme

GPU : Graphics Processing Unit

IoU : Intersection Over Union –Kesiştirilmiş bölge

K : Kesinlik

KIBT : Konik Işınlı Bilgisayarlı Tomografi

kVp : peek kilovoltaj

mA	: Miliamper
mAP	: Mean avarage precision–Ortalama ortalama kesinlik
MH	: Maksimum Havuzlama
NACP	: Amorf kalsiyum fosfat
NIR	: Near Infrared Dental Fluorescence – Yakın Kızılötesi Dental Floresan
OKT	: Optik Koharens Tomografi
ReLU	: Rectified Linear Unit – Doğrusal birim fonksiyonu
RPN	: Ragion Proposal Network– Bölge Öneri Ağı
s	: Saniye
SAM	: Spatial attention module –Uzamsal dikkat modülü
SBM	: Sınırlı Boltzmann Makineleri
SPR	: Sabit Protetik Restorasyon
SSD	: Single Shot Detector
TSA	: Tekrarlayan Sinir Ağları
YN	: Yanlış Negatif
YOLO	: You Only Look Once
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağı
Y-TZP	: İtriyum ile stabilize edilmis tetragonal zirkonya polikristalleri
AUC	: Area Under the Receiver Operating Characteristic Curve–İşletim Karakteristik Eğrisinin Altında Kalan Alan
ROC	: Receiver Operating Characteristic–İşletim Karakteristik Eğrisi
3B	: 3 boyutlu

ŞEKİLLER

Şekil 1.1. Marjinal aralık (MA), internal aralık (İA) ve mutlak marjinal uyumsuzluk (MMU) görseli

Şekil 1.2. Yapay zekânın alt birimlerinin şema üzerinde gösterimi

Şekil 1.3. Yapay zekânın tarihsel gelişim aşamaları içerisinden önemli bazı örnekler

Şekil 1.4. Makine öğreniminin veri kullanım şekillerine göre sınıflandırılması

Şekil 1.5. Biyolojik sinir hücresi

Şekil 1.6. Yapay sinir hücresinin basitçe yapısı (X=Girdi, W=Ağırlık)

Şekil 1.7. Evrişimli sinir ağlarının yapısı

Şekil 1.8. Evrişim örneği

Şekil 1.9. 2x2 filtre boyutu ile maksimum havuzlama yapılarak elde edilen çıktı verisi

Şekil 1.10. Modern nesne dedektörlerinin mimarisi

Şekil 1.11. YOLOV7'nin ağ mimarisi diyagramı girdi, omurga, boyun ve baş olmak üzere dört genel modül içermektedir

Şekil 1.12. ELAN, ELAN-L ve CBS modülleri

Şekil 1.13. SPPCSPC modülü

Şekil 1.14. REP modülü

Şekil 2.1. YOLOV7 modeli eğitimi sonrası SPR içeren görüntü bölümlerinin tespiti ve otomatik olarak kırpılması

Şekil 2.2. SPR'lerin tespitine yönelik YOLOV7 modelinin gelişim aşamalarının şeması

Şekil 2.3. Kırpma işlemi sonrası çözünürlüğü uygun olmayan görüntülere örnek

Şekil 2.4. Kırpılan panoramik görüntüler üzerinde Phyton programlama dili kullanılarak geliştirilen etiketleme aracı ile çürük (decay), çürüksüz dayanak (healthy) ve kayıp diş (missing) etiketlemelerinin yapılması

Şekil 2.5. CBAM modülü yapı şeması

Şekil 2.6. Çalışmamızda geliştirilen YOLOV7 modeli

Şekil 2.7. SPR altındaki çürüklerin YOLOV7 ve YOLOV7+CBAM ile tespit edilme şeması

Şekil 2.8. IoU gösterimi. IoU değeri eşik değerinden yüksekse nesne tespiti yapılabilmiş demektir.

Şekil 2.9. Karmaşıklık Matrisi

Şekil 3.1. Eğitilen YOLOV7 modelinin SPR tespitinin karmaşıklık matris değerleri

Şekil 3.2. Kırpılan görüntüler üzerindeYOLOV7 modelinin tahmin sonuçlarının karmaşıklık matris üzerinde gösterilmesi

Şekil 3.3. Kırpılan görüntüler üzerinde YOLOV7+CBAM modelinin tahmin sonuçlarının karmaşıklık matris üzerinde gösterilmesi

Şekil 3.4. YOLOV7 modeli Kesinlik-Duyarlılık eğrisi

Şekil 3.5. YOLOV7+CBAM modeli Kesinlik-Duyarlılık eğrisi

ÇİZELGELER

Çizelge 1.1. Sabit protetik restorasyonlarda başarısızlık nedenleri

Çizelge 1.2. Biyolojik sinir sistemindeki yapılar ve bunların yapay sinir sistemindeki yapılara karşılık gelen terimleri

Çizelge 2.1. SPR tespitinde kullanılan veri setlerinin sınıflandırılması

Çizelge 2.2. Çürük tespitinde kullanılan 2248 adet eğitim veri seti üzerindeki toplam etiket sayıları

Çizelge 2.3. Çürük tespitinde kullanılan 219 adet test veri seti üzerindeki etiket sayıları

Çizelge 3.1. Panoramik radyografi üzerinde YOLOV7 modelinin SPR tespit skorları

Çizelge 3.2. Kırpılmış görüntüler ile eğitilen YOLOV7 modelinin çürük tespit tahmin skorları

Çizelge 3.3. Kırpılmış görüntüler ile eğitilen YOLOV7+CBAM modelinin tahmin sonuçları

ÖZET

Derin Öğrenme Yöntemine Dayalı Yapay Zekâ Algoritmalarıyla Panoramik Radyografilerde İncelenen Sabit Protetik Restorasyonlar Altında Oluşan Çürüklerin Tespiti

Diş çürüklerinin, erken dönemde tespit edilerek tedavi edilmesi dişler üzerine yapılan restorasyonların başarısını arttırmaktadır. Diş çürüğünün varlığının hekim tarafından tespiti, yalnızca klinik muayene ile çoğu zaman mümkün olmamakta ve sıklıkla radyolojik tespit yöntemlerinden yararlanılması gerekmektedir. Diş üzerinde radyoopak görüntü veren dental restorasyon varlığı, restorasyon altında oluşmuş çürüklerin tespitini zorlaştırmaktadır. Hastaların diş eksikliklerini yerine koyan, estetik ve fonksiyonel işlevlerini yeniden oluşturan ve bu işlemleri çeşitli dental materyal ve teknikle yapabilen sabit protetik restorasyonlarda (SPR) en sık görülen geç komplikasyon restorasyon altında çürük oluşumudur. Bu restorasyonlar altında oluşan çürüklerin klinik olarak tespit edilmesi SPR'lerin prognozu açısından önem taşımaktadır. 2 boyutlu ve 3 boyutlu radyografiler, klinik pratiğinde sabit protetik restorasyon altındaki çürük lezyonlarının tespitinde kullanılabilseler de 2 boyutlu radyografilerde görüntüleme hatalarının sık olması; 3 boyutlu radyografilerde de hastaya verilen radyasyon dozunun fazla olması bu yöntemlerin dezavantajlarıdır. Protetik restorasyon altında çürüğün geleneksel yöntemlerle teşhis edilmesindeki zorluklar nedeniyle, farklı çürük tespit yöntemlerinin geliştirilmesi gerekmektedir. Bu çalışma, derin öğrenme yöntemlerine dayalı yapay zekâ algoritmalarından YOLOV7 kullanılarak panoramik radyografilerde sabit protetik diş restorasyonları altında çürük tespitinin etkinliğinin değerlendirilmesi amacıyla yapılmıştır. Veri seti olarak 1004 hastanın panoramik radyografileri kullanılmıştır. Önerdiğimiz çürük tespit sistemi iki aşamadan oluşmaktadır. Çalışmanın ilk aşamasında, panoramik radyografiler üzerindeki SPR'lerin otomatik olarak tespit edilmesi ve kırpılması yani asıl görüntüden seçilerek çıkarılması işlemi gerçekleştirilmiştir. Bu aşamada her bir radyografik görüntü üzerinde SPR'ler etiketlenmiş ve bu görüntülerle bir derin öğrenme modeli olan YOLOV7 eğitilmiştir. Eğitilen derin öğrenme modeli SPR'leri

0.966 kesinlik, 0.947 hassasiyet, 0.968 mAP (Mean Avarage Precision) ve 0.956 F1 skoru elde ederek tespit etmiştir. Bu çalışmanın ikinci aşaması kırpılan görüntüler üzerindeki SPR'lerin altındaki çürüklerin tespit edilmesini içermektedir. Bu aşamada görüntüler üzerinde çürük (decay), çürüksüz dayanak diş (healthy), kayıp diş (missing) etiketlemeleri yapılarak farklı bir YOLOV7 modeli elde edilmiştir. Bu model eğitim sonrası çürük etiketi için 0.791 duyarlılık, 0.837 kesinlik, 0.80 mAP, 0.813 F1 değeri elde ederken kayıp diş için 0.939 duyarlılık, 0.804 kesinlik, 0.931 mAP, 0.866 F1 değeri çürüksüz dayanak diş için 0.976 duyarlılık, 0.945 kesinlik, 0.978 mAP, 0.96 F1 skoru elde etmiştir. Orijinal YOLOV7 modeli ile eğitim yapıldıktan sonra, SPR altındaki çürükleri daha iyi tespit edebilmek için bu modelin içine dikkat mekanizmaları (CBAM) eklenmiş, modelin çürük tespit performansının arttığı gözlemlenmiştir. YOLOV7+CBAM modeli ile çürük etiketi için 0.827 duyarlılık, 0.834 kesinlik, 0.846 mAP, 0.83 F1 skoru; kayıp diş etiketi için 0.922 duyarlılık, 0.821 kesinlik, 0.933 mAP, 0.868 F1; çürüksüz dayanak diş etiketi için 0.964 duyarlılık, 0.945 kesinlik, 0.973 mAP ve 0.954 F1 skoru elde edilmiştir.

Çalışmamızda panoramik radyografilerde izlenen SPR altındaki çürükleri tespit etmek amacıyla derin öğrenme modellerinin kullanımı umut verici sonuçlar göstermiştir. Klinik uygulamalarda yaygın olarak tercih edilen panoramik radyografide yapay zekâ ile protetik restorasyonların altındaki çürüklerin tespiti hekimlere zaman yönetimi ve teşhis açısından kolaylık sağlayacağı düşünülmektedir. Literatür araştırmamıza göre SPR altındaki çürüklerin panoramik radyografik veriler kullanılarak derin öğrenme algoritmaları ile tespit edildiği başka bir çalışma bulunmamaktadır. Çalışmamızın sonuçlarını değerlendirme kapsamını genişletmek ve yapay zekânın SPR altındaki çürüklerin tespiti alanında geliştirilmesini sağlamak amacıyla bu alanda yeni çalışmaların yapılması gerekmektedir.

Anahtar Kelimeler: Çürük, Derin Öğrenme, Yapay Zekâ, Sabit Protez, Panoramik Radyografi, YOLO

ABSTRACT

Detection of Caries Formed Under Fixed Prosthetic Restorations Examined on Panoramic Radiographs with Artificial Intelligence Algorithms Based on Deep Learning Method

Early detection and treatment of dental caries increases the success of restorations on teeth. Detection of the presence of dental caries by the physician is often not possible with only clinical examination, and radiological detection methods should be used frequently. The presence of a radiopaque dental restorations on the tooth makes it difficult to detect caries formed under the restoration. The most common late complication in fixed dental prosthetic restorations (FDP) is the formation of caries under the restoration. The clinical diagnosis of caries formed under these restorations is important for the prognosis of FDPs. Although 2D and 3D radiographs can be used in clinical practice for the detection of carious lesions under fixed prosthetic restoration, they have disadvantages such as the frequency of imaging errors seen in 2D radiographs and the high radiation dose given to the patient in 3D radiographs. Due to the difficulties in diagnosing caries with traditional methods under prosthetic restoration, different caries detection methods need to be developed. This study was carried out to evaluate the effectiveness of caries detection under fixed prosthetic tooth restorations on panoramic radiographs using the artificial intelligence algorithm YOLOV7 based on deep learning methods. Panoramic radiographs of 1004 patients were used as the data set. The caries detection system we propose consists of two stages. The first stage of the study is the automatic detection and cropping of FDPs in panoramic radiographs, that is, their selection and extraction from the original images. At this stage, the deep learning model YOLOV7 is trained by labelling FDPs on each radiographic image. The trained deep learning model detected FDPs with a sensitivity of 0.966, a precision of 0.947, a mAP (Mean Average Precision) of 0.968, and a F1 score of 0.956. The second phase of this study involved the detection of caries under the FDPs on the cropped images. At this stage, a different YOLOV7 model was

obtained by labeling caries (decay), caries-free abutment (healthy), missing tooth (missing) on the images. After training with the original YOLOV7 obtained 0.791 sensitivity, 0.837 precision, 0.80 mAP and 0.813 F1 scores for the caries; 0.939 sensitivity , 0.804 precision, 0.931 mAP, 0.866 F1 scores for the missing tooth; 0.976 sensitivity, 0.945 precision, 0.978 mAP and 0.96 F1 scores have been obtained for the caries-free abutment tooth. Then attention mechanisms (CBAM) were added to this model in order to better detect caries under FDPs, and it was observed that the caries detection performance of the model increased. With the YOLOV7+CBAM model after testing results were 0.827 sensitivity, 0.834 precision, 0.846 mAP and 0.830 F1 scores for the caries; 0.922 sensitivity, 0.821 precision, 0.933 mAP and 0.868 F1 scores for the missing tooth ; 0.964 sensitivity, 0.945 precision, 0.973 mAP and 0.954 F1 scores were obtained for the caries-free abutment.

In our study, the use of deep learning models to detect caries under FDPs observed on panoramic radiographs gave promising results. It is thought that the detection of caries under prosthetic restorations with artificial intelligence in panoramic radiography, which is widely preferred in clinical applications, will provide convenience to physicians in terms of time management and diagnosis. According to our literature search, there is no other study in which caries under FDPs were detected by deep learning algorithms using panoramic radiographic data. In this field, new studies are required for developing artificial intelligence in the detection of caries under FDPs and evaluating the results of our study in a broader meanings.

Key words: Caries, Deep learning, Artificial intelligence, Fixed dental prostheses, Panoramic radiography, YOLO

1. GİRİŞ

Diş çürüğü, insanın yaşamı boyunca karşısına çıkabilecek, önlenebilir bakteriyel enfeksiyöz bir hastalık olarak tanımlanmaktadır (Featherstone, 2003). Konak (diş), diyet, zaman ve bakteri etkileşimi çürüğün etiyolojik faktörleri olarak sayılabilir. Bakteri biyofilmi içinde oluşan asit, diş sert dokusunda demineralizasyona yani sert dokuda mineral kaybına neden olmakta ve çürük oluşumu başlamaktadır (Featherstone, 2004). Çürük erken evrelerde tespit edilebilir ve tedavi edilirse hasta kooperasyonu ile beraber var olan çürüğün ilerlemesi yanı sıra yeni çürük oluşumu durdurulabilmektedir (Selwitz vd., 2007).

Seramik restorasyonlarda belirlenen ana başarısızlık nedenleri, katastrofik kırıklar, chipping ve sekonder çürüklerdir (Zoellner vd., 2002). Sabit protezlerde en yaygın görülen geç komplikasyonun çürük oluşumu olduğu belirtilmiştir (Della Bona & Kelly, 2008; Glantz vd., 1993). Sekonder (ikincil) çürük; mevcut restorasyonların kenarlarındaki veya dental örtücülerle ilişkili çürükler olarak tanımlanabilmektedir. Sekonder çürük oluşumu var olan dental restoratif materyalin özellikleri ile ilişkili olup, diş sert dokularının demineralize olması durumudur (Askar vd., 2020). Yıllar içerisinde sabit protetik restorasyon (SPR) yapım teknikleri ve materyalleri çok geliştiği halde, başta sekonder çürük olmak üzere çeşitli nedenlerle değiştirilmeleri gerekebilmektedir (Polat Sağsöz vd., 2015).

Günümüzde protetik tedavilerde kullanılan materyallerin çoğu radyoopak görüntü vermektedir. Radyopasite; protez kaide malzemeleri, protez astarları, elastomerik ölçü malzemeleri, protetik dental materyaller, endodontik sealerlar, postlar, endodontik retrograd malzemeler, direkt dolgulu restoratif materyaller ve rezin simanlar dahil olmak üzere tüm dental malzemelerin istenen bir özelliği olarak kabul edilmektedir (Watts & McCabe, 1999). Protetik restoratif materyallerin radyopaklık derecesi çürüklerin tespitini, siman artıklarının varlığının belirlenmesini, mevcut restorasyonların diş ve çevre dokularla uyumunun radyolojik olarak değerlendirilmesini etkilemektedir (Pekkan vd., 2011). Bununla birlikte, yüksek radyoopasiteye sahip dental restoratif materyaller, sıklıkla görüntü üzerindeki detayları gizleyerek tanıyı güçleştirebilmektedir (Pedrosa vd., 2011). Protetik restorasyonlar, plak tutulumuna neden olan marjinal boşluklara, hijyenik olmayan gövde altlarına sahip olabilmeleri nedenleriyle çürük oluşumu için risk yaratan alanlar

oluşturabilmektedir (Featherstone vd., 2011). Sabit protetik restorasyon altında çürük oluştuğunda, dayanak diş tedavi edilebildiği taktirde protez yenilenmekte ya da restorasyon deforme olmadan desimante edilebildi ise yeniden kullanılabilmektedir. Çürük oluşumu hasta tarafından semptomlarla veya hekim tarafından dental muayene ile fark edilemeyerek tedavi edilmediğinde çürük ilerleyerek dayanak diş kaybına dahi neden olabilmektedir (Zoellner vd., 2002). Sekonder çürüğün oluştuğu bölgede hastada hassasiyet, ağrı gibi semptomlar olabilmektedir (Longridge & Youngson, 2019). Kanal tedavili ve protetik diş tedavisi amacıyla prepare edilen dişlerde ise madde kaybının artması dolayısıyla zaten zayıf olan koronal diş dokusu, çürük ile beraber daha da zayıflamakta ve hastada hiçbir semptom oluşmaksızın kronda kırık meydana getirebilmektedir (Kishen, 2006). Bu durum tedavi planlamasının tamamen değişmesine yol açabilmektedir (Dikbas vd., 2013; Hull vd., 1997). Bu nedenle sabit protetik restorasyon altındaki çürüğün teşhis edilmesi büyük önem taşmaktadır.

Dekalsifiye alanların sond gibi sivri uçlu el aletleriyle teşhis edilmeye çalışılması, diş yüzeyine zarar verme riski taşımaktadır (Penning vd., 1992). Kron veya köprü tedavisi yapılmış dişlerde protez preparasyonu subgingival bölgede bitirilmiş ise sekonder çürük tespiti daha zor olmaktadır. Sabit protezlerde çürük tespitindeki bu sınırlamalar daha hassas ve özel teşhis yöntemlerine ihtiyaç duyulduğunun göstergesidir (Zoellner vd., 2002).

Tam kron kenarlarında sekonder çürüklerin tespitinde radyografik ve klinik muayene teknikleri arasındaki karşılaştırmalara bakıldığında, kapsamlı klinik muayene ve radyografik muayene sadece radyografi ile yapılan değerlendirmeden daha güvenilirdir (Zoellner vd., 2002). Panoramik, periapikal ve bite-wing radyografiler günümüz klinik pratiğinde SPR altındaki çürükleri belirlemek için klinik muayene ile birlikte kullanılmaktadır. Günümüzde bu 2 boyutlu görüntüleme yöntemlerine ek olarak 3 boyutlu görüntüleme teknikleriyle (Konik Işınlı Bilgisayarlı Tomografi, Bilgisayarlı Tomografi) de çürük tespit eden çalışmalar yapılmıştır. Bununla birlikte protetik restorasyon materyalinin radyoopositesi artefakt oluşmasına dolayısıyla çürük tespitinin zorlaşmasına neden olabilmektedir (Schulze vd., 2014).

Geleneksel yöntemlerle protetik restorasyon altındaki çürüklerin teşhisindeki zorluklar nedeniyle farklı çürük tespit yöntemlerinin geliştirilmesi ihtiyacı duyulmaktadır. SPR altında çürük tespiti için daimî yapıştırılmış bir protezin çıkarılma gerekliliği pratik olmayıp hem hekim hem hasta için endişe verici olabilmektedir (Vedpathak, 2016).

Bunun nedeni protezin çıkarılma esnasında protez materyalinin ve dişin kırılabilmesi, çıkarılamadığında hekim tarafından protezin kesilerek çıkarılması, protezin yenilenmesine sebebiyet verecek bu ve bunun gibi diğer durumların yaşanabilmesidir (Polat Sağsöz vd., 2015). Var olan çürük tespit yöntemlerinin gelişmesi ve yeni çürük tespit yöntemlerine olan ihtiyaç bütün bu bahsedilen zorluklardan kaynaklanmaktadır (Rodrigues vd., 2008). Yapay zekânın çürük tespit yöntemi olarak kullanımının düşüncesi bu ihtiyaçtan doğmuştur. Derin öğrenme algoritmalarından Evrişimli Sinir Ağları (ESA), bilgisayarlı görü problemlerinin çözümünde çok başarılı olarak kabul edilmektedir (Erickson vd., 2017). Günümüzde tıp ve diş hekimliği alanında radyolojik veriler üzerinde derin öğrenme algoritmaları kullanılarak yapılan çalışmalar artmıştır (Suzuki, 2017). Diş hekimliği alanında kullanılan iki ve üç boyutlu radyografiler üzerinde derin öğrenme algoritmaları kullanılarak çürük tespitinin sonuçlarının umut verici olduğu çalışmalar bulunmaktadır (Bayraktar & Ayan, 2022; Gomez, 2015; Lian vd., 2021; Nummikoski vd., 1992; Oztekin vd., 2023; Vinayahalingam vd., 2021) Altan ve arkadaşlarının yaptığı çalışmada yapay zekâ algoritmaları kullanarak panoramik radyografi üzerinden sabit protetik restorasyon tespitinin etkinliğini değerlendirmiştir (Altan vd., 2022). Konu ile ilgili literatür değerlendirmemizde protetik restorasyonlar altında oluşan çürüklerin yapay zekâ sistemleri ile tespit etkinliğinin değerlendirildiği herhangi bir çalışma bulunamamıştır. Araştırma konumuz yukarıda belirlenen sınırlamalar göz önüne alınarak, yapay zekâ sistemlerinin alt birimi olan derin öğrenme algoritmaları ile panoramik radyografilerde sabit protetik restorasyonlar altındaki çürüklerin tespit etkinliğini değerlendirmeyi amaçlamıştır.

1.1.Sabit Protetik Restorasyon Tanımı

Protetik Terimler Sözlüğü ‘ne göre restorasyon, kayıp diş yapısını, dişleri veya ağız dokularını restore eden veya değiştiren herhangi bir malzeme veya protez için kullanılan geniş bir terimdir(Driscoll, 2017). Dental protetik restorasyonların temel amacı eksik dişlerin yerine konulmasıdır. Ek olarak, ciddi şekilde hasar görmüş klinik kronları olan dişleri eski haline getirmek için, renk ve/veya şekil ve konturda estetik değişiklikler gerektiğinde de protetik restorasyonlar endikedir (Zitzmann vd., 2007). Yine Protetik Terimler Sözlüğü’nde sabit protezler; dişlerin hasta tarafından ağızdan çıkarılamayan benzerleriyle değiştirilmesi ve/veya restorasyonu ile ilgili protez dalı

olarak tanımlanmaktadır (Driscoll, 2017). SPR'ler tek bir dişin restorasyonunu içerebilirken, kaybedilen bir veya birden fazla dişin yeniden ağza kazandırılması amacıyla da yapılabilmektedir. SPR'ler doğru tanı ve tedavi ile uygulandığında bazen basit bazen komplike olarak tanımlanabilen restorasyonlarla hastaların estetik görünümünü mümkün olduğunca iyileştirirken aynı zamanda dental arkın fonksiyonel bütünlüğünün korunmasını sağlamaktadır (Rosenstiel, Land ve Fujimoto 2018).

Protetik restorasyonlar sabit veya hareketli olabilmektedir. Sabit yani hasta tarafından çıkarılamayan protetik restorasyonlar, içerdikleri dayanak ve gövde sayısına göre "kronlar" ve "köprüler" olarak alt bölümlere ayrılmaktadır. Genel olarak, doğal dişler, diş kökleri ve implantlar ve bunların kombinasyonu, protetik dental restorasyonlar için dayanak görevi görmektedir (Zitzmann vd., 2007). Sosyo-ekonomik faktörlerin düzelmesi ile daha iyi profilaksi ve düzenli hekim kontrolü, hastalarda düzenlenen ağız hijyeni, ağızda kalan diş sayısının artmasının ve son yıllarda tam dişsiz hasta sayısının kısmi dişsiz hastalara göre azalmasının yolunu açmıştır. Bu durum, sabit diş veya implant destekli protezlerle restore edilebilecek daha fazla tekli ve çoklu diş boşlukları ile sonuçlanmıştır (Pjetursson vd., 2015).

1.2. Sabit Protetik Restorasyonların Başarısızlık Nedenleri

Doğal dişlere en yakın morfoloji ve kullanım özelliklerine sahip SPR'ler, parsiyel dişsiz hastalarda iyi bir tedavi seçeneğidir (Sharma vd., 2012). Günümüzde protetik dental restorasyonların yapımında kullanılan teknik ve malzemelerdeki gelişmelere rağmen, uygulanan tedavi başarısız olabilmekte; sonuçta da kron ve köprülerin değiştirilmesi ihtiyacı ortaya çıkmaktadır. SPR 'lerin birçok başarısızlık nedeni bulunmakta, bununla beraber çürükler en yaygın başarısızlık nedeni olarak kabul edilmektedir (Alenezi vd., 2022). Başarısızlık türleri biyolojik, mekanik, estetik olarak üç başlıkta sınıflandırılabilmektedir (Sharma vd., 2012). SPR'lerin başarısız olma nedenleri Çizelge 1.1.'de gösterilmiştir.

Çizelge 1.1. Sabit protetik restorasyonlarda başarısızlık nedenleri (Mohammed Al Moaleem, 2016; Sharma vd., 2012)

Biyolojik	*Mekanik*	*Estetik*
Çürük	Marjinal uyumsuzluk	Hatalı renk seçimi
Aşırı preparasyon	Metal altyapının distorsiyonu	Aşırı ve/veya yetersiz kontur
Dayanak kırığı	Konnektör kırıkları	Hasta beklentilerinin proteze doğru şekilde yansıtılamaması
Endodontik tedavi gereksinimi	Porselen kırıkları	
Yetersiz oral hijyen	Restorasyon altındaki post-core kırıkları	
Periodontal problemler	Metal destekli porselen restorasyonlarda oksit tabakasında meydana gelen kırılmalar	
Metal alerjisi	Simantasyon başarısızlıkları (yanlış siman seçimi, siman çözülmesi, geçici simanın uzun süre ağızda kalması, geniş siman aralığı)	

1.3. Sabit Protetik Restorasyon Altında Çürük Oluşum Nedenleri

1.3.1 Sabit Protetik Restorasyonlarda Marjinal ve İnternal Uyumun Çürük ile İlişkisi

Prepare edilmiş dişin yüzeyi ile restorasyon iç yüzeyi arasındaki mesafenin marjinde oluşturduğu boşluk marjinal aralık olarak tanımlanmaktadır (Bilal Badar vd., 2022) Klinik olarak kabul edilebilir marjinal aralık için McLean ve Von Fraunhaufer tarafından yapılan çalışmada 120µm ve daha küçük marjinal aralığın tolere edilebilen maksimum marjinal açıklık olduğu sonucuna varılırken (McLean 1971), bazı yazarlar da 100 µm'dan az olması gerektiğini savunmaktadır (Reich vd., 2008). Günümüzdeki teknik gelişmelerle 20-75 µm kabul edilebilir marjinal aralık değeri olmakla birlikte klinik pratiğinde bu değerin elde edilmesinin zorluğu belirtilmektedir (Heboyan 2019).

İnternal aralık ise preparasyonun eksternal duvarından restorasyonun iç yüzeyine olan dikey mesafe olarak tanımlanmaktadır (Yu vd., 2019). 200 ila 300 µm arasındaki internal aralık değerleri klinik olarak kabul edilebilir değerler olarak belirtilmektedir

(Souza vd., 2012). Siman aralığının 50 ila 100 µm aralığında olmasının, simanların kimyasal ve fiziksel özellikleri göz önüne alındığında uygun olduğunu gösteren yayınlar bulunmaktadır (Komine vd., 2007; White vd., 1992). Amerikan Diş Hekimleri Birliği, dental adeziv ajanları için 25 µm ila 40 µm arasında bir film kalınlığı önermektedir. Bununla beraber bu aralıktaki restorasyon doğruluğunu klinik olarak elde etmek zordur ve 120-150 µm 'a kadar siman aralığı klinik olarak kabul edilebilir değerlerdir (Rizonaki vd., 2022). Günümüzde dijital ölçü yöntemlerinin gelişmesiyle siman aralıkları da dijital olarak oluşturulabilmektedir. Çoğu bilgisayar destekli tasarım ve bilgisayar destekli üretim (CAD/CAM) yazılım programlarındaki siman aralığı ayarları 0 ila 200 µm aralığındadır ve bazı seramik türleri için en iyi siman aralığı ayarına ilişkin üretici tavsiyeleri materyale spesifik değildir (Sultan vd., 2021).

Mutlak marjinal uyumsuzluk (absolute marjinal discrepancy), marjinal boşluk ile restorasyon kenarının uzatılma hatasının (aşırı uzatma veya az uzatma) açısal kombinasyonu olarak tanımlanmakta ve restorasyon marjlarındaki toplam uyumsuzluğu yansıtan en büyük hata ölçümü olarak kabul edilmektedir (Rizonaki vd., 2022). Marjinal aralık, internal aralık ve mutlak marjinal uyumsuzluk Şekil 1.1.'de gösterilmektedir.

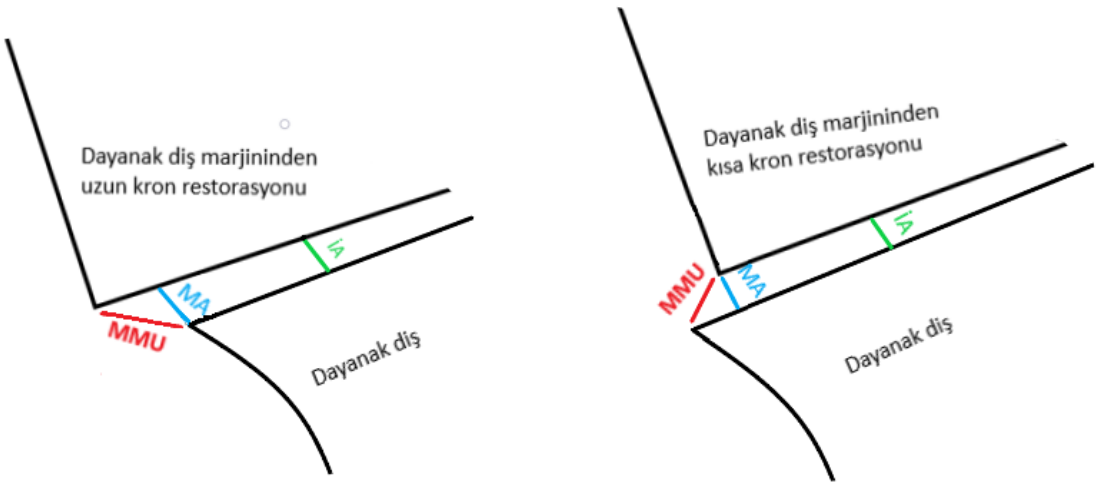

Şekil 1.1. Marjinal aralık (MA), internal aralık (İA) ve mutlak marjinal uyumsuzluk (MMU) görseli (Holmes vd., 1989)

Bitiş çizgisi konfigürasyonu, SPR'lerin internal ve marjinal uyumunu etkilemektedir. Rizonaki ve arkadaşlarının yaptıkları çalışmada, CAD/CAM ile üretilen lityum disilikat tam kronlarda yuvarlatılmış shoulder bitim çizgisinin en yüksek marjinal

uyum ve en az marjinal boşluk değerini; feather edge bitim çizgisinin en yüksek internal uyum ve en düşük marjinal uyum değerini elde ettiği sonucuna ulaşmışlardır (Rizonaki vd., 2022). Altan ve arkadaşları yaptıkları, farklı CAD/CAM materyallerinde yuvarlatılmış shoulder ve chamfer bitiş çizgilerinin kullanımı ile materyalin marjinal uyumunun ilişkisini değerlendirdikleri çalışmada, yuvarlatılmış shoulder bitiş çizgisinde daha küçük marjinal boşluk değerine elde etmişlerdir (Altan vd., 2023). Ottoni ve arkadaşlarının yaptıkları çalışmada üç boyutlu (3B) yazıcı ve ısı ile pressleme kullanarak üretilen tam seramik kron restorasyonlarında chamfer bitiş çizgisinin yuvarlatılmış shoulder basamağa göre daha iyi uyum gösterdiği sonucuna varmışlardır (Ottoni, vd., 2022). Yadav ve arkadaşlarının zirkonya ve hibrit seramik kronların bitiş çizgisi ile marjinal ve internal uyumu arasındaki ilişkiyi inceledikleri çalışmalarında heavy chamfer bitiş çizgisi tasarımının, zirkonya ve hibrit seramik kronlar için shoulder bitiş çizgisi tasarımından daha iyi bir marjinal uyum sağladığı sonucuna ulaşmışlardır (Yadav vd., 2023).

Mükemmel marjinal ve internal uyum, restorasyon başarılı ve uzun ömürlü olması açısından son derece önemlidir. Marjinal boşluk sabit protetik restorasyonun çevresinde plak birikimine uygun ve temizlenmesi zor bir alan yaratarak çürük riskini arttırmaktadır (Featherstone vd., 2011). İnternal adaptasyonun düşük olması, protez restorasyonların mekanik davranışını etkileyebilirken, büyük marjinal boşluklar doğrudan dental yapıştırma simanının çözünmesi ve biyolojik problemlerle ilişkilidir (Ottoni, vd., 2022). Kullanılan malzeme, preperasyon bitiş çizgisinin türü ve yapılacak restorasyonun üretim teknikleri, sabit protezlerin marjinal ve internal uyumunu etkileyen en önemli faktörlerdir. Restorasyon ile diş arasındaki marjinal ve internal boşluğun artışı, daha fazla plak birikimine, dişeti sulkusunda sıvı akışı artışına, kemik kaybına, ardından mikrosızıntıya, tekrarlayan çürüklere, periodontal hastalığa ve protetik restorasyonların ömrünün azalmasına yol açmaktadır (Heboyan, 2019). Marjinal adaptasyonun kabul edilen değerlerden daha geniş olduğu durumlar dışında (örneğin 200-400 μm), marjinal adaptasyon yetersizliği ve sekonder çürük arasında net bağlantı olduğunu gösteren çalışmaların arttırılması gerekmektedir (Bicer Yildirim & Unver, 2018).

Biyolojik genişlik, epitelyal ataşmanın (0,97 mm) ve bağ dokusu epitelinin (1,07 mm) boyutlarının toplamı olan 2,04 mm'lik alanı ifade etmektedir (Gargiulo, 1961). Dental protetik restorasyon da dahil olmak üzere tüm dental tedavilerde biyolojik genişlik

kavramı göz önünde bulundurulmalıdır. Yapılan restorasyon biyolojik aralığa zarar vermeden bitirildiğinde hastanın hem gingival ve dental dokularının sağlığı devam ettirilmekte hem de estetik olarak hekimi ve hastayı tatmin edici sonuçlar ortaya çıkmaktadır (Magne vd., 1999). Biyolojik genişliğe aykırı olarak yapılmış sabit dental protezlerin altında kalan dişlerde sekonder çürük oluşumu meydana gelmektedir (Kina vd., 2011).

Sabit kron/köprü restorasyonu tasarlarken protez kenarı gingival sınırın üzerinde (supragingival) veya altında (subgingival) bitirilebilmektedir. Hastanın estetik beklentilerini genel olarak subgingival marjin daha iyi karşılamaktadır. Bununla beraber subgingival preperasyon zorluğu, dokulara zarar verme riski, zamanla dişetinde çekilme riski, restorasyon kenarlarının hasta tarafından temizlenme zorluğu, dişeti altında siman artığı kalma riski, ardından periodontal çevrede irritasyon ve çürük oluşumu açısından riskli olmaktadır (Orkin vd., 1987). Subgingival marjinde biten protetik restorasyonlarda supragingival marjinde biten restorasyonlara göre plak birikimi dolayısıyla periodontal ve çürük problemleri daha fazla görülebilmektedir (Becker & Kaldahl, 2005; Silness, 1970). Dişeti altında biten restorasyon kenarları mine-dentin üzerinde değil dentin-sement üzerinde olacağından çürüğün ilerleme hızı da artmaktadır (Kuper vd., 2014). Dental restorasyon kenarlarının diş üzerinde sonlanma noktaları ve çürük riski ile ilgili sonuçlar net olmamakla beraber çalışmaların arttırılması gerekmektedir (Askar vd., 2020).

1.3.2. Protetik Materyal Seçimi ve Üretim Tekniğinin Çürük Üzerine Etkisi

Metal-seramik kaplamalar günümüzde hala çok yaygın olarak kullanılmaktadır (Pettenò vd., 2000). Uzun dönem başarısı düşünüldüğünde uzun yıllar ağızda kalabilmektedir (Walton, 2013). Bununla berber metal altyapılı seramik SPR'lerin üretiminde görülen materyal genleşmesi ve/veya büzülmesi marjinal uyumsuzluk problemlerine neden olabilmektedir. Metal kor üretiminin klasik yöntemi olan "kayıp mum tekniği" avantaj ve dezavantajlarıyla beraber sık kullanılmaktadır. Mum modellerde bozulma, döküm sonrası metalde oluşabilen bazı yüzey sorunları, zaman alan prosedürleri bu yöntemin dezavantajlarıdır. Bu dezavantajlar göz önüne alınması sonucu günümüzde CAD/CAM ve frezeleme veya direkt metal lazer sinterleme yöntemleri kullanılmaya başlanmış, bu sayede laboratuvar prosedürleri kolaylaşmış ve hızlanmıştır. Metal seramik kronların direkt metal lazer sinterleme, CAD/CAM ve

geleneksel döküm yöntemleriyle üretiminin, kabul edilebilir bir aralıkta benzer klinik marjinal adaptasyona sahip olduğu gösterilmiştir (Tamac vd., 2014).

Seramikler diş hekimliğinde, yüksek sıkıştırma ve aşınma dayanımı, kimyasal kararlılık, biyouyumluluk, uygun estetik, translüsensi, flüoresans ve doğal dişe benzer termal genleşme katsayısı gibi özelliklere sahip olmalarından dolayı estetik ve fonksiyonel dental restoratif tedaviler için tercih edilen malzemelerdir (Matos vd., 2020). Dental seramiklerin çeşidi dayanak ile uyumu etkileyebilen faktörlerdendir. Yadav ve arkadaşlarının CAD/CAM sistemi ile üretilen hibrit seramik ve zirkonya kronlar üzerinde yaptıkları çalışmada, preperasyon bitiş çizgisi aynı olan kronlardan hibrit seramik kron grubunun daha iyi marjinal uyum ve internal uyuma sahip olduklarını gözlemlemişlerdir (Yadav vd., 2023).

Günümüzde tam seramik kronlar hastanın estetik beklentilerini karşılamanın yanında yüksek marjinal uyum da içerir. Seramik kronların üretim ve kullanımının yaygınlaşması CAD/CAM sistemlerin yaygınlaşmasıyla paralellik göstermektedir. Hastaya ve hekime zamandan tasarruf sağlayarak estetik restorasyonlar yapılabilmesi seramik kronların kullanımını artmasında etkili olmuştur. CAD/CAM dışında seramik koping üretim teknikleri slip casting, ısıyla presleme, copy freze yöntemleridir (Martins vd., 2012). CAD/CAM sistemlerinde, diğer konvansiyonel seramik üretim yöntemlerine benzer hatta daha iyi marjinal uyum elde edilebilmektedir (Ardekani vd., 2012).

CAD/CAM teknolojisi ile seçilen iş akışına bağlı olarak, klinik olarak kabul edilebilir marjinal uyum ve dış yüzey konturu ile tam kapsamlı restorasyonlar üretilebilmektedir (Sadid-Zadeh vd., 2020). Bununla beraber CAD/CAM sistemlerinde yer alan, diş preparasyon tarama görüntülerinin elde edilmesindeki kısıtlamalar, kesici aletlerin boyut uyuşmazlığı ve diş preparasyon geometrisindeki değişkenler bu sistemlerle üretilen seramik kronların marjinal uyumlarında değişiklikler yaratabilmektedir (Hamza vd., 2013; Ottoni vd., 2022). Günümüzde kullanımı artan 3B baskı ve press kombinasyon teknikleri, siman aralığının azalmasına ve istenilen siman aralığına sahip kron/köprülerin üretilmesine katkıda bulunmaktadır (Ottoni vd., 2022). Peng ve arkadaşları geçici kronları CAD/CAM, 3B baskı ve konvansiyonel olarak ürettikleri çalışmada, en geniş marjinal ve internal aralık değerini konvansiyonel olarak üretilmiş geçici kronlarda bulmuşlardır (Peng vd., 2020).

Seramik içerikli dental materyalin dijital veya konvansiyonel yöntemlerle üretiminin, protezin marjinal uyumunu anlamlı düzeyde etkilemediği çalışmalar mevcuttur. 2019 yılında yapılan çalışmada CAD/CAM ve ısıyla presleme ile üretilen lityum disilikat kronların marjinal uyumları karşılaştırılmış ve her iki üretim şeklinde de klinik olarak kabul edilebilir düzeyde değerler bulunmuştur (Dolev vd., 2019). Al Hamad ve arkadaşlarının yaptıkları; metal, zirkonya ve lityum disilikat kronların farklı üretim şekilleri ile marjinal uyumun değişimini inceledikleri çalışmada kron tipi ve üretim yönteminin kronun marjinal uyumu açısından anlamlı bir fark teşkil etmediğini bulmuşlardır (Al Hamad vd., 2019).

Yapılan çalışmalar diş preperasyon sonlanması dentinde biten restorasyonların minede bitenlere göre mikrosızıntı riskinin daha yüksek olduğunu göstermiştir (Piwowarczyk vd., 2005; S. N. White vd., 1992, 1994).Bunun nedeni olarak dentinin mikrotübüler yapısı, tübüler yapının dentin sıvısı ile dolu olması ve dentinin mineye kıyasla daha yüksek organik içeriğe sahip olmasından dolayı dentin ve siman bağlantısının olumsuz etkilenmesi gösterilebilir (Swift & Perdigao, 1995).

2021 yılında yayınlanmış 10 yıllık retrospektif bir çalışmada SPR sağ kalımını veya başarısını, ileri hasta yaşının, tedavinin komplike veya basit olmasının, farklı SPR malzemelerinin kullanımının etkilemediği sonucuna varılmıştır (Alsterstål-Englund vd., 2021).

1.3.3. Siman Seçiminin Çürük Oluşumuna Etkisi

Sabit protetik restorasyonlarda kullanılan dental simanlar literatürde; simanların temel içeriklerine göre (çinko fosfat, çinko silikofosfat, çinko oksit öjenol, çinko poliakrilat, cam iyonomer ve rezin)(Craig & Powers, 2002), matriks bağlantı tipine göre (fosfat, fenolat, polikarboksilat, rezin ve rezin modifiye cam iyonomer)(O'brien, 2002), sertleşme reaksiyonuna göre (asit esaslı simanlar, polimerizasyon simanları)(Wilson & Nicholson, 1993), kullanım sürelerine göre (geçici siman, daimi siman)(Yu, 2014), kullanım konusundaki bilgi ve deneyime göre [geleneksel (çinko fosfat, polikarboksilat, cam iyonomer) ve çağdaş (rezin modifiye cam iyonomerler, rezin)] (Donovan & Cho, 1999) olmak üzere çeşitli sınıflara ayrılmıştır.

Dental simanların genel olarak görevleri ısı yalıtımı, estetik, fonksiyon sırasında restorasyonun mekanik tutulumunun arttırılması ve marjinal sızdırmazlıktır (Dhaniram vd., 2022). İdeal bir dental siman materyali, yüksek tutuculuk, dayanıklılık

ve kolay çıkarılma gibi özelliklere sahip olmanın yanında bakteriyel plak gelişimini de engellemelidir (Unosson vd., 2012).

Marjinal uyumun olmadığı veya siman aralığının geniş olduğu durumlarda siman ağız sıvılarında çözünmektedir. Bu durum çürüme, pulpal enflamasyon, periodontal problemler ile sonuçlanmaktadır (Craig & Powers, 2002). Dental simanların diş ve restorasyona zayıf bağlanma özelliklerinin olması da siman çözünmesi ve mikrosızıntı ile sonuçlanmaktadır (Jacobs & Windeler, 1991).

Çinkofosfat simanlar protetik restorasyonların simantasyonunda uzun yıllardan beri kullanılmaktadır. Sert, basma kuvvetlerine dayanıklı, ucuz olması avantajlarıyken; çözünürlüğü ve yüksek pH değerinde olması dezavantajıdır (Hill & Lott, 2011). Lila-Lila-Krasniqi ve arkadaşlarının yaptığı, dental simanların anti bakteriyel etkilerinin değerlendirildiği çalışmada çinko fosfat simanın çinko iyonları salarak bakteri büyümesini inhibe ettiği görülmüştür (Lila-Krasniqi vd., 2022). Zmener ve arkadaşlarının yaptığı çalışmada rezin modifiye cam iyonomer siman, self-adeziv rezin siman ve çinkofostat simanın mikrosızıntı miktarı karşılaştırıldığında çinkofosfatın çok daha yüksek bakteriyel mikrosızıntıya neden olduğu görülmüştür. Buna neden olarak da çinkofosfat simanın dentine kimyasal olarak bağlanamaması gösterilmiştir (Zmener vd., 2014). Yine yapılan bir çalışmada dentin ve minede sonlanan restorasyonlarda en yüksek mikrosızıntı çinkofosfat simanda bulunurken en düşük mikrosızıntı değerleri self-adeziv rezin siman, takiben rezin modifiye cam iyonomer siman ve konvensiyonel cam iyonomer simanda (CİS) gösterilmiştir (Piwowarczyk vd., 2005).

Polikarboksilat simanlar sabit protetik restorasyonların daimî yapıştırılmasında güncel olarak kullanılmaktadır. Çinko fosfat simanlar gibi yüksek çözünürlük ve düşük adezyon en büyük problemidir. Bununla beraber en büyük avantajı pulpa dokusunu irrite etmemesidir (Hill, 2007). Polikarboksilat simanın asidik bir ortamda erozyona karşı düşük dirence sahip olması mide reflü sorunu olan veya sıklıkla asitli içecekler tüketen hastalarda çözünerek çürük oluşumuna neden olabilmektedir (Hill & Lott, 2011).

CİS düşük genleşme katsayısına sahip olmakla beraber mine ve dentin ile güçlü fizikokimyasal bağlanma sağlamaktadır. CİS kalsiyum florür salınımı yapmasıyla çürük oluşumunu önleyici etkiye sahiptir (Marcushamer vd., 1993). CİS'ten salınan

florür hem diş minesinin remineralize olmasını sağlamakta hem de yüksek çürük riskli hastaların oral florasına olumlu katkıda bulunmaktadır (Benelli vd., 1993). CİS tükürükte düşük çözünürlüğe ve yüksek basma dayanımına sahiptir. Ayrıca protetik materyaller ile iyonik bağlar oluşturabilmektedir. Bu özellikleri ile CİS, diş ve protetik materyal arasındaki siman aralığında kalıcılığı yüksek ve çürük oluşumu açısından önleyici etkiye sahip bir simandır (Millett vd., 2003). CİS karıştırılırken oluşabilecek poroziteler diş ile siman arasındaki bağı azaltarak çözünmeye ve mikrosızıntıya sebebiyet verebilmektedir (Mitchell & Douglas, 1997).

Streptococcus mutans (S.mutans) diş çürüğünde rol oynayan önemli bir bakteri grubudur (Featherstone, 2003). Yapılan çalışmada rezin bazlı siman üzerinde biriken S. Mutans sayısının rezin modifiye cam iyonomer siman üzerinde biriken S. Mutans sayısından anlamlı ölçüde yüksek bulunmuştur (Mota vd., 2008). Ortodontik braketler etrafında oluşan çürüklerin siman ile ilişkisinin in vivo olarak incelendiği çalışma, rezin modifiye cam iyonomer simanının, yüksek çürük riski taşıyan hastalarda, braket etrafındaki mine demineralizasyonunu azaltabileceğini göstermiştir (Pascotto vd., 2004). Rezin modifiye cam iyonomer simanların florür salınımı yaptığı bilinmektedir (Musa vd., 1996). Bununla birlikte CİS kadar belirgin florür salınımı yoktur (Prabhakar vd., 2010).

Rezin simanlar günümüzde diş hekimliği alanında yaygın olarak kullanılmaktadır (Leung vd., 2022). Geleneksel simanlarla karşılaştırıldığında rezin bazlı adeziv materyaller; yüksek derecede renk stabilitesi, diş sert dokusuna ve dental materyallere adeziv bağlantı, düşük çözünürlükle birlikte düşük su emilimi ve daha iyi mekanik özellikler sunmaktadır (Giti vd., 2016). Rezin simanların bütün bu avantajlarının yanında diş çevre dokularına olan toksik etkisi olumsuz özelliğidir. Diemer ve arkadaşları yaptığı çalışmada rezin simanların, özellikle osteoblastik hücreler üzerinde yoğun sitotoksik etkisi olduğunu gözlemlemiştir (Diemer vd., 2021).

Günümüzde anti-bakteriyel ve uzun süreli remineralizasyon özelliklerine sahip yeni nesil biyoaktif dental rezin simanların geliştirilmesine artan bir ihtiyaç vardır (Sauro & Pashley, 2016). Kitosan, klorheksidin, antibiyotikler ve triklosan gibi, antibakteriyel etkileri olan maddeler biyo-etkileşimli rezin içerikli dental materyaller oluşturmak için kullanılmıştır. Bununla beraber bu materyallerin salınım sürelerinin kısıtlı olması nedeniyle etki süreleri de kısıtlı olmaktadır. Öte yandan, rezin esaslı malzemelerle ko-polimerize edilmiş antibakteriyel monomerleri birlikte kullanarak bakteriyi temas

yoluyla etkisiz hale getirme düşüncesi, uzun süreli etki açısından umut verici sonuçlar göstermiştir (Melo, Guedes, vd., 2013). Bu düşünce sonucu negatif yüklü bakteri hücre zarına bağlanabilen, pozitif yüklü bir kuaterner amin, N+ içeren bir grup katyonik bileşik olan kuaterner amonyum metakrilatlar (KAM) uzun süreli temas ile öldürücü antibakteriyel etkiler üretmek için dental rezin materyallere eklenmiştir (Ge vd., 2015; Melo vd., 2018). Diğer yandan dimetilaminoheksadesil metakrilat (DMAHDM) rezin içerikli dental materyallere dâhil edildiğinde daha kısa zincir uzunluğuna sahip KAM'lardan daha güçlü antibakteriyel özellikler sergilemiştir (F. Li vd., 2013).

Bir diğer çürük önleyici etkisi araştırılan madde amorf kalsiyum fosfattır. İnsan üzerinde yapılan araştırmalarda, ticari florür salan rezin bazlı materyallere kıyasla, Ca ve P iyonu salınımı sağlayan amorf kalsiyum fosfatın (NACP) rezin bazlı materyallere eklenmesiyle diş yapılarında dört kat fazla mineral rejenerasyonu elde edilmiştir (Weir vd., 2012). NACP'li rezin bazlı materyallerin, NACP'siz rezin bazlı materyallere göre üç kat daha az mineral kaybına sahip olduğu gösterilmiştir (Melo, Weir, vd., 2013). AlSahafi ve arkadaşlarının yaptıkları çalışmada rezin simana DMAHDM ve NACP dâhil edilmesinin, tükürükte Ca ve P iyonu salınımını dolayısıyla remineralizasyon potansiyelini arttırdığını görmüşlerdir (AlSahafi vd., 2022).

Dental simanların radyoopositeleri siman artıkları gözle görülmediğinde önem kazanmaktadır. Dentinden daha radyoopak bir dental siman kullanılmadığında, siman hattının radyografide saptanması zorlaşmaktadır (Rubo & El-Mowafy, 1998). Polikarboksilat ve çinko fosfat simanların radyoopositesi mineden daha fazladır (Pekkan, 2016). Restorasyon kenarı diş eti altında ve restorasyonun marjinal uyumunun ideal olmadığı durumlarda, restorasyon kenarında siman artığı kalma ihtimali yüksektir. Bu durum o bölgede periodontal probleme ve diş çürüğüne sebebiyet verebilmektedir. Dental siman renginin gözle görülebilmesi ve hekim tarafından simantasyon sonrası siman artıklarının tamamen temizlenebilmesi bu bağlamda büyük önem taşımaktadır (Stanford vd., 1987).

1.4. Sabit Protetik Restorasyon Altında Oluşan Çürüklerin Tespit Yöntemleri

Çürük tespiti, hastalığın mevcut olup olmadığını belirlemenin objektif bir yöntemini ifade etmektedir. Çürük tespiti ve çürük teşhisi terminolojileri kullanım olarak

karışabilen, bununla beraber iki farklı anlamı ifade eden kavramlardır. Çürük lezyon değerlendirmesi, tespit edildikten sonra bir lezyonu karakterize etmeyi veya izlemeyi amaçlamaktadır. Çürük teşhisi ise bir profesyonel tarafından, çürüğün tespiti ve lezyonun değerlendirilmesi ile elde edilen tüm verilerin, hastanın çürük risk faktörleri de göz önünde bulundurularak özetlenmesidir (Gomez, 2015).

SPR altında kalan dişler, çürük oluşumu açısından bazı durumlarda riskli alanlar oluşturmaktadır (Tanaka vd., 2012). Restorasyon kenarı supragingival bitirildiğinde çürük tespiti klinik olarak daha kolayken subgingival biten restorasyon kenarlarında çürük tespiti zorlaşmaktadır (Becker & Kaldahl, 2005). Sivri uçlu sond ile dokunsal ve görsel muayene SPR altındaki çürüklerin tespitinde kullanmakta bununla beraber özellikle aproksimal ve posterior bölgede SPR altında oluşan çürüklerin tespitinde yetersiz kalmaktadır (Ghodasra & Brizuela, 2022). Bütün bu nedenlerle SPR altındaki çürüklerin tespit edilmesi amacıyla ek yöntemlere ihtiyaç duyulmaktadır.

1.4.1. Floresan Yöntemler

Günümüzde çürük tespitinde kullanılmakta olan floresan yöntemlerin geliştirilmesi amacıyla çalışmalar yapılmaktadır. Lazer floresan, Floresan Yardımıyla Çürük Temizleme [(Fluorescence Aided Caries Excavation (FACE)], Yakın Kızılötesi Dental Floresan [Near Infrared Dental Fluorescence (NIR)] bu yöntemlerdendir (Amaechi vd., 2018; X. Zhang vd., 2013). NIR yöntemi özellikle posterior bölgedeki erken dönem çürüklerin tespitinde kullanılmaktadır (Ahrari vd., 2021). Antibakteriyel etkisi bulunan indosiyanin yeşili içeren gargara ile NIR kullanımının çürük tespitinde başarılı olduğu görülmüştür (Li, 2021). Sınırlamalarından dolayı sekonder çürüklerin tespitinde diğer çürük tespit yöntemlerine yardımcı olarak kullanılmaktadır (Rodrigues vd., 2008) Floresan yöntemlerin SPR altındaki çürüklerin tespitinde kullanımına dair herhangi bir çalışma literatür taramamızda bulunamamıştır.

1.4.2. Optik Koherens Tomografi

Optik koherens tomografi (OKT, Dental Imaging System, Amerika), dokuların optik özelliklerindeki farklılıklara dayalı geliştirilmiş olan, biyolojik yapıların kesitsel görüntülenmesini sağlayan invaziv olmayan bir teşhis tekniğidir. Prensipte ultrasonik darbeye benzer şekilde dâhili mikro yapıdan yansıyan yakın kızılötesi ışık dalgalarını kullanmaktadır. OKT, gastroenteroloji, oftalmoloji ve dermatoloji dahil olmak üzere çok sayıda klinik uygulamada kullanılmakta ve diş hekimliğinde gelecek vaat eden bir

teknoloji olarak popüler hale gelmektedir (Katkar vd., 2018). OKT çeşitlerinden polarizasyona duyarlı OKT, erken çürük lezyonlarının görüntülenmesi için özellikle değerli kabul edilmektedir. Bu sistemde demineralizasyon alanından yansıtma, sağlam mineden yansıtmadan çok daha büyüktür. Dental restorasyonlarda sekonder çürüklerin tespitinde OKT kullanımı ile ilgili çalışmalar mevcuttur (Hsieh vd., 2013). Bu nedenle SPR altındaki çürüklerin tespitinde geliştirilmesi umut verici olabilir.

1.4.3. Radyografik Yöntemler

Görsel ve dokunsal muayene çürüğün bukko-lingual yönde geniş olması, posterior dişlerde tespitin zorlaşması, diş üzerinde ışık geçişini engelleyen protetik veya restoratif materyaller olması gibi nedenlerle SPR altındaki çürüklerin tespitinde yetersiz gelebilmektedir (Nummikoski vd., 1992). Üç ve iki boyutlu radyografik yöntemler günümüzde dental restorasyon altında oluşan çürüklerin tespitinde sıkça kullanılmaktadır (Murat vd., 2013). Çürük, sert dokuda demineralizasyon oluşumu ile meydana gelmekte dolayısıyla sert doku değişiklikleri radyografik görüntüye yansımaktadır (Matalon vd., 2003).

1.4.3.1 Konik Işınlı Bilgisayarlı Tomografi (KIBT)

2 boyutlu radyografik yöntemler, dental restorasyona komşu çürükleri tespit etmekte bununla beraber çürüğün bukkal veya lingual yerleşimli olması bu çürüklerin görüntülenmesini zorlaştırmaktadır. Dişte bukkale veya linguale uzanan restorasyon varlığında ise var olan çürüğün üzerini dental restorasyonun kapatması durumunda çürük tespiti imkânsız olmaktadır (Murat vd., 2013). 3 boyutlu radyografik yöntemlere çürük tespitinde bu nedenle ihtiyaç duyulmuştur (Gaalaas vd., 2016). Konik ışınlı bilgisayarlı tomografi (KIBT) protetik diş tedavisinde teşhis ve tedavi planlamasında kullanılan üç boyutlu ekstraoral radyografik görüntüleme yöntemidir (Shah et al., 2014). KIBT ve bilgisayarlı tomografi (BT) SPR altındaki çürük tespitinde kullanılmıştır (Bilgin vd., 2014). BT kullanımı hastaya yüksek dozda radyasyon vereceği için diş hekimliğinde kullanımı yaygınlaşmamıştır (Tsiklakis vd., 2014). KIBT, BT'ye göre azaltılmış radyasyon dozu ve maaliyeti ile diş hekimliğinde tercih edilmektedir. Vedpathak yaptığı çalışmada metal-seramik ve full seramik restorasyon komşuluğunda bulunan çürüğün, KIBT kullanarak tespitinin başarılı olduğunu göstermiştir (Vedpathak, 2016). Lityum disilikat, zirkonya seramik ve metal-seramik restorasyonlar ile yapılan bir diğer çalışmada da restorasyon kenarındaki çürük tespitinde KIBT başarılı sonuç vermiştir (Bilgin vd., 2014). KIBT çürük tespitinde,

sabit protetik restorasyon sökümü olmadan başarılı sonuç verse de metal restorasyonlarda meydana gelen artefakt varlığı hekimi yanlış sonuca götürebilmektedir (Aglarci vd., 2015). KIBT kullanımında en büyük problem ise hastaya verilen yüksek radyasyon dozudur ve bu nedenle diş hekimliği günlük rutininde kullanılması uygun değildir (Silva vd., 2008). Uluslararası Radyolojik Koruma Komisyonu'nun tavsiyeleri ile 1977'de belirlenen ve günümüzde hala geçerliliği olan "makul olarak ulaşılabilecek kadar düşük" (As Low As Reasonably Achievable) yani ALARA prensibi, tüm radyasyon dozlarının mümkün olduğu kadar düşük tutulmasını tanımlayan prensiptir. ALARA prensibine uygun olarak hastaların teşhis ve tedavisinde KIBT kullanılma gerekliliği hekim tarafından bilinçli bir şekilde sorgulanmalıdır. Son zamanlarda önerilen "tanısal olarak kabul edilebilecek kadar düşük" (as low as diagnostically acceptable) yani ALADA prensibi, görüntü kalitesini dolayısıyla dozunu; teşhis amacı, hasta kategorisi ve terapötik seçimlerin belirlediğini açıklamaktadır (Cederhag vd., 2023). KIBT, görüntülemedeki başarısı ile diş hekimliğinde önemi artmış bir görüntüleme aracıdır. Bununla beraber KIBT taraması ile tekrarlanan birikmiş radyasyona maruz kalma ile kanser riski artmaktadır (Al-Haj Husain vd., 2023). KIBT intraoral radyografik görüntüleme yöntemlerine göre çok daha yüksek dozlarda radyasyon salmakta bu nedenle günlük diş hekimliği rutininde çürük tespiti için kullanım kararı hekim tarafından titizlikle verilmelidir (Silva vd., 2008).

1.4.3.2. Periapikal Radyografi

Periapikal radyografi diş hekimliğinin tüm alanlarında kullanımı olan intraoral radyografi çeşididir (White & Pharoah, 2014)Periapikal radyografi protetik diş tedavisinde çeşitli amaçlar için kullanılmaktadır.

a) Dayanak dişler belirlenirken;
   - kron-kök oranını incelenmesi
   - kök şekillerinin incelenmesi
   - kök artığı varlığı
   - periodontal sağlığın incelenmesi
   - endodontik tedavi varlığı ve uygunluğu
   - apikal lezyon varlığı
   - alveoler kret seviyesi

-anterior dişlerin aproksimallerinin incelenmeside bite-wing radyografiye yardımcı olarak (Fava & Dummer, 2003; Reynolds, 1968)

b) İmplant üstü protezlerin planlaması ve tedavisinde;

- çevresel anatomik yapıların yakınlığının belirlenmesi,
- implant yapımı sonrasında implant konumunun kontrolü
- implant çevresi kemik sağlığının incelenmesi
- implant ve implant dayanağı (abutment) uyumunun incelenmesi (De Bruyn vd., 2013; De-Azevedo-Vaz vd., 2021)

c) Post yapımında;

- kanal boyu ölçümü
- post yapım sırasında ve sonrasında kontrol amacıyla kanal boyu kontrolü
-perforasyon varlığının incelenmesi (Fava & Dummer, 2003)

Periapikal radyografiler sekonder çürüklerin tespitinde kullanılmaktadır(Bicer Yildirim & Unver, 2018). Talaeipour, Nemati Anaraki, Heidarkhan Tehrani ve Golpasha yaptıkları çalışmada periapikal radyografilerin sekonder çürük tespitinde yeterince doğru sonuç verdiğini bulmuşlardır (Talaeipour vd., 2016).

1.4.3.3. Bite-wing Radyografi

Günümüzde bite-wing radyografiler çürük tespitinde diş hekimliği pratiğinde kullanılmaktadır. Bite-wing radyografi ile görsel ve dokunsal muayenenin çürük tespitinde beraber kullanılması en yaygın çürük tespit yöntemidir (Gomez, 2015). Bite-wing radyografinin çürük tespitindeki başarısını arttıran aproksimal çürük derinliğinin artmasıdır; yani çürük derinliği azaldıkça bite-wing ile çürük tespiti zorlaşmaktadır (Lederer vd., 2019).

Bite-wing radyografi protetik restorasyonların altında kalan çürüklerin tespitinde, siman artıklarını tespit ederken ve restorasyon ile diş uyumunu kontrol ederken kullanılmaktadır (Bicer Yildirim & Unver, 2018; Pette vd., 2013).

1.4.3.4. Panoramik Radyografi

Panoramik radyografi, maksiller ve mandibular dental arklar ve çevre anatomisinin iki boyutlu olarak görüntülenmesini sağlayan, kavisli yüzey tomografisi prensibine dayalı ektraoral görüntüleme tekniğidir (Shah vd., 2014). Diş hekimliği pratiğinde en sık kullanılan görüntüleme yöntemidir (Clark & Curzon, 2004). İlk olarak 1904 tarihinde Bouchacourt, maksilla ve mandibular arkları tek bir film üzerinde görüntüleme fikrini

öne sürmüştür. Bouchacourt bu fikri intraoral yoldan hastaya X ışını vererek dental arkların görüntüsünü ağız dışına taşıma şeklinde açıklamıştır (Schaffer, 1967). Daha sonra 1922 yılında ilk patenti alınan panoramik radyografi cihazı, 1933 yılında Dr. H. Numata tarafından Japonya'da klinikte kullanılabilecek hale getirilmiştir (Zulauf, 1922). 1946 yılında Finlandiyalı Prof. Dr. Yrjo V. Paatero panoramik radyografiyi hastada intraoral olarak kullanmış fakat verim alamadığı için extraoral olarak filmi yerleştirmiş ve bu yönde makaleler yayınlamıştır. 1957 yılında Paatero ve T. Nieminen isimli mühendisin beraber tasarladıkları 3 rotasyon merkezli panoramik cihazı Helsinki Üniversitesi'nde kullanılmış ve geliştirilmiştir (Hallikainen, 1996).

Panoramik radyografilerin diş hekimliğinde; dental dokular ve çevresinde oluşan patolojilerin (kist, enfeksiyon,tümör vb.) incelenmesi, çene-yüz bölgesi kemiklerde oluşan travma yaralanmalarının incelenmesi, dişli ve tam dişsiz hastalarda dentisyonun teşhis ve tedavi sırasında incelenmesi, süt ve daimi dentisyonun gelişiminin izlenmesi, çeşitli sebeplerle intraoral radyografi kullanılamayan yetişkin ve çocuk hastalarda kullanılması, temporomandibular eklem rahatsızlıklarında tanıya yardımcı olması amacıyla kullanılmaktadır (White & Pharoah, 2014). Panoramik cihazlar çalışma prensiplerine göre; tek rotasyon merkezli cihazlar (Rotograph), iki rotasyon merkezli cihazlar (Panorex), üç rotasyon merkezli cihazlar (Orthopantomograph) ve çok rotasyon merkezli cihazlar olarak dörde ayrılmaktadır. Günümüzde magnifikasyon ve distorsiyonu minimuma indirebilen devamlı hareket eden çok rotasyon merkezli panoramik cihazlar kullanılabilmektedir (Molteni, 2020).

Panoramik radyografilerin avantajları; yüze ait anatomik yapıların kapsamlı görüntüsünün alınabilmesi, radyasyon dozunun görüntülenen alan ve diğer görüntüleme yöntemleri düşünüldüğünde düşük olması, hasta konumlandırmasının kolaylığı, kısa sürede görüntülemenin gerçekleşmesi, görüntü üzerinde sağ ve sol olarak karşılaştırma yapılabilmesi ve hasta bilgilendirmesi açısından hekime kolaylık sağlamasıdır. Panoramik radyografilerin dezavantajları ise; sert ve yumuşak dokuların birbiri üzerine süperpoze olabilmesi, distorsiyon, magnifikasyon, hayalet görüntü ve artefakt oluşumu, imaj tabakası dışına çıkan bölgelerin incelenme güçlüğü ve görüntü kalitesindeki yetersizlik nedeniyle her zaman tek başına teşhiste yeterli olamamasıdır (White & Pharoah, 2014).

Dental radyoloji diş hekimliğinin ayrılmaz bir parçası olmuştur. Dijital radyolojinin gelişmesiyle günümüzde bilgisayar ortamında radyolojik verilerin depolanabilmesi

kolaylaşmış buna bağlı olarak yapay zekâ sistemlerinin diş hekimliği alanında geliştirilebilmesi için yeterli sayıda veri bulunabilmesi kolaylaştırmıştır (Abreu vd., 1999). Panoramik radyografide kullanılan dijital dedektör özelliklerinden kontrast ve uzaysal çözünürlük kavramları bu anlamda önem kazanmaktadır. Uzaysal çözünürlük, bir görüntüleme sisteminin birbirine yakın duran küçük nesneleri ayırt etme yeteneğidir. Kontrast çözünürlük, yoğunluk bakımından az miktarda farklılık gösteren alanları ayırt etme yeteneği, bir başka deyişle densite farklarıdır. Dijital radyografide, gri seviyelerin sayısı (kontrast çözünürlüğü) ve piksel boyutu (uzaysal çözünürlük) dijital görüntünün çözünürlüğünü belirlemektedir (Angelopoulos vd., 2004). Pratikte sık kullanılan periapikal ve bite-wing radyografilere kıyasla panoramik radyografi daha düşük uzaysal çözünürlüğe sahiptir bu da detay verme ile ilgili sorunlara sahip olduğunu göstermektedir (Shah vd., 2014).

Panoramik radyografilerde görüntü netliği ve çözünürlüğü obje, fokal spot arası ilişkiye bağlıdır. Buna göre;

a) Dental x-ray cihazlarında kullanılan fokal spot 1mm'den küçük veya eşit olmalıdır. Fokal spotun büyümesi görüntü netliğinin azalmasıyla sonuçlanmaktadır.
b) Obje-fokal spot arasındaki mesafenin artması görüntünün bulanıklığının azalmasına neden olmaktadır.
c) Obje-film arası mesafe azaldıkça görüntü netliği artmaktadır (Orhan & Delantoni, 2022).

Panoramik radyografilerde hastanın doğru pozisyonlandırılması, alınan görüntünün netliği ve çözünürlüğüne etki eden önemli bir faktördür (Dhillon vd., 2012). Hasta pozisyonlandırılması sırasıyla şu şekildedir;

I. Radyografiden önce artefakt oluşturabilecek baş ve boyun bölgesindeki metal objeler ve ağız içindeki hareketli bölümlü protezler çıkarılmalıdır.
II. Tiroid koruyucu kurşun boyunluklar hastanın radyasyondan korumasında yararlıdır fakat artefakt oluşturduğu için hastaya kurşun önlük giydirilmedir.
III. Hastanın antero-posterior konumu, alt ve üst dişlerin birbiri üzerine süperpozisyonunu önlemek ve çenelerin imaj tabakası içinde kalmasını sağlamak adına çene desteği ve ısırma çubuğu kullanılarak ayarlanır.

IV. Hastanın sagital hattı ısırma çubuğunun tam ortasına gelmeli, Frankfurt düzlemi yere paralel olmalıdır.

V. Hastaya cihaz üzerindeki kollardan tutması ve pozisyonunu bozmadan bir adım ileri atarak iki ayağını yan yana getirmesi istenir. Bu pozisyona "ski pozisyonu" adı verilmektedir.

VI. Hava boşluğunun görüntüde görünmemesi ve doku dansitesinin eşit duruma getirilmesi için hastadan yutkunması, dilini damağına değdirmesi ve dudaklarını kapatması istenir.

VII. Hastanın radyografi alım esnasında bu pozisyonunu koruması beklenmektedir (Orhan & Delantoni, 2022).

Panoramik radyografilerde görüntüleme hataları şöyledir;

a) İmaj Tabakası (Focal Trough): Panoramik radyografideki üç boyutlu kavisli görüntü katmanına imaj tabakası (focal trough) adı verilmektedir. Bu bölge içerisinde yer alan yapılar birbiri üzerine süperpoze olmamakta, bulanıklaşmamakta, görüntü üzerindeki nesnelerde büyüme-küçülme olmamakta, panoramik görüntü üzerinde nesneler net olarak izlenmektedir (Liang & Frederiksen, 2004).

b) Magnifikasyon: Görüntüsü alınan nesnenin görüntü üzerinde gerçek boyutundan daha büyük görünmesidir. Panoramik radyografide hasta başının pozisyonuna ve imaj tabakası kurallarına dikkat edilerek alınan radyografilerde bile nesneye gönderilen x ışını demetindeki fotonların yayılım yolu nedeniyle %15-20 oranında büyüme gerçekleşmektedir (Devlin & Yuan, 2013). Görüntüde hasta konumlandırılmasındaki hata nedeniyle yatay büyütme ve dikey büyütme arasında fark meydana gelmesi magnifikasyon ile sonuçlanmaktadır. Magnifiksayon hastaların anatomik faktörlerine bağlı olarak da değişebilmektedir (Choi vd., 2004). Kanin ve küçük azı bölgesinde magnifikasyon en fazlayken, 3. molar dişe doğru magnifikasyon azalmaktadır (Samawi & Burke, 1984).

c) Başın konumlandırma hataları: Panoramik radyografilerde minimal düzeyde süperpozisyon ve distorsiyon meydana gelebilmektedir. Bunun nedeni çoğunlukla hasta başının yanlış konumlanmasıdır (Farman, 2007). Hastanın görüntü alım esnasında baş pozisyonunu oynatması ise nadir görülen distorsiyon sebebidir (Pine & ten Bosch, 1996). Hasta başı konumlandırma hatalarına bağlı panoramik radyografide oluşabilecek değişiklikler şunlardır;

1) Hastanın çenesi yukarıda olduğunda kondiller arası mesafe artar, oklüzal düzlem düzleşir. Maksiller lateral ve santral dişlerin keskinlikleri azalır.

2) Hastanın çenesi aşağıda olduğunda oklüzal düzlem kurvatürlü görünür ve mandibular anterior dişlerin kök uçları bulanıklaşır.

3) Servikal omurga, filmin alt yarısında ortalanmış, piramit şeklinde opaklık olarak görünür.

4) Baş pozisyonu ısırma çizgisinin önünde konumlandığında, maksiller ve mandibular dişler daha ince ve puslu görünür. Servikal omurga orta hatta ve mandibular çeneye süperpoze olur.

5) Baş pozisyonu ısırma çizgisinin arkasında konumlandığında mandibular anterior dişler normalden daha geniş ve bulanık görünür.

6) Hasta dilini damakta konumlandırmadığında, maksiller dişler üzerinde dil sırtı ve damak arasındaki hava boşluğu koyu bir gölge şeklinde süperpoze olur.

7) Radyografinin çekimi esnasında hastanın başını hareket ettirmesi bulanık görüntüye neden olur.

8) Hastanın başı tek tarafa doğru eğimli olduğunda, bir taraf kondilin diğer kondilden daha yukarıda görünmesine ve mandibulanın bir tarafının eğimli olmasına neden olur.

9) Hasta başını bir tarafa doğu döndürdüğünde, kondillerde asimetrik görüntünün oluşmasına, bir taraftaki dişlerin ve ramusun aksi taraftaki görüntüden geniş olmasına neden olur (Dhillon vd., 2012).

d) Hayalet Görüntü (Ghost İmage): İmaj tabakası dışındaki cisimlerin ve anatomik yapıların neden olduğu distorsiyona uğramış görüntülere hayalet görüntü (ghost image) adı verilmektedir. Her zaman cismin veya anatomik yapının olması gereken konumundan daha yukarıda, distorsiyona uğramış ve opak olarak görünmektedirler (Hacıosmanoğlu vd., 2019).

Dental materyaller genellikle radyografi üzerinde radyoopak görüntü vermektedir. Radyopasite, direkt restoratif materyaller, kavite astarları, protez kaide materyalleri, elastomerik ölçü materyalleri, endodontik patlar, postlar, retrograd dolgu malzemeleri, simanlar ve adeziv sistemler dahil olmak üzere tüm dental sistemlerde istenilen bir özelliktir (Watts & McCabe, 1999). Dental materyallerin radyoopak olması;

- Sabit veya hareketli protezlerin ve geçici kronların radyoopak olması, bu malzemelerin kazara yutulmasını takiben lokalize edilmesine yardımcı olmaktadır (Price, 1986).
- Restoratif materyallerin radyoopak olması, restorasyonların şeklini, konturunu ve eksikliklerini radyolojik olarak tespit etmeyi kolaylaştırmaktadır (O'Rourke vd., 1995)
- Diş pulpasını görüntüde ayırt edebilmeyi sağlamaktadır (Pekkan, 2016)
- Restoratif materyallerin radyoopasitesi, restorasyon altında oluşmuş sekonder çürükler ile radyolüsensi farkından dolayı çürüklerin saptanmasını kolaylaştırabilmektedir (Pedrosa vd., 2011).
- Restorasyon kenar uyumsuzluklarının periodontal etkilerinin gözlemlenmesini sağlamaktadır (Pekkan vd., 2011).
- Subgingivalde bitirilmiş restorasyonlarda, radyografik değerlendirme yoluyla marjinal adaptasyonu izlemek yeterli radyoopak materyal kullanıldığında daha kolay olmaktadır (Manicone vd., 2007).
- Siman bütünlüğünün bozulduğu durumlarda, internal ve marjinal boşlukların ve mevcut restorasyonların genel durumunun radyolojik değerlendirme ve teşhisine yardımcı olmaktadır (Pekkan vd., 2011).

İdeal olarak, restoratif materyaller mineye eşdeğer veya daha yüksek radyoopasite değerlerine sahip olmalıdır (Sabbagh vd., 2004). Seramik inlay malzemeleri üzerinde yapılan bir in vitro çalışmada, felspatik seramik blokların sekonder çürüklerin tespitine izin verecek kadar yeterli radyoopasiteye sahip olmadığı; radyografilerinin yanlış yorumlanmasının restorasyonların gereksiz yere değiştirilmesine neden olduğu sonucuna varılmıştır (El-Mowafy, Brown ve McComb 1991). Alümina ve zirkonya seramiklerin radyoopasitesi mineden daha yüksektir. Baz metal ve altın alaşım kullanılan dental restorasyonların da zirkonya gibi radyografik görüntüde yüksek radyoopasiteye sahip oldukları bilinmektedir (Manicone vd., 2007; Pekkan vd., 2011). Bununla beraber yüksek radyoopasiteye sahip dental materyallerin radyolojik görüntü üzerinde sekonder çürük üzerine süperpoze olması çürüğün görülmesini engelleyebilmektedir (Attar vd., 2003; Pedrosa vd., 2011). Aynı zamanda yüksek radyopasite, teşhisin yanlış yorumlanmasına neden olabilecek Mach etkisine neden olabilmektedir (Pekkan vd., 2011). Mach etkisi veya Mach bantları, daha açık olanların yanındaki daha koyu nesnelerin kenarlarının daha açık görünmesini veya

bunun tersini sağlayan optik bir olgudur. Bir başka deyişle Mach bantları yan yana gelen gri tonlu nesnelerin arasındaki sınır boyunca gözlenen, açık renkli alanın yanlış bir şekilde daha da açık görünmesine, koyu renkli alanın ise daha koyu görünmesine neden olan optik yanılsamadır (Eagleman, 2001). Mach etkisi, dental röntgenler üzerinde gözlenen ve beyaz görünen dental restorasyonların çevresinde çürük benzeri, yanlış yorumlamaya yol açabilecek bir gölge oluşmasına neden olabilmektedir. SPR altında bulunan çürüklerin teşhisini zorlaştıran önemli bir etkendir (Martínez-Rus vd., 2011).

Dental 2 boyutlu radyografi teknikleri çürük tespit etmek amacıyla klinik pratiğinde sıklıkla kullanılsa da minede ve mine-dentin sınırındaki derin olmayan çürük kavitelerinde başarısı düşüktür (Matalon vd., 2003). Başlangıç çürükler tespit edilmediğinde özellikle restorasyon altında ve klinik olarak görülmesi zor bölgelerdeyse, çürüğün ilerlemesi olasıdır (Kidd & Fejerskov, 2004). Bu da başlangıç çürüklerinin tespit edilmesi ve tedavi protokollerinin yerine getirilebilmesi için radyolojik muayeneye olan ihtiyacı arttırmıştır (Dove, 2001; NIH consensus statement, 2001). Tek başına panoramik radyografiler dental patolojileri belirlemede yeterli olmadığı için diğer intraoral radyografilerle beraber kullanılması daha doğrudur (Rekow, 2020). Dental radyolojik yöntemler SPR altındaki çürüklerin tespitinde kullanılırken, hekimlerin dental materyal bilgisi, deneyimi ve radyolojinin sınırlılıkları çürük tespit etkinliğini etkilemektedir. Bu çalışma derin öğrenme yöntemlerini panoramik radyografide izlenen SPR altındaki çürüklerin tespitinde kullanarak yeni bir çürük tespit yöntemi geliştirilmesi amacıyla yapılmıştır.

1.5. Yapay Zekâ (Artificial İntelligence)

1.5.1. Yapay zekânın tarihçesi

İnsan zekâsı kavramı, bireyin akıl yürütme, problem çözme, kavramları anlama ve etkili bir şekilde öğrenme yeteneği olarak tanımlanmaktadır. Yapay zekâ, insan zekâsını irdelemek, taklit etmek ve geliştirmek amacıyla bilgisayar programları geliştiren bilim ve mühendislik çalışmaları bütünüdür (McCarthy, 2004). Yapay zekâ sistemlerinin makine öğrenimi, yapay sinir ağları ve derin öğrenme olarak isimlendirilen alt birimleri Şekil 1.2.'de gösterilmiştir (Soffer vd., 2019).

Yapay zekânın tarihi 1940'lara kadar gitse de Alan Turing'in 1950 yılında makinelerin düşünebilirliğini sorguladığı ve "Turing Testi"nden bahsettiği konferans, bu alanda dönüm noktası olarak kabul edilmektedir. Turing Testi'nin ortaya çıkması, çeşitli oyun benzeri testler ile makine ve insan zekâsının performans kapasitelerinin deneysel ve sezgisel olarak test edilmesine dayanmaktadır (Turing, 2009). 1955 yazında Dartmouth Kolejinde yapay zekâ alanında çalışma başlatılmıştır. John McCarthy, Marvin Minsky, Nathaniel Rochester ve Claude Shannon tarafından yürütülen çalışmaların başlama nedeni, makinelerin insan zekâsını taklit edebilmek için yeterli kapasitede olmasına rağmen bu makinelerde çalıştırılacak insan beynini taklit edebilecek programların yazılamamış olmasıdır. Bu proje sonunda, 1956 yılında Darthmouth Konferansında John McCarthy tarafından yapay zekâ terimi ilk kez kullanılmıştır (McCarthy vd., 2006). 1959 yılında Arthur Samuel, "makine öğrenimi" kavramını öne sürmüştür (Samuel, 1988). 1964 yılında Joseph Weizenbaum tarafından tanıtılan Eliza, ilk doğal dil işleme programı olup, insan konuşmasını taklit ederek iletişim kurabilmiş ve gelecekteki chatbot'lar için altyapı görevi görmüştür. 1966 yılında Stanford Araştırma Enstitüsü'nde yaratılan, ilk genel amaçlı mobil robot olarak tanıtılan Shakey, karmaşık talimatlara uygun olan eylemleri gerçekleştirebilmiştir. Bu gelişme yapay zekânın robotik alanda gelişmesinde önemli bir aşama olarak kabul görmüştür. 1960'larda Ulusal Tıp Kütüphanesi tarafından Tıbbi Literatür Analizi ve Erişim Sisteminin ve web tabanlı arama motoru PubMed'in geliştirilmesi, biyotıptaki gelişmelerin hızlanması için önemli bir dijital kaynak haline gelmiştir. Yapay zekânın geliştirilebilmesi için gereken teknolojinin yetersizliği nedeniyle ilki 1976; uzman dijital bilgi veri tabanlarının geliştirilmesi ve sürdürülmesindeki aşırı maliyet nedeniyle ikincisi 1980'lerin sonlarından 1990'ların başına kadar uzanan yılları kapsayan dönem "yapay zekâ kışı" olarak adlandırılmaktadır (Kaul vd., 2020).

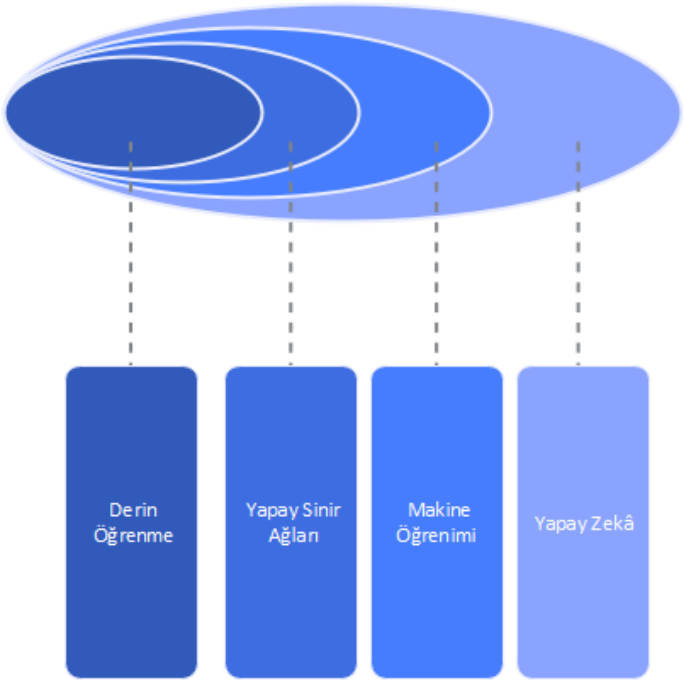

Şekil 1.2. Yapay zekânın alt birimlerinin şema üzerinde gösterimi (Soffer vd., 2019)

IBM'in 1997'de dünya satranç şampiyonu Garry Kasparov'u yenmeyi başaran, saniyede 200 milyon olası hareketi hesaplayabilen Deep Blue adlı bilgisayar programı yapay zekânın popülerliğini yeniden kazanmasının önünü açmıştır (Haenlein & Kaplan, 2019). 2011'de, Watson adlı bilgisayarlı soru yanıtlama sistemi, üç yarışmacıyı karşı karşıya getiren ve yarışmacıların sorulan soruları çok hızlı bir şekilde anlama ve yanıtlama yeteneklerini test eden bir bilgi yarışması olan Jeopardy!'de en yüksek sıralamadaki iki oyuncuyu yenmiştir (Ferrucci vd., 2013). Apple tarafından 2011'da geliştirilen Siri, 2014'te Amazon tarafından geliştirilen Alexa ve Microsof tarafından geliştirilen Cortana, 2016'da Google tarafından geliştirilen Google Asistant günümüzde de popülerliğini koruyan akıllı kişisel asistan olarak tanımlanmış bilgisayar yazılım sistemleridir (López vd., 2018). 2015 yılında Google tarafından geliştirilen program AlphaGO, 2017 yılında masa oyunu olan Go'da dünya şampiyonunu yenmeyi başarmıştır. Go oyununun satrançtan çok daha karmaşık ve olasılık içeren hamleler ile kazanılabilmesi nedeniyle bu gelişme bilim dünyasında heyecan yaratmıştır (Haenlein & Kaplan, 2019). Yapay zekânın hedefi insan beyninin düşünme, karar verme, öğrenme, akıl yürütme, sorunları alternatif seçenekleri

değerlendirerek çözme gibi yeteneklerini keşfetmektir. 2015 yılında Hong Kong Company-Hanson Robotics'in kurucusu Dr. David Anshan tarafından etkinleştirilen insansı robot Sophia ile bu hedefe bir adım daha yaklaşılmıştır (Goertzel vd., 2017). Genel anlamıyla 2000'li yıllarda teknolojik ilerlemelerle beraber daha büyük veri kümeleri ve önemli ölçüde iyileştirilmiş bilgi işlem gücü ile yapay zekânın kullanımı her alanda yaygınlaşmaya başlamıştır (Kaul vd., 2020). Günümüzdeki yapay zekâ ile ilgili en güncel gelişme olarak OpenAI'in 2022'de piyasaya sürdüğü ChatGPT sayılabilir. Doğal Dil İşleme (Natural Leanguage Processing) tekniklerini kullanan ChatGPT'yi diğer sohbet botlarından veya sanal asistanlardan ayıran ise soruları yanıtlama ve kullanıcı tarafından yapılan varsayımları kendisine göre doğru veya yanlış olarak yorumlayabilmesidir (Hassani & Silva, 2023). Yapay zekânın tarihsel gelişimiyle ilgili şema Şekil 1.3'te gösterilmiştir.

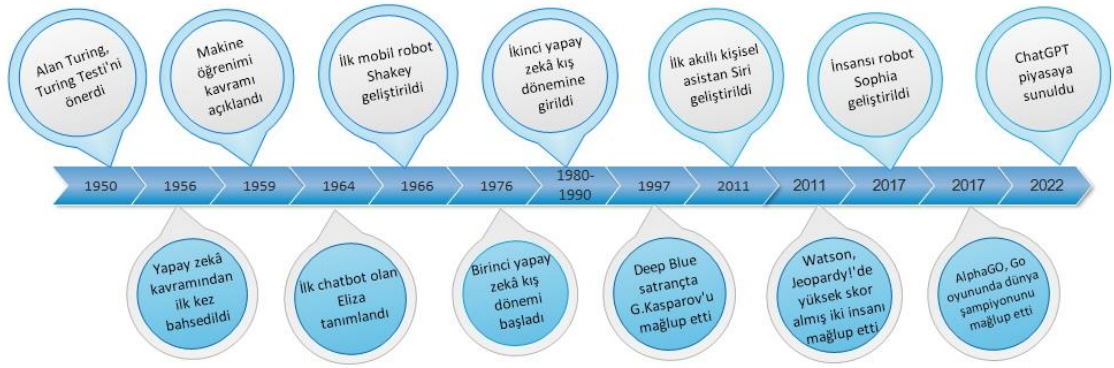

Şekil 1.3. Yapay zekânın tarihsel gelişim aşamaları içerisinden önemli bazı örnekler

1.5.2. Makine Öğrenimi

Makine öğrenimi geniş anlamda, açıkça programlanmaya ihtiyaç duymadan, veriler yardımıyla makinenin deneyimlediği bilgilerle belirli görevleri gerçekleştirebilen bilgisayar modellerinin ve algoritmalarının tasarımına odaklanan bilimsel bir alan olarak kabul edilmektedir (Raschka vd., 2020). Makine öğreniminde uygulayıcı tarafından bir kodlama yapılmaksızın makinenin verilerden öğrendikleri ile kendi karar verme mekanizmasını kullanarak sorunlara çözüm üretebilmesi beklenmektedir (Lynn vd., 2019). Makine öğrenimi, eğitim modelinin veri kullanım şekline göre alt sınıflara ayrılmaktadır (Sarker, 2021). Makine öğrenimi sınıflandırması ve veri kullanım şekilleri Şekil 1.4.'te verilmektedir.

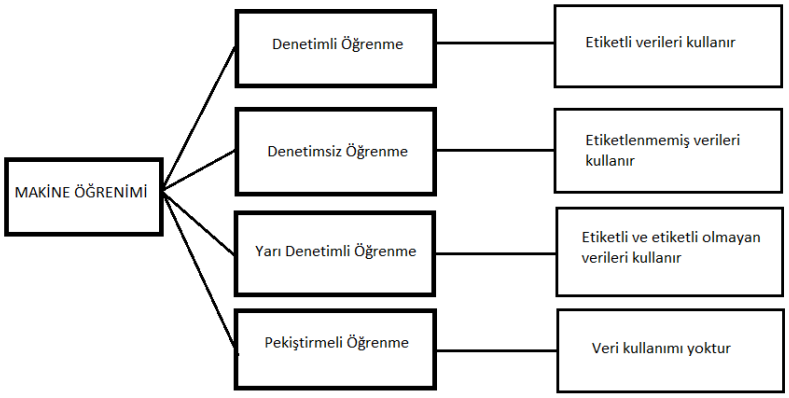

Şekil 1.4. Makine öğreniminin veri kullanım şekillerine göre sınıflandırılması (Mohammed vd., 2016)

a) Denetimli öğrenme

Denetimli öğrenme yönteminde, algoritmanın eğitimi için kullanılacak veriler etiketlenmelidir. Etiketlenen veriler ile eğitilen algoritmanın daha önce görmediği örnekler için tahminler oluşturması beklenmektedir (Han vd., 2022; Mohammed vd., 2016). Yani algoritma önce etiketlenen veriler aracılığı ile eğitilir sonrasında ise hiç görmediği örnekler için tahminler ortaya koymaktadır. Denetimli öğrenme, regresyon ve sınıflandırma problemlerinin çözümünde kullanılmaktadır (Sarker vd., 2019).

b) Denetimsiz öğrenme

Denetimsiz öğrenme yönteminde, eğitim verileri etiketli değildir (Han vd., 2022). Verilerde etiketleme yapılmadığı için denetimsiz olarak isimlendirilen bu eğitim modeli şekli, gruplandırma, kümeleme, cisimlerin boyutlarını büyütme-küçültme, verilerdeki anormal durumları algılama gibi uygulamalarda kullanılmaktadır (Sarker, 2021).

c) Yarı denetimli öğrenme

Yarı denetimli öğrenme etiketli ve etiketli olmayan verilerin beraber kullanıldığı, denetimli ve denetimsiz öğrenmenin karması sayılabilecek öğrenme şeklidir (Montagnon et al., 2020). Böyle bir eğitim yöntemi mali problemler veya uzman yetersizliği gibi sebeplerle etiketlenmiş veri sayısının yetersiz olduğu durumlarda, etiketsiz verilerin de kombine olarak kullanılabilirliğinin araştırılması amacıyla geliştirilmiştir (Zhu & Goldberg, 2009)

d) Pekiştirmeli öğrenme

Pekiştirmeli öğrenme, çeşitli eylemlerin ve davranışların ödül veya ceza ile sonuçlanabileceği, makinelerin bu sonuçları tahmin ederek karar vermesini inceleyen öğrenme şeklidir (Sarker, 2021).

1.5.3. Yapay Sinir Ağları

1.5.3.1. Yapay Sinir Ağlarının Tarihçesi

Yapay sinir ağı (YSA), biyolojik sinir ağlarının yapısına benzeyen bir hesaplama modeli olarak, nörofizyolog Warren McCulloch ve matematikçi Walter Pitts tarafından ‘‘A Logical Calculus of the Ideas Immanent in Nervous Activity,’’ isimli makale ile 1943 yılında tanıtılmıştır (McCulloch & Pitts, 1943). Makalede tanıtılan McCulloch-Pitt Modeli, yapay nöronların çalışma şeklinin anlaşılması açısından önemli bir temel oluşturmuştur (Haglin vd., 2019). 1958 yılında Frank Rosenblatt, algılayıcı (perceptron) modeli ile biyolojik nöronun yapısından ilham alan bir makine olarak tanıtılmıştır. 1960’ların sonuna kadar Rosenblatt’ın algılayıcısı kabul görse de 1969 yılında Minsky ve Papert tarafından yazılan “BPerceptrons” adlı kitapta algılayıcıya yönelik sorunlar matematiksel analizler kullanılarak eleştirilmiştir (Haglin vd., 2019). 1949 yılında nörolog Donald Hebb, beyin hücrelerinin pre ve post sinaptik aktivitelerini gözlemleyerek sinir ağları teorisini oluşturmuştur (Seung, 2000). 1960 yılında Widrow ve Hoff, ilişkisel belleğe sahip, mantıksal işlemleri yapabilen ve bilgileri depolayabilen ADALİNE’ı (Adaptive Linear Combiner) tanıtmıştır (Widrow & Hoff, 1962). 1979 yılında Fukushima tarafından görsel örnekleri tanıyabilen çok katmanlı “Neocognitron” adlı sinir ağı modeli tasarlanmıştır (Fukushima vd., 1983). 1986 yılında Rumelhart, çok katmanlı ağlarda gerçek çıktı vektörü ile istenen çıktı vektörü arasındaki farkın en aza indirilmesini amaçlayan geriye yayılma (backpropagating) algoritmasını geliştirmiştir (Rumelhart vd., 1986). Geri yayılım algoritması çok katmanlı ağlarda her görüntü için sınıflandırma performansının etkinliğini hesaplayarak eğitimin verimliliğini arttırmayı amaçlayan algoritma olarak tanımlanmaktadır (Krizhevsky vd., 2017). 1990'ların sonunda, sinir ağları ve geri yayılım, makine öğrenimi topluluğu tarafından büyük ölçüde terk edilmiş bunun sonucunda bilgisayarla görme, konuşma ve tanıma toplulukları tarafından göz ardı edilmiştir (LeCun vd., 2015). Bunun yanı sıra, Hinton ve arkadaşları tarafından çok büyük sinir ağı sistemlerinin yavaş ve pratikte kullanımının mümkün olmadığını, daha fazla katmanla beraber hiyerarşi ile çalışan derin bir sinir ağının bu eksiklikleri

tamamlayabileceğini anlatan bir makale yayınlaması önemli bir atılım olarak kabul edilmiştir (Hinton vd., 2006).

1.5.3.2. Yapay Sinir Ağlarının Yapısı

Biyolojik sinir sistemi nöron adı verilen sinir hücrelerinden; bu hücreler de soma (hücre gövdesi), akson ve dendrit isimli uyarıları almak ve iletmekle görevli özelleşmiş bölümlerden oluşmaktadır (Fain, 1999). Yapay sinir ağları (YSA), biyolojik sinir hücrelerinin yapay sinir ağlarındaki karşılığı olan işlemci elemanların fonksiyonlarının çeşitli algoritmalar ile modellenmesi yoluyla oluşturulmuştur. Biyolojik sinir sistemindeki yapılar Şekil 1.5'te gösterilirken, bu yapıların yapay sinir sistemindeki yapılara karşılık gelen terimleri Çizelge 1.2'de gösterilmektedir. Bir işlemci elemanda girdi sinyalleri, basit toplama fonksiyonu ile birleştirilerek aktivasyon fonksiyonu yoluyla diğer işlemci elemana iletilmektedir. Yapay sinir ağlarının yapısında bulunan sırasıyla girdi, gizli veya ağırlık katmanı ve çıktı katmanı olarak adlandırılan katmanlar arasındaki iletim sonucu veri işleme gerçekleşmektedir (Papik vd., 1998). Yapay sinir hücresinin yapısı Şekil 1.6.'da gösterilmektedir (Soffer vd., 2019). YSA, bağlantı özelliklerine göre "ileri beslemeli" ve "geri beslemeli" olmak üzere iki gruba ayrılmaktadır (P. M. Cheng vd., 2021).

1. **İleri beslemeli ağlar:** İnsan sinir sisteminden ilham alan, verilen görevi yerine getirmek için birlik içinde çalışan ve sonunda karmaşık girdi verileri üzerindeki görevleri ağırlıklar kullanarak yerine getiren, birbirine katmanlar halinde bağlı yapay nöron ağıdır. İleri beslemeli bir ağ sisteminde, bir ağın eğitimi sonucu oluşan yanıtlar ile bir önceki ağlarda oluşan yanıtlar birbirinden bağımsızdır. (Jain vd., 1996).
2. **Geri beslemeli ağlar: G**eri beslemeli ağlar dinamik sistemlerdir. Bu ağ yapılarında genelde beklenen çıktı ile ağ yapısından çıkan çıktı karşılaştırılarak aradaki fark yani hata belirlenir. Bu hatayı aza indirgemek için geri beslemeli ağ kullanılır. Tek yönlü olmayan ağ sistemleridir. Geri besleme, aynı katmandaki nöronlar arasında olabileceği gibi farklı katmanlardaki nöronlar arasında da olabilir (Jain vd., 1996).

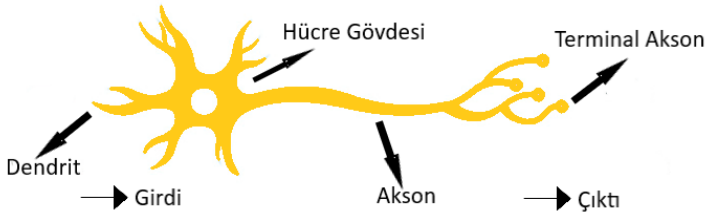

Şekil 1.5. Biyolojik sinir hücresi (Soffer vd., 2019).

Çizelge 1.2. Biyolojik sinir sistemindeki yapılar ve bunların yapay sinir sistemindeki yapılara karşılık gelen terimleri (Soffer vd., 2019).

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

1.5.3.3. Yapay Sinir Ağlarının Eğitimi

YSA' nın diğer bir süreci olan eğitim ve öğrenim sürecinin temel amacı girdi ve çıktı arasında bir eşleştirme yapmaktır. Bir ağın eğitilmesi, bir eğitim veri kümesinde modelin tahmin ettiği değerler ile veri kümesindeki olması gereken gerçek değerler (ground truth) arasındaki farkları en aza indirecek olan evrişim katmanlarındaki filtreleri ve tam bağlı katmanlardaki ağırlıkları bulabilme sürecidir (Yamashita vd., 2018). Modern sinir ağları milyonlarca parametre içermekte ve her bir düğümdeki parametreler ayarlanarak eğitilmektedir. Parametreler, bir eğitim veri setinde iyi performans gösteren bir dizi parametre bulmaya çalışan, gradyan iniş (gradiant descent) adı verilen bir optimizasyon algoritması aracılığıyla ayarlanmaktadır. Gradyan iniş yaygın olarak, hatayı en aza indirmek için ağın öğrenilebilir parametrelerini, yani filtre ve ağırlıklarını tekrarlı olarak güncelleyen bir optimizasyon algoritmasıdır. Eğitilen YSA ağının performansı ve ortaya çıkan tahminin yanlışlığı, bir kayıp veya hata fonksiyonu (loss function) aracılığıyla nicel olarak değerlendirilmektedir (Chartrand vd., 2017). Geri yayılım algoritması (Back Propagation), kayıp fonksiyonu ve gradyan iniş optimizasyon algoritmasının önemli

roller oynadığı sinir ağlarını eğitmek için yaygın olarak kullanılan bir yöntemdir (Yamashita vd., 2018).

-Geri yayılım algoritması: YSA da modelin tahmin çıktıları ile veri kümesindeki olması gereken gerçek değerler arasındaki fark hata olarak kabul edilmektedir. Bu hata sinir ağı üzerinden geriye doğru yayılımla yani YSA eğitim süresince kullanılan tüm ağırlık ve eşik değerlerindeki güncellemelerle dereceli olarak indirilmeye çalışılmaktadır (Asilkan & Irmak, 2009). Veri kümesinin tamamında tekrarlanan ileri ve geri yayılım algoritmalarının işlevi sonucunda optimize edilmiş bir ağ oluşturulmaktadır (Soffer vd., 2019).

-Toplama/birleştirme fonksiyonu: YSA'ya gelen girdilerin, kendilerine ait ağırlıklarla çarpıldıktan sonra matematiksel işlemlerle birleştirilmesi işlemini gerçekleştiren fonksiyondur (Papik vd., 1998).

-Aktivasyon fonksiyonu: Aktivasyon işlevi, biyolojik nöronların temel davranışlarına ilişkin gözlemlerden esinlenilerek geliştirilmiştir. Bir sinir ağı katmanındaki aktivasyon fonksiyonunun rolü, toplama fonksiyonu tarafından hücreye gönderilen net bilgiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirlemektir Aktivasyon fonksiyonu ile modelin öğrenme gücünü arttıracak olan doğrusal olmayan (non-linear) yapı işlemci elemanların çıkışlarında oluşur (Chartrand vd. 2017). Bir sinir ağındaki tüm yapay sinir hücrelerinin aktivasyon fonksiyonu birbirinden farklı olabilmektedir. Her göreve göre uygun bir aktivasyon fonksiyonunun seçilmesi gerekmektedir (Yamashita vd., 2018). En bilinen aktivasyon fonksiyonları sigmoid, tanh fonksiyonları ve doğrusal birim fonksiyonudur [Rectified Linear Unit (ReLU)] (Chartrand vd., 2017; Soffer vd., 2019).

YSA'ların çalışma prensibine göre, girdi katmanından alınan değerler öğrenmeyi temsil eden ve sayısal değerler içeren ağırlıklar ile çarpılmaktadır. Hesaplanan değer çıktı katmanına iletilerek beklenen değerlerle karşılaştırılması yapılmakta, elde edilen toplam hata hesaplanarak ağırlıklar güncellenmektedir. Belirli bir tekrar sayısına veya istenilen hata büyüklüğüne ulaşıldığında yapay sinir ağının öğrenmeyi tamamladığı kabul edilmektedir (Erickson vd., 2017).

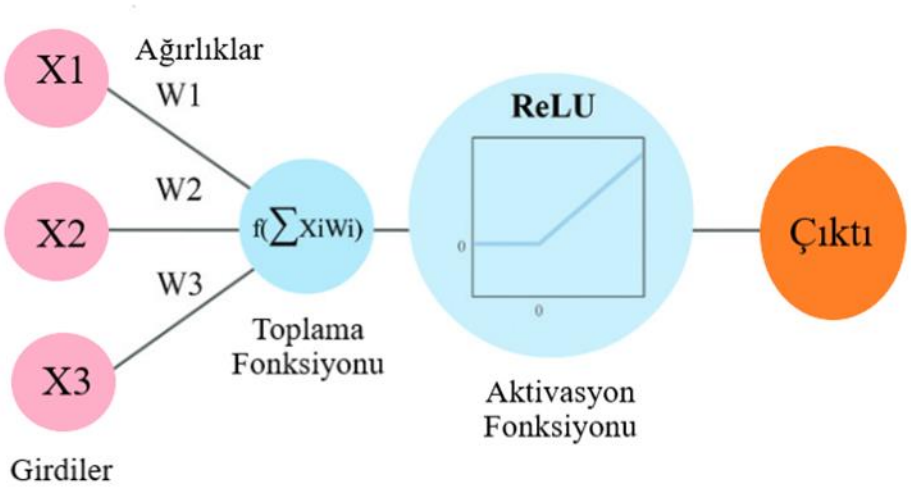

Şekil 1.6. Yapay sinir hücresinin basitçe yapısı (X=Girdi, W=Ağırlık) (Soffer vd., 2019).

1.5.4.Derin Öğrenme

Yapay sinir ağlarındaki katmanlı sistemi oluşturan nöronlar matematiksel işlemlerle bir araya gelerek katmanlar arası bilgi aktarımı sağlamaktadır. Çok katmanlı bu nöronların birbirlerine bağlanması ve katman sayılarının artması daha karmaşık problemlerin çözülmesine imkân tanımıştır (Shwartz-Ziv & Tishby, 2017). Sinir ağlarındaki giriş ve çıkış tabakaları arasındaki gizli tabakanın arttırılması makine öğreniminin alt konusu olan "derin öğrenme" kavramını oluşturmuştur (Pesapane vd., 2018). Igor Aizenberg önderliğinde derin öğrenme ifadesi ilk kez 2000 yılında tanıtılmıştır (Aizenberg, Aizenberg ve Vandewalle 2000). Derin öğrenme algoritmaları büyük veri gruplarını, çok fazla tabaka içeren sinir ağlarını kullanarak analiz edebilmekte, çıkarımlar yapabilmekte, tahminler üretebilmektedir (Janowczyk & Madabhushi, 2016). Derin Öğrenme birden fazla gizli katmana sahip olmasından dolayı "derin" adını almaktadır (LeCun vd., 2015).

1.5.4.1.Derin Öğrenme Mimarileri

Derin öğrenme algoritmalarından bazıları; tekrarlayan sinir ağları, sınırlı Boltzmann makineleri, uzun-kısa süreli bellek ağları, derin oto-kodlayıcılar, derin inanç ağları, evrişimli (konvolüsyonel) sinir ağları (ESA) olarak isimlendirilmektedir (Tan vd., 2021).

1. Tekrarlayan Sinir Ağları (Recurrent Neural Networks)

Tekrarlayan Sinir Ağları (TSA), bir veya daha fazla geri besleme döngüsüne sahip yapay nöronlardan oluşan, girdi ve çıktı verilerinin birbirlerine bağımlı olduğu derin öğrenme algoritmasıdır (Salehinejad vd., 2017). Geleneksel sinir ağlarında girdi ve çıktılar birbirinden bağımsızdır. TSA'da amaç sıralı bilgiyi kullanarak hatayı minimuma indirmektir (Bengio, Simard ve Frasconi 1994).

2. Sınırlı Boltzmann Makineleri (Restricted Boltzman Machine)

Görünür ve gizli katmanlarından oluşan, bu katmanlar üzerinde nöronlar gibi çalışan düğüm adı verilen yapıların katmanlar arası simetrik bağlantılı olduğu; fakat aynı katmanda bulunan düğümlerde bağlantı bulunmadığı modeldir. Sınırlı Boltzmann Makinelerinde (SBM) aynı katmandaki düğümler birbirleriyle bağlantılı olmadığı için "sınırlı" kabul edilmektedir (Shetty vd., 2020). Katman içi iletişim olmayan SBM'lerde her düğüm, girdiyi işleyen ve bu girdiyi iletip iletmeyeceği konusunda rastgele kararlar alan bir hesaplama odağıdır (Salakhutdinov vd., 2007).

3. Uzun Kısa Süreli Bellek Ağları (Long-Short Term Memory)

Tekrarlayan sinir ağları ile gerçekleştirilen işlemler arasındaki sürenin artması bir sonraki veri dizisinin tahmin edilmesi işlemini zorlaştırdığından, "hafıza hücreleri" TSA'ların gizli katmanına eklenmiştir (Hochreiter & Schmidhuber, 1997). Bu gelişmeyle hafıza hücreleri, hangi verilerin kullanılacağına veya hangisinin silineceğine dair güncellemeyi yapmakta, işlem hızlanarak verimlilik artmaktadır. Veri sınıflandırma, veri tahmini ve kümeleme yapabilen algoritmalar olarak tanımlanmaktadır (Shetty vd., 2020).

4. Derin Oto-Kodlayıcılar (Deep Autoencoders)

Girdi, gizli ve çıktı olarak üç katmanlı derin oto-kodlayıcılarda, girdi verisi gizli katmandaki düğümlerde sıkıştırılmış temsile eşlendikten sonra en az kayıpla çıktı katmanında oluşturulmaktadır (Farina vd., 2020). Derin oto-kodlayıcılarda girdi katmanındaki değerler çıktı katmanına kopyalanmakta yani, sinir ağına girdi olarak verilen veri çıktı katmanında tekrar oluşturulmaktadır. Burada amaç girdi verisinin sıkıştırılmış gösteriminden en iyi özelliklerin öğrenilmesidir. İleri beslemeli, tekrarlanmayan sinir ağı modeli olan derin oto-kodlayıcılarda veriler kodlama-kod çözücü işleminden geçmektedirler (Krizhevsky & Hinton, 2011).

5. Derin İnanç Ağları (Deep Belief Networks)

Birden fazla ve birbiri ardına ekli SBM ağının oluşturduğu, girdi verisinin ilk SBM ağından çıktıya dönüşüp diğer SBM ağına girdi olarak verildiği ve art arda bu sistemle devam eden sinir ağı Derin İnanç Ağı olarak adlandırılmaktadır (Krizhevsky & Hinton, 2011). Denetimsiz öğrenme modeli olan bu sistemde amaç girdilerden çıkan özelliklerin arttırılarak paralel olarak verimliliğin ve üretimin de arttırılmasıdır (Kiran vd., 2018).

6. Evrişimli Sinir Ağları (Convolutional Neural Network)

Evrişimli sinir ağları (ESA) bilgisayarlı görü problemlerini çözmek üzere geliştirilmiş yapay sinir ağlarıdır (Erickson vd., 2017). ESA'lar memelilerin görsel korteksindeki nöral yapının hiyerarşik düzene bağlı çalışma şeklinden esinlenilerek oluşturulmuştur (Hubel & Wiesel, 1968). Bu hiyerarşik düzende nöronların basit veya karmaşık olması ve düzeyleri, nöronun kendi uyarı alanını oluşturmaktadır. Her nöronun kendi uyarı alanına göre uyaranı cevaplandırdığı matematiksel işlem "evrişim" olarak adlandırılmaktadır (Albawi vd., 2018; Fukushima vd., 1983). İleri yönlü sinir ağı olan ESA'lar yüksek boyutlu verilerden düşük boyutlu verilerin çıkarılması prensibine dayanmaktadır (Girshick vd., 2014). ESA'ların yapısı Şekil 1.7.'de gösterilmektedir.

ESA çok katmanlı mimarisinin katmanları şöyle sıralanabilir;

- Evrişim katmanı
- Aktivasyon katmanı
- Havuzlama katmanı
- Tam bağlı katman (Albawi vd., 2018)

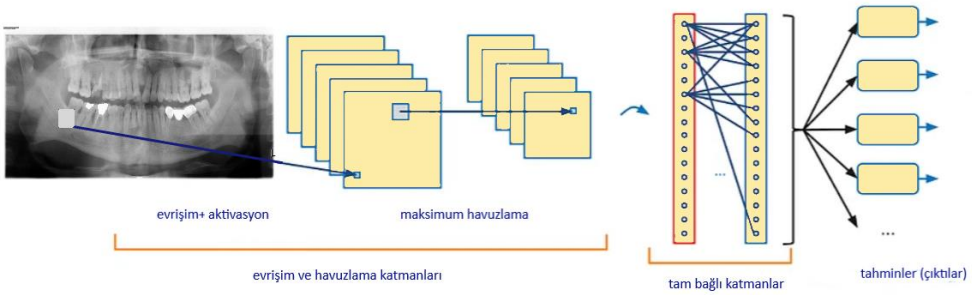

Şekil 1.7. Evrişimli sinir ağlarının yapısı

- **Evrişim katmanı**

Evrişim işlemi filtre adı verilen küçük bir sayı dizisinin giriş verisine uygulanması ile giriş verilerinin çeşitli özelliklerini temsil eden sayı dizlilerinin matematiksel işlemler sonucu çıktı verisine dönüştürülmesidir (Yamashita vd., 2018). Bir başka deyişle giriş verisinde bulunan ve farklı özellikleri temsil eden 1 ve 1'den büyük değerler, filtre üzerindeki sayısal değerler ile beraber yapılan matematiksel işlemler sonucu özellik haritaları üzerinde tutulur (Ajit vd., 2020). Her bir özellik haritasındaki sayısal birimler bir filtrenin tüm girdi görüntüsüne uygulanması ile elde edilmektedir (LeCun vd., 2015).

Bir evrişim katmanında girdi verisi yükseklik (a), genişlik (b) ve derinlik (c) olarak (a x b x c) üç boyutta düzenlenir. Evrişim katmanı da (d x e x f) boyutlarında x adet filtreden oluşmaktadır. Bu filtreler ile, her biri a-d+1 ve b-e+1 boyutunda k adet birbirine bağlı özellik haritaları üretilmektedir. Burada sırasıyla d ve e değerleri a ve b değerlerinden küçük; f değeri c değerinden küçük veya eşit olmalıdır (Alzubaidi vd., 2021).

5x5 boyutlu girdi verisinin, boyutu 3 × 3 olan bir filtre ile filtrelenmesi sonucu 5-3+1x5-3+1=3x3 boyutunda özellik haritası üreten evrişim işleminden bir bölüm Şekil 1.8.'de gösterilmektedir. Filtrenin her bir öğesi ile girdi verisi üzerinde uygulanan alana denk gelen bölümde (mavi renk ile gösterilen bölüm) ilk olarak çarpma (her bölüm kendi karşısına gelen bölüm ile çarpılır) sonrasında toplama işlemleri (çıkan sonuçların hepsi toplanır) yapılarak çıktı verisi üzerindeki değerler oluşturulur. İşlemin açık hali 1x1+2x0+1x1+2x0+0x1+0x0+1x1+0x0+2x1=5 şeklindedir. Bu işlem tüm kutucuklarda uygulanacak ve çıktı verisi özellik haritası olarak adlandırılacaktır (Yamashita vd., 2018).

Evrişimli sinir ağlarında parametre terimi, sinir ağlarındaki eğitim sonucu öğrenilmiş değişkeni ifade ederken, hiperparametre sinir ağlarının eğitimi öncesinde ayarlanması gereken değişkenleri ifade etmektedir (Yamashita vd., 2018). ESA'lar için filtre parametredir; filtre boyutu ile sayısı ise hiperparametredir ve evrişim işleminde hiperparametre değerinin değiştirilmesi özellik haritalarının "derinliğinin" değişmesi anlamına gelmektedir. Filtre sayısının artması özellik haritasının derinliğinin artması yani girdi görüntüsünden alınan bilginin artması anlamına gelmektedir (Ajit vd., 2020).

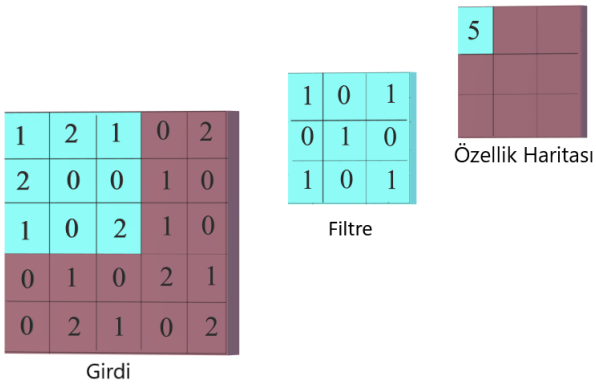

Şekil 1.8. Evrişim örneği (Yamashita vd., 2018)

- **Aktivasyon katmanı**

Evrişim katmanından çıkan doğrusal olan verinin, eğitimin hızlandırılması amacıyla doğrusal olmayan bir yapıya dönüştürüldüğü yapı aktivasyon katmanıdır. Bu katmanda aktivasyon fonksiyonu olarak önceki yıllarda sigmoid ve tanh kullanılsa da günümüzde sıklıkla doğrusal birim fonksiyon (ReLU) kullanılmaktadır (Albawi vd., 2018).

- **Havuzlama katmanı**

Havuzlama katmanında parametre sayısı azaltılarak aşağı örnekleme işlemi uygulanmaktadır. Aşağı örnekleme ile özellik haritalarının genişlik ve yüksekliğini yani boyutunu azalarak önemli bilgiler korunmaktadır (Albawi vd., 2018). Aşağı örnekleme, hesaplama yükünün azaltılması ve gereğinden fazla uyumun (overfitting) önüne geçmek amacıyla yapılmaktadır (Yamashita vd., 2018). Maksimum ve ortalama havuzlama sık tercih edilen havuzlama türleridir (Ajit vd., 2020). Maksimum havuzlamada, özellik haritası üzerindeki maksimum eleman filtre boyutunda yeni matris üzerinde saklanmaktadır (Albawi vd., 2018)(Şekil 1.9.).

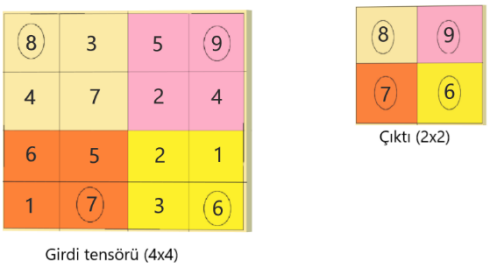

Şekil 1.9. 2x2 filtre boyutu ile maksimum havuzlama yapılarak elde edilen çıktı verisi (Yamashita vd., 2018)

Ortalama havuzlamada, girdi verisi üzerindeki özellikleri temsil eden değerler maksimum havuzlamada olduğu gibi parçalara bölünmekte, fakat bu defa her parça üzerindeki değerlerin ortalaması alınarak çıktı verisine aktarılmaktadır (Lin, Chen ve Yan 2013). Parametre içermeyen ortalama havuzlama, her boyuttan girdi alabilmektedir (Cui vd., 2017). Maksimum havuzlama ve ortalama havuzlamanın birleşimi olan karışık havuzlama yöntemi, girdi verisindeki öğrenilebilir özelliklerin sayısını yani parametreyi azaltarak gereğinden fazla uyumun önüne geçilmesini sağlar (D. Yu vd., 2014). Gereğinden fazla uyum eğitilen modelin, veri setindeki gereksiz bilgiyi öğrenerek yeni veri setinde daha önce karşılaşmadığı verilerde başarısız sonuçlar vermesi yani aslında eğitilemediğinin görülmesi sorunudur (Pençe vd., 2019). Veri setinin arttırılması, eğitim veri setinden test veri setini ayırarak model eğitiminin tamamlanması, ağırlıklar üzerinde düzenlemelerin yapılması, eğitim modelinde karmaşıklığın azaltılması gibi yöntemlerle aşırı öğrenme azaltılabilmekte hatta önlenebilmektedir (Chen vd., 2021).

- **Tam bağlı katman**

Art arda gelen evrişim ve havuzlama katmanlarından elde edilen özellik haritaları, tek boyutlu sayı dizisine dönüşerek düzleştirilmekte ve sınıflandırıcıya verilmek üzere son olarak tam bağlı katmanlara bağlanmaktadır (Alzubaidi vd., 2021). Tam bağlı katmandan önceki katmanlarda görüntüye ait çeşitli özelliklerin en güçlü sinyalleri birleştirilerek görüntünün hangi sınıfa ait olduğunun olasılıkları hesaplanmaktadır (Ker vd., 2018). Tam bağlı katmanda çok sayıda parametre (ağırlıklar) kullanılması sinir ağının yavaşlamasına ve aşırı öğrenmeye neden olabilmektedir (Cui vd., 2017).

1.5.4.2. Derin Öğrenme Kütüphaneleri

Derin öğrenme algoritmalarında kullanılan modellerin eğitilmesi, devamlı olarak bu algoritmaları kullanan kişiler tarafından güncellenen ve yenilenen yazılım kütüphaneleri aracılığı ile sağlanmaktadır (İnik vd., 2017). Günümüzde sık kullanılan yazılım kütüphanelerinden bazıları "Theano, Caffe, Tensorflow, Keras, PyTorch" sayılabilmektedir (Tan vd., 2021; Toğaçar & Ergen, 2019).

- **Theano:** MILA LAB tarafından geliştirilen Theano, Python programlama dili ile yazılmıştır. Çok boyutlu diziler gibi matematiksel işlemleri kolaylaştıran yazılım kütüphanesidir (Al-Rfou vd., 2016).

- **Caffe:** Berkeley Vision and Learning Center (BVLC) tarafından geliştirilmiş, Python ve Matlab arabirimlerini içeren yazılım kütüphanesidir. Önceden eğitilmiş ağlar kullanmaktadır (Jia vd., 2014).
- **Tensorflow:** Google tarafından geliştirilmiş, Python arayüzü kullanılmış kütüphanedir. Görüntü işleme esnasında sayısal hesaplamada verimli olması en önemli özelliğidir (Toğaçar & Ergen, 2019).
- **Keras:** Google tarafından geliştirilmiş, Python programlama dili kullanılmıştır. Keras kütüphanelerinin temelinde Tensorflow ve Theano yazılımı mevcuttur. Keras yazılım kütüphanesinin kullanımı ESA, TSA ve her ikisini beraber kullanan ağları desteklemesi açısından avantajlıdır. Hızlı sonuç vermek üzerine geliştirilmişlerdir (İnik vd., 2017).
- **PyTorch:** 2017 yılında tanıtılan PyTorch, Python proglama dili kullanan bir derin öğrenme kütüphanesidir. PyTorch, birçok kütüphaneye entegre olarak çalışmakta, birçok sinir ağında yüksek performans sunmaktadır. Diğer kütüphanelerin aksine daha verimli bellek kullanımına sahip olan PyTorch, GPU (Graphics Processing Unit) desteği veren hızlı ve esnek olma özelliklerini taşımaktadır (Tan vd., 2021).

1.5.4.3. Derin Öğrenme ve Radyolojik Görüntü Analizi

1990 yılından önce tıbbi görüntülerin analizi, eğitim ve test verilerinin kullanıldığı karmaşık derin öğrenme modellerinde yapılamazken, 1990 yılından sonra yeni algoritmaların gelişmesi bu durumu mümkün kılmıştır (Litjens vd., 2017). Günümüzde bilgisayarlı görü problemlerinde kullanımı çok başarılı olan ESA'lar tıbbi radyolojik görüntüler üzerinde, sınıflandırma (classification), tespit (detection) ve segmentasyon (segmentation) amacıyla kullanılmaktadırlar (Cruz-Roa vd., 2014; Everingham vd., 2015; Heo vd., 2021; Kainz vd., 2015; Lin vd., 2014; Ludovic vd., 2013; Russakovsky vd., 2015; Veta vd., 2015).

a) **Sınıflandırma:** Görüntülenen bölge üzerinde benzer özelliklerin gruplandırılmasıdır. Buna örnek olarak radyolojik görüntüde gözlenen malignite türünün belirlenmesi verilebilmektedir (M. Kim vd., 2019). İkili veya çoklu sınıflandırma yapılabilmektedir (Cheng vd., 2021).
b) **Tespit:** Radyografik görüntüde istenen anatomik yapıların veya patolojik durumların lokalize edilmesidir (Ker vd., 2018). Bu durum diş hekimliğinde,

radyografi üzerinde apikal lezyonların veya diş kronunda çürük tespit edilmesi şeklinde olabilmektedir (Ekert vd., 2019; Lee vd., 2018). Tespit amacıyla kullanılan ESA'lar, bölge önerileri ve regresyon gibi ek işlevlere sahip ek katmanlar içermesiyle sınıflandırma görevi için kullanılan ESA sistemlerinden ayrılmaktadır (Heo vd., 2021).

c) **Segmentasyon:** Radyografik görüntü üzerindeki anatomik veya patolojik yapıların piksel düzeyinde algılanması ve tanımlanmasıdır (Heo vd., 2021). Semantik (anlamsal), örnek veya her ikisini de içeren panoptik segmentasyon olarak sınıflandırılmaktadırlar (Minaee vd., 2021). Semantik segmentasyon görüntü üzerinde izlenen ayrı ayrı her yapının piksel düzeyinde etiketlenmesidir. Örneğin, karaciğer görüntüsü üzerindeki her piksel parankim, tümör veya kan damarına atanabilir. Örnek segmentasyonda aynı sınıfa ait birden çok yapının piksel düzeyinde algılanmasıyla ve betimlenmesiyle semantik segmentasyonun alanı genişletilmiştir. Örnek verilmek istenirse bir göğüs radyografisinde izlenen akciğer nodüllerinin her biri aynı sınıftadır fakat piksel düzeyinde ayrı ayrı örnek segmentasyonla tanımlanır (Cheng vd., 2021). Her iki segmentasyonu içeren panoptik segmentasyon semantik ve örnek segmentasyondan gelen farklı tahminlerin çatışmasını çözebilmek amacıyla kullanılmaktadır (Mohan & Valada, 2021).

1.5.4.4. Nesne Tespiti ve Derin Öğrenme Modelleri

Girdi verisi olarak görüntüyü kullanan derin öğrenme modelleriyle nesne tespiti yapılırken, görüntünün farklı ölçeklerde olması problem yaratabilmektedir (Bochkovskiy, Wang ve Liao 2020; Nickolls ve Dally 2010). Bir modelin geniş ölçek aralığındaki nesneleri algılamasını sağlamak amacıyla görüntü piramitleri ve bu piramitler üzerine inşa edilen özellik piramitleri (feature pyramids) oluşturulmuştur. ESA görüntü analizi üzerine tasarlanmış sinir ağı modelidir (Kim vd., 2020). ESA sistemleri görüntü ölçeği üzerindeki değişimlere rağmen başarılı sonuçlar veren bir sistemdir. ESA sistemlerinin özellik piramitleri ile beraber kullanımının daha doğru sonuçlar verdiği fakat bu işlemin zaman alıcı olduğu görülmüştür. Bu sisteme de özellik piramidi ağı (feature pyramid network) adı verilmiştir (Lin vd., 2017).

Nesne tespit dedektörlerinin mimarisi "omurga", "boyun" ve "baş" olarak üç bölümden oluşmaktadır. Omurga, girdi verisinden nesne tespiti için yararlı olan özelliklerin çıkarılmasından sorumludur. Nesne tespit dedektörünün yüzeyel

katmanlarından, tespit edilecek nesnenin kenar, doku gibi alt düzey özelliklerini çıkarırken, daha derin katmanlardan nesneye ait bölümleri, anlamsal bilgileri gibi üst düzey özelliklerini çıkartmaktadır. Sonraki yıllarda nesne tespit dedektörüne eklenen ve "boyun" olarak adlandırılan kısım, omurga ve baş kısmı arasına yerleştirilerek farklı katmanlardan gelen özellik haritalarını toplamaktadır. Boyun bölümü evrişimli katmanlar, özellik piramidi ağı veya diğer mekanizmaları içerebilmektedir. Detektörün baş kısmı, omurga ve boyun bölümlerinin sağladığı özelliklere göre tahminlerin üretildiği son bölümdür. Baş kısmı tek aşamalı dedektör ve iki aşamalı dedektör olarak ikiye ayrılmaktadır (Bochkovskiy vd., 2020). Nesne tespitinde etkinliği kabul gören derin öğrenme modelleri YOLO (You Only Look Once), SSD (Single Shot Multibox Dedector) ve Faster R-CNN 'dir (Kumar & Srivastava, 2020). Nesne tespitinde kullanılan derin öğrenme modellerinin mimari yapısı Şekil 1.10.'da gösterilmektedir.

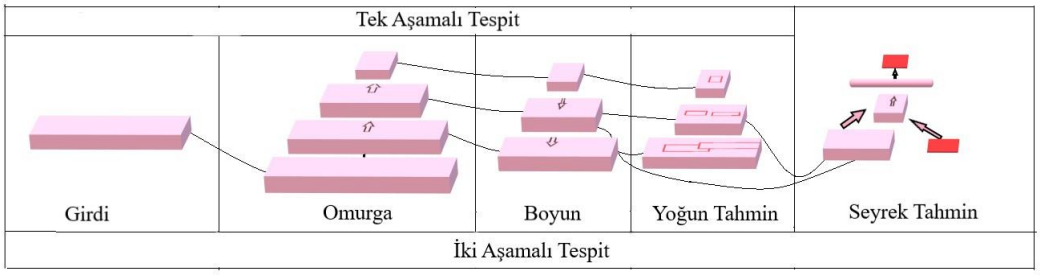

Şekil 1.10. Modern nesne dedektörlerinin mimarisi (Bochkovskiy vd., 2020)

I. R-CNN (Regions with CNN)

R-CNN modeli görsel veriler üzerinde nesne tespitinde kullanılması önerilen ESA temelli ilk modeldir bu nedenle nesne tespit amaçlı kullanılacak diğer derin öğrenme modellerine öncü olmuştur (Çalışkan & Demir, 2022). R-CNN algoritmaları, ilk olarak görüntü verisi üzerinde potansiyel sınırlayıcı kutular oluşturur. Ardından sınırlanan kutular üzerinde bölge önerme yöntemleri kullanmakta ve kutlar üzerinde sınıflandırma yapmaktadır. Son olarak sınırlayıcı kutuların iyileştirilmesi, tekrarlanan tespitlerin yok edilmesi ve görseldeki diğer nesneleri temel alarak kutuların yeniden skorlandırılması gerçekleşmektedir (Girshick vd., 2014). Sonuç olarak R-CNN sistemleri görüntü üzerindeki nesnelerin her birini belirli sayıda bölgeye kutulayarak bölmekte ve her bölüm için farklı ESA'lar kullanmaktadır. Bu da nesne tespit hızının

yavaşlamasına ve tespit sonucunun iyileştirilmesinin zorlaşmasına neden olmaktadır (Redmon vd., 2016).

II. Fast R-CNN

R-CNN modelinde eğitimin yavaş olması sebebiyle geliştirilen Fast R-CNN modelinde, R-CNN katmanlarındaki her bölge için ESA tek seferde çalıştırılarak hesaplamalar yapılmaktadır. Bu sayede eğitim ve test süresi azalarak verim arttırılmaktadır (Girshick, 2015; Gkioxari vd., 2015).

III. Faster R-CNN

R-CNN ve Fast R-CNN modellerinin eğitimini basitleştirmek amacıyla Faster R-CNN geliştirilmiştir. Faster R-CNN iki aşamalı eğitim modelidir. İlk aşamada bölge öneri ağı [Ragion Proposal Network (RPN)] adı verilen tamamen evrişimli sinir ağı, herhangi bir boyuttan aldığı girdide obje skoruna göre nesne önerileri oluşturmaktadır. İkinci aşamada Fast R-CNN mimarisine gelen nesne önerileri optimize ederek RPN ve Fast R-CNN algoritmalarının evrişimli katmanlarının ortak kullanılmasıyla nesne teklifi üretilmekte ve optimize etmek için ESA'dan yalnızca bir defa geçmesidir (Jiang & Learned Miller, 2017).

IV. SSD (Single Shot Multi Box Detector)

2016 yılında geliştirilen SSD, görüntü üzerindeki nesneyi algılarken, arka plan bilgisini kullanarak gerçek zamanlı olarak nesne tespiti yapmaktadır (W. Liu vd., 2015). SSD modeli ile nesne tespiti yapılırken tek bir evrişimli ağın kullanılması sistemin hızını arttırmıştır (Kumar & Srivastava, 2020).

V. YOLO (You Only Look Once)

Nesne tespitinde en sık kullanılan derin öğrenme modeli YOLO (You Only Look Once), ilk olarak 2015 yılında Redmon ve arkadaşları tarafından tanımlanmıştır (Zhiqiang & Jun, 2017). YOLO sistemi, insan görsel sisteminin, görüntüdeki nesnelerin nerede olduğunu ve birbirleriyle nasıl etkileşimde bulunduklarını aynı zamanlı olarak algılayabilmesinden ilham alınarak geliştirilmiştir (Jeong vd., 2018). Nesneleri sınırlayan kutular üzerinde bu kutular içerisindeki nesnelerin sınıfının olasılıklarını gerçek zamanlı tahmin eden tek bir evrişimli sinir ağından oluşmaktadır. Görüntü üzerindeki birden çok sınırlayıcı kutu içerisindeki nesneleri ve bu kutuların sınıf olasılıklarını, görüntü üzerinde işlemleri yinelemeden, görüntüye bir defa bakarak

öngörebilmektedir. Bütün bu işlemleri tek bir regresyon problemi olarak değerlendiren YOLO hem basitleştirilmiş hem de diğer modellere göre daha hızlı çalışan bir eğitim sistemidir (Redmon vd., 2016; Zhiqiang & Jun, 2017).

YOLOV1 mimarisi 24 adet evrişimli katman ve bunu takiben 2 tam bağlı katmandan oluşmaktadır. YOLO özellik haritalarının sayısını azaltmak ve parametre sayısını nispeten düşük tutmak amacıyla 1x1 evrişimli katman kullanmaktadır. YOLO algoritmasının temel omurga ağı Joseph Redmon tarafından oluşturulan DarkNet ağıdır. Saniyede 45 kare hızında işleme yeteneğine sahip YOLO'nun temel mimarilerinden Fast YOLO sürümü saniyede 150 kare ve daha fazlasını işleyecek kapasitededir. Fast YOLO daha hafif bir model sayılabilecek dokuz evrişimli katmana sahip bir YOLO modelidir (Redmon vd., 2016).

2017 yılında YOLOV1'de oluşabilen nesne tespit hataları, nispeten düşük duyarlılık skorları gibi problemler, 19 adet evrişim katmanı ve beş havuzlama katmanı içeren DarkNet-19 ağı kullanılarak geliştirilen YOLOV2 ile çözülmeye çalışılmıştır. YOLOV2'yi geliştiren yazarlar aynı makalede 9.000'den fazla kategoriyi tespit edebilen YOLO9000 'u tanıtmışlardır. YOLOV2, kutular içindeki nesnelerde yüksek çözünürlük, direkt konum tahmini, çok yönlü eğitim (multi-scale training) gibi özelliklere sahip hale getirilmiştir (Redmon & Farhadi, 2017).

2018 yılında 53 evrişim katmanına sahip Darknet-53 mimarisi kullanılarak geliştirilen YOLOV3 tanıtılmıştır. Bu yeni model nesne tespitinde kendinden önceki modellere göre çok daha başarılı olmuştur; ayrıca küçük nesneleri tahmin edebilmesini sağlayan çok ölçekli tahmin özelliğine sahiptir (Redmon & Farhadi, 2018).

Alexey Bochkovskiy ve ark. (2020) yılında YOLO'nun nesne tespit hızını arttırdığı yeni sürümü YOLOV4'ü tanıtmıştır. YOLOV4 geliştirilirken yazarlar en iyi performans gösteren Darknet-53'ün CSPNet ile modifikasyonu olan CSPDarknet-53'ü mimari yapıda kullanmışlardır. YOLOV4, YOLOV3'ün mAP skorunu %10 hızını ise %12 arttırmıştır (Bochkovskiy vd., 2020).

YOLOV5 2020 yılında geliştirilmiştir. YOLOV5n, YOLOV5s, YOLOV5m, YOLOV5l, YOLOV5x şeklinde 5 versiyonu olan YOLOV5'in en basiti, ağırlık dosyası diğerlerine göre daha küçük fakat yüksek tespit hızına sahip olan YOLOV5s'dir (Wang vd., 2020). YOLOV5 modelinin omurga yapısını CSPDarknet-

53 oluşturmakta ve üç farklı boyutta özellik haritası oluşturabilmektedir (Xu vd., 2021).

YOLOV6 ve YOLOV7 algoritmaları sırasıyla Haziran ve Temmuz 2022'de yayınlanmıştır. YOLOV6, Meituan araştırıcıları tarafından yayınlanmıştır (Li vd., 2022). Omurga yapısı RepVGG veya CSPStackRep mimarisinden oluşmaktadır. Tek kanallı geliştirilmiş YOLO (single channel improved) (SEC-YOLO) ve çok kanallı geliştirilmiş YOLO (multi-channel improved)) (MEC-YOLO) olarak iki ana bölüm içermektedir (MCE-YOLO). YOLOv6 modeli, önceki YOLO sürümlerine göre daha doğru nesne algılama elde etmek için tek ve çok kanallı teknikleri birleştirmektedir (Yung vd., 2022).

YOLOV7 algoritması Chien-Yao Wang, Alexey Bochkovskiy ve Hong-yuan Mark Liao tarafından tasarlanmıştır. YOLOV7'deki aktivasyon fonksiyonundaki iyileştirmeler ve modelin bazı parçalarının optimize edilmesi dışında ağın temel mimarisi değiştirilmemiştir (Wang vd., 2022). YOLOV7 girdi, omurga, boyun ve baş bölümlerinden oluşmaktadır (Liu vd., 2023). YOLOV7 mimarisi Şekil 1.11.'te gösterilmektedir.

1) **Girdi:** Girdi modülü girdi görüntüsü omurga ağına beslenmeden önce ilk olarak bu mimarinin kabul ettiği boyut olan 640x640 oranında yeniden boyutlandırmaktadır (Liu vd., 2023).
2) **Omurga:** YOLOV7'de YOLO algoritmasının diğer sürümleri, bu yeni mimaride optimize edilmiştir. YOLOV7'nin omurga ağı, CBS (Convolutional Batch and SİLU Activation), E-ELAN ve Maksimum Havuzlama (MH) modüllerini içermektedir (Şekil1.12). En temel modül olan CBS, diğer modüllere entegre edilmiştir (Zhang vd., 2023).
3) **Boyun:** Boyun kısmı, SPPCSPC modülü, ELAN-L modülü ve Üst Örnekleme [Up Sample (UP)] modüllerinden oluşmaktadır. Aşağıdan yukarıya doğru alt düzey bilgiler üst düzeye kolayca aktarılabilir, bu da farklı hiyerarşik özelliklerin verimli bir şekilde birleşmesini sağlamaktadır. SPPCSPC modülü, maksimum havuzlama yoluyla farklı tespit alanları elde eden CBS modülü, Birleştirme modülü ve MH modüllerini içermektedir (Şekil 1.13).
4) **Baş:** YOLOV7 baş kısmı özellik piramidi ağı [Feature Pyramid Networks] mimarisi kullanılarak yapılandırılmıştır (Liu vd., 2023). Baş kısmında Rep (RepVGG Blok) ve evrişim katmanı (Conv) kullanılarak sırasıyla 20 × 20, 40

× 40 ve 80 × 80 olmak üzere üç farklı ölçekte özellik haritası model tahmin çıktılarını oluşturulmaktadır. REP yapısı, eğitim ve dağıtım versiyonlarına bölünmüştür (Şekil 1.14). Eğitim versiyonunun üç dalı vardır. Üst dal, özellik çıkarımı için kullanılan 3 × 3 evrişim; orta dal, özellikleri yumuşatmak için kullanılan 1 × 1 evrişim ve alt dal evrişim içermeyen kimlik bölümüdür. Dağıtım versiyonu, eğitim modülü 1 adımlı 3 × 3 boyutlu evrişim katmanı içermektedir (Cao vd., 2023).

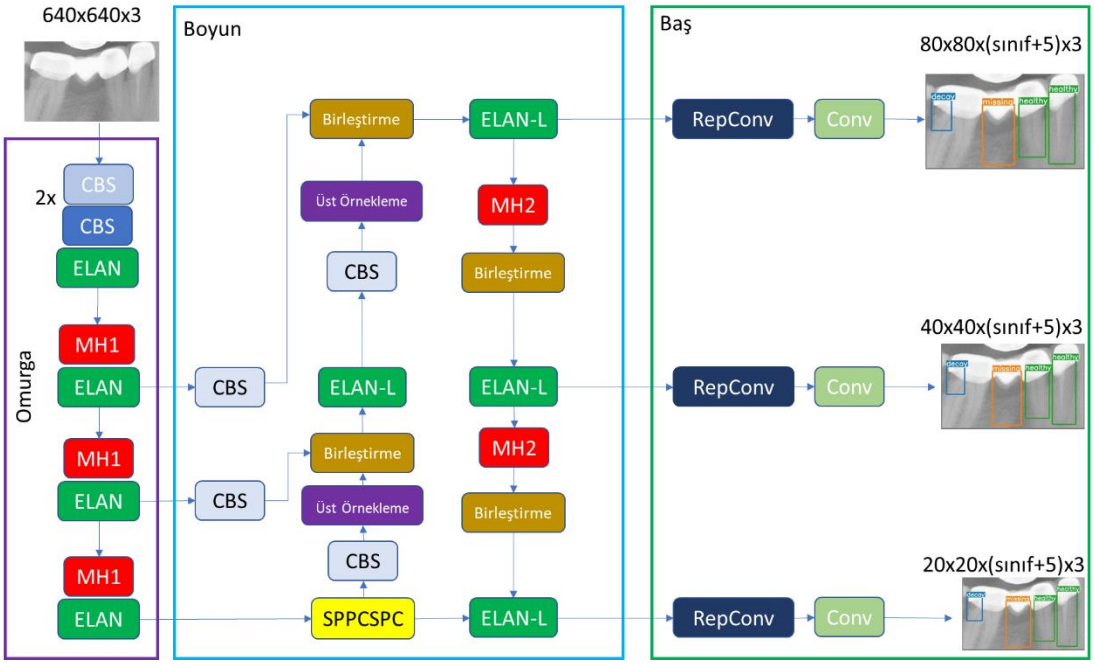

Şekil 1.11. YOLOV7'nin ağ mimarisi girdi, omurga, boyun ve baş olmak üzere dört genel modül içermektedir.

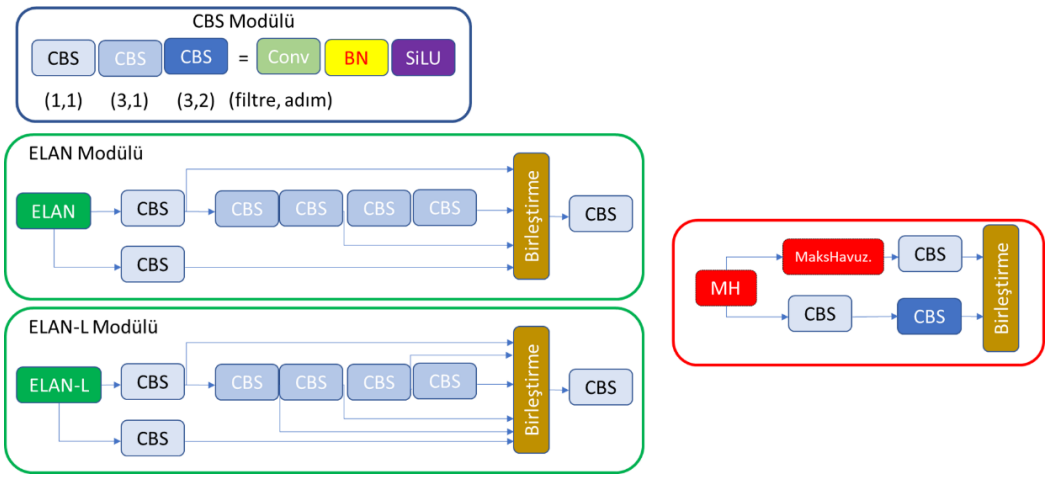

Şekil 1.12. ELAN, ELAN-L ve CBS modülleri

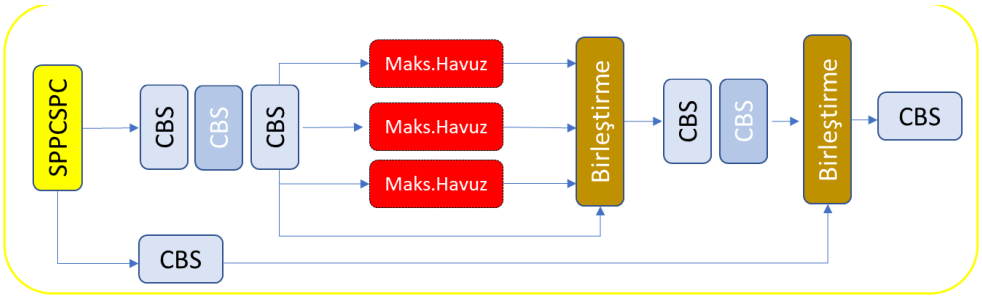

Şekil 1.13. SPPCSPC modülü

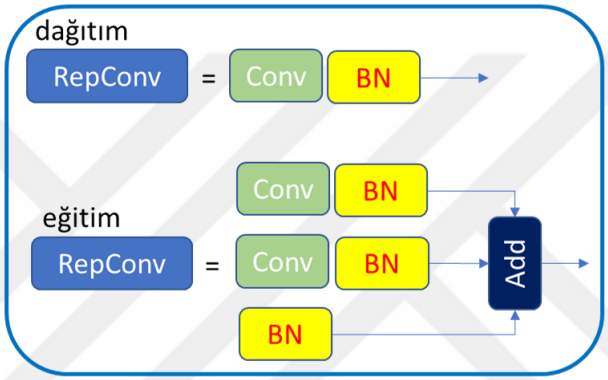

Şekil 1.14. REP modülü

YOLOV7, YOLOV5'ten %120 daha hızlı, ayrıca aynı hacme sahip YOLOV5'ten daha doğru skorlar elde etmiştir. YOLOV7'nin doğruluğu ve hızı, önceki YOLO algoritmalarına kıyasla artmıştır. Derin öğrenmede, bazı algoritmalar algoritma doğruluğunu takip ederken, diğerleri algoritma hızını takip eder. YOLO, algoritma doğruluğunu dikkate alırken algoritma hızını takip eder, ancak algoritma doğruluğu ana odak noktası değildir. YOLO'nun veri açıklamaları için özel format gereksinimleri de vardır, bu da uygulamaların karmaşıklığını artırmaktadır (Cao vd., 2023).

1.5.4.5. Derin Öğrenme ve Diş Hekimliği

Derin öğrenme yöntemlerinden, özellikle görüntüleme alanında en başarılı kabul edilen ESA'lar ile tıbbi radyolojik veriler kullanılarak yapılan çalışmalar artmaktadır (Suzuki, 2017). Diş hekimliğinde radyolojik görüntüleme, teşhis ve tedavi aşamalarının önemli bir parçasıdır (Whaites & Drage, 2013). Diş hekimliğinde

radyografik görüntüler üzerinde ESA'ların kullanım alanlarına yönelik çeşitli çalışmalar mevcuttur. Bunlar;

- Diş çürüğü tespiti (Bayraktar & Ayan, 2022; Lee vd., 2018; Vinayahalingam vd., 2021)
- Dişlerin tespiti ve numaralandırılması (Kim vd., 2020)
- Dental implantlarda kırık tespiti (D.Lee vd., 2021)
- Apikal lezyon tespiti(Ekert vd., 2019; Orhan vd., 2020)
- Maksiller ve mandibular çene lezyonları tespiti (Ariji vd., 2019; Lee vd., 2020)
- Periodontal hastalıklar tespiti (Krois vd., 2019; Lee vd., 2018)
- Maksiller sinüslerde patoloji varlığı ve tespiti (Murata vd., 2019)
- Yirmilik dişlerin gelişimlerinin evrelerinin değerlendirilmesi (De Tobel vd., 2017)
- Diş kök kırıklarının tespiti (Fukuda vd., 2020)
- Diş köklerinin morfolojisinin tespiti (Hiraiwa vd., 2019)
- Sefalometrik filmlerde anatomik noktaların yerlerinin belirlenmesi (Kunz vd., 2020)
- Aterosklerotik karotis plaklarının tespiti (Kats vd., 2019)

1.5.5. Protetik Diş Tedavisi Alanında Yapay Zekâ Uygulamaları

Protetik diş tedavisi diş hekimliğinin diğer disiplinleri ile bağlantılı diş hekimliği alanıdır. Protetik diş tedavilerinde başarı, diğer tüm diş hekimliği disiplinlerinin tedavi başarısının yanında hastaların sosyo-ekonomik durumlarının ve psikolojik sağlıklarının hekim tarafından değerlendirilmesi ile elde edilmektedir (Zitzmann vd., 2010). Birden fazla faktörün tedavi akışını ve sonucu etkilemesi protetik diş tedavisinin karmaşık olmasına neden olmaktadır (Söderfeldt vd., 1996). Derin öğreneme algoritmaları karmaşık problemleri çözmek için geliştirilmeleri nedeni ile protetik diş tedavisi uygulamalarında kullanımı, diğer tıp ve diş hekimliği disiplinlerinde olduğu gibi artmaya başlamıştır (Pareek & Kaushik, 2022).

Protetik diş tedavisi alanında yapay zekâ uygulamalarının kullanımı ile ilgili çalışmalardan bazıları aşağıdaki gibidir.

1) 2016 yılında Chen ve ark. deneyimsiz diş hekimlerine, hareketli protez planlaması yaparken yardımcı olması için derin öğrenme yöntemlerini kullanarak bir karar modeli geliştirmiştir (Chen vd., 2016).

2) 2017 yılında Raith ve arkadaşlarının yaptığı çalışmada, yapay sinir ağları dişleri geometrik özelliklerine göre sınıflandırılmış, dijital modeller üzerinde dişlerin tasarımının bu sınıflandırma aracılığı ile hızla yapılabildiğini dolayısıyla protetik restorasyon tasarımlarının klinik uygulamada daha hızlı yapılabileceğini göstermişlerdir (Raith vd., 2017).
3) CAD/CAM sistemlerinin, çeşitli materyallerden elde edilmiş hazır blokların işlenerek estetik kron/köprü restorasyonlarının yapımı içi protetik diş tedavisi alanında kullanılması bir başka yapay zekâ atılımıdır (Susic vd., 2017).
4) 2020 yılında Lernel ve arkadaşları bireye özel tasarlanan hibrid implant dayanak (abutment) üzeri simante edilen implant destekli monolitik zirkonya kronların tamamen dijital akış ile üretilmesinde yapay zekâ kullanımına yönelik protokol uygulamışlar ve başarılı sonuç almışlardır (Lerner vd., 2020). Yapay zekânın ve alt birimlerinin diş hekimliğinin tüm alanlarında kullanım potansiyeli olmakla birlikte protetik diş tedavisinde kullanılan kavramların karmaşıklığı nedeniyle bu alanda kullanımında tereddüt yaşanmaktadır (Bernauer vd., 2021).

Günümüzde panoramik radyografiler diş hekimliği klinik rutininde çürük tespitinde yaygın olarak kullanılsa da bu radyografik yöntemin kısıtlılıkları nedeniyle panoramik radyografiler üzerinde çürük tespiti güç olabilmektedir (Abreu vd., 1999; Shah vd., 2014) Panoramik radyografi üzerinde sabit protetik restorasyonların altındaki dayanaklarda oluşan çürüklerin tespitini zorlaştıran diğer etken ise radyoopak protetik materyallerin çürük üzerine süperpoze olabilmesidir(Attar vd., 2003; Goshima & Goshima, 1991). Radyografik görüntü üzerinde Mach etkisi veya Mach bandı oluşumu, SPR'lerin komşuluğundaki daha radyolüsent görüntü veren çürüklerin tespitini zorlaştırmaktadır (Martínez-Rus vd., 2011). Tüm bu kısıtlamalarına rağmen panoramik radyografi günlük diş hekimliği pratiğinde sıklıkla kullanılmaktadır (Clark & Curzon, 2004). Bununla birlikte sınırlamalar göz önüne alındığında günümüzde kullanılan çürük tespit yöntemlerinin yetersiz kalması yeni tespit metotları arayışına neden olmuştur (Rodrigues vd., 2008). Panoramik radyografi üzerinde yapay zekâ ile çürük tespit etkinliğinin arttırılması hekimlere klinik pratiğinde büyük fayda sağlayacağı düşünülmektedir. Yapay zekâ ile 2 ve 3 boyutlu radyografik görüntü verileri kullanılarak çürük tespiti yapılan çalışmalar mevcuttur (Bayraktar & Ayan, 2022; Ezhov vd., 2021; Lee vd., 2018). SPR altındaki çürüklerin panoramik

radyografik veriler kullanılarak derin öğrenme algoritmaları ile tespit edildiği başka çalışma bulunmamaktadır. Yapay zekânın alt birimi olan derin öğrenme algoritmalarının çürük tespitinde kullanılması ile ilgili yapılan ve olumlu sonuç alınmış çalışmalar doğrultusunda bu tez çalışması derin öğrenme algoritmaları kullanılarak panoramik radyografiler üzerinde gözlenen sabit kron/köprü restorasyonları altındaki çürüklerin tespit etkinliğinin değerlendirilmesi amacıyla yapılmıştır.

1.6. Amaç

Bu çalışmanın amacı derin öğrenme yöntemine dayalı geliştirilen yapay zekâ algoritmalarıyla panoramik radyografiler üzerinde incelenen sabit protetik restorasyonlar altında oluşan çürüklerin tespit etkinliğinin değerlendirilmesidir.

1.7. Hipotez

Bu çalışmanın H_0 hipotezi panoramik radyografiler üzerinde izlenen sabit protetik restorasyonlar altında oluşan çürüklerin derin öğrenme yöntemine dayalı yapay zekâ algoritmaları ile tespit etkinliğinin düşük olacağıdır.

2. GEREÇ VE YÖNTEM

2.1.Panoramik Görüntülerin Toplanması

Bu çalışmada Kırıkkale Üniversitesi Girişimsel Olmayan Araştırmalar Etik Kurulu'nun etik onayı (Tarih: 28/09/2022, Karar No:2022.09.22) alınmış olup, Kırıkkale Üniversitesi Diş Hekimliği Fakültesi Protetik Diş Tedavisi Anabilim Dalındaki radyografilerin depolandığı veri tabanından elde edilen veriler kullanılmıştır. 2016-2023 tarih aralığında muayene ve/veya tedavi olmak amacıyla fakülteye gelen 25-75 yaş aralığında ve ağız içinde diş üzeri sabit protetik restorasyonları olan 1004 adet hastanın panoramik radyografisi JPEG formatında kaydedilerek çalışmaya dâhil edilmiştir. Çalışmamızda diş üzeri SPR içeren panoramik radyografileri kullanılan hastaların üniversite bünyesinde bulunan hasta kayıt sistemine kaydedilmiş işlemlerinde; SPR altında kalan dişlerden en az bir tanesine çürük nedeniyle dolgu, kanal tedavisi veya çekim tedavilerinden en az birinin yapılmış veya yapılacak olması, eski sabit protezlerini değiştirmiş veya değiştirecek olması çalışmaya dâhil edilme kriterlerinden olmuştur. Bu sayede çürük varlığının doğrulanma ihtimali arttırılmaya çalışılmıştır. Çalışmaya dâhil edilmeme kriterleri ise görüntüde SPR bulunmaması, panoramik radyografi üzerinde tespit edilecek olan SPR altındaki çürük, dayanak dişler ve kayıp diş alanlarının optimum değerlendirilmesine engel teşkil edecek miktarda artefakt ve süperpozisyonların bulunmasıdır. Hastaların yaşı ve cinsiyeti tez çalışmasında dikkate alınmamıştır.

Bu çalışmada Gendex GXDP-700 (Gendex, PA, ABD) markalı cihaz ile 66 kVp, 10 mA, 16 s ışınlama; KaVo OP 2D (KaVo Dental, Tuusula, Finlandiya) markalı cihaz ile 73 kVp, 9,6 mA, 10 s ışınlama ve Instrumentarium OP200 (Instrumentarium Dental, Tuusula, Finlandiya) markalı cihaz ile 66 kVp, 10 mA, 14 s ışınlama ile çekilmiş panoramik radyografiler kullanılmıştır.

2.2. Yöntem

Bu tez çalışmasının yöntem bölümü iki aşamadan oluşmaktadır. İlk aşamada panoramik radyografiler üzerinde izlenen diş üzeri SPR'ler etiketlenerek (labelling) işaretlenmiş ve bir derin öğrenme modeli eğitildikten sonra bu model tarafından otomatik olarak tespit edilmiştir. Tespit edilen SPR içeren bölümler radyografik

görüntülerden kırpma (cropping) işlemiyle çıkarılmıştır. İkinci aşamada ise kırpılan görüntüler yeni veri seti olarak kullanılmış, bu görüntüler üzerinde SPR'lerin altındaki çürükler, eğitilen farklı bir derin öğrenme modeli ile tespit edilmiştir.

2.2.1 SPR'lerin YOLOV7 ile Tespiti ve Kırpılması

2.2.1.1 Panoramik Radyografiler Üzerinde SPR'lerin Etiketlenmesi

Belirlenen kriterlere uygun olan 1004 adet farklı piksel boyutlarındaki panoramik radyografiler YOLOV7 mimarilerinin kabul ettiği giriş görüntü boyutu olan 640x640 piksel boyutunda yeniden boyutlandırılmıştır. Daha sonra, dayanağı diş olan SPR'ler, dayanakları ve gövde altlarını da içerecek şekilde görüntüler üzerinde etiketlenmiştir. Bu aşamada etiketleme işlemi Protetik Diş Tedavisi Anabilim Dalı'nda (BA) uzmanlık eğitimine devam eden 3 yıllık deneyime sahip diş hekimi tarafından yapılmıştır. Etiketleme işlemi, Python programlama dili kullanılarak geliştirilmiş bir etiketleme aracı ile gerçekleştirilmiştir.

2.2.1.2 SPR'lerin Panoramik Radyografi Üzerinde YOLOV7 ile Tespit Edilmesi

Panoramik radyografilerden 904 adedi eğitim, 100 adedi test veri seti olarak kullanılmak üzere rastgele ayrılmış ve YOLOV7 modeli SPR'leri tespit etmek üzere ilk aşamada etiketlenen radyografiler ile eğitilmiştir. Aynı görüntülerin eğitim seti ve test seti içerisinde kullanılmamasına dikkat edilmiştir. YOLOV7 modeli 32 alt küme boyutu (batch size) kullanılarak 200 iterasyon (epoch) boyunca eğitilmiştir. SPR tespitinde kullanılan veri setlerinin sınıflandırılması Çizelge 2.1.'de gösterilmiştir.

Çizelge 2.1. SPR tespitinde kullanılan veri setlerinin sınıflandırılması

Sınıf	Görüntü Sayısı	Etiket Sayısı
Eğitim	904	2248
Test	100	243

2.2.1.3 SPR İçeren Alanların Otomatik Olarak Kırpılması

Görüntü kırpma YOLO derin öğrenme ağlarının eğitiminin verimini arttırmak için önerilen işlemlerden bir tanesidir (Jeong vd., 2018). Çalışmamızda SPR, SPR altındaki dayanak ve kayıp dişleri içeren alanların kırpılması yani görüntüden seçilerek çıkarılması ile eğitilen derin öğrenme modelinin çürük tespit etkinliği arttırılmaya çalışılmıştır. SPR içeren görüntü bölümleri YOLOV7 modeli ile otomatik olarak tespit edildikten sonra Şekil 2.1.'de gösterildiği gibi kırpılmıştır. SPR'lerin tespitine yönelik YOLOV7 modelinin gelişim şeması Şekil 2.2.'de gösterilmiştir.

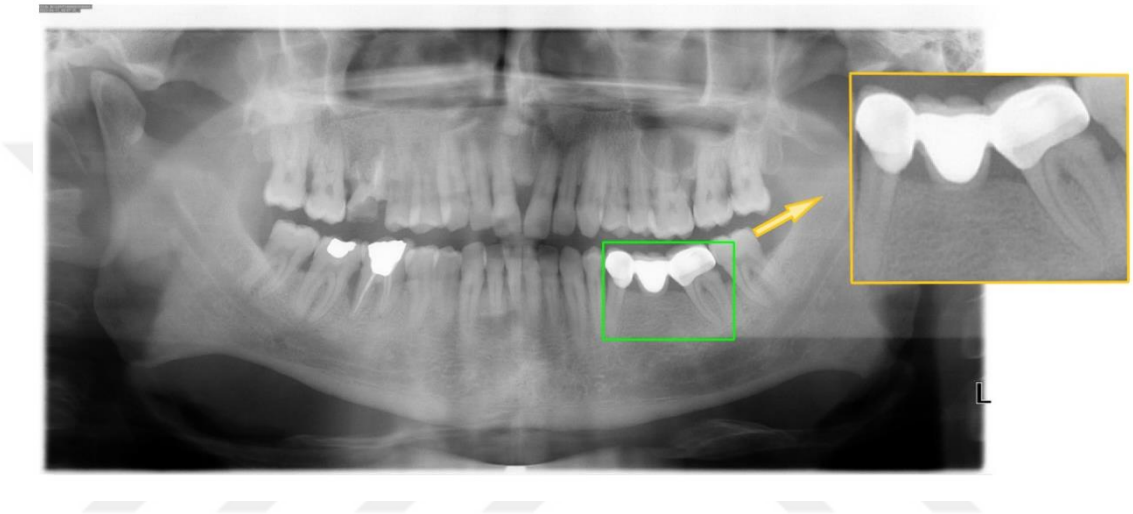

Şekil 2.1. YOLOV7 modeli eğitimi sonrası SPR içeren görüntü bölümlerinin tespiti ve otomatik olarak kırpılması

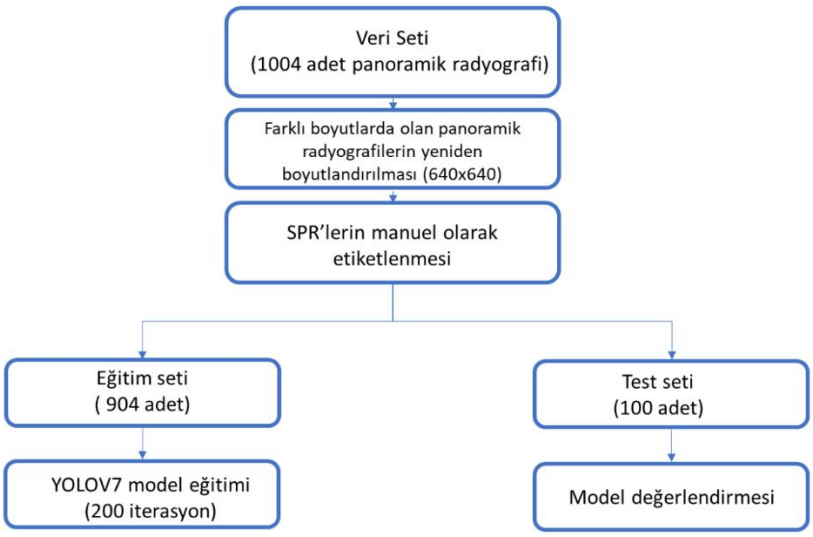

Şekil 2.2. SPR'lerin tespitine yönelik YOLOV7 modelinin gelişim aşamalarının şeması

2.2.2 SPR Altındaki Çürüklerin Derin Öğrenme Modeli ile Tespiti

2.2.2.1 Kırpılan Görüntüler Üzerinde Etiketleme Yapılması

Kırpılan görüntülerin çözünürlükleri kendi içlerinde, SPR'ler altındaki çürüklerin etiketleyiciler tarafından net görülebileceği piksel boyutlarında düzenlenmiştir. İlk aşamada 904 adet eğitim verisi üzerinde 2248 adet, 100 adet test verisi üzerinde 243 adet etiketleme yapılmış, etiketlenen SPR'ler otomatik olarak kırpılmıştır. İlk aşamada kullanılan eğitim ve test veri setlerinden elde edilen kırpılmış görüntüler, ikinci aşamada aynı şekilde eğitim ve test veri seti olarak kullanılmıştır. Çalışmamızda SPR altındaki çürüklerin bir derin öğrenme modeli ile tespiti yapılırken çürük ile karışabilecek kayıp diş alanları (missing) ve çürüksüz dayanak dişler (healthy) de çürükler (decay) ile beraber etiketlenmiştir (Şekil 2.4.). Bu aşamada etiketleme işlemi biri Protetik Diş Tedavisi Anabilim Dalı'nda (BA), diğeri Restoratif Diş Tedavisi Anabilim Dalı'nda (BA) uzmanlık eğitimine devam eden 3 yıllık deneyime sahip iki uzmanlık öğrencisi diş hekimi tarafından yapılmıştır. Veri setinde iki diş hekiminin tespitinin eşleşmediği tüm kırpılmış görüntüler çalışmadan çıkarılmıştır. Bu sayede etiketleme işleminin doğruluğunu arttırmaya yönelik bulanık altın standart (referans standart) (fuzzy gold standart) oluşturulmaya çalışılmıştır (Bayraktar & Ayan, 2022; Walsh, 2018). Test veri setinde kırpma işlemi sonrası 24 adet kırpılmış görüntünün çözünürlükleri bozulmuş, bu nedenle görüntüler üzerinde etiketleme aşamasında fikir birliğine varılamamış ve çalışmanın ikinci aşamasında kullanılmamıştır. Bu görüntü örneklerinden iki tanesi Şekil 2.3.'de gösterilmiştir.

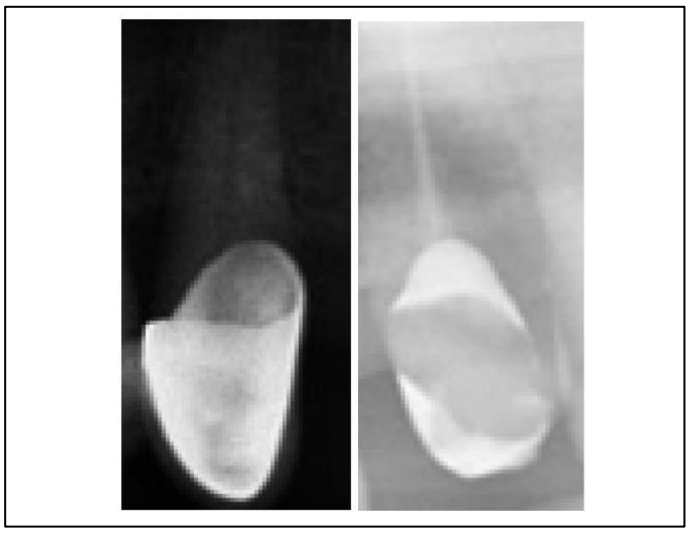

Şekil 2.3. Kırpma işlemi sonrası çözünürlüğü uygun olmayan görüntülere örnek

Etiketleme işlemi, Python programlama dili kullanılarak geliştirilmiş bir etiketleme aracı ile gerçekleştirilmiştir. 2248 adet eğitim veri seti üzerinde çürük için 950, kayıp diş için 1978, çürüksüz dayanak için 4158 adet etiket elde edilmiştir (Çizelge 2.2.). 219 adet test veri seti üzerinde ise çürük için 110, kayıp diş için 258 ve çürüksüz dayanak için 502 adet etiket elde edilmiştir (Çizelge 2.3.).

Çizelge 2.2. Çürük tespitinde kullanılan 2248 adet eğitim veri seti üzerindeki toplam etiket sayıları

Sınıf	Etiket Sayısı
Hepsi	7086
Çürük	950
Kayıp Diş	1978
Çürüksüz Dayanak	4158

Çizelge 2.3. Çürük tespitinde kullanılan 219 adet test veri seti üzerindeki etiket sayıları

Sınıf	Etiket Sayısı
Hepsi	870
Çürük	110
Kayıp Diş	258
Çürüksüz Dayanak	502

2.2.2.2 YOLOV7 Mimarisi Üzerinde Yapılan Geliştirmeler

YOLOV7 mimarisinde SPR altındaki çürüklerin daha iyi tespit edilmesi için literatürde sıkça kullanılan dikkat mekanizmalarından Evrişimli Blok Dikkat Modülü [Convolutional Block Attention Module (CBAM)] kullanılmıştır. CBAM modülleri mimari içerisinde çeşitli bölgelere eklenmiş, en iyi tespit performansını elde eden mimari tez kapsamında sunulmuştur.

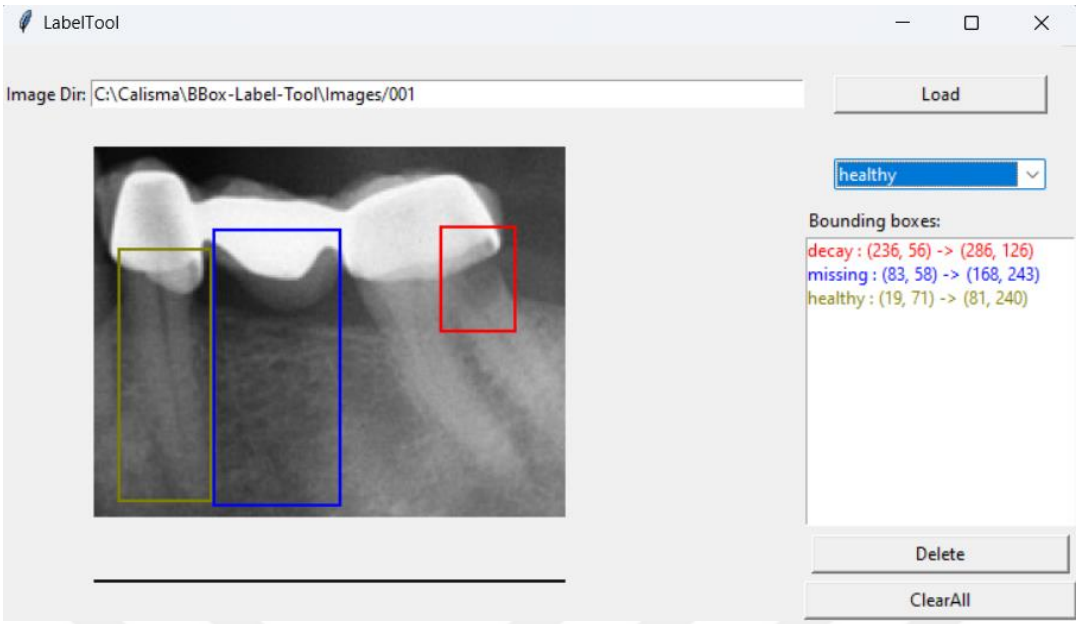

Şekil 2.4. Kırpılan panoramik görüntüler üzerinde Phyton programlama dili kullanılarak geliştirilen etiketleme aracı ile çürük (decay), çürüksüz dayanak (healthy) ve kayıp diş (missing) etiketlemelerinin yapılması

2.2.2.3 CBAM Modülü

CBAM, ESA yapılarında sıkça kullanılan hafif ama etkili dikkat mekanizmaları arasındadır. CBAM modülünün eklenme nedeni modelin girdi verisinden özellik çıkarma yeteneğini geliştirmektir. Bunu modelin kullandığı ağırlıklar üzerinde değişiklikler yaparak gerçekleştirmektedir (Jiang vd., 2022). CBAM, kanal dikkat modülü [Channel Attention Module (CAM)] ve uzamsal dikkat modülünden [Spatial Attention Module (SAM)] oluşmaktadır. CAM, görüntünün ön planına ve anlamlı alana ağın daha fazla dikkat etmesini sağlarken; SAM, tüm resim üzerindeki bağlamsal bilgi açısından en zengin olan konuma ağın daha fazla dikkat ederek odaklanmasını sağlamaktadır. (Cao vd., 2023). CBAM modülüne ait görsel Şekil 2.5. ‘te verilmiştir.

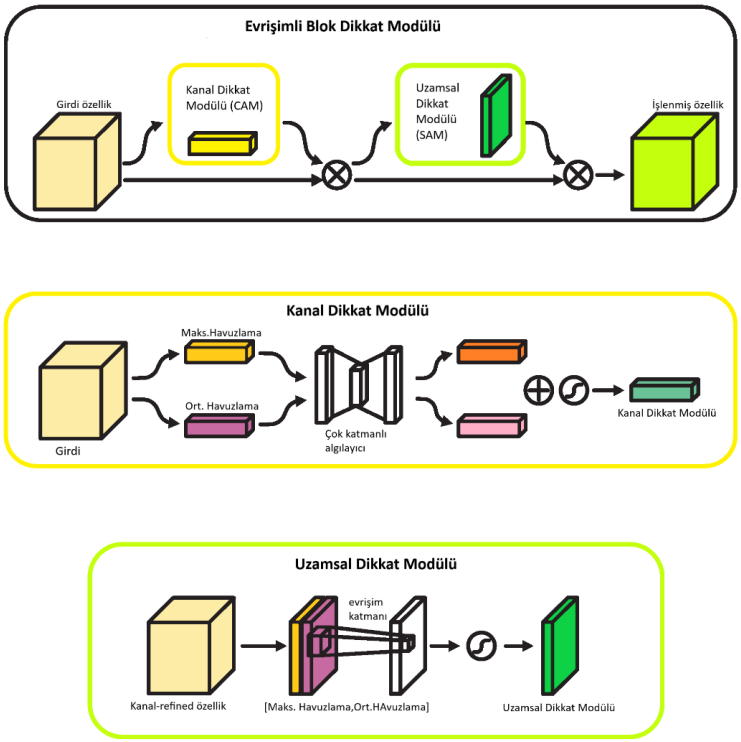

Şekil 2.5. CBAM modülü yapı şeması (Cheng, Liu ve Morimoto 2020)

2.2.2.4 Geliştirme Ortamı

Model geliştirme Python programlama dili kullanılarak gerçekleştirilmiştir. Modellerin kurulması ve test işlemlerinde PyTorch, Opencv kütüphanelerinden yararlanılmıştır. Tüm süreç, Nvidia 1080Ti ekran kartı, iki Xenon işlemci, 32 GB RAM ve Ubuntu 14.04 işletim sistemine sahip bir bilgisayar kullanılarak gerçekleştirilmiştir.

2.2.2.5 SPR Altındaki Çürüklerin YOLOV7 ve YOLOV7+CBAM ile Tespiti

Orijinal YOLOV7 modeli SPR altındaki çürükleri, çürüksüz dişleri ve kayıp dişleri tespit etmesi için eğitilmiştir. Eğitim sonunda geliştirilen modelin performansı test verisi ile değerlendirilmiştir. Orijinal YOLOV7 modeli ile eğitim yapıldıktan sonra, SPR altındaki çürükleri daha iyi tespit edebilmek için bu modelin içine dikkat mekanizmalarından CBAM modülü eklenmiştir (Şekil 2.6.). CBAM modülünün model içerisindeki konumları ve adetleri değiştirilerek model tespit skorları değerlendirilmiş, bunun sonucunda omurga ve boyun kısmının birleştiği bölüme üç adet CBAM modülü eklenmesinin model tespit skorunu olumlu yönde etkilediği

görülmüştür. Bu sayede modelin çürük tespit performansının arttığı gözlemlenmiştir. SPR altındaki çürüklerin YOLOV7 ve YOLOV7+CBAM ile tespit edilme şeması Şekil 2.7.'te gösterilmektedir.

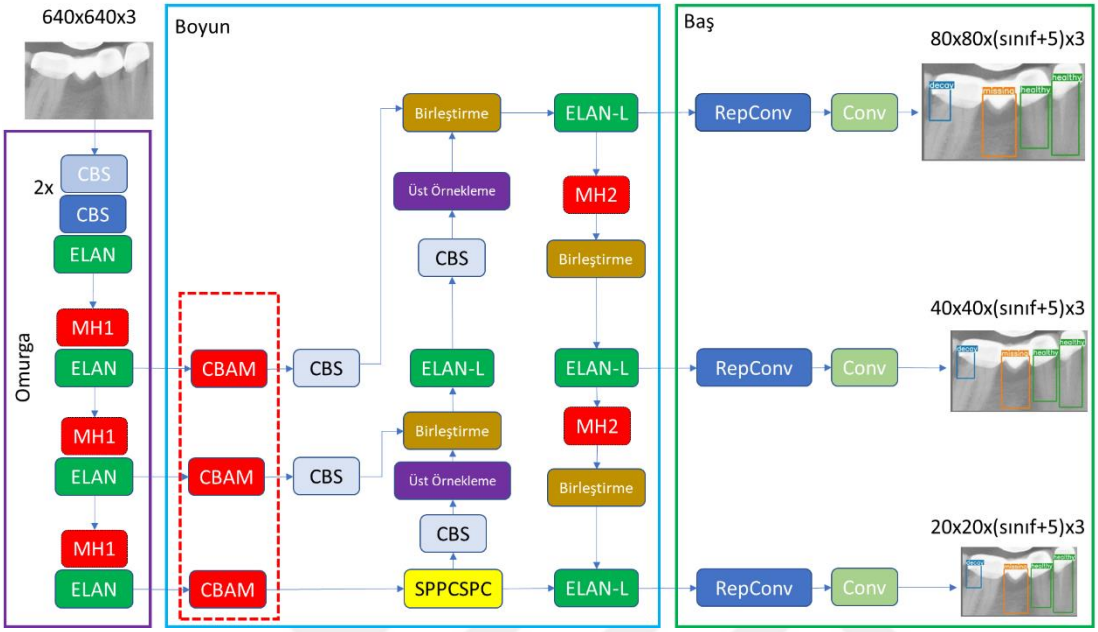

Şekil 2.6. Çalışmamızda geliştirilen YOLOV7 modeli

2.2.3. İstatistiksel Analiz

Karmaşık problemleri çözmek amacıyla geliştirilen yapay zekâ modellerinin veri setleri üzerindeki başarısını eğitilen diğer modellerle karşılaştırmak amacıyla performans metrikleri kullanılmıştır (Lin vd., 2014).

2.2.3.1.Performans Metrikleri

Nesne tespitinde kullanılan performans metrikleri, eğitilen bir modelin nesne algılama görevinde ne kadar iyi performans gösterdiğini değerlendirmek için bir ölçü görevindedir. Nesne tespit eden sistemlerin objektif olarak veya bunların birbirleri ile kıyaslama yoluyla karşılaştırılmasına olanak tanımaktadır. Buna göre, PASCAL VOC ve MSCOCO gibi önde gelen yarışmalar, nesne algılamaya yönelik farklı algoritmaların veri kümelerinde nasıl performans gösterdiğini değerlendirmek için çeşitli ölçümler kullanmışlardır (Everingham vd., 2009; Lin vd., 2014).

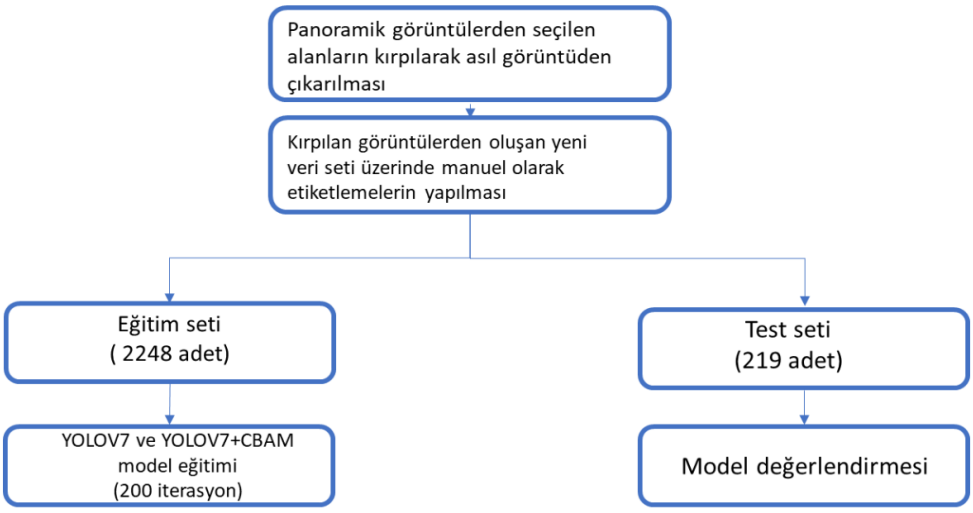

Şekil 2.7. SPR altındaki çürüklerin YOLOV7 ve YOLOV7+CBAM ile tespit edilme şeması

a) **Kesiştirilmiş Bölge (Intersection Over Union) (IoU)**

Makine öğreniminde kullanılan test verileri üzerinde hedeflenen değerler (ground truth) ile modelin tahmini değerleri arasındaki benzerlik, Jaccard indeksi ile ölçülmektedir. Jaccard İndeksi veya IoU, nesnenin kullanıcı tarafından etiketlenen gerçek sınırlayıcı kutu ile modelin tahmin ettiği sınırlayıcı kutunun ne kadar kesiştiği ile ilgili değer olarak tanımlanmaktadır (Şekil 2.8.). IoU değeri ile model eğitimi öncesi belirlenen eşik değeri (threshold) karşılaştırılarak eğitilen modelin nesne tespitinde ne kadar başarılı olduğunun yorumu yapılabilmektedir. IoU değeri ve eşik değeri 0 ile 1 arasında değişmektedir. (Padilla, Netto ve da Silva 2020). Nesne tespiti ve segmentasyon gibi farklı bilgisayarlı görü problemlerinde iyi çalıştığı kanıtlanan eşik değeri 0,5 olarak kabul edilmektedir. Bu nedenle çalışmamızda eşik değeri 0,5 olarak kabul edilmiştir (Everingham vd., 2009). Görüntü verilerinin üzerindeki nesneler için IoU puanı hesaplanmasının önemi, belirlenen eşik değeri üzerindeki IoU değerinin pozitif tahmin; eşik değeri altındaki değerin negatif tahmin olarak değerlendirilmesidir.

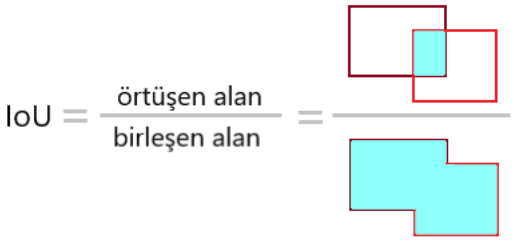

Şekil 2.8. IoU gösterimi. IoU değeri eşik değerinden yüksekse nesne tespiti yapılabilmiş demektir.

b) Karmaşıklık Matrisi (Confusion Matrix)

Pozitif ve negatif tahmin değerleri karmaşıklık matrisi üzerinde yerleştirilerek model performansı değerlendirilmektedir. İkili sınıflandırma veya çoklu sınıflandırma görevlerinde gerçek değerler ile eğitilen modelin tahmin değerleri bu matriste gösterilmektedir. Karmaşıklık matrisi ve bu matriste kullanılan terimler aşağıdaki gibidir (Şekil 2.9.).

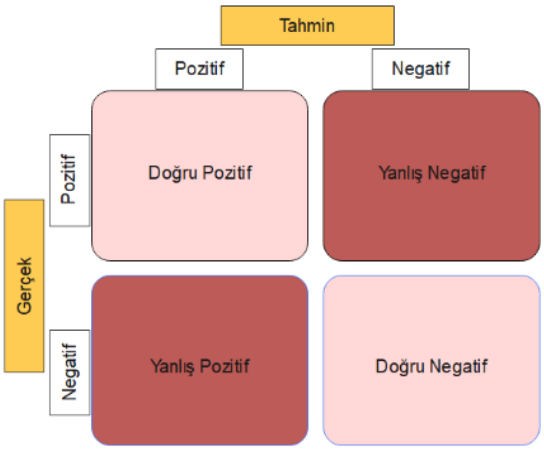

Şekil 2.9. Karmaşıklık Matrisi

Doğru Pozitif (DP): Nesnenin işaretlendiği alanda modelin nesne var dediği durumdur

Yanlış Pozitif (YP): Nesnenin işaretlenmediği alanda modelin nesne var dediği durumdur

Yanlış Negatif (YN): Nesnenin işaretlendiği alanda modelin nesne yok dediği durumdur

Doğru Negatif (DN): Nesnenin işaretlenmediği alanda modelin nesne yok dediği durumdur.

Nesne tespitinde, herhangi bir görüntüde model tarafından algılanmaması gereken sonsuz sayıda sınırlayıcı kutu olabileceği için doğru negatif değeri kullanılmamaktadır (Padilla et al., 2020). Bu tez çalışması da nesne tespiti üzerine yapıldığından dolayı çalışmamızda doğru negatif değeri ve doğru negatifin kullanıldığı ölçütler [Doğruluk, Doğru Negatif Oranı, Özgüllük (Specificity)] kullanılmamıştır.

Nesne tespitinde modellerin başarısının değerlendirilmesinde ikili sınıflandırma ve çoklu sınıflandırma için yaygın olarak kullanılan ölçütlerden kesinlik, duyarlılık, F1 skoru ve mAP değeri çalışmamızda model performanslarını değerlendirmek için kullanılmıştır (Lipton vd., 2014).

c) Kesinlik (Precision): Pozitif tahminlerden ne kadarının doğru tahmin edildiğini gösteren orandır.

$$\text{Kesinlik} = \text{Doğru Pozitif} / (\text{Doğru Pozitif} + \text{Yanlış Pozitif})$$

d) Duyarlılık (Recall, Sensitivity): Gerçekte pozitif olan örneklerin ne kadarının doğru tahmin edildiğinin oranıdır.

$$\text{Duyarlılık} = \text{Doğru Pozitif} / (\text{Doğru Pozitif} + \text{Yanlış Negatif})$$

Duyarlılık değeri yüksek, kesinlik değeri düşük olduğunda, işaretlenen tüm nesnelerin model tarafından tespit edildiğini, ancak çoğu tespitin yanlış olduğunu yani yanlış pozitif sayı değerinin fazla olduğu anlaşılmaktadır. Duyarlılık değeri düşük, kesinlik değerinin yüksek olduğu durumda ise, tahmin edilen nesnelerin gerçekte olanla çoğunlukla eşleşmediği yani yanlış negatif değerinin yüksek olduğu anlamına gelmektedir. Yukarıda bahsedilen matematiksel işlemler üzerinde incelendiğinde de bu yorum teyit edilebilir. Yüksek kesinlik ve yüksek duyarlılık, nesne tespiti yapan modelin çoğunlukla nesneleri doğru şekilde tespit edebildiğini göstermektedir (Metz, 1978).

e) F1 Skoru: Kesinlik (K) ve duyarlılık (D) değerlerini tek bir sayıya indirgeyen, bu değerlerin harmonik ortalamasıdır (Lipton vd., 2014).

$$F1 = 2(K \times D)/(K + D)$$

f) Mean Avarage Precision (mAP): Faster R-CNN, SSD, YOLO vb. gibi nesne dedektörlerinin doğruluğunu değerlendirmek için kullanılan başka bir kriterdir. Kesinlik-Duyarlılık eğrisi 0 ile 1 arasındaki duyarlılık değerlerinin ortalamasını alarak bu değerleri özetleyen tek bir sayı metriğidir. Kesinlik ve duyarlılık değerleri ayrı ayrı değerlendirildiğinde bir modelin performansını analiz etmek için yeterli değildir.

Kesinlik-Duyarlılık eğrisi bu iki skorun farklı noktalarda hangi değerler üzerinde kesiştiğine bağlı olarak ortalama bir değer olan mAP skorunu vermekte, bu sayede modelin ne kadar doğru sonuç verdiği yorumlanabilmektedir (Zhiqiang & Jun, 2017).

$$mAP = \sum S\ j=1\ AP(j)\ S$$

3.BULGULAR

3.1. Panoramik Radyografi Üzerinde SPR Tespit Eden Modelin Değerlendirmesi

İstenilen kriterlere uygun olan 1004 adet panoramik radyografinden 904 adet görüntü eğitim, 100 adet görüntü test verisi olarak belirlenmiştir. Eğitilen YOLOV7 modeli test grubunda 100 görüntüde bulunan 243 adet SPR etiketinden 230'unu doğru pozitif, 8'ini yanlış pozitif ve 13'ünü yanlış negatif olarak değerlendirmiştir. Eğitilen YOLOV7 modelinin SPR tespitinin karmaşıklık matris değerleri Şekil 3.1.'de gösterilmektedir. Bu değerlendirme sonucu 0,947 duyarlılık, 0,966 kesinlik, 0,968 mAP ve 0.956 F1 skorları elde edilmiştir (Çizelge 3.1.).

Çizelge 3.1. Panoramik radyografi üzerinde YOLOV7 modelinin SPR tespit skorları

Test veri seti	Etiket sayısı	Duyarlılık	Kesinlik	mAP	F1
100	**243**	**0.947**	**0.966**	**0.968**	**0.956**

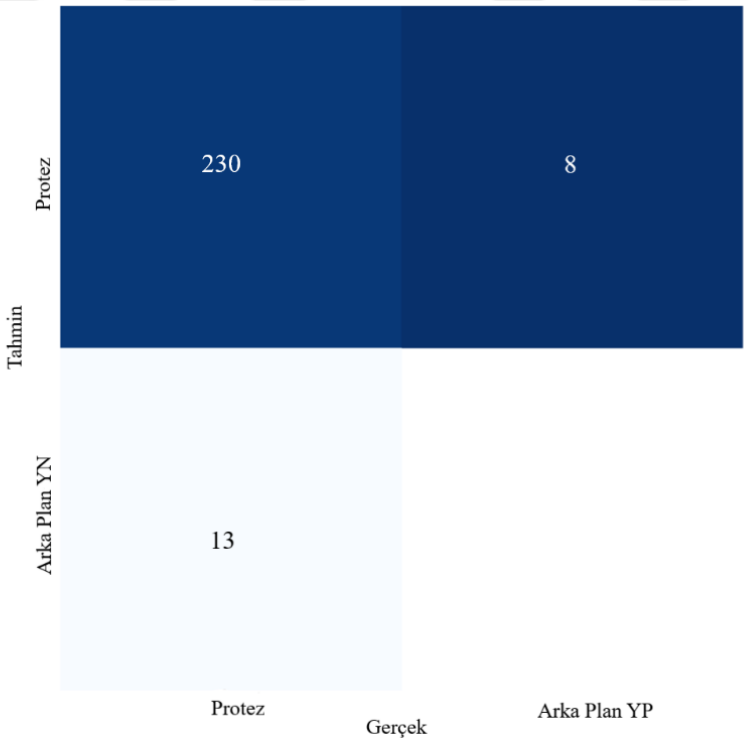

Şekil 3.1. Eğitilen YOLOV7 modelinin SPR tespitinin karmaşıklık matris değerleri

3.2. SPR Altındaki Çürüklerin YOLOV7 ile Tespit Skorları

1004 adet panoramik radyografiden SPR içeren bölümlerin bir derin öğrenme modeli ile otomatik olarak tespiti yapıldıktan sonra kırpılmış ve 2491 adet görüntü elde edilmiştir. Kırpılan görüntülerden 2248 adet görüntü eğitim 219 adet görüntü test veri seti olarak kullanılmıştır. 219 adet test veri seti üzerinde toplam 870 adet etiketleme yapılarak, bu etiketlerden 110 adedi çürük, 258 adedi kayıp diş, 502 adedi çürüksüz dayanak olarak etiketlenmiştir. Eğitilen YOLOV7 modeli test grubunda bulunan 110 adet çürük etiketinden 87'sini doğru pozitif, 17'sini yanlış pozitif ve 23'ünü yanlış negatif olarak; 258 adet kayıp diş etiketinden 242'sini doğru pozitif, 59'unu yanlış pozitif, 16'sını yanlış negatif olarak; 502 adet çürüksüz dayanak etiketinden 490'ını doğru pozitif, 29'unu yanlış pozitif ve 12'sini yanlış negatif olarak tahmin etmiştir. Kırpılan görüntüler üzerinde YOLOV7 modelinin karmaşıklık matris değerleri Şekil 3.2.'de gösterilmektedir. YOLOV7 modelinin kırpılan görüntüler üzerinde çürük etiketi için 0.791 duyarlılık, 0.837 kesinlik, 0.80 mAP, 0.813 F1; kayıp diş için 0.939 duyarlılık, 0.804 kesinlik, 0.931 mAP, 0.866 F1; çürüksüz dayanak diş için 0.976 duyarlılık, 0.945 kesinlik, 0.978 mAP, 0.96 F1 skorları elde edilmiştir (Çizelge 3.2.).

Çizelge 3.2. Kırpılmış görüntüler ile eğitilen YOLOV7 modelinin tahmin skorları

	Hepsi	Çürük	Kayıp Diş	Çürüksüz Dayanak Diş
Duyarlılık	**0.902**	**0.791**	**0.939**	**0.976**
Kesinlik	**0.862**	**0.837**	**0.804**	**0.945**
mAP	**0.903**	**0.80**	**0.931**	**0.978**
F1	**0.881**	**0.813**	**0.866**	**0,96**

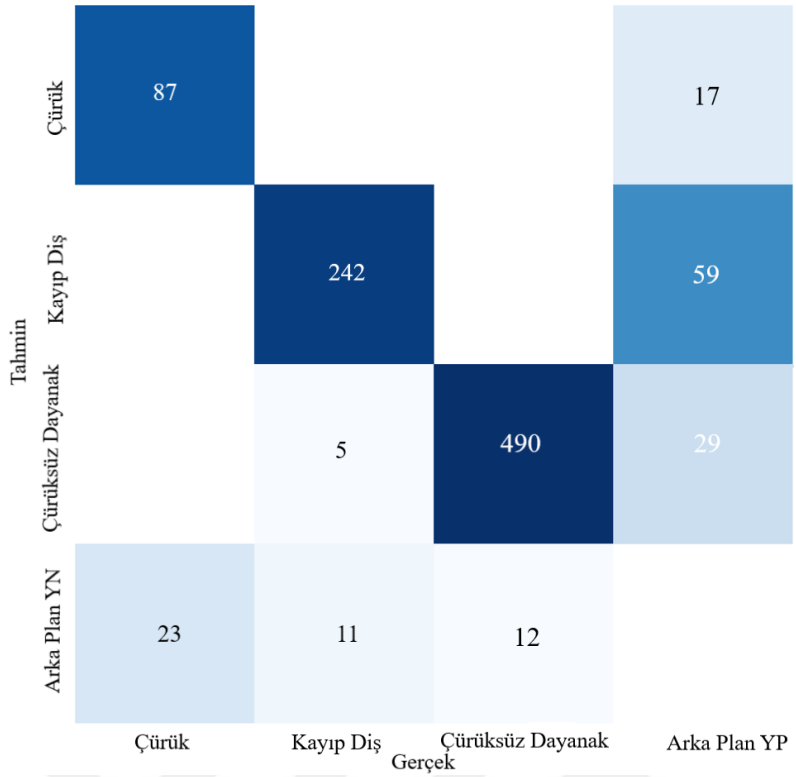

Şekil 3.2. Kırpılan görüntüler üzerindeYOLOV7 modelinin tahmin sonuçlarının karmaşıklık matris üzerinde gösterilmesi

3.3. SPR Altındaki Çürüklerin YOLOV7+CBAM ile Tespit Skorları

Orijinal YOLOV7 modeli ile eğitim yapıldıktan sonra, SPR altındaki çürükleri daha iyi tespit edebilmek için bu modelin içine dikkat mekanizmaları (CBAM) eklenmiş, modelin çürük tespit performansının arttığı gözlemlenmiştir. Eğitilen YOLOV7+CBAM modeli test grubunda bulunan 110 adet çürük etiketinden 91'ini doğru pozitif, 18'ini yanlış pozitif ve 19'unu yanlış negatif olarak; 258 adet kayıp diş etiketinden 238'ini doğru pozitif, 52'sini yanlış pozitif, 20'sini yanlış negatif olarak; 502 adet çürüksüz dayanak etiketinden 484'ünü doğru pozitif, 28'ini yanlış pozitif ve 18'ini yanlış negatif olarak tahmin etmiştir. Kırpılan görüntüler üzerinde YOLOV7+CBAM modelinin karmaşıklık matris değerleri Şekil 3.3.'de gösterilmektedir. YOLOV7+CBAM modeli ile eğitim sonucu çürük etiketi için 0.827 duyarlılık, 0.834 kesinlik, 0.846 mAP, 0.83 F1 skoru; kayıp diş etiketi için 0.922 duyarlılık, 0.821 kesinlik, 0.933 mAP, 0.868 F1 skoru; çürüksüz dayanak diş etiketi için 0.964 duyarlılık, 0.945 kesinlik, 0.973 mAP ve 0.954 F1 skoru elde edilmiştir (Çizelge 3.3.).

Çizelge 3.3. Kırpılmış görüntüler ile eğitilen YOLOV7+CBAM modelinin tahmin sonuçları

	Hepsi	Çürük	Kayıp Diş	Çürüksüz Dayanak Diş
Duyarlılık	**0.905**	**0.827**	**0.922**	**0.964**
Kesinlik	**0.866**	**0.834**	**0.821**	**0.945**
mAP	**0.918**	**0.846**	**0.933**	**0.973**
F1	**0.885**	**0.83**	**0.868**	**0.954**

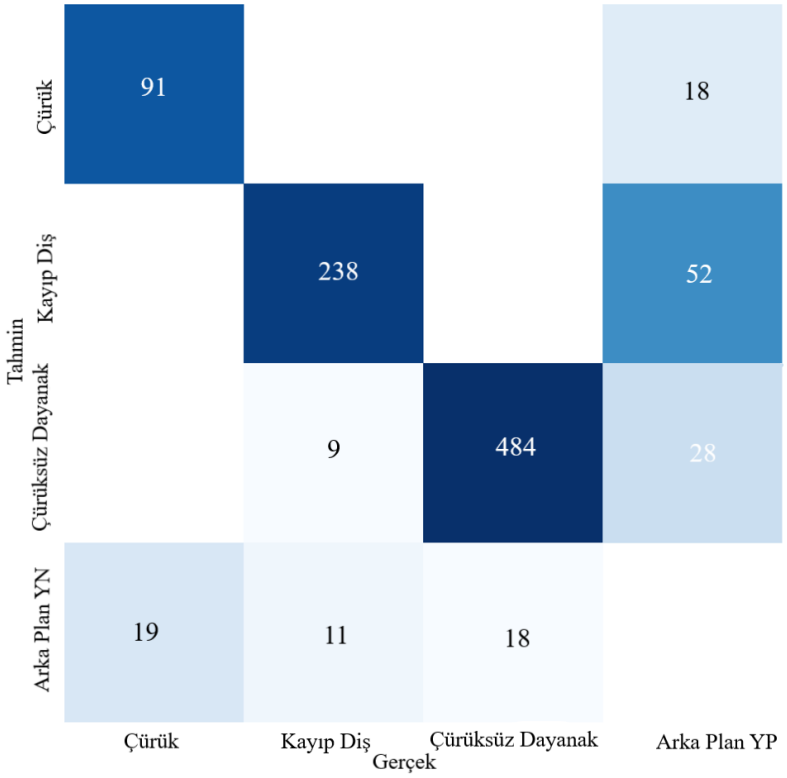

Şekil 3.3. Kırpılan görüntüler üzerinde YOLOV7+CBAM modelinin tahmin sonuçlarının karmaşıklık matris üzerinde gösterilmesi

0.5 eşik değerinde eğitilen YOLOV7 ve YOLOV7+CBAM modellerinin Kesinlik-Duyarlılık eğrileri eğitilen modellerin performansının değerlendirmesini sağlamaktadır. Orijinal YOLOV7 ve YOLOV7+CBAM modellerinin Kesinlik-Duyarlılık eğrileri sırasıyla Şekil 3.4 ve Şekil 3.5'te gösterilmiştir. YOLOV7+CBAM modelinin çürük tespitinde daha yüksek performans gösterdiği bu eğrilere göre oluşturulan mAP skorlarına bakıldığında gözlenebilmektedir.

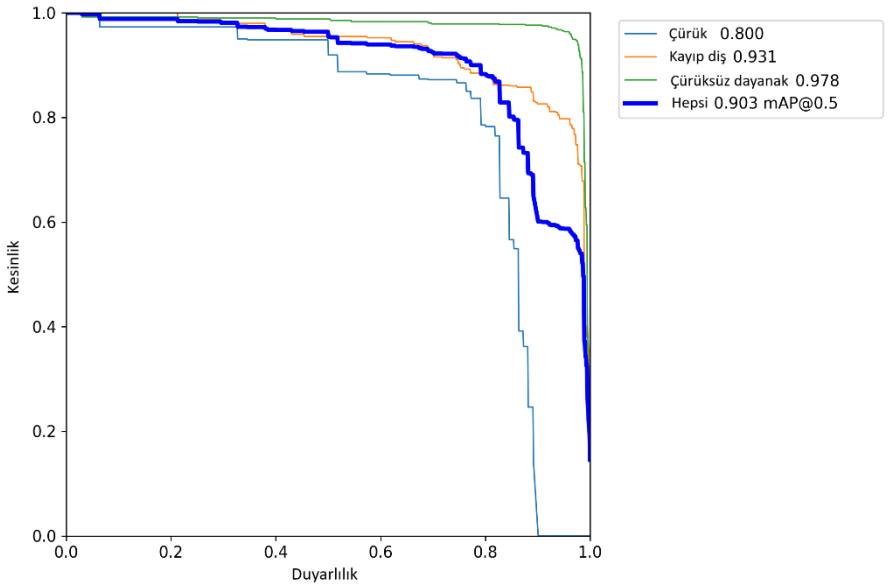

Şekil 3.4. YOLOV7 modeli Kesinlik-Duyarlılık eğrisi

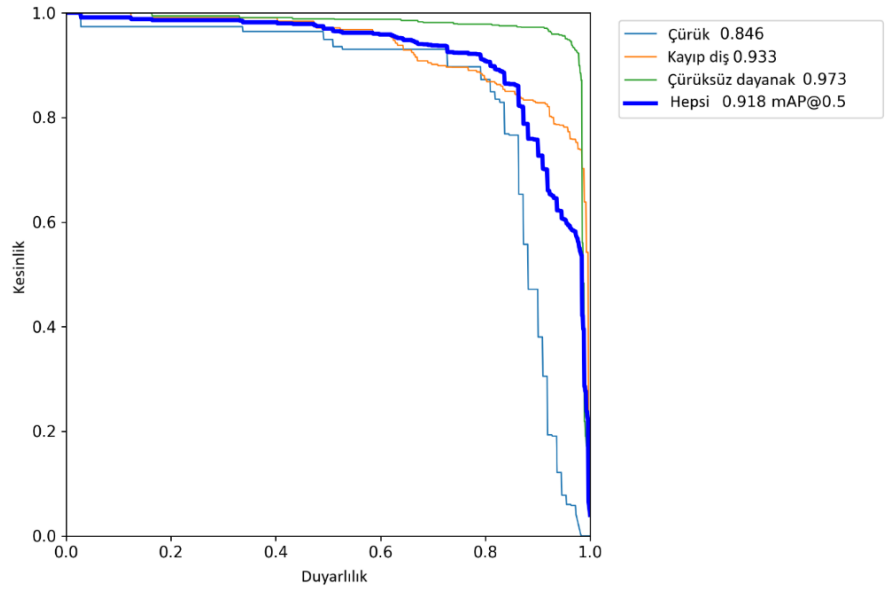

Şekil 3.5. YOLOV7+CBAM modeli Kesinlik-Duyarlılık eğrisi

4. TARTIŞMA ve SONUÇ

Derin öğrenme algoritmaları, insan davranışlarını taklit etmek üzerine geliştirilen, karmaşık görevleri yerine getirmek amacıyla tasarlanmış yapay zekâ tabanlı sistemlerdir (McCarthy, 2004). Derin öğrenme algoritmalarını tıp ve diş hekimliği alanında çeşitli amaçlarla kullanan çalışmalar artmaktadır. Yapay zekâ uygulamalarının diş hekimliği alanında geliştirilmesi, hekimlerin teşhis süresini kısaltarak tedavi aşamasına daha fazla yoğunlaşabilmelerinin önünü açabileceği düşünülmektedir (Pareek & Kaushik, 2022).

Sabit protetik restorasyonlar tek ve/veya çoklu diş eksikliklerinin tedavisinde kullanılmaktadır. Bu restorasyonların ömrü marjinal uyuma, kullanılan materyal çeşidine, materyalin üretim şekline, kullanılan siman çeşidine ve hastanın ağız hijyenini idame ettirebilme becerisine bağlı olarak değişiklik gösterebilmektedir (Rosenstiel vd., 2018). Sabit protetik restorasyonlar altında sekonder çürük oluşumu, bu restorasyonların en yaygın başarısızlık sebebidir. Bu nedenle SPR'ler altındaki çürüklerin tespiti büyük önem taşımaktadır (Della Bona & Kelly, 2008).

Çalışmamız panoramik radyografilerde izlenen SPR altındaki çürüklerin tespitinde derin öğrenme modelleri kullanılarak yeni bir çürük tespit yöntemi geliştirilmesi amacıyla yapılmıştır. Orijinal YOLOV7 modeli çürük etiketi için 0.791 duyarlılık, 0.837 kesinlik, 0.80 mAP, 0.813 F1 skoru elde ederken, YOLOV7+CBAM modeli ile eğitim sonucu çürük etiketi için 0.827 duyarlılık, 0.834 kesinlik, 0.846 mAP, 0.83 F1 skoru elde edilmiştir. Çalışma bulgularımıza göre, panoramik radyografiler üzerinde izlenen sabit protetik restorasyonlar altında oluşan çürüklerin derin öğrenme yöntemine dayalı yapay zekâ algoritmaları ile tespit etkinliğinin düşük olacağını savunan H_0 hipotezi reddedilmiştir.

Çürük tespitinin geleneksel yöntemleri arasında görsel muayene, sond kullanılarak dokunsal muayene ve radyolojik muayene yer almaktadır (Gomez, 2015). Geleneksel yöntemler ile çürük tespitinin kısıtlamaları mevcuttur. Görsel ve dokunsal muayene esnasında erken demineralizasyon, remineralizasyon ve dental restorasyon altı lezyonlar özellikle posterior bölgede gözden kaçabilmektedir. Dokunsal muayenede çürük tespitinde kullanılan sond gibi sivri el aletleri, demineralize olmuş diş dokusuna zarar verebilmektedir (Mansour vd., 2016). Sekonder çürük oluşumu çoğunlukla dental restorasyonların aproksimalinde ve diş eti sınırında gerçekleşmektedir (Mjör,

2005). Çürük, dental restorasyonlar komşuluğunda oluşmuş ise görsel ve dokunsal olarak çürüğün tespiti zorlaşmaktadır (Nummikoski vd., 1992). Marjinal diş etinden daha derinde, restorasyon altında ve dentin-sement üzerinde çürük oluşumunun daha kolay ve görsel olarak görülmesinin zor olması çürük tespitinde diğer bir problemdir (Kuper vd., 2014). SPR materyallerinin radyoopasitesinin yüksek olması ve çürük üzerine süperpoze olabilmeleriyle radyografik görüntüler üzerinde çürük tespitini engelleyebilmektedir (Pekkan, 2016). Özellikle restorasyon altındaki çürüklerin tespitindeki bu zorluklar nedeniyle yeni bir çürük tespit yöntemi geliştirilebilmesi amacıyla çalışmamız gerçekleştirilmiştir.

Çürük tespitinde zorlayıcı bir diğer etken ağız boşluğundaki metal restorasyonların sayısının artmasıyla metal artefaktların ve görüntü bozulmasının (light streak) artmasıdır (Aglarci vd., 2015; Schulze vd., 2014). Görüntü çözünürlüğü bakımından panoramik radyografiler KIBT'ye göre avantaja sahiptir. Vadiati Saberi ve arkadaşlarının yaptıkları çalışmada periapikal, KIBT ve panoramik radyografileri metal nesnelerin varlığında ve yokluğunda trabeküler kemik modelinin fraktal analizlerini karşılaştırmışlardır. Buna göre KIBT'nin görüntü çözünürlüğü daha düşük ve radyasyon dozu panoramik radyografiye göre daha yüksek olduğu için kemiğin trabeküler yapısının değerlendirilmesinde panoramik radyografilerin kullanımının daha uygun olduğu sonucuna varmışlardır (Vadiati Saberi vd., 2021). Gaalaas ve arkadaşlarının yaptıkları çalışmada 2 boyutlu ve 3 boyutlu yeni nesil radyografik görüntü elde eden cihazları çürük tespit etkinliğine göre karşılaştırmışlar ve artefakt azaltma ayarına sahip KIBT'nin çürük tespitinde çok daha başarılı olduğunu bulmuşlardır (Gaalaas vd., 2016). Panoramik radyografi hem en çok kullanılan radyografi tekniği olması hem de KIBT gibi aynı anda tüm ağzın görüntüsünün izlenebildiği bir radyografiye kıyasla metal artefakt miktarının daha az olması nedeniyle çalışmamızda tercih edilmiştir.

Wrzesien ve arkadaşlarının panoramik radyografi, sefalometrik radyografi ve KIBT ile görüntü alımı sırasında hastalarda beyin, omurilik, tiroid ve göz merceğinin absorbe ettiği radyasyon dozlarını belirlemek amacıyla yaptıkları çalışmada KIBT'nin panoramik veya sefalometrik görüntüleme tekniklerine göre hastaları daha yüksek radyasyon dozuna maruz bıraktığı sonucuna varmışlardır (Wrzesień & Olszewski, 2017). KIBT ile görüntü alımı panoramik radyografilere göre maliyet açısından da dezavantajlıdır (Gaalaas vd., 2016). SPR altında oluşan çürüklerin tespiti,

restorasyonun prognozu açısından her anlamda önemli olsa da yüksek radyasyon dozlarının insan sağlığına olan olumsuz etkisi göz önünde bulundurulduğunda, avantajlarına rağmen günümüzde hala KIBT'nin yalnızca çürük tespit etme amacıyla kullanılması doğru görülmemektedir (Silva vd., 2008). Panoramik radyografi düşük dozda radyasyon salma oranı, kolay ve hızlı görüntü vermesi, düşük maliyetli olması nedeniyle çalışmamızda kullanılmıştır.

2 boyutlu bite-wing, periapikal ve panoramik radyografiler diş hekimliği pratiğinde en sık kullanılan görüntüleme yöntemleridir (Rekow, 2020). Periapikal radyografi dişin daha çok apikal çevre dokularının görüntüsünü yansıtan radyografi tekniğidir (Fava & Dummer, 2003). Bite-wing radyografiler çürük tespitinde en yaygın kullanılan radyografidir (Pette vd., 2013). Takahashi ve arkadaşları yaptıkları çalışmada interproksimal çürüğün her aşamasının tespitinde bite-wing radyografinin periapikal radyografiye göre daha üstün olduğunu bulmuşlardır (Takahashi vd., 2019). Kron-köprü restorasyonlarında sekonder çürük oluşumunun değerlendirilmesinde panoramik radyografinin sınırlamaları nedeniyle intraoral radyografiler ile desteklenmesi gerektiği bilinmektedir (White & Pharoah, 2014). Nalçacı ve arkadaşları yaptıkları çalışmada, kron/köprü restorasyonları olan dişlerde sekonder çürüğün değerlendirilmesinde bite-wing ve panoramik radyografinin beraber kullanımının, tek başına panoramik radyografi ile çürük tespitinden daha başarılı sonuç verdiğini göstermişlerdir (Nalçacı, Baran ve Olgun 2006). Çalışmamızın sınırlaması olarak kullandığımız panoramik radyografilerde izlenen çürükler bite-wing veya periapikal radyografi teknikleri ile desteklenmemiştir.

Bite-wing radyografi, yüksek hassasiyet ve özgüllük ile birlikte çürük lezyonlarını saptamak ve derinliklerini değerlendirmek için en yaygın kullanılan yaklaşımdır. Bununla beraber tek seferde tüm ağzın kapsamlı olarak görüntülenmesini sağlayamaması dolayısıyla radyografi üzerinde çürük tespitinin ağzın her kadranında aynı anda yapılamaması dezavantajıdır (Lian vd., 2021). Panoramik radyografi ekstaoral görüntüleme tekniğidir ve intraoral görüntüleme tekniklerine göre daha fazla hasta konforu sağlamakta, tek seferde hastaya ait daha fazla intraoral bilgi edinilmesine imkân verebilmektedir (Gaalaas vd., 2016).

Dişli veya dişsiz çenelerin incelenmesi, dişlerin birbiriyle olan ilişkileri, hastanın TME problemleri, eski restorasyonların varlığı ve bunların idame ettirilebilir olması, hastanın ağız hijyenine büyük oranda bağlı olan kemik kayıpları, çürük, apikal lezyon

gibi dental patolojilerin varlığı, dişlerin kron/kök oranının belirlenmesi gibi tüm tespitlerin aynı anda yapılabildiği panoramik radyografi, protetik diş tedavisi alanında vazgeçilmez bir görüntüleme aracıdır (Al-Sammarraie vd., 2020; White & Pharoah, 2014). Deneyimli dental radyologlar panoramik radyografi üzerinde izlenen anatomik ve patolojik bulguları genel diş hekimlerine göre daha kolay teşhis edebilmektedir (Rushton, Horner ve Worthington 2001). Deneyimli diş hekimleri tarafından radyografi üzerinde izlenen çürük lezyonlarının doğru tespit edilme olasılığının daha az deneyimli diş hekimlerinin bu lezyonları doğru tespit etme olasılığından neredeyse dört kat daha fazla olduğu gösterilmiştir (Geibel vd., 2017). Yapay zekâ teknolojisinin geliştirilmesine yönelik çalışmalarla, deneyimli ve deneyimsiz diş hekimlerinin panoramik radyografi üzerinde dişsel ve dişsel olmayan patolojileri derin öğrenme algoritmaları kullanılarak tespit edebilmesi, doğru endikasyon konulması ve doğru tedavinin gerçekleştirilebilmesine yönelik kolaylaştırıcı bir etken olabileceği düşünülmektedir.

Panoramik radyografi protetik diş tedavisi alanında sıkça kullanılmasına rağmen, yapılan çalışmalara bakıldığında, protetik diş tedavisi, panoramik radyografi ve yapay zekâ sistemlerini beraber konu alan çalışma sayısı sınırlıdır (Abdalla-Aslan vd., 2020; Altan vd., 2022; Başaran vd., 2022; Lee vd., 2021). Protetik diş tedavisi ve yapay zekânın bir arada kullanıldığı çalışmaların az olması, protetik diş tedavisinin teşhis, planlama ve tedavi aşamalarının her birinin karmaşık kararlar ve işlemler barındırması olabilir. Yapay zekâ yöntemlerinin gelişmesinin diş hekimliğinin tüm alanlarında olduğu gibi protetik diş tedavisinin her aşamasında bu yöntemlerin kullanılabilmesine imkân vererek hekimlere yardımcı olabileceği düşünülmektedir (Söderfeldt vd., 1996).

Derin öğrenme modelleri ne kadar çok veri ile eğitilirse o kadar iyi sonuç alınmaktadır (Krizhevsky & Hinton, 2011). Çalışmamızda kullanılacak olan panoramik radyografiler, fakültenin radyolojik veri arşivinden 2016-2023 yılları arasındaki dönemi kapsayacak şekilde toplanmış ve istenilen kriterlere uygun 1004 adet panoramik görüntü seçilmiştir. Bu görüntüler üzerinde diş üzeri SPR, SPR altındaki diş dayanakları ve gövde altlarını içeren bölümlerin asıl görüntü üzerinden kırpılarak çıkarılması sonucu 2491 adet veri elde edilmiştir. Çalışmamızda, kırpılmadan önceki 1004 adet ham veri ile model eğitimi yapılmadığından, kırpılmış görüntülerle eğitilen model ile çürük tespit skorları karşılaştırılamamıştır.

Eğitim ve test veri sayısının belirlenmesinde, panoramik radyografi kullanılarak yapay zekâ ile tespit yapan diğer çalışmalar referans alınmıştır. Lian ve arkadaşları panoramik radyografi üzerinden yapay zekâ uygulamaları ile çürük tespiti ve sınıflandırması yaptıkları çalışmada 1160 adet panoramik radyografiden %7'sini (89 adet) test verisi olarak kullanmışlardır (Lian vd., 2021). Altan ve arkadaşları panoramik radyografi üzerinden derin öğrenme algoritmaları ile protetik restorasyonların tespitini değerlendirdikleri çalışmada 5126 adet panoramik görüntüden %10'unu (521 adet) test verisi olarak kullanmışlardır (Altan vd., 2022). Bahsi geçen çalışmalara benzer olarak çalışmamızın ilk aşamasında toplam görüntü sayısının yaklaşık %10'u (100 adet); ikinci aşamasında yeni veri setindeki toplam görüntü sayısının yaklaşık %9'u (219 adet) test verisi olarak kullanılmıştır.

Çalışmamız panoramik radyografiler üzerinde yalnızca SPR'ler altındaki çürüklerin tespit edilmesi amacıyla yapılmıştır. Bu amaçla eğitilen derin öğrenme modelinin çürük tespit aşamasında SPR altındaki çürükler dışındaki diğer bölgelere odaklanarak yanlış tespit sonuçlarına ulaşma ihtimalinin ekarte edilebilmesi için asıl görüntü üzerinden ilgilenilen alanlar yani diş üstü SPR'ler, dişsiz gövde altları ve dayanak diş kökleri bir bütün olarak etiketlenmiş ve görüntüden kırpılarak çıkarılmıştır. Görüntü kırpma YOLO derin öğrenme ağlarının eğitiminin verimini arttırmak için önerilen işlemlerden bir tanesidir (Jeong vd., 2018). Kırpılacak görüntülerin optimal boyutta olacak şekilde etiketlenmesi çalışmamızda göz önüne alınmıştır. İlgilenilen alan boyutu, istenilen bölgenin çevresindeki yapıların görüntüsünü çok fazla içermemeli, sadece istenilen bölgeye odaklanacak şekilde etiketleme yapılmalıdır. Bu sayede ilgilenilen bölgedeki cisimler ile model eğitimi kolaylaşmaktadır (Trebeschi vd., 2017).

Karmaşıklık matrisi veya hata matrisi, ikili veya çoklu sınıflandırma problemlerinde gerçek ve tahmin edilen değerleri grafik haline getirerek görselleşmesini sağlayan ve bu değerleri elde eden algoritmanın performansının, performans metrikleri kullanılarak istatistiksel olarak değerlendirilmesine imkân veren bir tablo düzenidir. Performans metrikleri, eğitilen bir modelin nesne algılama görevinde ne kadar iyi performans gösterdiğini değerlendirmek için bir ölçü görevindedir. Çeşitli performans metrikleri derin öğrenme modellerinin performans değerlendirilmesinde kullanılmaktadır. İkili ve çoklu sınıflandırma için yaygın olarak kullanılan performans metriklerinden bazıları doğruluk, kesinlik, duyarlılık, F1 puanı ve Jaccard indeksi

diğer adıyla IoU'dur (Lipton vd., 2014). Çalışmamızda duyarlılık, kesinlik, mAP ve F1 skorları ile model değerlendirilmesi yapılmıştır.

F1 skoru kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır. AUC [İşletim Karakteristik Eğrisinin Altında Kalan Alan (Area Under the Receiver Operating Characteristic Curve)], ROC [İşletim Karakteristik Eğrisi (Receiver Operating Characteristic)] adı verilen ve modelin duyarlılık ve kesinlik arasındaki ilişkiyi gösteren grafiğin, altında kalan alanı ifade eden performans metriğidir. F1 ve AUC genellikle benzer bağlamlarda tartışılır ve aynı nihai hedefe sahiptir, ancak aynı değildirler ve model performansını ölçmek için farklı yaklaşımlara sahiptirler. Bu farklılıklardan en önemlisi AUC ve F1 skorlarının dengesiz veri kümelerindeki davranışlarıdır (Bej vd., 2021). AUC, genellikle yanıltıcı sonuçlara yol açan dengesiz veri kümelerinde iyi performans göstermezken, F1 sınıf dengesizliği fazla olan veri setlerinde model performansını objektif olarak ölçmeye devam edebilmektedir (DeVries vd., 2021). Çalışmamızın ikinci aşamasında 219 adet test verisi üzerinde 870 adet etiketten 110 adedi çürük, 258 adedi çürüksüz dayanak ve 502 adedi kayıp diş etiketidir. Etiket sınıflarının homojen dağılım göstermemesi göz önüne alınarak çalışmamızda F1 skorunun performans değerlendirilmesinde kullanımı tercih edilmiştir.

PASCAL VOC, Open Images 2019, Google AI Open Images gibi derin öğrenme modellerinin performanslarının değerlendirildiği çoğu yarışmada, ortalama ortalama kesinlik yani mAP değeri ve türevleri, tespit sonuçlarını değerlendirmek için benimsenen ölçütlerden biri olarak kabul edilmektedir (Padilla vd., 2020). Algoritmanın ilgilenilen nesnelere karşı ne kadar hassas olduğunun ve yanlış tahminleri ne kadar engellediğinin iyi bir birleşik ölçüsü olarak kabul edilen mAP skoru ne kadar yüksek olursa, ağ o kadar kusursuz sayılabilir (Li vd., 2019). Çalışmamızda mAP değeri performans değerlendirmesinde kullanılmıştır.

Kesinlik pozitif tahminlerin ne kadarının doğru tahmin edildiğini gösteren orandır. Duyarlılık gerçekte pozitif olan örneklerin ne kadarının doğru tahmin edildiğinin oranıdır (Cottam vd., 2020). Doğruluk değeri tüm tahminler içinde doğru tahmin edilen örneklerin yüzdesidir. Bir başka değişle DP ve DN değerlerinin toplamının tüm değerlerin toplamına oranı olarak formüle edilebilmektedir (Metz, 1978). Belirli bir görüntüde algılanmaması gereken sonsuz sayıda sınırlayıcı kutu olduğundan, nesne algılama bağlamında DN skorunun geçerli olmadığına dikkat etmek önemlidir.

Doğruluk değeri nesne tespit skorlarından biri olmakla beraber, güvenilirliği kesinlik ve duyarlılığa göre daha düşüktür. Bir sınıfa ait olan örnek sayısı diğer sınıflara ait olan örneklerden sayıca daha fazla olduğunda dengesiz veri seti oluşmaktadır (Padilla vd., 2020). Elimizdeki veri setinde hasta sayısının 90 adet ve hasta olmayanların 10 adet olduğu bir durumda dengesiz bir veri setimiz olmuş olur ve eğer algoritmamız hiçbir şey öğrenmeden her sınıfı hasta kabul ederse bu veri setindeki doğruluk oranı %90 olmaktadır (DP 90, YP 10, YN 0). Bu değer başarılı bir sonuç olmakla beraber elimizdeki algoritma hiçbir şey öğrenmeden her şeye pozitif sonucunu verdiği için, hasta olmayan sınıftaki örnekler üzerinde düşünüldüğünde çok başarısız bir modeldir. Çalışmamızda doğruluk skorunun kullanımı bu durum göz önüne alınarak tercih edilmemiştir.

Duyarlılık ve kesinlik değerlerine bakıldığında bu iki değerin arasında bağlantı bulunduğu görülmektedir (Metz, 1978). Nesne detektörünün tespit sonuçlarında YP düşük ise, kesinlik yüksek olacaktır. Bununla birlikte böyle bir durumda eğitilen model birçok pozitifi atlamış ise yüksek bir YN ve dolayısıyla düşük duyarlılık skoru elde edilmektedir. Bu durumun tersine, eğitilmiş model pozitifleri atlamamış aksine gerçekten daha fazla pozitif bulmuşsa, duyarlılık artacak, ancak YP de artarak kesinliği azaltacaktır. İyi bir nesne detektörü, yalnızca ilgili nesneleri tanımlarken (YP = 0 ≡ yüksek kesinlik) tüm gerçek değerleri (ground truth) (YN = 0 ≡ yüksek duyarlılık) bulmalıdır. Bu nedenle, belirli bir nesne detektörünün duyarlılık skoru arttıkça kesinlik skoru da yüksek kalıyorsa bu dedektörün nesne tespitinde iyi olduğu kabul edilebilmektedir (Padilla vd., 2020). Çalışmamızın iki aşamasında da eğitilen orijinal YOLOV7 modeli ile SPR tespitinde 0.947 duyarlılık, 0.966 kesinlik, çürük tespitinde 0.791 duyarlılık, 0.837 kesinlik, YOLOV7+CBAM modeli ile çürük tespitinde 0.827 duyarlılık, 0.834 kesinlik skoruna ulaşmıştır.

YOLOV7 algoritması, YOLOR, PP-YOLOE, YOLOX, Scaled-YOLOV4 ve YOLOV5 gibi güncel diğer algoritmalarla karşılaştırıldığında daha yüksek bir çıkarım hızına ve doğruluğuna sahiptir (Yung et al., 2022). YOLOV7 yüksek doğruluk elde ederken 30 FPS (frame per second) (saniye başına düşen kare sayısı) hızı geçebilen bir nesne tespit dedektörüdür (Li vd., 2022). CBAM hafif ve genel bir modül olma özelliği ile herhangi bir ESA mimarisine sorunsuz şekilde entegre edilebilen, modelin tespit etmesi istenen nesnelere odaklanmasını, bu sayede model performansının artmasını sağlayabilen bir dikkat modüldür. CBAM modülü, ESA mimarilerinin farklı

bölümlerine eklenebilmektedir (Woo vd., 2018). Jiang ve arkadaşları yaptığı çalışmada, orijinal YOLOV7 algoritmasının önce omurga bölümüne CBAM modülü eklemiş fakat bu durum modelin tespit performansını olumsuz yönde etkilemiştir. Bunun üzerine modülü omurga ve baş bölümünün birleştiği bölüme eklemişler, CBAM-YOLOV7 ismini verdikleri algoritmanın orijinal YOLOV7 algoritmasıyla karşılaştırıldığında tahmin skorlarının kesinlik için 0,0104, duyarlılık için 0,093, mAP için 0,0115 arttığı sonucuna varmışlardır (Jiang vd., 2022). Çalışmamızda YOLOV7 mimarisi üzerinde omurga ve boyun bölümünün birleştiği bölüme üç adet CBAM modülü eklenmiş ve bu konumda diğer bölümlerle karşılaştırıldığında modelin çürük tespit skorunu olumlu yönde etkilediği görülmüştür. Geliştirilen YOLOV7+CBAM modeli ile çürük tespitinde duyarlılık skoru 0.036, mAP skoru 0.046, F1 skoru 0.017 oranında artmış; kesinlik skorunda ise 0.003 azalma olmuştur. Çürük tespit detektörlerinin duyarlılık ve kesinlik skorlarının 1'e ve birbirlerine yakın değerlerde olması, bu detektörün nesne tespitinde başarılı olduğunu göstermektedir (Gomez, 2015). Orijinal YOLOV7 ile yapılan çürük tespitinde duyarlılık ve kesinlik skorları arasındaki farkın (0.46) YOLOV7+CBAM ile yapılan çürük tespitinde duyarlılık ve kesinlik skorları arasındaki farktan (0.07) daha fazla olması; ayrıca duyarlılık skorunun CBAM eklenmeden önceki skora göre daha yüksek olması model performansının arttığını göstermektedir. Bununla beraber çürük tespit skorunu arttırmak amacıyla yapılan diğer etiketlemeler için YOLOV7+CBAM'ın tespit skorları ile orijinal YOLOV7'nin tespit skorları karşılaştırıldığında kayıp diş için duyarlılık 0.017, çürüksüz dayanak diş için duyarlılık ve mAP skorlarında sırasıyla 0.012 ve 0.005 düşüş meydana gelmiştir. Bu düşüş istatistiksel olarak anlamlı olmayıp bu alanda daha fazla çalışmanın yapılması gerektiğini göstermektedir.

Görüntü analizi üzerine geliştirilen, derin öğrenme yöntemlerinden ESA algoritmaları ile 2 ve 3 boyutlu radyografik görüntülerin beraber kullanması, diş hekimliği alanında yapay zekânın kullanım alanının artmasına yol açmıştır (Erickson vd., 2017; Mao vd., 2021; Orhan vd., 2020). Panoramik radyografi ve derin öğrenme algoritmalarını dental diagnoz amacıyla kullanan çalışmalar mevcuttur. Abdalla-Aslan ve arkadaşları panoramik radyografik görüntülerde toplam 738 adet amalgam, kompozit, kök kanal tedavisi, implant, kor ve kron restorasyonları bulunan 83 adet panoramik görüntü üzerinde restorasyon tespitinin ve sınıflandırılmasının değerlendirildiği çalışmalarında, kron etiketi için %100 duyarlılık skoru elde etmişlerdir (Abdalla-Aslan

vd., 2020). Bu çalışmayla karşılaştırıldığında çalışmamızda daha fazla veri kullanıldığından, daha gerçekçi sonuçlar elde edilmiştir. Başaran ve arkadaşları panoramik görüntüler üzerinde bir derin öğrenme modeli kullanarak kron, gövde, kök kanal tedavisi, implant, implant destekli kron, çürükten etkilenmiş diş, rezidüel kök, çürük ve diş taşı tespiti yaptıkları çalışma sonucu; kron tespitinde 0.9674 duyarlılık, 0.86 kesinlik, 0.91 F1; gövde (pontik) tespitinde 0.7738 duyarlılık, 0.87 kesinlik, 0.82 F1 skoru elde etmiştir. Aynı çalışmada çürük tespiti için 0.3026 duyarlılık ve 0,5096 kesinlik skorları ile diğer bakılan parametrelere göre en kötü sonuçları elde etmiştir (Başaran vd., 2022). Çalışmamızın ilk aşamasında diş üzeri SPR'ler tespit edilmiş, eğitilen YOLOV7 modeli SPR'leri test verisinde 243 adet SPR etiketi üzerinde,0.947 duyarlılık, 0.966 kesinlik ve 0.956 F1 skoru elde ederek tespit etmiştir. Çalışmamızın skorlarının genel anlamda daha yüksek olmasının nedeni, veri seti sayımız yakın olsa da Başaran ve ark. (2022) kron ve gövde etiketi sayısının çalışmamızdaki sabit protetik restorasyon etiketi sayısından düşük olmasıyla açıklanabilir. Ayrıca çalışmamızda çürük tespit performansının artmasına yönelik yapılan işlemlerin daha yüksek çürük tespit skorları elde etmemize neden olduğu düşünülmektedir. Altan ve arkadaşları yaptıkları, panoramik radyografi üzerinden diş ve implant üstü SPR'leri YOLOV4 modeli ile tespit ettikleri çalışmada 5126 panoramik radyografiden 521 adet panoramik radyografiyi test verisi olarak kullanmışlar; kron etiketi için 0.79 duyarlılık, 0.74 kesinlik, 0.76 F1; köprü etiketi için 0.95 duyarlılık, 0.84 kesinlik ve 0.89 F1 skoru elde etmişlerdir (Altan vd., 2022). Altan ve arkadaşlarının çalışmasıyla karşılaştırıldığında çalışmamız hem test hem eğitim veri seti sayısı bakımından dezavantaja sahip olmasına rağmen çalışmamızda daha yüksek skorlar elde edilmiştir. Bu durum çalışmamıza dâhil edilme kriterleri arasında panoramik radyografi üzerinde tespit edilecek SPR, SPR altındaki çürük, dayanak dişler ve kayıp diş alanlarının optimum değerlendirilmesine engel teşkil edecek miktarda artefakt ve süperpozisyonların bulunmaması olarak açıklanabilir.

Çalışmamızın ikinci aşamasında 2491 adet kırpılmış görüntüden 219 adet görüntü rastgele seçilerek test verisi olarak kullanılmıştır. 219 adet görüntü üzerinde totalde 870 adet etiketten 110 adedi çürük, 258 adedi kayıp diş, 502 adedi ise çürüksüz dayanak etiketleridir. YOLOV7 modeli eğitim sonrası çürük etiketi için 0.791 duyarlılık, 0.837 kesinlik, 0.80 mAP ve 0.813 F1 skoru; kayıp diş için 0.939 duyarlılık, 0.804 kesinlik, 0.931 mAP, 0,866 F1 skoru; çürüksüz dayanak diş için 0.976

duyarlılık, 0.945 kesinlik, 0.978 mAP, 0.96 F1 skoru elde etmiştir. Orijinal YOLOV7 modeli ile eğitim yapıldıktan sonra, SPR altındaki çürükleri daha iyi tespit edebilmek için bu modelin içine dikkat mekanizmaları (CBAM) eklenmiş, modelin çürük tespit performansının arttığı gözlemlenmiştir. YOLOV7+CBAM modeli ile eğitim sonucu çürük etiketi için 0.827 duyarlılık, 0.834 kesinlik, 0.846 mAP, 0.83 F1 skoru; kayıp diş etiketi için 0.922 duyarlılık, 0.821 kesinlik, 0.933 mAP, 0.868 F1; çürüksüz dayanak diş etiketi için 0.964 duyarlılık, 0.945 kesinlik, 0.973 mAP ve 0.954 F1 skoru elde edilmiştir. Bu skorlara bakıldığında çürük etiket sayısının, çürüksüz dayanak ve kayıp diş etiket sayılarına kıyasla daha düşük olması, modelin çürük tespitinde diğer etiket sınıflarına göre daha düşük duyarlılık, kesinlik, mAP ve F1 skoru elde etmesine neden olduğu düşünülmüştür. Öte yandan en yüksek etiket sayısına sahip çürüksüz dayanak en yüksek tespit skorlarını almıştır. Bu sonuçlara bakıldığında veri fazlalığı ile modelin tespit başarısının doğru orantılı olduğu bu çalışmayla da teyit edilmiştir.

Yapay sinir ağlarından ESA'ların tıbbi radyolojik görüntüler üzerinde sınıflandırma (classification), tespit (detection) ve segmentasyon (segmentation) amaçlarıyla kullanıldığı bilinmektedir. Yaptığımız literatür taramasında, dental radyoloji ve derin öğrenme algoritmalarının beraber kullanıldığı çalışma sayısının son yıllarda arttığı, özellikle dental radyolojik görüntüler ile diş çürüğü tespiti yapılan çalışmaların başarılı sonuçlar verdiği gözlemlenmiştir. Lian ve arkadaşları derin öğrenme algoritmalarıyla yaptıkları çalışmalarında panoramik radyografik görüntüler üzerinde çürük tespitinde ESA tabanlı nnU-Net ile 0,821 duyarlılık skoru elde etmişlerdir (Lian vd., 2021). Haghanifar ve arkadaşları yaptığı çalışmada, akciğer radyografileri üzerinden pnömoni tespiti için geliştirilen CheXNET adlı derin öğrenme algoritmalarına dayalı sistemi, DenseNet algoritması ile 470 adet panoramik radyografi üzerinden çürük tespit etmek amacıyla uyarlayarak yeni bir otomatik çürük tespit sistemi olarak geliştirdikleri PaXNET sistemi ile 0.694 duyarlılık skoru elde etmiştir (Haghanifar vd., 2023). 1004 adet panoramik radyografi üzerinde SPR altındaki çürüklerin derin öğrenme modelleri ile tespit edildiği çalışmamız sonucunda orijinal YOLOV7 modeli 0.791 duyarlılık, 0.837 kesinlik, 0.80 mAP ve 0.813 F1 skoru; YOLOV7+CBAM modeli ile 0.827 duyarlılık, 0.834 kesinlik, 0.846 mAP, 0.830 F1 skoru elde edilmiştir. Diğer çalışmalarla karşılaştırıldığında çalışmamızın sonuçları umut vericidir. Bununla beraber veri seti arttırılarak bu alanda yeni çalışmaların yapılmasının faydalı olacağı düşünülmektedir.

Duyarlılık bir testin tanısal yeteneğini tanımlamak ve ölçmek için yaygın olarak kullanılan ölçütlerden biridir ve 0 ile 1 (%100) arasındaki değerler olarak ifade edilir, 1'e yakın değerler yüksek kaliteli bir sonucu göstermektedir (Gomez, 2015). Çalışmamızda SPR altındaki çürüklerin tespitinde duyarlılık değeri orijinal YOLOV7 ile 0,791; YOLOV7+CBAM ile 0.827 bulunmuştur, yani klinik pratiğinde kullanılması için geliştirilme ihtiyacı vardır. Panoramik radyografi protetik diş tedavisi alanında teşhis ve tedavi aşamasında çok kullanılan dental radyografi tekniği olduğu için çalışmamızda kullanılmıştır. Diğer iki boyutlu dental radyografi teknikleri ve derin öğrenme yöntemleri kullanılarak SPR altındaki çürük tespiti ile ilgili çalışma literatür taramamızda bulunamamış bu nedenle kendi çalışmamızla karşılaştırma yapılamamıştır.

Panoramik görüntünün kalitesi birden fazla faktöre bağlıdır. Görüntü kontrastı bunlardan biridir ve doğru peek kilovoltajın (kVp) seçilmesine bağlıdır. Panoramik radyografilerde bazen baş pozisyonlandırma hatalarına bağlı olarak da görüntüde bozulmalar olabilmektedir. Panoramik radyografilerde uzaysal çözünürlük ve kontrast çözünürlüğü de görüntü üzerinde nesnelerin tespit olasılığını değiştirebilmektedir (Angelopoulos vd., 2004). Çalışmamızda kullanılan panoramik radyografilerin dahil edilme kriterleri arasında, radyografi üzerinde tespit edilecek SPR, SPR altındaki çürük, dayanak dişler ve kayıp diş alanlarının optimum değerlendirilmesine engel teşkil edecek miktarda artefakt ve süperpozisyonların bulunmaması yer almaktadır. Bu çalışmada kullanılan panoramik görüntüler farklı zaman aralıklarında ve üç farklı cihaz ile elde edilmiştir. Bu cihazlarla alınan panoramik radyografilerin görüntü çözünürlükleri farklılık gösterse de geliştirdiğimiz nesne tespit detektörünün bu görüntüler üzerindeki tespit etkinliği ayrı ayrı değerlendirilmemiştir. Ayrıca geliştirdiğimiz algoritmanın farklı görüntüleme merkezlerinde ve diş muayenehanelerinde daha farklı görüntü kalitesindeki radyografiler kullanılarak SPR altındaki çürükleri tespit etkinliğinin değerlendirilmesinin yararlı olacağı düşünülmektedir.

Çalışmamızın ilk aşamasında kırpılan görüntüler çalışmanın ikinci aşamasında yeni veri seti olarak kullanılmış, bu nedenle kırpılan görüntülerin çözünürlükleri, SPR'ler altındaki çürüklerin etiketleyici tarafından net görülebileceği piksel boyutlarında düzenlenmiştir. Bu düzenleme esnasında bazı görüntülerin çözünürlükleri ve boyutları istenilen düzeyde olmadığı için test verisinden çıkarılmıştır. Bu sebeple ilk aşamada

243 adet etiket içeren test verisi ikinci aşamada 219 adete düşmüştür. İleriye yönelik çalışmalarda panoramik radyografilerin çözünürlük kalitesinin yükselmesine yönelik teknolojinin gelişmesiyle, çalışmamızda geliştirilen modelin pratik kullanımının arttırılacağı düşünülmektedir.

Çalışmamızın en büyük sınırlaması panoramik radyografi üzerinde izlenen çürüklerin mikro-BT ile varlığının doğrulanması veya çekilmiş dişlerdeki çürüğün histolojik incelenmesinin yapılması gibi altın standart yöntemlerinden herhangi birinin uygulanmamasıdır. Çalışmamızın çürük etiketleme aşamasında, iki hekimin deneyimlerine bağlı olarak ve çalışmanın yapıldığı üniversitenin hasta kayıt sisteminde etiketlenecek dişlerde çürük olmasına yönelik işlemlerin yapılmış olmasına dikkat edilmiştir. Kesin bir altın standart yönteminin uygulanmaması, "bulanık" etiketlemenin görsel ve dokunsal incelemesi sonucu elde edilen verilerle doğrulanmaması çalışmamızın bir diğer sınırlamasıdır.

Bu çalışmada, tüm panoramik radyografi görüntüleri manuel olarak toplandığından dolayı veri toplama işlemi uzun bir zaman gerektirmiş, bu durum veri sayısını etkilemiştir. Çalışmamızda kullanılan veri sayısı arttırılarak, farklı radyografi teknikleri ve farklı derin öğrenme algoritmaları kullanılarak çürük tespiti yapılması ve bu sonuçların karşılaştırılması yapılabilir.

Çalışmamızda çürük tespit skorlarının arttırılmasına yönelik olarak görüntü kırpma (cropping), çürük tahmini ile karışabilecek kayıp diş ve çürüksüz dayanak diş etiketlemesi, orijinal YOLOV7 mimarisi üzerine CBAM modülü eklenmesi yöntemleri bu çalışmada uygulanmıştır. Bu yöntemlerin bu konu üzerinde bir arada kullanıldığı literatür taramamızda başka bir çalışma bulunmamakta, bu alanda daha fazla çalışma ihtiyacı olduğu görülmektedir.

Bu tez çalışmasının sınırları dahilinde elde edilen sonuçlar şunlardır:

1) Orijinal YOLOV7 modeli çürük tespitinde 0.791 duyarlılık, 0.837 kesinlik, 0.80 mAP, 0.813 F1 skoru elde ederken, YOLOV7+CBAM modeli 0.827 duyarlılık, 0.834 kesinlik, 0.846 mAP, 0.83 F1 skoru elde etmiştir.
2) Çalışmamızda panoramik radyografilerde izlenen SPR altındaki çürüklerin tespit edilmesi amacıyla derin öğrenme modellerinin kullanımının umut vadeden sonuçlar verdiği gözlenmiştir.

SPR altındaki çürüklerin doğru ve erken dönem tespiti, dayanak dişlerin ömrünü ve sonraki yapılacak tedavilerin prognozunu önemli ölçüde etkilemektedir. Derin öğrenme algoritmalarının SPR'lerin altındaki çürüklerin SPR'ler sökülmeden doğru ve erken tespiti için geliştirilmesi hem hekimlerin teşhis aşamasında daha az zaman harcaması ve tedaviye odaklanmasını kolaylaştırmak, hem restorasyonların prognozunu olumlu yönde etkilemesi açısından önemlidir. Yaptığımız çalışma, derin öğrenmeye dayalı yapay zekâ algoritmalarının, diş hekimlerinin en sık kullandığı panoramik radyografi üzerinde SPR altındaki diş çürüklerini tespit etmede başarılı sonuçlar elde edebileceğini göstermiştir. Bununla beraber hem veri sayısı arttırılarak hem de farklı görüntüleme cihazlarında ve farklı derin öğrenme modelleri kullanılarak daha fazla çalışma yapılması gerekmektedir.

5. KAYNAKLAR

Abdalla-Aslan, R., Yeshua, T., Kabla, D., Leichter, I., & Nadler, C. (2020). An artificial intelligence system using machine-learning for automatic detection and classification of dental restorations in panoramic radiography. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, *130*(5), 593-602. https://doi.org/10.1016/j.oooo.2020.05.012

Abreu, M., Tyndall, D. A., Platin, E., Ludlow, J. B., & Phillips, C. (1999). Two-and three-dimensional imaging modalities for the detection of caries. A comparison between ®lm, digital radiography and tuned aperture computed tomography (TACT TM). *Dentomaxillofacial Radiology*, *28*, 152-157. http://www.stockton-press.co.uk/dmfr

Aglarci, O. S., Bilgin, M. S., Erdem, A., & Ertas, E. T. (2015). Is it possible to diagnose caries under fixed partial dentures with cone beam computed tomography? *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, *119*(5), 579-583. https://doi.org/10.1016/j.oooo.2015.02.004

Ahrari, F., Akbari, M., Mohammadi, M., Fallahrastegar, A., & Najafi, M. N. (2021). The validity of laser fluorescence (LF) and near-infrared reflection (NIRR) in detecting early proximal cavities. *Clinical Oral Investigations*, *25*(8), 4817-4824. https://doi.org/10.1007/S00784-021-03786-Y/TABLES/2

Aizenberg, I. N., Aizenberg, N. N., & Vandewalle, J. (2000). Multiple-Valued Threshold Logic and Multi-Valued Neurons. *Multi-Valued and Universal Binary Neurons*, 25-80. https://doi.org/10.1007/978-1-4757-3115-6_2

Ajit, A., Acharya, K., & Samanta, A. (2020). A Review of Convolutional Neural Networks. *International Conference on Emerging Trends in Information Technology and Engineering, ic-ETITE 2020*, 1-5. https://doi.org/10.1109/IC-ETITE47903.2020.049

Al Hamad, K. Q., Al Quran, F. A., AlJalam, S. A., & Baba, N. Z. (2019). Comparison of the Accuracy of Fit of Metal, Zirconia, and Lithium Disilicate Crowns Made from Different Manufacturing Techniques. *Journal of Prosthodontics*, *28*(5), 497-503. https://doi.org/10.1111/JOPR.13029

Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2018). Understanding of a convolutional neural network. *Proceedings of 2017 International Conference on Engineering and Technology, ICET 2017*, *2018-Janua*, 1-6. https://doi.org/10.1109/ICENGTECHNOL.2017.8308186

Alenezi, A., Alkhudhayri, O., Altowaijri, F., Aloufi, L., Alharbi, F., Alrasheed, M., Almutairi, H., Alanazi, A., Yehya, M., & Al Asmari, D. (2022). Secondary caries in fixed dental prostheses: Long-term clinical evaluation. *Clinical and Experimental Dental Research*. https://doi.org/10.1002/CRE2.696

Al-Haj Husain, A., Stadlinger, B., Özcan, M., Schönegg, D., Winklhofer, S., Al-Haj Husain, N., Piccirelli, M., & Valdec, S. (2023). Buccal bone thickness assessment for immediate anterior dental implant planning: A pilot study comparing cone-beam computed tomography and 3D double-echo steady-state MRI. *Clinical Implant Dentistry and Related Research, 25*(1), 35-45. https://doi.org/10.1111/CID.13160

Al-Rfou, R., Alain, G., Almahairi, A., Angermueller, C., Bahdanau, D., Ballas, N., Bastien, F., Bayer, J., Belikov, A., Belopolsky, A., Bengio, Y., Bergeron, A., Bergstra, J., Bisson, V., Snyder, J. B., Bouchard, N., Boulanger-Lewandowski, N., Bouthillier, X., de Brébisson, A., … Zhang, Y. (2016). *Theano: A Python framework for fast computation of mathematical expressions*. https://doi.org/10.48550/arxiv.1605.02688

AlSahafi, R., Mitwalli, H., Alhussein, A., Melo, M. A. S., Martinho, F., Lynch, C. D., Oates, T. W., Xu, H. H. K., & Weir, M. D. (2022). Novel rechargeable nanostructured calcium phosphate crown cement with long-term ion release and antibacterial activity to suppress saliva microcosm biofilms. *Journal of Dentistry, 122*, 104140. https://doi.org/10.1016/J.JDENT.2022.104140

Al-Sammarraie, A. A., Khalid Abdulkareem, A., & Abdulrahman Al-Sammarraie, A. (2020). Diagnostic Value of Panoramic Radiography Diagnostic Value of Panoramic Radiography in Completely Edentulous Patients. *Journal of International Dental and Medical Research, 13*(2), 646-650.

Alsterstål-Englund, H., Moberg, L.-E., Petersson, J., & Smedberg, J.-I. (2021). A retrospective clinical evaluation of extensive tooth-supported fixed dental prostheses after 10 years. *The Journal of Prosthetic Dentistry, 125*(1), 65-72. https://doi.org/10.1016/j.prosdent.2019.10.009

Altan, B., Çınar, Ş., Uz, B. B., & Özkan, D. (2023). Evaluation of the marginal fit of finish line designs of novel CAD/CAM restoration materials. *Journal of Health Sciences and Medicine, 6*(1), 116-121. https://doi.org/10.32322/jhsm.1216516

Altan, B., Gunec, H. G., Cinar, S., Kutal, S., Gulum, S., & Aydin, K. C. (2022). Detecting Prosthetic Restorations Using Artificial Intelligence on Panoramic Radiographs. *Scientific Programming, 2022*, 1-6. https://doi.org/10.1155/2022/6384905

Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data, 8*(1), 53. https://doi.org/10.1186/s40537-021-00444-8

Amaechi, B. T., Owosho, A. A., & Fried, D. (2018). Fluorescence and Near-Infrared Light Transillumination. *Dental Clinics of North America, 62*(3), 435-452. https://doi.org/10.1016/j.cden.2018.03.010

Angelopoulos, C., Bedard, A., Katz, J. O., Karamanis, S., & Parissis, N. (2004). *Digital Panoramic Radiography: An Overview*. https://doi.org/10.1053/j.sodo.2004.05.003

Ardekani, K. T., Ahmad, •, Ahangari, H., & Farahi, • Leila. (2012). Marginal and Internal Fit of CAD/CAM and Slip-Cast Made Zirconia Copings. *J Dent Res Dent Clin Dent Prospect*, *6*(2), 42-48. https://doi.org/10.5681/joddd.2012.010

Ariji, Y., Yanashita, Y., Kutsuna, S., Muramatsu, C., Fukuda, M., Kise, Y., Nozawa, M., Kuwada, C., Fujita, H., Katsumata, A., & Ariji, E. (2019). Automatic detection and classification of radiolucent lesions in the mandible on panoramic radiographs using a deep learning object detection technique. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, *128*(4), 424-430. https://doi.org/10.1016/j.oooo.2019.05.014

Asilkan, Ö., & Irmak, S. (2009). İkinci el otomobillerin gelecekteki fiyatlarının yapay sinir ağları ile tahmin edilmesi. *Suleyman Demirel University The Journal of Faculty of Economics and Administrative Sciences Y*, *14*(2), 375-391.

Askar, H., Krois, J., Göstemeyer, G., Bottenberg, P., Zero, D., Banerjee, A., & Schwendicke, F. (2020). Secondary caries: what is it, and how it can be controlled, detected, and managed? *Clinical Oral Investigations*, *24*(5), 1869-1876. https://doi.org/10.1007/s00784-020-03268-7

Attar, N., Tam, L. E., & McComb, D. (2003). Mechanical and physical properties of contemporary dental luting agents. *Journal of Prosthetic Dentistry*, *89*(2), 127-134. https://doi.org/10.1067/MPR.2003.20

Başaran, M., Çelik, Ö., Bayrakdar, I. S., Bilgir, E., Orhan, K., Odabaş, A., Aslan, A. F., & Jagtap, R. (2022). Diagnostic charting of panoramic radiography using deep-learning artificial intelligence system. *Oral Radiology*, *38*(3), 363-369. https://doi.org/10.1007/s11282-021-00572-0

Bayraktar, Y., & Ayan, E. (2022). Diagnosis of interproximal caries lesions with deep convolutional neural network in digital bitewing radiographs. *Clinical oral investigations*, *26*(1), 623-632.

Becker, C. M., & Kaldahl, W. B. (2005). Current theories of crown contour, margin placement, and pontic design. *The Journal of Prosthetic Dentistry*, *93*(2), 107-115. https://doi.org/10.1016/j.prosdent.2004.11.005

Bej, S., Davtyan, N., Wolfien, M., Nassar, M., & Wolkenhauer, O. (2021). LoRAS: an oversampling approach for imbalanced datasets. *Machine Learning*, *110*(2), 279-301. https://doi.org/10.1007/s10994-020-05913-4

Benelli, E. M., Serra, M. C., Rodrigues, Jr. A. L., & Cury, J. A. (1993). In situ Anticariogenic Potential of Glass lonomer Cement. *Caries Research*, *27*(4), 280-284. https://doi.org/10.1159/000261551

Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning Long-Term Dependencies with Gradient Descent is Difficult. *IEEE Transactions on Neural Networks*, *5*(2), 157-166. https://doi.org/10.1109/72.279181

Bernauer, S. A., Zitzmann, N. U., & Joda, T. (2021). The Use and Performance of Artificial Intelligence in Prosthodontics: A Systematic Review. *Sensors*, *21*(19), 6628. https://doi.org/10.3390/s21196628

Bicer Yildirim, A. Z., & Unver, S. (2018). Etiology of Secondary Caries in Prosthodontic Treatments. Içinde *Dental Caries - Diagnosis, Prevention and Management*. InTech. https://doi.org/10.5772/intechopen.76097

Bilal Badar, S., Zafar, K., Ghafoor, R., & Khan, F. R. (2022). Radiographic evaluation of the margins of clinically acceptable metal-ceramic crowns. *Journal of the Pakistan Medical Association*, *72*(01). https://doi.org/10.47391/JPMA.AKU-08

Bilgin, M. S., Aglarci, O. S., & Erdem, A. (2014). Posttreatment diagnosis of caries under fixed restorations: A pilot study. *The Journal of Prosthetic Dentistry*, *112*(6), 1364-1369. https://doi.org/10.1016/j.prosdent.2014.06.014

Bochkovskiy, A., Wang, C.-Y., & Liao, H.-Y. M. (2020). YOLOv4: Optimal Speed and Accuracy of Object Detection. *arXiv preprint*. http://arxiv.org/abs/2004.10934

Cao, L., Zheng, X., & Fang, L. (2023). The Semantic Segmentation of Standing Tree Images Based on the Yolo V7 Deep Learning Algorithm. *Electronics*, *12*(4), 929. https://doi.org/10.3390/electronics12040929

Cederhag, J., Iskanderani, D., Alstergren, P., Shi, X.-Q., & Hellén-Halme, K. (2023). Visibility of anatomical landmarks in the region of the mandibular third molar, a comparison between a low-dose and default protocol of CBCT. *Acta Odontologica Scandinavica*, 1-7. https://doi.org/10.1080/00016357.2023.2170462

Chartrand, G., Cheng, P. M., Vorontsov, E., Drozdzal, M., Turcotte, S., Pal, C. J., Kadoury, S., & Tang, A. (2017). Deep Learning: A Primer for Radiologists. *RadioGraphics*, *37*(7), 2113-2131. https://doi.org/10.1148/rg.2017170077

Chen, Q., Wu, J., Li, S., Lyu, P., Wang, Y., & Li, M. (2016). An ontology-driven, case-based clinical decision support model for removable partial denture design. *Scientific Reports*, *6*(1), 27855. https://doi.org/10.1038/srep27855

Chen, T., Zhang, Z., Liu, S., Chang, S., & Wang, Z. (2021, Şubat 10). Robust Overfitting may be mitigated by properly learned smoothening. *In International Conference on Learning Representations*.

Cheng, P. M., Montagnon, E., Yamashita, R., Pan, I., Romero, F. P., Chartrand, G., Kadoury, S., & Tang, A. (2021). Deep Learning: An Update for Radiologists Published under a CC BY 4.0 license. *RadioGraphics*, *41*, 1427-1445. https://doi.org/10.1148/rg.2021200210

Cheng, Y., Liu, Z., & Morimoto, Y. (2020). Attention-Based SeriesNet: An Attention-Based Hybrid Neural Network Model for Conditional Time Series Forecasting. *Information*, *11*(6), 305. https://doi.org/10.3390/info11060305

Choi, Y. G., Kim, Y. K., Eckert, S. E., & Shim, C. H. (2004). Cross-sectional study of the factors that influence radiographic magnification of implant diameter and length. *International Journal of Oral & Maxillofacial Implants*, *19*(4).

Clark, H. C., & Curzon, M. E. (2004). A prospective comparison between findings from a clinical examination and results of bitewing and panoramic radiographs for dental caries diagnosis in children. *Eur J Paediatr Dent*, *5*(4), 203-209.

Cottam, J. A., Heller, N. C., Ebsch, C. L., Deshmukh, R., Mackey, P., & Chin, G. (2020). Evaluation of Alignment: Precision, Recall, Weighting and Limitations. *2020 IEEE International Conference on Big Data (Big Data)*, 2513-2519. https://doi.org/10.1109/BigData50022.2020.9378064

Craig, R., & Powers, J. (2002). *Restorative dental materials* (11. bs).

Cruz-Roa, A., Basavanhally, A., González, F., Gilmore, H., Feldman, M., Ganesan, S., Shih, N., Tomaszewski, J., & Madabhushi, A. (2014). Automatic detection of invasive ductal carcinoma in whole slide images with convolutional neural networks. *https://doi.org/10.1117/12.2043872*, *9041*, 904103. https://doi.org/10.1117/12.2043872

Cui, Y., Zhou, F., Wang, J., Liu, X., Lin, Y., & Belongie, S. (2017). Kernel Pooling for Convolutional Neural Networks. *In Proceedings of the IEEE conference on computer vision and pattern recognition*, 2921-2930.

Çalışkan, D., & Demir, Ö. (2022). Derin Öğrenme Yöntemleri ile Şüpheli Davranış Tespiti. *International Periodical of Recent Technologies in Applied Engineering*, *3*(1), 28-43. https://doi.org/10.29228/porta.8

De Bruyn, H., Vandeweghe, S., Ruyffelaert, C., Cosyn, J., & Sennerby, L. (2013). Radiographic evaluation of modern oral implants with emphasis on crestal bone level and relevance to peri-implant health. *Periodontology 2000*, *62*(1), 256-270. https://doi.org/10.1111/prd.12004

De Tobel, J., Radesh, P., Vandermeulen, D., & Thevissen, P. W. (2017). An automated technique to stage lower third molar development on panoramic radiographs for age estimation: a pilot study. *The Journal of Forensic Odonto-stomatology*, *35*(2), 42.

De-Azevedo-Vaz, S. L., Araujo-Siqueira, C., Carneiro, V. C., Oliveira, M. L., & Azeredo, R. A. (2021). Misfit detection in implant-supported prostheses of different compositions by periapical radiography and cone beam computed tomography: An in vitro study. *The Journal of Prosthetic Dentistry*, *126*(2), 205-213. https://doi.org/10.1016/J.PROSDENT.2020.04.020

Della Bona, A., & Kelly, J. R. (2008). The clinical success of all-ceramic restorations. *Journal of the American Dental Association*, *139*(9 SUPPL.), S8-S13. https://doi.org/10.14219/jada.archive.2008.0361

Devlin, H., & Yuan, J. (2013). Object position and image magnification in dental panoramic radiography: A theoretical analysis. *Dentomaxillofacial Radiology*, *42*(1), 29951683. https://doi.org/10.1259/DMFR/29951683

DeVries, Z., Locke, E., Hoda, M., Moravek, D., Phan, K., Stratton, A., Kingwell, S., Wai, E. K., & Phan, P. (2021). Using a national surgical database to predict complications following posterior lumbar surgery and comparing the area under the curve and F1-score for the assessment of prognostic capability. *The Spine Journal*, *21*(7), 1135-1142. https://doi.org/10.1016/j.spinee.2021.02.007

Dhaniram, T., Bharti, D., Pankaj, D., & Anupam, B. (2022). Comparative evaluation of retention of lithium disilicate crowns with four different cementation systems- An in-vitro Study. *Journal of Pharmaceutical Negative Results*, 1090-1096. https://doi.org/10.47750/pnr.2022.13.S06.146

Dhillon, M., Raju, S. M., Verma, S., Tomar, D., Mohan, R. S., Lakhanpal, M., & Krishnamoorthy, B. (2012). Positioning errors and quality assessment in panoramic radiography. *Imaging Science in Dentistry*, *42*(4), 207. https://doi.org/10.5624/isd.2012.42.4.207

Diemer, F., Stark, H., Helfgen, E.-H., Enkling, N., Probstmeier, R., Winter, J., & Kraus, D. (2021). In vitro cytotoxicity of different dental resin-cements on human cell lines. *Journal of Materials Science: Materials in Medicine*, *32*(1), 4. https://doi.org/10.1007/s10856-020-06471-w

Dikbas, I., Tanalp, J., Tomruk, C. O., & Koksal, T. (2013). Evaluation of reasons for extraction of crowned teeth: A prospective study at a university clinic. *Acta Odontologica Scandinavica*, *71*(3-4), 848-856. https://doi.org/10.3109/00016357.2012.680908

Dolev, E., Bitterman, Y., & Meirowitz, A. (2019). Comparison of marginal fit between CAD-CAM and hot-press lithium disilicate crowns. *Journal of Prosthetic Dentistry*, *121*(1), 124-128. https://doi.org/10.1016/J.PROSDENT.2018.03.035

Donovan, T. E., & Cho, G. C. (1999). Contemporary evaluation of dental cements. *Compendium of Continuing Education in Dentistry (Jamesburg, N.J. : 1995)*, *20*(3), 197-199, 202.

Dove, S. B. (2001). Radiographic Diagnosis of Dental Caries. *Journal of Dental Education*, *65*(10), 985-990. https://doi.org/10.1002/j.0022-0337.2001.65.10.tb03474.x

Driscoll, C. F. F. M. A. G. A. D. K. K. L. M. T. J. (2017). The Glossary of Prosthodontic Terms. *The Journal of Prosthetic Dentistry*, *117*(5), C1-e105. https://doi.org/10.1016/j.prosdent.2016.12.001

Eagleman, D. M. (2001). Visual illusions and neurobiology. *Nature Reviews Neuroscience*, *2*(12), 920-926. https://doi.org/10.1038/35104092

Ekert, T., Krois, J., Meinhold, L., Elhennawy, K., Emara, R., Golla, T., & Schwendicke, F. (2019). Deep Learning for the Radiographic Detection of Apical Lesions. *Journal of Endodontics*, *45*(7), 917-922.e5. https://doi.org/10.1016/j.joen.2019.03.016

El-Mowafy, O. M., Brown, J. W., & McComb, D. (1991). Radiopacity of direct ceramic inlay restoratives. *Journal of Dentistry*, *19*(6), 366-368. https://doi.org/10.1016/0300-5712(91)90058-7

Erickson, B. J., Korfiatis, P., Akkus, Z., & Kline, T. L. (2017). Machine Learning for Medical Imaging. *RadioGraphics*, *37*(2), 505-515. https://doi.org/10.1148/rg.2017160130

Everingham, M., Eslami, S. M. A., Van Gool, L., Williams, C. K. I., Winn, J., & Zisserman, A. (2015). The Pascal Visual Object Classes Challenge: A Retrospective. *International Journal of Computer Vision*, *111*(1), 98-136. https://doi.org/10.1007/S11263-014-0733-5/FIGURES/27

Everingham, M., Van Gool, L., I Williams, C. K., Winn, J., Zisserman, A., Everingham, M., Van Gool Leuven, L. K., CKI Williams, B., Winn, J., & Zisserman, A. (2009). The Pascal Visual Object Classes (VOC) Challenge. *International Journal of Computer Vision*, *88*, 303-308. https://doi.org/10.1007/s11263-009-0275-4

Ezhov, M., Gusarev, M., Golitsyna, M., Yates, J. M., Kushnerev, E., Tamimi, D., Aksoy, S., Shumilov, E., Sanders, A., & Orhan, K. (2021). Clinically applicable artificial intelligence system for dental diagnosis with CBCT. *Scientific Reports*, *11*(1), 15006. https://doi.org/10.1038/s41598-021-94093-9

Fain, G. L. (1999). *Molecular and cellular physiology of neurons*. Harvard University Press.

Farina, M., Nakai, Y., & Shih, D. (2020). Searching for new physics with deep autoencoders. *Physical Review D*, *101*(7), 075021. https://doi.org/10.1103/PhysRevD.101.075021

Farman, A. G. (2007). Getting the Most Out of Panoramic Radiographic Interpretation. Içinde *Panoramic Radiology* (ss. 1-5). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-46230-9_1

Fava, L. R. G., & Dummer, P. M. H. (2003). Periapical radiographic techniques during endodontic diagnosis and treatment. *International Endodontic Journal*, *30*(4), 250-261. https://doi.org/10.1046/j.1365-2591.1997.00078.x

Featherstone, J. (2003). The Caries Balance: Contributing Factors and Early Detection. *JOURNAL OF THE CALIFORNIA DENTAL ASSOCIATION*.

Featherstone, J. (2004). The Continuum of Dental Caries—Evidence for a Dynamic Disease Process. *Journal of Dental Research*, *83*, 39-42. https://doi.org/10.1177/154405910408301s08

Featherstone, J., Singh, S., & Curtis, D. A. (2011). Caries Risk Assessment and Management for the Prosthodontic Patient. *Journal of Prosthodontics*, *20*(1), 2-9. https://doi.org/10.1111/j.1532-849X.2010.00596.x

Ferrucci, D., Levas, A., Bagchi, S., Gondek, D., & Mueller, E. T. (2013). Watson: Beyond jeopardy! *Artificial Intelligence*, *199-200*, 93-105. https://doi.org/10.1016/J.ARTINT.2012.06.009

Fukuda, M., Inamoto, K., Shibata, N., Ariji, Y., Yanashita, Y., Kutsuna, S., Nakata, K., Katsumata, A., Fujita, H., & Ariji, E. (2020). Evaluation of an artificial intelligence system for detecting vertical root fracture on panoramic radiography. *Oral Radiology*, *36*(4), 337-343. https://doi.org/10.1007/S11282-019-00409-X/FIGURES/6

Fukushima, K., Miyake, S., & Ito, T. (1983). Neocognitron: A neural network model for a mechanism of visual pattern recognition. *IEEE transactions on systems, man, and cybernetics*, *5*, 826-834.

Gaalaas, L., Tyndall, D., Mol, A., Everett, E. T., & Bangdiwala, A. (2016). Ex vivo evaluation of new 2D and 3D dental radiographic technology for detecting caries. *Dentomaxillofacial Radiology*, *45*(3). https://doi.org/10.1259/DMFR.20150281/FORMAT/EPUB

Gargiulo, A. W. W. F. M. O. B. (1961). Dimensions and relations of the dentogingival junction in humans. . . *J. Periodontol.*, *32*, 261-267.

Ge, Y., Wang, S., Zhou, X., Wang, H., Xu, H., & Cheng, L. (2015). The Use of Quaternary Ammonium to Combat Dental Caries. *Materials*, *8*(6), 3532-3549. https://doi.org/10.3390/ma8063532

Geibel, M.-A., Carstens, S., Braisch, U., Rahman, A., Herz, M., & Jablonski-Momeni, A. (2017). Radiographic diagnosis of proximal caries—influence of experience and gender of the dental staff. *Clinical Oral Investigations*, *21*(9), 2761-2770. https://doi.org/10.1007/s00784-017-2078-2

Ghodasra, R., & Brizuela, M. (2022). Dental Caries Diagnostic Testing. Içinde *StatPearls*. StatPearls Publishing.

Girshick, R. (2015). Fast R-CNN. *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, 1440-1448.

Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation. *In Proceedings of the IEEE conference on computer vision and pattern recognition*, 580-587.

Giti, R., Vojdani, M., Abduo, J., & Bagheri, R. (2016). The Comparison of Sorption and Solubility Behavior of Four Different Resin Luting Cements in Different Storage Media. *J Dent*, *17*(2), 91-97.

Gkioxari, G., Girshick, R., & Malik, J. (2015). Contextual Action Recognition with R-CNN. *2015 IEEE International Conference on Computer Vision (ICCV)*, 1080-1088. https://doi.org/10.1109/ICCV.2015.129

Glantz, P.-O. J., Nilner, K., Jendresen, M. D., & Sundberg, H. (1993). Quality of fixed prosthodontics after 15 years. *Acta Odontologica Scandinavica*, *51*(4), 247-252. https://doi.org/10.3109/00016359309040574

Goertzel, B., Mossbridge, J., Monroe, E., Hanson, D., & Yu, G. (2017). Humanoid Robots as Agents of Human Consciousness Expansion. *arxiv*.

Gomez, J. (2015). Detection and diagnosis of the early caries lesion. *BMC Oral Health*, *15*(1), 1-7. https://doi.org/10.1186/1472-6831-15-S1-S3/FIGURES/3

Goshima, T., & Goshima, Y. (1991). Optimum radiopacity of composite inlay materials and cements. *Oral Surgery, Oral Medicine, Oral Pathology*, *72*(2), 257-260. https://doi.org/10.1016/0030-4220(91)90173-A

Hacıosmanoğlu, N., Eren, H., Küçükkalem, M. F., & Görgün, S. (2019). Dijital panoramik radyograflarda çekim sırasında yapılan hatalar. *Selcuk Dental Journal*, *6*(4), 209-215.

Haenlein, M., & Kaplan, A. (2019). A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence. *California Management Review*, *61*(4), 5-14. https://doi.org/10.1177/0008125619864925

Haghanifar, A., Majdabadi, M. M., Haghanifar, S., Choi, Y., & Ko, S. B. (2023). PaXNet: Tooth segmentation and dental caries detection in panoramic X-ray using ensemble transfer learning and capsule classifier. *Multimedia Tools and Applications*, 1-21. https://doi.org/10.1007/S11042-023-14435-9/FIGURES/11

Haglin, J. M., Jimenez, G., & Eltorai, A. E. M. (2019). Artificial neural networks in medicine. *Health and Technology*, *9*(1), 1-6. https://doi.org/10.1007/S12553-018-0244-4/FIGURES/3

Hallikainen, D. (1996). History of Panoramic Radiography. *Acta Radiologica*, *37*(3), 441-445. https://doi.org/10.3109/02841859609177678

Hamza, T. A., Ezzat, H. A., El-Hossary, M. M. K., El Megid Katamish, H. A., Shokry, T. E., & Rosenstiel, S. F. (2013). Accuracy of ceramic restorations made with two CAD/CAM systems. *Journal of Prosthetic Dentistry*, *109*(2), 83-87. https://doi.org/10.1016/S0022-3913(13)60020-7

Han, J., Pei, J., & Tong, H. (2022). *Data mining: concepts and techniques* (4th bs). Morgan Kaufman.

Hassani, H., & Silva, E. S. (2023). The Role of ChatGPT in Data Science: How AI-Assisted Conversational Interfaces Are Revolutionizing the Field. *Big Data and Cognitive Computing*, *7*(2), 62. https://doi.org/10.3390/bdcc7020062

Heboyan, A. G. (2019). Marginal and internal fit of fixed prosthodontic constructions: a literature review. *International Journal of Dental Research and Reviews*. https://doi.org/10.28933/ijdrr-2019-06-1105

Heo, M.-S., Kim, J.-E., Hwang, J.-J., Han, S.-S., Kim, J.-S., Yi, W.-J., & Park, I.-W. (2021). Artificial intelligence in oral and maxillofacial radiology: what is currently possible? *Dentomaxillofacial Radiology*, *50*(3), 50. https://doi.org/10.1259/dmfr.20200375

Hill, E. E. (2007). Dental Cements for Definitive Luting: A Review and Practical Clinical Considerations. *Dental Clinics of North America*, *51*(3), 643-658. https://doi.org/10.1016/j.cden.2007.04.002

Hill, E., & Lott, J. (2011). A clinically focused discussion of luting materials. *Australian Dental Journal*, *56*(SUPPL. 1), 67-76. https://doi.org/10.1111/J.1834-7819.2010.01297.X

Hinton, G. E., Osindero, S., & Teh, Y.-W. (2006). A Fast Learning Algorithm for Deep Belief Nets. *Neural Computation*, *18*(7), 1527-1554. https://doi.org/10.1162/neco.2006.18.7.1527

Hiraiwa, T., Ariji, Y., Fukuda, M., Kise, Y., Nakata, K., Katsumata, A., Fujita, H., & Ariji, E. (2019). A deep-learning artificial intelligence system for assessment of root morphology of the mandibular first molar on panoramic radiography. *Dentomaxillofacial Radiology*, *48*(3), 20180218. https://doi.org/10.1259/dmfr.20180218

Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, *9*(8), 1735-1780. https://doi.org/10.1162/neco.1997.9.8.1735

Holmes, J. R., Bayne, S. C., Holland, G. A., & Sulik, W. D. (1989). Considerations in measurement of marginal fit. *The Journal of Prosthetic Dentistry*, *62*(4), 405-408. https://doi.org/10.1016/0022-3913(89)90170-4

Hsieh, Y.-S., Ho, Y.-C., Lee, S.-Y., Chuang, C.-C., Tsai, J., Lin, K.-F., & Sun, C.-W. (2013). Dental Optical Coherence Tomography. *Sensors*, *13*(7), 8928-8949. https://doi.org/10.3390/s130708928

Hull, P. S., Worthington, H. V., Clerehugh, V., Tsirba, R., Davies, R. M., & Clarkson, J. E. (1997). The reasons for tooth extractions in adults and their validation. *Journal of Dentistry*, *25*(3-4), 233-237. https://doi.org/10.1016/S0300-5712(96)00029-2

İnik, Ö., Ülker, E., Bölümü, B. M., Üniversitesi, G., Üniversitesi, S., & Konya, T. (2017). Derin Öğrenmede Kullanılan Veri Setleri ve Yazılım Kütüphaneleri. *International Symposium on Multidisciplinary Studies and Innovative Technologies Proceedings Book*.

Jacobs, M. S., & Windeler, A. S. (1991). An investigation of dental luting cement solubility as a function of the marginal gap. *The Journal of Prosthetic Dentistry*, *65*(3), 436-442. https://doi.org/10.1016/0022-3913(91)90239-S

Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial neural networks: a tutorial. *Computer*, *29*(3), 31-44. https://doi.org/10.1109/2.485891

Janowczyk, A., & Madabhushi, A. (2016). Deep learning for digital pathology image analysis: A comprehensive tutorial with selected use cases. *Journal of Pathology Informatics*, *7*(1), 29. https://doi.org/10.4103/2153-3539.186902

Jeong, H.-J., Park, K.-S., & Ha, Y.-G. (2018). Image Preprocessing for Efficient Training of YOLO Deep Learning Networks. *2018 IEEE International*

Conference on Big Data and Smart Computing (BigComp), 635-637. https://doi.org/10.1109/BigComp.2018.00113

Jia, Y., Shelhamer, E., Donahue, J., Karayev, S., Long, J., Girshick, R., Guadarrama, S., & Darrell, T. (2014). Caffe: Convolutional architecture for fast feature embedding. *MM 2014 - Proceedings of the 2014 ACM Conference on Multimedia*, 675-678. https://doi.org/10.1145/2647868.2654889

Jiang, H., & Learned Miller, E. (2017). Face Detection with the Faster R-CNN. *2017 12th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2017)*, 650-657. https://doi.org/10.1109/FG.2017.82

Jiang, K., Xie, T., Yan, R., Wen, X., Li, D., Jiang, H., Jiang, N., Feng, L., Duan, X., & Wang, J. (2022). An Attention Mechanism-Improved YOLOv7 Object Detection Algorithm for Hemp Duck Count Estimation. *Agriculture 2022, Vol. 12, Page 1659*, *12*(10), 1659. https://doi.org/10.3390/AGRICULTURE12101659

Kainz, P., Pfeiffer, M., & Urschler, M. (2015). *Semantic Segmentation of Colon Glands with Deep Convolutional Neural Networks and Total Variation Segmentation*. https://doi.org/10.48550/arxiv.1511.06919

Katkar, R. A., Tadinada, S. A., Amaechi, B. T., & Fried, D. (2018). Optical Coherence Tomography. *Dental Clinics of North America*, *62*(3), 421-434. https://doi.org/10.1016/j.cden.2018.03.004

Kats, L., Vered, M., Zlotogorski-Hurvitz, A., & Harpaz, I. (2019). Atherosclerotic carotid plaque on panoramic radiographs: neural network detection. *Int J Comput Dent*, *22*(2), 163-169.

Kaul, V., Enslin, S., & Gross, S. A. (2020). History of artificial intelligence in medicine. *Gastrointestinal Endoscopy*, *92*(4), 807-812. https://doi.org/10.1016/J.GIE.2020.06.040

Ker, J., Wang, L., Rao, J., & Lim, T. (2018). Deep Learning Applications in Medical Image Analysis. *IEEE Access*, *6*, 9375-9389. https://doi.org/10.1109/ACCESS.2017.2788044

Kidd, E. A. M., & Fejerskov, O. (2004). What constitutes dental caries? Histopathology of carious enamel and dentin related to the action of cariogenic biofilms. *Journal of Dental Research*, *83*(SPEC. ISS. C). https://doi.org/10.1177/154405910408301S07/FORMAT/EPUB

Kim, C., Kim, D., Jeong, H., Yoon, S.-J., & Youm, S. (2020). Automatic Tooth Detection and Numbering Using a Combination of a CNN and Heuristic Algorithm. *Applied Sciences*, *10*(16), 5624. https://doi.org/10.3390/app10165624

Kim, M., Yun, J., Cho, Y., Shin, K., Jang, R., Bae, H., & Kim, N. (2019). Deep Learning in Medical Imaging. *Neurospine*, *16*(4), 657-668. https://doi.org/10.14245/ns.1938396.198

Kina, J. R., Dos Santos, P. H., Kina, E. F., Suzuki, T. Y., & Dos Santos, P. L. (2011). Periodontal and prosthetic biologic considerations to restore biological width in posterior teeth. *J. Craniofac. Surg.*, *22*, 1913-1916.

Kiran, B., Thomas, D., & Parakkal, R. (2018). An Overview of Deep Learning Based Methods for Unsupervised and Semi-Supervised Anomaly Detection in Videos. *Journal of Imaging*, *4*(2), 36. https://doi.org/10.3390/jimaging4020036

Kishen, A. (2006). Mechanisms and risk factors for fracture predilection in endodontically treated teeth. *Endodontic Topics*, *13*(1), 57-83. https://doi.org/10.1111/j.1601-1546.2006.00201.x

Komine, F., Iwai, T., Kobayashi, K., & Matsumura, H. (2007). Marginal and Internal Adaptation of Zirconium Dioxide Ceramic Copings and Crowns with Different Finish Line Designs. *Dental Materials Journal*, *26*(5), 659-664. https://doi.org/10.4012/dmj.26.659

Krizhevsky, A., & Hinton, G. E. (2011). Using Very Deep Autoencoders for Content-Based Image Retrieval. *in European Symposium on Artificial Neural Networks*, *1*, 489-494.

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, *60*(6), 84-90. https://doi.org/10.1145/3065386

Krois, J., Ekert, T., Meinhold, L., Golla, T., Kharbot, B., Wittemeier, A., Dörfer, C., & Schwendicke, F. (2019). Deep Learning for the Radiographic Detection of Periodontal Bone Loss. *Scientific Reports*, *9*(1), 8495. https://doi.org/10.1038/s41598-019-44839-3

Kumar, A., & Srivastava, S. (2020). Object Detection System Based on Convolution Neural Networks Using Single Shot Multi-Box Detector. *Procedia Computer Science*, *171*, 2610-2617. https://doi.org/10.1016/j.procs.2020.04.283

Kunz, F., Stellzig-Eisenhauer, A., Zeman, F., & Boldt, J. (2020). Artificial intelligence in orthodontics. *Journal of Orofacial Orthopedics / Fortschritte der Kieferorthopädie*, *81*(1), 52-68. https://doi.org/10.1007/s00056-019-00203-8

Kuper, N. K., Opdam, N. J. M., Ruben, J. L., de Soet, J. J., Cenci, M. S., Bronkhorst, E. M., & Huysmans, M. C. D. N. J. M. (2014). Gap Size and Wall Lesion Development Next to Composite. *Journal of Dental Research*, *93*, 108S-113S. https://doi.org/10.1177/0022034514534262/ASSET/IMAGES/LARGE/10.1177_0022034514534262-FIG2.JPEG

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*(7553), 436-444. https://doi.org/10.1038/nature14539

Lederer, A., Kunzelmann, K. H., Heck, K., Hickel, R., & Litzenburger, F. (2019). In-vitro validation of near-infrared reflection for proximal caries detection. *European Journal of Oral Sciences*, *127*(6), 515-522. https://doi.org/10.1111/EOS.12663

Lee, D.-W., Kim, S.-Y., Jeong, S.-N., & Lee, J.-H. (2021). Artificial Intelligence in Fractured Dental Implant Detection and Classification: Evaluation Using Dataset from Two Dental Hospitals. *Diagnostics*, *11*(2), 233. https://doi.org/10.3390/diagnostics11020233

Lee, J. H., Kim, D. hyung, Jeong, S. N., & Choi, S. H. (2018). Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. *Journal of Periodontal & Implant Science*, *48*(2), 114. https://doi.org/10.5051/jpis.2018.48.2.114

Lee, J., Kim, D., & Jeong, S. (2020). Diagnosis of cystic lesions using panoramic and cone beam computed tomographic images based on deep learning neural network. *Oral Diseases*, *26*(1), 152-158. https://doi.org/10.1111/odi.13223

Lee, Kim, D.-H., Jeong, S.-N., & Choi, S.-H. (2018). Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *Journal of Dentistry*, *77*, 106-111. https://doi.org/10.1016/j.jdent.2018.07.015

Lerner, H., Mouhyi, J., Admakin, O., & Mangano, F. (2020). Artificial intelligence in fixed implant prosthodontics: a retrospective study of 106 implant-supported monolithic zirconia crowns inserted in the posterior jaws of 90 patients. *BMC Oral Health*, *20*(1), 80. https://doi.org/10.1186/s12903-020-1062-4

Leung, G. K. H., Wong, A. W. Y., Chu, C. H., & Yu, O. Y. (2022). Update on Dental Luting Materials. *Dentistry Journal 2022, Vol. 10, Page 208*, *10*(11), 208. https://doi.org/10.3390/DJ10110208

Li, C., Li, L., Jiang, H., Weng, K., Geng, Y., Li, L., Ke, Z., Li, Q., Cheng, M., Nie, W., Li, Y., Zhang, B., Liang, Y., Zhou, L., Xu, X., Chu, X., Wei, X., & Wei, X. (2022). *YOLOv6: A Single-Stage Object Detection Framework for Industrial Applications*.

Li, F., Weir, M. D., & Xu, H. H. K. (2013). Effects of Quaternary Ammonium Chain Length on Antibacterial Bonding Agents. *Journal of Dental Research*, *92*(10), 932-938. https://doi.org/10.1177/0022034513502053

Li, Y., Huang, C., Ding, L., Li, Z., Pan, Y., & Gao, X. (2019). Deep learning in bioinformatics: Introduction, application, and perspective in the big data era. *Methods*, *166*, 4-21.

Li, Z. (2021). Indocyanine-Green-Aided Near-Infrared Fluorescence Dental Imaging: A Novel and Ionizing-Radiation-Free Imaging Modality. *LSU Doctoral Dissertations*. https://doi.org/10.31390/gradschool_dissertations.5696

Lian, L., Zhu, T., Zhu, F., & Zhu, H. (2021). Deep Learning for Caries Detection and Classification. *Diagnostics*, *11*(9), 1672. https://doi.org/10.3390/diagnostics11091672

Liang, H., & Frederiksen, N. (2004). Focal trough and patient positioning. *Dentomaxillofacial Radiology*, *33*(2), 128-129. https://doi.org/10.1259/dmfr/26975780

Lila-Krasniqi, Z. D., Bajrami Halili, R., Hamza, V., & Krasniqi, S. (2022). Evaluation of Antimicrobial Effectiveness of Dental Cement Materials on Growth of Different Bacterial Strains. *Medical Science Monitor Basic Research*, *28*, e937893. https://doi.org/10.12659/MSMBR.937893

Lin, M., Chen, Q., & Yan, S. (2013). *Network In Network*.

Lin, T. Y., Dollar, P., Girshick, R., He, K., Hariharan, B., & Belongie, S. (2017). Feature Pyramid Networks for Object Detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2117-2125.

Lin, T. Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., & Zitnick, C. L. (2014). Microsoft COCO: Common objects in context. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, *8693 LNCS*(PART 5), 740-755. https://doi.org/10.1007/978-3-319-10602-1_48/COVER

Lipton, Z. C., Elkan, C., & Narayanaswamy, B. (2014). *Thresholding Classifiers to Maximize F1 Score*.

Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, *42*, 60-88. https://doi.org/10.1016/j.media.2017.07.005

Liu, K., Sun, Q., Sun, D., Peng, L., Yang, M., & Wang, N. (2023). Underwater Target Detection Based on Improved YOLOv7. *Journal of Marine Science and Engineering*, *11*(3), 677. https://doi.org/10.3390/jmse11030677

Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., & Berg, A. C. (2015). SSD: Single Shot MultiBox Detector. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, *9905 LNCS*, 21-37. https://doi.org/10.1007/978-3-319-46448-0_2

Longridge, N. N., & Youngson, C. C. (2019). Dental pain: dentine sensitivity, hypersensitivity and cracked tooth syndrome. *Primary Dental Journal*, *8*(1), 44-51.

López, G., Quesada, L., & Guerrero, L. A. (2018). Alexa vs. Siri vs. Cortana vs. Google Assistant: A Comparison of Speech-Based Natural User Interfaces. Içinde I. L. Nunes (Ed.), *Advances in Intelligent Systems and Computing* (ss. 241-250). https://doi.org/10.1007/978-3-319-60366-7_23

Ludovic, R., Daniel, R., Nicolas, L., Maria, K., Humayun, I., Jacques, K., Frédérique, C., Catherine, G., Gilles, L. N., & Metin N, G. (2013). Mitosis detection in breast cancer histological images An ICPR 2012 contest. *Journal of Pathology Informatics*, *4*(1), 8. https://doi.org/10.4103/2153-3539.112693

Lynn, T., Mooney, J. G., Rosati, P., & Cummins, M. (Ed.). (2019). *Disrupting Finance*. Springer International Publishing. https://doi.org/10.1007/978-3-030-02330-0

Magne, P., Magne, M., & Belser, U. (1999). The Esthetic Width in Fixed Prosthodontics. *Journal of Prosthodontics*, *8*(2), 106-118. https://doi.org/10.1111/j.1532-849X.1999.tb00019.x

Manicone, P. F., Rossi Iommetti, P., & Raffaelli, L. (2007). An overview of zirconia ceramics: Basic properties and clinical applications. *Journal of Dentistry*, *35*(11), 819-826. https://doi.org/10.1016/J.JDENT.2007.07.008

Mansour, S., Ajdaharian, J., Nabelsi, T., Chan, G., & Wilder-Smith, P. (2016). Comparison of caries diagnostic modalities: A clinical study in 40 subjects. *Lasers in Surgery and Medicine*, *48*(10), 924-928. https://doi.org/10.1002/LSM.22460

Mao, Y.-C., Chen, T.-Y., Chou, H.-S., Lin, S.-Y., Liu, S.-Y., Chen, Y.-A., Liu, Y.-L., Chen, C.-A., Huang, Y.-C., Chen, S.-L., Li, C.-W., Abu, P. A. R., & Chiang, W.-Y. (2021). Caries and Restoration Detection Using Bitewing Film Based on Transfer Learning with CNNs. *Sensors*, *21*(13), 4613. https://doi.org/10.3390/s21134613

Marcushamer, M., Garcia-Godoy, F., & Chan, D. C. (1993). Caries protection after orthodontic band cementation with glass ionomer. *ASDC Journal of Dentistry for Children*, *60*(4-5), 300-303.

Martínez-Rus, F., García, A. M., De Aza, A. H., & Pradíes, G. (2011). Radiopacity of zirconia-based all-ceramic crown systems. *The International journal of prosthodontics*, *24*(2).

Martins, L. M., Lorenzoni, F. C., Melo, A. O. de, Silva, L. M. da, Oliveira, J. L. G. de, Oliveira, P. C. G. de, & Bonfante, G. (2012). Internal fit of two all-ceramic systems and metal-ceramic crowns. *Journal of Applied Oral Science*, *20*(2), 235-240. https://doi.org/10.1590/S1678-77572012000200019

Matalon, S., Feuerstein, O., & Kaffe, I. (2003). Diagnosis of approximal caries: Bite-wing radiology versus the Ultrasound Caries Detector. An in vitro study. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology*, *95*(5), 626-631. https://doi.org/10.1067/moe.2003.164

Matos, J. D. M. de, Nakano, L. J. N., Bottino, M. A., Jesus, R. H. de, & Maciel, L. C. (2020). Current Considerations for Dental Ceramics and Their Respective Union Systems. *Revista Brasileira de Odontologia*, *77*, 1. https://doi.org/10.18363/rbo.v77.2020.e1768

McCarthy, J. (2004). *What is artificial intelligence.*

McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI magazine*, *27*(4), 12-12. https://doi.org/https://doi.org/10.1609/aimag.v27i4.1904

McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, *5*(4), 115-133. https://doi.org/10.1007/BF02478259/METRICS

McLean JW., V. F. J. A. (1971). The estimation of cement film thickness by an in vivo technique. *Br Dent Journal*, *131*(107), 11.

Melo, M., Guedes, S. F. F., Xu, H. H. K., & Rodrigues, L. K. A. (2013). Nanotechnology-based restorative materials for dental caries management. *Trends in Biotechnology*, *31*(8), 459-467. https://doi.org/10.1016/J.TIBTECH.2013.05.010

Melo, M., Weir, M. D., Rodrigues, L. K. A., & Xu, H. H. K. (2013). Novel calcium phosphate nanocomposite with caries-inhibition in a human in situ model. *Dental Materials*, *29*(2), 231-240. https://doi.org/10.1016/J.DENTAL.2012.10.010

Melo, M., Weir, M., Passos, V., Rolim, J., Lynch, C., Rodrigues, L., & Xu, H. (2018). Human In Situ Study of the effect of Bis(2-Methacryloyloxyethyl) Dimethylammonium Bromide Immobilized in Dental Composite on Controlling Mature Cariogenic Biofilm. *International Journal of Molecular Sciences*, *19*(11), 3443. https://doi.org/10.3390/ijms19113443

Metz, C. E. (1978). Basic principles of ROC analysis. *Seminars in Nuclear Medicine*, *8*(4), 283-298. https://doi.org/10.1016/S0001-2998(78)80014-2

Millett, D. T., Duff, S., Morrison, L., Cummings, A., & Gilmour, W. H. (2003). In vitro comparison of orthodontic band cements. *American Journal of Orthodontics and Dentofacial Orthopedics*, *123*(1), 15-20. https://doi.org/10.1067/mod.2003.48

Minaee, S., Boykov, Y. Y., Porikli, F., Plaza, A. J., Kehtarnavaz, N., & Terzopoulos, D. (2021). Image Segmentation Using Deep Learning: A Survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1-1. https://doi.org/10.1109/TPAMI.2021.3059968

Mitchell, C. A., & Douglas, W. H. (1997). Comparison of the porosity of hand-mixed and capsulated glass-ionomer luting cements. *Biomaterials*, *18*(16), 1127-1131. https://doi.org/10.1016/S0142-9612(97)00038-0

Mjör, I. A. (2005). Clinical diagnosis of recurrent caries. *The Journal of the American Dental Association*, *136*(10), 1426-1433. https://doi.org/10.14219/jada.archive.2005.0057

Mohammed Al Moaleem, M. (2016). Systems and Techniques for Removal of Failed Fixed Partial Dentures: A Review. *American Journal of Health Research*, *4*(4), 109. https://doi.org/10.11648/j.ajhr.20160404.17

Mohammed, M., Khan, M. B., & Bashier, E. B. M. (2016). *Machine Learning* (1st bs). CRC Press. https://doi.org/10.1201/9781315371658

Mohan, R., & Valada, A. (2021). EfficientPS: Efficient Panoptic Segmentation. *International Journal of Computer Vision*, *129*(5), 1551-1579. https://doi.org/10.1007/s11263-021-01445-z

Molteni, R. (2020). The way we were (and how we got here): Fifty years of technology changes in dental and maxillofacial radiology. *Dentomaxillofacial Radiology*, *50*(1), 20200133. https://doi.org/10.1259/DMFR.20200133/FORMAT/EPUB

Mota, S. M., Enoki, C., Ito, I. Y., Elias, A. M., & Matsumoto, M. A. N. (2008). Streptococcus mutans counts in plaque adjacent to orthodontic brackets bonded with resin-modified glass ionomer cement or resin-based composite. *Brazilian Oral Research*, *22*(1), 55-60. https://doi.org/10.1590/S1806-83242008000100010

Murat, S., Kamburoğlu, K., Isayev, A., Kurşun, S., & Yüksel, S. (2013). Visibility of Artificial Buccal Recurrent Caries Under Restorations Using Different Radiographic Techniques. *Operative Dentistry*, *38*(2), 197-207. https://doi.org/10.2341/12-158-L

Murata, M., Ariji, Y., Ohashi, Y., Kawai, T., Fukuda, M., Funakoshi, T., Kise, Y., Nozawa, M., Katsumata, A., Fujita, H., & Ariji, E. (2019). Deep-learning classification using convolutional neural network for evaluation of maxillary sinusitis on panoramic radiography. *Oral Radiology*, *35*(3), 301-307. https://doi.org/10.1007/s11282-018-0363-7

Musa, A., Pearson, G. J., & Gelbier, M. (1996). In vitro investigation of fluoride ion release from four resin-modified glass polyalkenoate cements. *Biomaterials*, *17*(10), 1019-1023. https://doi.org/10.1016/0142-9612(96)84678-3

Nalçacı, R., Baran, İ., & Olgun, E. E. (2006). Kron-Köprü Restorasyonlarında Sekonder Çürüğün Radyolojik ve Klinik Olarak Değerlendirilmesi. *European Annals of Dental Sciences*, *33*(1), 97-105. https://dergipark.org.tr/en/pub/eads/issue/63737/964734

Nickolls, J., & Dally, W. J. (2010). The GPU Computing Era. *IEEE Micro*, *30*(2), 56-69. https://doi.org/10.1109/MM.2010.41

NIH consensus statement. (2001). Diagnosis and management of dental caries throughout life. *National Institutes of Health*, *18*(1), 1-23.

Nummikoski, P. V, Martinez, T. S., Matteson, S. R., McDavid, W. D., & Dove, S. B. (1992). Digital subtraction radiography in artificial recurrent caries detection. *Dentomaxillofacial Radiology*, *21*(2), 59-64. https://doi.org/10.1259/dmfr.21.2.1397457

O'brien, W. J. (2002). *Dental Materials and Their Selection* (3. bs).

Orhan, K., Bayrakdar, I. S., Ezhov, M., Kravtsov, A., & Özyürek, T. (2020). Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans. *International Endodontic Journal*, *53*(5), 680-689. https://doi.org/10.1111/iej.13265

Orhan, K., & Delantoni, A. (2022). Basic Principles of Panoramic Radiography. *Atlas of Dentomaxillofacial Anatomical Imaging*, 25-38. https://doi.org/10.1007/978-3-030-96840-3_4

Orkin, D. A., Reddy, J., & Bradshaw, D. (1987). The relationship of the position of crown margins to gingival health. *The Journal of Prosthetic Dentistry*, *57*(4), 421-424. https://doi.org/10.1016/0022-3913(87)90006-0

O'Rourke, B., Walls, A. W. G., & Wassell, R. W. (1995). Radiographic detection of overhangs formed by resin composite luting agents. *Journal of Dentistry*, *23*(6), 353-357. https://doi.org/10.1016/0300-5712(94)00009-5

Ottoni, R., Griggs, J., Corazza, P., & Borba, M. (2022). Optimization of lithium disilicate glass-ceramic crowns: finish line, scanning and processing methods. *The International Journal of Prosthodontics*. https://doi.org/10.11607/ijp.7598

Ottoni, R., Marocho, S. M. S., Griggs, J. A., & Borba, M. (2022). CAD/CAM versus 3D-printing/pressed lithium disilicate monolithic crowns: Adaptation and fatigue behavior. *Journal of Dentistry*, *123*, 104181. https://doi.org/10.1016/j.jdent.2022.104181

Oztekin, F., Katar, O., Sadak, F., Yildirim, M., Cakar, H., Aydogan, M., Ozpolat, Z., Talo Yildirim, T., Yildirim, O., Faust, O., & Acharya, U. R. (2023). An Explainable Deep Learning Model to Prediction Dental Caries Using Panoramic Radiograph Images. *Diagnostics*, *13*(2), 226. https://doi.org/10.3390/diagnostics13020226

Padilla, R., Netto, S. L., & da Silva, E. A. B. (2020). A Survey on Performance Metrics for Object-Detection Algorithms. *2020 International Conference on Systems, Signals and Image Processing (IWSSIP)*, 237-242. https://doi.org/10.1109/IWSSIP48289.2020.9145130

Papik, K., Molnar, B., Schaefer, R., Dombovari, Z., Tulassay, Z., & Feher, J. (1998). Application of neural networks in medicine-a review. *Med Sci Monit*, *4*(3), 538-546.

Pareek, M., & Kaushik, B. (2022). Artificial intelligence in prosthodontics: a scoping review on current applications and future possibilities. *International Journal of Advances in Medicine*, *9*(3), 367. https://doi.org/10.18203/2349-3933.ijam20220444

Pascotto, R. C., Navarro, M. F. de L., Filho, L. C., & Cury, J. A. (2004). In vivo effect of a resin-modified glass ionomer cement on enamel demineralization around orthodontic brackets. *American Journal of Orthodontics and Dentofacial Orthopedics*, *125*(1), 36-41. https://doi.org/10.1016/S0889-5406(03)00571-7

Pedrosa, R., Brasileiro, I., dos Anjos Pontual, M., dos Anjos Pontual, A., & da Silveira, M. (2011). Influence of materials radiopacity in the radiographic diagnosis of secondary caries: evaluation in film and two digital systems. *Dentomaxillofacial Radiology*, *40*(6), 344-350. https://doi.org/10.1259/dmfr/93764866

Pekkan, G. (2016). Radiopacity of Dental Materials: An Overview. *Avicenna Journal of Dental Research*, *8*(2), 8-8. https://doi.org/10.17795/ajdr-36847

Pekkan, G., Pekkan, K., Hatipoglu, M. G., & Tuna, S. H. (2011). Comparative radiopacity of ceramics and metals with human and bovine dental tissues. *Journal of Prosthetic Dentistry*, *106*(2), 109-117. https://doi.org/10.1016/S0022-3913(11)60104-2

Pençe, İ., Kalkan, A., & Şişeci Çeşmeli, M. (2019). Türkiye Sanayi Elektrik Enerjisi Tüketiminin 2017-2023 dönemi için Yapay Sinir Ağları ile Tahmini. *Mehmet Akif Ersoy Üniversitesi Uygulamalı Bilimler Dergisi*, *3*(2), 206-228. https://doi.org/10.31200/makuubd.538878

Peng, C. C., Chung, K. H., Yau, H. T., & Ramos, V. (2020). Assessment of the internal fit and marginal integrity of interim crowns made by different manufacturing methods. *Journal of Prosthetic Dentistry*, *123*(3), 514-522. https://doi.org/10.1016/J.PROSDENT.2019.02.024

Penning, C., van Amerongen, J. P., Seef, R. E., & ten Cate, J. M. (1992). Validity of Probing for Fissure Caries Diagnosis. *Caries Research*, *26*(6), 445-449. https://doi.org/10.1159/000261485

Pesapane, F., Codari, M., & Sardanelli, F. (2018). Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine. *European Radiology Experimental*, *2*(1), 35. https://doi.org/10.1186/s41747-018-0061-6

Pette, G., Ganeles, J., & Norkin, F. (2013). Radiographic appearance of commonly used cements in implant dentistry. *International Journal of Periodontics & Restorative Dentistry*, *33*(1).

Pettenò, D., Schierano, G., Bassi, F., Bresciano, M. E., & Carossa, S. (2000). Comparison of Marginal Fit of 3 Different Metal-Ceramic Systems: An In Vitro Study. *Int J Prosthodont.*, *13*(5), 405-408.

Pine, C. M., & ten Bosch, J. J. (1996). Dynamics of and Diagnostic Methods for Detecting Small Carious Lesions. *Caries Research*, *30*(6), 381-388. https://doi.org/10.1159/000262348

Piwowarczyk, A., Lauer, H. C., & Sorensen, J. A. (2005). Microleakage of various cementing agents for full cast crowns. *Dental Materials*, *21*(5), 445-453. https://doi.org/10.1016/J.DENTAL.2004.07.009

Pjetursson, B. E., Sailer, I., Makarov, N. A., Zwahlen, M., & Thoma, D. S. (2015). All-ceramic or metal-ceramic tooth-supported fixed dental prostheses (FDPs)? A systematic review of the survival and complication rates. Part II: Multiple-unit FDPs. *Dental Materials*, *31*(6), 624-639. https://doi.org/10.1016/j.dental.2015.02.013

Polat Sağsöz, N., Yanıkoğlu, N., Aladağ, L. İ., Özdemir, H., & Çiftçi, H. (2015). Sabit Protetik Restorasyonların Söküm Nedenlerinin Araştırılması ve Geleneksel Söküm Yöntemleri ile KaVo CORONAflex Restorasyon Sökücüsünün Karşılaştırılması. *Atatürk Üniversitesi Diş Hekimliği Fakültesi Dergisi*, *24*(3), 378-385. https://doi.org/10.17567/DFD.52609

Prabhakar, A. R., Mahantesh, T., & Ahuja, V. (2010). Comparison of Retention and Demineralization Inhibition Potential of Adhesive Banding Cements in Primary Teeth. *Journal of Dentistry for Children*, *77*(2), 66-71.

Price, C. (1986). A method of determining the radiopacity of dental materials and foreign bodies. *Oral Surgery, Oral Medicine, Oral Pathology*, *62*(6), 710-718. https://doi.org/10.1016/0030-4220(86)90269-0

Raith, S., Vogel, E. P., Anees, N., Keul, C., Güth, J.-F., Edelhoff, D., & Fischer, H. (2017). Artificial Neural Networks as a powerful numerical tool to classify specific features of a tooth based on 3D scan data. *Computers in Biology and Medicine*, *80*, 65-76. https://doi.org/10.1016/j.compbiomed.2016.11.013

Raschka, S., Patterson, J., & Nolet, C. (2020). Machine learning in python: Main developments and technology trends in data science, machine learning, and artificial intelligence. *Information*, *11*(4), 193.

Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779-788.

Redmon, J., & Farhadi, A. (2017). YOLO9000: Better, Faster, Stronger. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 7263-7271.

Redmon, J., & Farhadi, A. (2018). YOLOv3: An Incremental Improvement. *arXiv preprint*.

Reich, S., Gozdowski, S., Trentzsch, L., Frankenberger, R., & Lohbauer, U. (2008). Marginal Fit of Heat-pressed vs CAD/CAM Processed All-ceramic Onlays Using a Milling Unit Prototype. *Operative Dentistry*, *33*(6), 644-650. https://doi.org/10.2341/07-162

Rekow, E. D. (2020). Digital dentistry: The new state of the art — Is it disruptive or destructive? *Dental Materials*, *36*(1), 9-24. https://doi.org/10.1016/j.dental.2019.08.103

Reynolds, J. M. (1968). Abutment selection for fixed prosthodontics. *The Journal of Prosthetic Dentistry*, *19*(5), 483-488. https://doi.org/10.1016/0022-3913(68)90064-4

Rizonaki, M., Jacquet, W., Bottenberg, P., Depla, L., Boone, M., & De Coster, P. J. (2022). Evaluation of marginal and internal fit of lithium disilicate CAD-CAM crowns with different finish lines by using a micro-CT technique. *The Journal of Prosthetic Dentistry*, *127*(6), 890-898. https://doi.org/10.1016/j.prosdent.2020.11.027

Rodrigues, J. A., Hug, I., Diniz, M. B., & Lussi, A. (2008). Performance of Fluorescence Methods, Radiographic Examination and ICDAS II on Occlusal Surfaces in vitro. *Caries Research*, *42*(4), 297-304. https://doi.org/10.1159/000148162

Rosenstiel, S. F., Land, M. F., & Fujimoto, J. (2018). *Güncel Sabit Protezler* (5th bs).

Rubo, M. H. M., & El-Mowafy, O. (1998). Radiopacity of Dual-Cured and Chemical-Cured Resin-Based Cements. *International Journal of Prosthodontics*, *11*(1), 70-74.

Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, *323*(6088), 533-536. https://doi.org/10.1038/323533a0

Rushton, V., Horner, K., & Worthington, H. (2001). Screening panoramic radiology of adults in general dental practice: radiological findings. *British Dental Journal*, *190*(9), 495-501.

Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C., & Fei-Fei, L. (2015). ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision*, *115*(3), 211-252. https://doi.org/10.1007/S11263-015-0816-Y/FIGURES/16

Sabbagh, J., Vreven, J., & Leloup, G. (2004). Radiopacity of resin-based materials measured in film radiographs and storage phosphor plate. *Oper Dent.*, *29*(6), 677-684.

Sadid-Zadeh, R., Katsavochristou, A., Squires, T., & Simon, M. (2020). Accuracy of marginal fit and axial wall contour for lithium disilicate crowns fabricated using three digital workflows. *Journal of Prosthetic Dentistry*, *123*(1), 121-127. https://doi.org/10.1016/J.PROSDENT.2018.11.003

Salakhutdinov, R., Mnih, A., & Hinton, G. (2007). Restricted Boltzmann machines for collaborative filtering. *Proceedings of the 24th international conference on Machine learning*, 791-798. https://doi.org/10.1145/1273496.1273596

Salehinejad, H., Sankar, S., Barfett, J., Colak, E., & Valaee, S. (2017). *Recent Advances in Recurrent Neural Networks*.

Samawi, S. S. B., & Burke, P. H. (1984). Angular Distortion in the Orthopantomogram. *British Journal of Orthodontics*, *11*(2), 100-107. https://doi.org/10.1179/bjo.11.2.100

Samuel, A. L. (1988). Some studies in machine learning using the game of checkers. II—recent progress. *Computer Games I*, 366-400.

Sarker, I. H. (2021). *Machine Learning: Algorithms, Real-World Applications and Research Directions*. *2*, 160. https://doi.org/10.1007/s42979-021-00592-x

Sarker, I. H., Kayes, A. S. M., & Watters, P. (2019). Effectiveness analysis of machine learning classification models for predicting personalized context-aware smartphone usage. *Journal Of Big Data*, *6*(57), 14-28. https://doi.org/10.1186/s40537-019-0219-y

Sauro, S., & Pashley, D. H. (2016). Strategies to stabilise dentine-bonded interfaces through remineralising operative approaches – State of The Art. *International Journal of Adhesion and Adhesives, 69*, 39-57. https://doi.org/10.1016/J.IJADHADH.2016.03.014

Schaffer, A. W. (1967). The Panoramic in oral surgery. *Oral Surgery, Oral Medicine, Oral Pathology*, *24*(3), 359-363. https://doi.org/10.1016/0030-4220(67)90042-4

Schulze, R., Heil, U., Groß, D., Bruellmann, D. D., Dranischnikow, E., Schwanecke, U., & Schoemer, E. (2014). Artefacts in CBCT: a review. *https://doi.org/10.1259/dmfr/30642039*, *40*(5), 265-273. https://doi.org/10.1259/DMFR/30642039

Selwitz, R. H., Ismail, A. I., & Pitts, N. B. (2007). Dental caries. *The Lancet*, *369*(9555), 51-59. https://doi.org/10.1016/S0140-6736(07)60031-2

Seung, H. S. (2000). Half a century of Hebb. *Nature Neuroscience*, *3*(S11), 1166-1166. https://doi.org/10.1038/81430

Shah, N., Bansal, N., & Logani, A. (2014). Recent advances in imaging technologies in dentistry. *World Journal of Radiology*, *6*(10), 794. https://doi.org/10.4329/WJR.V6.I10.794

Sharma, A., Rahul, G. R., Poduval, S. T., & Shetty, K. (2012). Removal of failed crown and bridge. *J Clin Exp Dent*, *4*(3), 167-172. https://doi.org/10.4317/jced.50690

Shetty, D., C.A, H., Varma, M. J., Navi, S., & Ahmed, M. R. (2020). Diving Deep into Deep Learning: History, Evolution, Types and Applications. *International Journal of Innovative Technology and Exploring Engineering*, *9*(3), 2835-2846. https://doi.org/10.35940/ijitee.A4865.019320

Shwartz-Ziv, R., & Tishby, N. (2017). Opening the Black Box of Deep Neural Networks via Information. *Journal of Quantitavie Cell Science*, *95*(4), 351-460.

Silness, J. (1970). Periodontal conditions in patients treated with dental bridges. *Journal of Periodontal Research*, *5*(1), 60-68. https://doi.org/10.1111/j.1600-0765.1970.tb01839.x

Silva, M. A. G., Wolf, U., Heinicke, F., Bumann, A., Visser, H., & Hirsch, E. (2008). Cone-beam computed tomography for routine orthodontic treatment planning: A radiation dose evaluation. *American Journal of Orthodontics and Dentofacial Orthopedics*, *133*(5), 640.e1-640.e5. https://doi.org/10.1016/J.AJODO.2007.11.019

Soffer, S., Ben-Cohen, A., Shimon, O., Amitai, M. M., Greenspan, H., & Klang, E. (2019). Convolutional Neural Networks for Radiologic Images: A Radiologist's Guide. *Radiology*, *290*(3), 590-606. https://doi.org/10.1148/RADIOL.2018180547

Souza, R. O. A., Özcan, M., Pavanelli, C. A., Buso, L., Lombardo, G. H. L., Michida, S. M. A., Mesquita, A. M. M., & Bottino, M. A. (2012). Marginal and Internal Discrepancies Related to Margin Design of Ceramic Crowns Fabricated by a CAD/CAM System. *Journal of Prosthodontics*, *21*(2), 94-100. https://doi.org/10.1111/j.1532-849X.2011.00793.x

Söderfeldt, B., Palmqvist, S., Eriksson, T., Kronström, M., & Carlsson, G. E. (1996). A questionnaire instrument to assess clinical decision-making in prosthodontics among general practitioners. *Acta Odontologica Scandinavica*, *54*(5), 314-319. https://doi.org/10.3109/00016359609003544

Stanford, C. M., Fan, P. L., Schoenfeld, C. M., Knoeppel, R., & Stanford, J. W. (1987). Radiopacity of light-cured posterior composite resins. *The Journal of the American Dental Association*, *115*(5), 722-724. https://doi.org/10.14219/jada.archive.1987.0308

Sultan, S., Hegazy, M., Shakal, M., & Magdy, S. (2021). Effect of virtual cement gap settings on the marginal fit of cemented resin-ceramic crowns on implant abutments. *The Journal of prosthetic dentistry*, *125*(5), 804.e1-804.e6. https://doi.org/10.1016/J.PROSDENT.2021.02.014

Susic, I., Travar, M., & Susic, M. (2017). The application of CAD / CAM technology in Dentistry. *IOP Conference Series: Materials Science and Engineering*, *200*, 012020. https://doi.org/10.1088/1757-899X/200/1/012020

Suzuki, K. (2017). Overview of deep learning in medical imaging. *Radiological Physics and Technology*, *10*(3), 257-273. https://doi.org/10.1007/s12194-017-0406-5

Swift, E. J., & Perdigao, J. (1995). Bonding to enamel and dentin: A brief history and state of the art. *QUINTESSENCE INTERNATIONAL-ENGLISH EDITION*, *26*, 95-110.

Takahashi, N., Lee, C., Da Silva, J. D., Ohyama, H., Roppongi, M., Kihara, H., Hatakeyama, W., Ishikawa-Nagai, S., & Izumisawa, M. (2019). A comparison of diagnosis of early stage interproximal caries with bitewing radiographs and periapical images using consensus reference. *Dentomaxillofacial Radiology*, *48*(2), 20170450. https://doi.org/10.1259/dmfr.20170450

Takahashi, T., Nozaki, K., Gonda, T., Mameno, T., & Ikebe, K. (2021). Deep learning-based detection of dental prostheses and restorations. *Scientific Reports*, *11*(1), 1960. https://doi.org/10.1038/s41598-021-81202-x

Talaeipour, A., Nemati Anaraki, S., Heidarkhan Tehrani, S., & Golpasha, M. (2016). In Vivo Diagnostic Accuracy of Digital Radiography in the Detection of Secondary Caries in Anterior Teeth. *Journal of Research in Dental and Maxillofacial Sciences*, *1*(2), 36-40. https://doi.org/10.29252/JRDMS.1.2.36

Tamac, E., Toksavul, S., & Toman, M. (2014). Clinical marginal and internal adaptation of CAD/CAM milling, laser sintering, and cast metal ceramic

crowns. *The Journal of Prosthetic Dentistry*, *112*(4), 909-913. https://doi.org/10.1016/j.prosdent.2013.12.020

Tan, F. G., Yüksel, A. S., Aydemir, E., & Ersoy, M. (2021). Derin Öğrenme Teknikleri ile Nesne Tespiti ve Takibi Üzerine Bir İnceleme. *European Journal of Science and Technology*, *25*, 159-171. https://doi.org/10.31590/ejosat.878552

Tanaka, J., Mukai, N., Tanaka, M., & Tanaka, M. (2012). Relationship between Cariogenic Bacteria and pH of Dental Plaque at Margin of Fixed Prostheses. *International Journal of Dentistry*, *2012*, 1-4. https://doi.org/10.1155/2012/452108

Toğaçar, M., & Ergen, B. (2019). Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması. *Fırat Üniversitesi Müh. Bil. Dergisi*, *31*(1), 109-121.

Trebeschi, S., Van Griethuysen, J. J., Lambregts, D. M., Lahaye, M. J., Parmar, C., Bakers, F. C., & Aerts, H. J. (2017). Deep learning for fully-automated localization and segmentation of rectal cancer on multiparametric MR. *Scientific reports*, *7*(1), 5301.

Tsiklakis, K., Syriopoulos, K., & Stamatakis, H. C. (2014). Radiographic examination of the temporomandibular joint using cone beam computed tomography. *http://dx.doi.org/10.1259/dmfr/27403192*, *33*(3), 196-201. https://doi.org/10.1259/DMFR/27403192

Turing, A. M. (2009). Computing Machinery and Intelligence. Içinde *Parsing the Turing Test* (ss. 23-65). Springer Netherlands. https://doi.org/10.1007/978-1-4020-6710-5_3

Unosson, E., Cai, Y., Jiang, X., Lööf, J., Welch, K., & Engqvist, H. (2012). Antibacterial Properties of Dental Luting Agents: Potential to Hinder the Development of Secondary Caries. *International Journal of Dentistry*, *2012*, 1-7. https://doi.org/10.1155/2012/529495

Vadiati Saberi, B., Khosravifard, N., Nooshmand, K., Dalili Kajan, Z., & Ghaffari, M. E. (2021). Fractal analysis of the trabecular bone pattern in the presence/absence of metal artifact–producing objects: Comparison of cone-beam computed tomography with panoramic and periapical radiography. *Dentomaxillofacial Radiology*, *50*(6), 20200559. https://doi.org/10.1259/dmfr.20200559

Vedpathak, P. R. (2016). Cone Beam Computed Tomography- An Effective Tool in Detecting Caries Under Fixed Dental Prostheses. *JOURNAL OF CLINICAL AND DIAGNOSTIC RESEARCH*, *10*(8), 10-13. https://doi.org/10.7860/JCDR/2016/18589.8228

Veta, M., van Diest, P. J., Willems, S. M., Wang, H., Madabhushi, A., Cruz-Roa, A., Gonzalez, F., Larsen, A. B. L., Vestergaard, J. S., Dahl, A. B., Cireşan, D. C., Schmidhuber, J., Giusti, A., Gambardella, L. M., Tek, F. B., Walter, T., Wang, C. W., Kondo, S., Matuszewski, B. J., … Pluim, J. P. W. (2015). Assessment of

algorithms for mitosis detection in breast cancer histopathology images. *Medical Image Analysis*, *20*(1), 237-248. https://doi.org/10.1016/J.MEDIA.2014.11.010

Vinayahalingam, S., Kempers, S., Limon, L., Maal, T., Bergé, S., Xi, T., & Hanisch, M. (2021). *The Automatic Detection of Caries in Third Molars on Panoramic Radiographs Using Deep Learning: A Pilot Study*. https://doi.org/10.21203/rs.3.rs-379636/v1

Walsh, T. (2018). Fuzzy gold standards: Approaches to handling an imperfect reference standard. *Journal of Dentistry*, *74*, S47-S49. https://doi.org/10.1016/J.JDENT.2018.04.022

Walton, T. R. (2013). The up to 25-Year Survival and Clinical Performance of 2,340 High Gold–Based Metal-Ceramic Single Crowns. *The International Journal of Prosthodontics*, *26*(2), 151-160. https://doi.org/10.11607/ijp.3136

Wang, C.-Y., Bochkovskiy, A., & Liao, H.-Y. M. (2022). *YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors*. https://doi.org/https://doi.org/10.48550/arXiv.2207.02696

Wang, R., Zhao, J., Wu, W., Chen, B., & Liu, B. (2020). Recognition and Locating of Damaged Poles in Distribution Network through Images Shot by Unmanned Aerial Vehicle (UA V). *Proceedings of 2020 IEEE International Conference on Information Technology, Big Data and Artificial Intelligence, ICIBA 2020*, 1048-1052. https://doi.org/10.1109/ICIBA50161.2020.9277438

Watts, D. C., & McCabe, J. F. (1999). Aluminium radiopacity standards for dentistry: An international survey. *Journal of Dentistry*, *27*(1), 73-78. https://doi.org/10.1016/S0300-5712(98)00025-6

Weir, M. D., Chow, L. C., & Xu, H. H. K. (2012). Remineralization of Demineralized Enamel via Calcium Phosphate Nanocomposite. *Journal of Dental Research*, *91*(10), 979-984. https://doi.org/10.1177/0022034512458288

Whaites, E., & Drage, N. (2013). *Essentials of dental radiography and radiology*. Elsevier Health Sciences.

White, S. N., Ingles, S., & Kipnis, V. (1994). Influence of marginal opening on microleakage of cemented artificial crowns. *The Journal of Prosthetic Dentistry*, *71*(3), 257-264. https://doi.org/10.1016/0022-3913(94)90464-2

White, S. N., Yu, Z., & Kipnis, V. (1992). Effect of seating force on film thickness of new adhesive luting agents. *The Journal of Prosthetic Dentistry*, *68*(3), 476-481. https://doi.org/10.1016/0022-3913(92)90414-6

White, S., & Pharoah, M. (2014). *Oral radiology-E-Book: Principles and interpretation*. https://books.google.com.tr/books?hl=en&lr=&id=V7PwAwAAQBAJ&oi=fnd&pg=PP1&dq=Pharoah+MJ.+Oral+radiology:+principles+and+interpretation.+2004.&ots=EovuXT9DYM&sig=kgMIUXQlfBlQuFK0tQ3pEEAX0UU&redir_esc=y#v=onepage&q=Pharoah MJ. Oral radiology%3A principles a

Widrow, B., & Hoff, M. E. (1962). Associative Storage and Retrieval of Digital Information in Networks of Adaptive “Neurons”. Içinde *Biological Prototypes and Synthetic Systems* (ss. 160-160). Springer US. https://doi.org/10.1007/978-1-4684-1716-6_25

Wilson, A., & Nicholson, J. (1993). Acid-base cements, their biomedical and industrial applications. *New York:Cambridge University Press*, 1-383.

Woo, S., Park, J., Lee, J.-Y., & Kweon, I. S. (2018). *CBAM: Convolutional Block Attention Module* (ss. 3-19).

Wrzesień, M., & Olszewski, J. (2017). Absorbed doses for patients undergoing panoramic radiography, cephalometric radiography and CBCT. *International Journal of Occupational Medicine and Environmental Health*, *30*(5), 705-713. https://doi.org/10.13075/ijomeh.1896.00960

Xu, R., Lin, H., Lu, K., Cao, L., & Liu, Y. (2021). A Forest Fire Detection System Based on Ensemble Learning. *Forests 2021, Vol. 12, Page 217*, *12*(2), 217. https://doi.org/10.3390/F12020217

Yadav, P., Sharma, V., Paliwal, J., Meena, K. K., Madaan, R., & Gurjar, B. (2023). An In Vitro Comparison of Zirconia and Hybrid Ceramic Crowns With Heavy Chamfer and Shoulder Finish Lines. *Cureus*, *15*(1). https://doi.org/10.7759/cureus.33940

Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology. *Insights into Imaging*, *9*(4), 611-629. https://doi.org/10.1007/S13244-018-0639-9/FIGURES/15

Yu, D., Wang, H., Chen, P., & Wei, Z. (2014). *Mixed Pooling for Convolutional Neural Networks* (ss. 364-375). https://doi.org/10.1007/978-3-319-11740-9_34

Yu, H. (2014). *Article in Oral Health and Dental Management*.

Yu, H., Chen, Y., Cheng, H., & Sawase, T. (2019). Finish-line designs for ceramic crowns: A systematic review and meta-analysis. *The Journal of Prosthetic Dentistry*, *122*(1), 22-30.e5. https://doi.org/10.1016/j.prosdent.2018.10.002

Yung, N. D. T., Wong, W. K., Juwono, F. H., & Sim, Z. A. (2022). Safety Helmet Detection Using Deep Learning: Implementation and Comparative Study Using YOLOv5, YOLOv6, and YOLOv7. *2022 International Conference on Green Energy, Computing and Sustainable Technology (GECOST)*, 164-170. https://doi.org/10.1109/GECOST55694.2022.10010490

Zhang, X., Tu, R., Yin, W., Zhou, X., Li, X., & Hu, D. (2013). Micro-computerized tomography assessment of fluorescence aided caries excavation (FACE) technology: comparison with three other caries removal techniques. *Australian Dental Journal*, *58*(4), 461-467. https://doi.org/10.1111/ADJ.12106

Zhang, Y., Sun, Y., Wang, Z., & Jiang, Y. (2023). YOLOv7-RAR for Urban Vehicle Detection. *Sensors*, *23*(4), 1801. https://doi.org/10.3390/s23041801

Zhiqiang, W., & Jun, L. (2017). A review of object detection based on convolutional neural network. *2017 36th Chinese Control Conference (CCC)*, 11104-11109. https://doi.org/10.23919/ChiCC.2017.8029130

Zhu, X., & Goldberg, A. B. (2009). Introduction to Semi-Supervised Learning. *Synthesis Lectures on Artificial Intelligence and Machine Learning*, *3*(1), 1-130. https://doi.org/10.2200/S00196ED1V01Y200906AIM006

Zitzmann, N. U., Hagmann, E., & Weiger, R. (2007). What is the prevalence of various types of prosthetic dental restorations in Europe? *Clinical Oral Implants Research*, *18*, 20-33. https://doi.org/10.1111/j.1600-0501.2007.01435.x

Zitzmann, N. U., Krastl, G., Hecker, H., Walter, C., Waltimo, T., & Weiger, R. (2010). Strategic considerations in treatment planning: deciding when to treat, extract, or replace a questionable tooth. *The Journal of prosthetic dentistry*, *104*(2), 80-91.

Zmener, O., Pameijer, C. H., & Hernandez, S. (2014). Resistance against bacterial leakage of four luting agents used for cementation of complete cast crowns. *Am J Dent*, *27*(1), 51-55.

Zoellner, A., Heuermann, M., Weber, H.-P., & Gaengler, P. (2002). Secondary caries in crowned teeth: Correlation of clinical and radiographic findings. *The Journal of Prosthetic Dentistry*, *88*(3), 314-319. https://doi.org/10.1067/mpr.2002.128122

Zulauf, A. F. (1922). *Panoramic XZ-ray apparatus* (Patent 1408559).

ÖZGEÇMİŞ

Adı Soyadı: Betül AYHAN

Doğum Yeri ve Tarihi:

Medeni durumu:

Uyruğu: T.C.

Yabancı Dil: İngilizce

Eğitim Durumu:

Lise: İzmir Anadolu Lisesi/İZMİR (2008-2012)

Yüksek Lisans: Ege Üniversitesi Diş Hekimliği Fakültesi (2013-2018)

Uzmanlık: Atatürk Üniversitesi Diş Hekimliği Fakültesi Protetik Diş Tedavisi (2020-2021); Kırıkkale Üniversitesi Diş Hekimliği Fakültesi Protetik Diş Tedavisi (2021-)

KIRIKKALE ÜNİVERSİTESİ
GİRİŞİMSEL OLMAYAN ARAŞTIRMALAR ETİK KURUL KARARI

Toplantı Tarihi: 28.09.2022
Toplantı Sayısı: 2022/12
Karar No: 2022.09.22

Üniversitemiz Girişimsel Olmayan Araştırmalar Etik Kurulu 28.09.2022 Çarşamba günü saat 10:00'da Prof. Dr. Sema ZERGEROĞLU'nun başkanlığında toplanarak gündemdeki, Kırıkkale Üniversitesi Diş Hekimliği Fakültesi Protetik Diş Tedavisi Anabilim Dalı, Prof. Dr. Saadet SAĞLAM ATSÜ'nün danışmanlığında yürütülecek olan Arş. Gör. Betül AYHAN'ın uzmanlık tezi **"Derin Öğrenme Yöntemine Dayalı Yapay Zeka Algoritmalarıyla Panoramik Radyografilerde İncelenen Sabit Protetik Restorasyonlar Altında Oluşan Çürüklerin Tespiti"** isimli araştırma konusu yardımcı araştırmacı, Arş. Gör. Dr. Enes AYAN'ın, katılımıyla yürütülecek olan uzmanlık tezi başvurusunu görüştü.

KARAR: Kırıkkale Üniversitesi Diş Hekimliği Fakültesi Protetik Diş Tedavisi Anabilim Dalı, Prof. Dr. Saadet SAĞLAM ATSÜ'nün danışmanlığında yürütülecek olan Arş. Gör. Betül AYHAN'ın uzmanlık tezi **"Derin Öğrenme Yöntemine Dayalı Yapay Zeka Algoritmalarıyla Panoramik Radyografilerde İncelenen Sabit Protetik Restorasyonlar Altında Oluşan Çürüklerin Tespiti"** isimli araştırma konusu yardımcı araştırmacı, Arş. Gör. Dr. Enes AYAN'ın, katılımıyla yürütülecek olan uzmanlık tezi başvurusunu Kırıkkale Üniversitesi Girişimsel Olmayan Araştırmalar Etik Kurulu Yönergesinde belirtilmiş olan Etik İlkelere uygun bulunmuştur.