



YAKIN DOĐU ÜNİVERSİTESİ  
Eđitimde 37 Yıl

KUZEY KIBRIS TÜRK CUMHURİYETİ  
YAKIN DOĐU ÜNİVERSİTESİ  
LİSANSÜSTÜ EĐİTİM ENSTİTÜSÜ

ORTOPANTOMOĞRAFİLER ÜZERİNDE; DİŐLERİN,  
ÇÜRÜKLERİN, DENTAL RESTORASYONLARIN VE KÖK  
ARTIKLARININ YAPAY ZEKA TABANLI OTOMATİK  
SEGMENTASYONU

EMEL GARDİYANOĐLU  
DOKTORA TEZİ

AĐIZ, DİŐ VE ÇENE RADYOLOJİSİ ANABİLİM DALI

DANIŐMAN  
PROF. DR. SEÇİL AKSOY

2023-LEFKOŐA

Onay

Emel Gardiyanođlu tarafından hazırlanan Ortopantomografiler Üzerinde Dişlerin, Çürüklerin, Dental Restorasyonların ve Kök Artıklarının Yapay Zekâ Tabanlı Otomatik Segmentasyonu” başlıklı tez, kapsam ve nitelik açısından kalite standartlarına uygunluğu ile ilgili Ağız, Diş ve Çene Radyolojisi Anabilim Dalında Doktora Tezi olarak 02/05/2023 tarihinde kabul edilmiştir.

Jüri Üyeleri

Adı – Soyadı

İmza

Juri Başkanı: Prof. Dr. Kaan Orhan

Juri Üyesi: Prof. Dr. İ. Hakan Avsever

Danışman: Prof. Dr. Seçil Aksoy

Juri Üyesi: Yrd. Doç. Dr. Melis Mısırlı Gülbeş

Juri Üyesi: Yrd. Doç. Dr. Gürkan Ünsal

Anabilim/ Anasanat Dalı Başkanı Onayı

Lisansüstü Eğitim Enstitüsü Onayı

  
02/05/2023

Prof. Dr. Seçil Aksoy

Ağız, Diş ve Çene Radyolojisi

Anabilim Dalı Başkanı

02/05/2023

Prof. Dr. Kemal Hüsnü Can Başer

Enstitü Müdürü



## **Etik İkelere Uygunluk Beyanı**

Bu tezin içinde sunduđum verileri, bilgileri ve belgeleri akademik ve etik kurallar çerçevesinde elde ettiđimi; tüm bilgi, belge, deđerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduđumu; çalışmada bana ait olmayan tüm veri, düşünce, sonuç ve bilgilere bilimsel etik kurallar geređi olarak eksiksiz şekilde uygun atıf yaptıđımı ve kaynak göstererek belirttiđimi beyan ederim.

Emel Gardiyanođlu

02/05/2023

## **Teşekkür**

Doktora eğitimim süresince her konuda desteğini esirgemeyen tez danışman hocam, Sayın Prof. Dr. Seçil Aksoy'a;

Fikirleri ile birçok kişiye rehber olan hocam Sayın Prof. Dr. Kaan Orhan'a;

Ayrıca tez yazım aşamasında bana sonsuz destek olan ve yardımını esirgemeyen hocam Dr. Gürkan Ünsal'a ve tezimin ortaya çıkmasında büyük emeği olan hocam Sayın Nurullah Akkaya'ya;

Tüm kalbimle teşekkürlerimi sunarım.

Emel Gardiyanoglu

## Özet

# Ortopantomografiler Üzerinde Dişlerin, Çürüklerin, Dental Restorasyonların ve Kök Artıklarının Yapay Zekâ Tabanlı Otomatik Segmentasyonu

Gardiyanoglu, Emel

Doktora, Ağız, Diş ve Çene Radyolojisi Anabilim Dalı

Mayıs 2023, 92 sayfa

Araştırmamızın amacı, Ortopantomografi (OPG) görüntülerinde çeşitli dental tedavi materyalleri ve patolojilerinin başarılı otomatik segmentasyonunu sağlamaktır. Çalışmaya Yakın Doğu Üniversitesi Ağız, Diş ve Çene Radyolojisi bölümü arşivinden elde edilen 8138 OPG görüntüsü dahil edilmiştir. OPG görüntüleri png formatına dönüştürülmüş ve segmentasyon araçlarının veritabanına aktarılmıştır. Tüm dişler, kron-köprü restorasyonları, diş implantları, kompozit-amalgam dolgular, diş çürükleri, artık kökler ve kök kanalı tedavileri manuel çizim semantik segmentasyon tekniği ile manuel olarak segmente edilmiştir. Tüm görüntüler, kenar boşlukları oluşturma noktaları ile belirlenerek bölümlere ayrılmış ve model bu segmentasyonlarla eğitilmiştir. Tüm segmentasyonlar; %80 eğitim seti, %10 doğrulama seti ve %10 test seti olarak üçe ayrılmış ve test setindeki en başarılı model tüm ölçümler arasından seçilmiştir. İstatistiksel analiz için Dice Similarity Score (DSC) ve doğruluk değerleri hesaplanmıştır. Sonuç olarak oluşturduğumuz YZ programının OPG'ler üzerinde hesaplanan DSC ve doğruluk değerleri sırasıyla diş segmentasyonu için 0.85 ve 0.95, diş çürükleri için 0.88 ve 0.99, dental dolgular için 0.87 ve 0.99, kron-köprü restorasyonları için 0.93 ve 0.99, diş implantları için 0.94 ve 0.99, kök kanalı tedavileri için 0.78 ve 0.99, kalan kökler için 0.78 ve 0.99' olarak bulunmuştur. Bu yapay zeka programı diş hekimlerinin panoramik radyografilerde hem dental durumun değerlendirilmesinde hem de mevcut patolojilerin teşhisinde iyi bir yardımcı olacaktır.

**Anahtar Sözcükler:** otomatik segmentasyon, ortopantomografi, yapay zekâ, derin öğrenme.

## **Abstract**

### **Automatic Segmentation of Teeth, Caries, Dental Restorations and Residual Roots on Orthopantomographs: Convenience and Pitfalls**

**Gardiyanoglu, Emel**

**PhD, Department of Dentomaxillofacial Radiology**

**May 2023, 92 pages**

The aim of our research is to provide successful automatic segmentation of various dental treatment materials and pathologies in Orthopantomography (OPG) images. 8138 OPG images obtained from the archive of the Department of Dentomaxillofacial Radiology were included in the study. OPG images were converted to png format and transferred to the segmentation tool's database. All teeth, crown-bridge restorations, dental implants, composite-amalgam fillings, dental caries, residual roots and root canal fillings were manually segmented using the manual drawing semantic segmentation technique. All images are segmented with margins determined by the rendering points, and the model is trained with these segmentations. All segmentations were divided into three as 80% training set, 10% validation set and 10% test set, and the most successful model in the test set was selected among all measurements. Dice Similarity Score (DSC) and accuracy values were calculated for statistical analysis. The calculated DSC and accuracy values across all OPGs 0.85 and 0.95 for the tooth segmentation, 0.88 and 0.99 for dental caries, 0.87 and 0.99 for dental restorations, 0.93 and 0.99 for crown-bridge restorations, 0.94 and 0.99 for dental implants, 0.78 and 0.99 for root-canal fillings, 0.78 and 0.99 for residual roots, respectively. This artificial intelligence program will be a good help for dentists both in the evaluation of the dental condition and in the diagnosis of existing pathologies in panoramic radiographs.

**Keywords:** automatic segmentation, orthopantomography, artificial intelligence, deep learning

## İçindekiler

Onay Sayfası	II
Etik İlkelere Uygunluk Beyanı	III
Teşekkür	IV
Özet	V
Abstract	VI
İçindekiler	VII
Tablolar Listesi	X
Şekiller Listesi	XI
Kısaltmalar	XIII

### BÖLÜM I

Giriş .....	1
Sağlık Alanında Yapay Zekanın Kullanımı .....	
Araştırmanın Amacı .....	2

### BÖLÜM II

Diş Hekimliğinde Kullanılan İki Boyutlu Görüntüleme Yöntemleri .....	3
Periapikal Radyografiler .....	4
Bitewing Radyografiler .....	5
Ortopantomografi .....	5
Lateral Sefalometrik Radyografiler .....	9
Yapay Zeka .....	10

Yapay Zekanın Tarihçesi .....	14
Yapay zeka Öğrenme Biçimleri .....	17
Makine Öğrenimi .....	17
Derin Öğrenme .....	19
Sinir Ağları .....	20
Yapay sinir ağları .....	22
Evrışimli sinir ağları .....	25
Diş Hekimliğinden Yapay Zeka-Makine Öğrenimi ve Derin Öğrenme Uygulamaları .....	28
Yapay Zekanın Diş Hekimliğinde Kullanımı-Agrawal ve Nikhade'nin Yaklaşımı .....	29
Yapay Zekanın Ağız Kanseri Vakalarında Kullanımı .....	30
Yapay Zekanın Ortodonti Alanında Kullanımı .....	31
Yapay Zekanın Periyodontoloji Alanında Kullanımı .....	32
Yapay Zekanın Restoratif Kullanımı .....	32
Yapay Zekanın Endodonti Alanında Kullanımı .....	33
Yapay Zekanın Diğer Uygulama Alanları .....	34
Ağız, Diş ve Çene Radyolojisi'nde Yapay Zeka Uygulamaları .....	34
Yapay Zeka Kullanımı ile İlgili Limitasyonlar .....	37
Yapay zeka ve Diş Hekimliğinin Geleceği .....	379

### BÖLÜM III

Yöntem .....	41
Etik Kurul Onayı .....	41
Veri Setinin Oluşturulması .....	41
OPG Görüntülerinin Elde Edilmesi .....	41
OPG Görüntülerinden İncelenecek Yapıların Tespit Edilmesi .....	42



Semantik Segmentasyon .....	42
Sınıflandırma Modellerinin Performans Ölçütleri .....	43
Dice Similarity Coefficient Hesaplanması .....	43
BÖLÜM IV	
Bulgular ve Yorumlar .....	45
BÖLÜM V	
Tartışma .....	55
BÖLÜM VI	
Sonuç ve Öneriler .....	65
Kaynakça .....	66
Ekler .....	80

## **Tablo Listesi**

Tablo 1: Tüm OPG'lerde hesaplanan DSC ve doğruluk deęerleri.....	45
--	----

## Şekiller Listesi

- Şekil 1. Makine Öğrenme Modeli (Lawrynowicz ve Tresp, 2014)
- Şekil 2. Derin Öğrenmenin Yararı (Mathew, Amudha ve Sivakumari, 2021)
- Şekil 3. Örnek Yapay Sinir Ağı Mimarisi (Walczak ve Cerpa, 2003)
- Şekil 4. Derin Evrişimsel Sinir Ağı Algoritması Şeması
- Şekil 5. Görüntü Bölütleme İşlemi
- Şekil 6. Dental İmplantların Manuel Segmentasyon İşlemi
- Şekil 7. Dişlerin Manuel (üst) ve Otomatik (alt) Segmentasyonu.
- Şekil 8. Sağ Maksiller İkinci Molarda ve Sağ Alt Birinci Molarda Çürük Lezyonların Manuel (sol) ve Otomatik (sağ) Segmentasyonu.
- Şekil 9. Köprü Restorasyonlarının Manuel (üst) ve Otomatik (alt) Segmentasyonu
- Şekil 10. Sol Maksiller Premolar ve Molar Bölgelerdeki Dental İmplantların Manuel (üst) ve Otomatik (alt) Segmentasyonu.
- Şekil 11. Sağ ve Sol Mandibuler 1. Molar Dişlerdeki Kök Kanal Tedavilerinin Manuel (üst) ve Otomatik (alt) Segmentasyonu.
- Şekil 12. Artık Köklerin Manuel (üst) ve Otomatik (alt) Segmentasyonu.
- Şekil 13. Maksiller 3.Molar Dişlerin Maksiller Sinüs Tabanı Arasındaki Süperpozisyona Bağlı Segmentasyon Hatası
- Şekil 14. Mandibular Sol Birinci ve İkinci Premolar Diş Arasındaki Süperpozisyona Bağlı Segmentasyon Hatası
- Şekil 15. Sağ Maksiller İkinci ve Üçüncü Molar Dişlerin Süperpozisyonlara Bağlı Olarak Eksik Segmentasyonları İzlenmektedir.
- Şekil 16. Mandibuler Sol Birinci Premolar Dişte Geniş Amalgam Restorasyonun Kron-Köprü Segmentasyonu Olarak Hatalı Etiketlenmesi.
- Şekil 17. (A) Mandibular Sağ Birinci Molar Dişteki Geniş Amalgam Dolgusunun Kron Restorasyonu Olarak Hatalı Segmentasyonu (B) Maksiller Sağ İkinci Molar Dişteki Geniş Amalgam Dolgusunun Kron Restorasyonu Olarak Hatalı

Segmentasyonu (C) Maksiller Sol Kanin Dişin Distalinde Bulunan Distal Metalik Uzantının (protez resti), Kron-Köprü Restorasyonu Olarak Hatalı Segmentasyonu.

Şekil 18. OPG’de İmplant Abutmentlarının ve Protez Barının Düzgün Olarak Segment Edildiği ve İmplantların Model Tarafından Ayırt Edilebildiği Görülmektedir.

Şekil 19. İmplant, İmplant Abutmanı ve İmplantı Üstü Kronun Bölümleri İle Segmentasyonlar Arasındaki Fark

Şekil 20. Tek Gütaperka İle Yapılmış Kanal Tedavisi Bulunan Sol Mandibuler 1. Molar Dişin Hatalı Segmentasyonu.

## Kısaltmalar

2B	2 Boyutlu
3B	3 Boyutlu
BM	Birleşmiş Milletler
BD	Büyük veri
CAD	Computer Aided Diagnosis
CNN	Convolutional Neural Networks – Evrişimli Sinir Ağları
DL	Deep Learning
GAN	Generative Adversarial Networks - Üretken Çekişmeli Ağlar
GPU	Graphics Processing Unit
IR	Industry Revolution - Endüstri Devrimi
KIBT	Konik Işınli Bilgisayarlı Tomografi
LCR	Lateral sefalometrik radyografinin
ML	Machine Learning
OPG	Ortopantomogram
YSA	Yapay Sinir Ağları
YZ	Yapay zeka

# BÖLÜM I

## Giriş

Dördüncü Sanayi Devrimi ile hayatımızdaki yeri geri dönülemez biçimde sağlamlaşan Yapay zeka (YZ), kapsamının genişliği nedeniyle tanımlanması oldukça güç bir kavramdır. YZ'yi tanımlamanın güçlüğü teknolojik unsurlar ile insani becerileri bir araya getirebilme becerisinden kaynaklanmaktadır. Teknoloji ve insani becerilerin birlikte anıldığı pek çok yaklaşımda teknoloji ailesi, öğrenme, sorun çözme, yorumlama, esnek uyarılma, makine zekası, simülasyon gibi anahtar kavramlar çerçevesinde ele alındığı görülmektedir. Kısaca insan zekasına ilişkin süreçlerin bilgisayar sistemleri tarafından yürütülmesi şeklinde açıklanabilecek YZ, daha doğru ve etkili tahminler yapmaya, hacimli verileri sınıflandırmaya ve analiz etmeye kadar pek çok alanda hizmet vermektedir. Sağlık hizmetleri de bu kullanım alanlarından biri olmuştur. Yapay zeka sağlık alanında ameliyat maliyetlerinin daha uygun hale getirilmesinden, hastalıkların teşhisine ve hatta klinik karar alma süreçlerine kadar pek çok alanda fırsat sunmaktadır.

Makine öğrenme günümüzde iş amaçlı oldukça yaygın kullanılan bir YZ türüdür. Makine öğrenme ile yüklü miktarda veri hızlı bir biçimde işlenmektedir ve bu işlemler sayesinde, zamanla öğrenen YZ, yaptıkları işleri daha başarılı bir şekilde tamamlamaktadır. Arama motoru sıralamasından, alışveriş tavsiyelerine kadar yaygın bir biçimde ve gündelik hayat akışında deneyimlenen bu algoritma kuşkusuz sağlık alanında da kullanılmaktadır.

### **Yapay Zekanın Sağlık Alanında Kullanımı**

Sağlık alanında kullanılan YZ yöntemleri, görüntüleme verilerindeki karmaşık kalıpları otomatik olarak tanımlama ve radyografik özelliklerin nitel yerine nicel değerlendirmelerini sağlama konusunda mükemmeldir. Özellikle toraksik görüntüleme, beyin görüntülemesi veya abdominal ve pelvik görüntülemede YZ nodüllerin ya da tümörlerin tespit edilmesinde ve bu tümörlerin benign ya da malign olarak sınıflandırılmasında kullanılabilmektedir. Aynı zamanda YZ, tarama mamografisinin uzmanlarca yorumlanması teknik olarak zor olan mikrokalsifikasyonları tanımlayarak ve karakterize ederek radyoloğa yardımcı olabilmektedir (Hosny, vd. 2018).

YZ'nin tıpta olduđu kadar diř hekimliđinde de uygulamaları son yıllarda hızlı artmaktadır. Özellikle diř hekimliđi radyolojisinde kullanılan periapikal radyograflar, bite-wing radyograflar, ortopantomografiler (OPG) ve konik ışınlı bilgisayarlı tomografi YZ'nin son alıřmalarının bđyđk bir kısmını temsil etmektedir. Klinisyenler, YZ algoritmalarını kullanarak diř đrđđđ, apikal lezyon, odontonejik kistler gibi yapıları tespit edebilmekle beraber ortodontik tedavi planı, endodontik tedavi planı, dental implant cerrahisi gibi planlama gerektiren tedavilerde de YZ'den faydalanmaktadır.

YZ'nin bu amalar dođrultusunda geliřtirilen algoritmaları, klinisyenlerin genellikle retrospektif bir veriseti izerindeki segmentasyonları (iřaretlemeleri) ile eđitildikten ve farklı verisetlerinde de gđvenilirlikleri test edildikten sonra kullanıcılara sunulan yazılımlar haline getirilmektedir.

#### **Arařtırmanın Amacı**

Ortopantomograflar izerinde; diřlerin, kron-köprđ restorasyonlarının, dental implantların, dolguların, diř đrđklerinin, kök kalıntılarının ve kök kanal dolumlarının YZ tabanlı otomatik segmentasyonu sađlamak iin geliřtirilen, ticari olmayan bir algoritmanın bařarısını test etmek, ilgili sđrete rastlanılan limitasyonları ve klinisyenlerin bu yazılımları kullanırken dikkat etmesi gereken noktaları tartıřmaktır.

## BÖLÜM II

### Diş Hekimliğinde Kullanılan İki Boyutlu Görüntüleme Yöntemleri

Radyografik incelemeler, diş hekimliğinde hastalık durumlarını belirlemek ve uygun tedaviyi planlamak için kullanılan birincil teşhis araçlarıdır. X ışınlarının keşfinden sonra 1895 yılında Dr. Otto Walkhoff, ilk dental röntgen görüntüsünü elde etmiştir. Dental radyograflar, görüntü kalitesi doğru yorumlama için yeterli olduğunda oldukça değerli teşhis araçlarıdır (Gupta, vd., 2014).

İntra oral radyografi sisteminin çalışma prensibi, x-ışınlarının bir film veya dijital reseptör üzerinden iletilmesi, atenü olması ve kaydedilmesi esasına dayanmaktadır. Röntgen cihazının doğru bir projeksiyon sağlaması için, nesnenin ve sensörün optimize edilmiş geometrik konfigürasyonu gerekmektedir. Görüntüleme sisteminin bileşenlerinden herhangi birinin bu geometrik kuralları ihlal etmesi halinde elde edilen görüntüde açısal hatalar meydana gelebilmektedir. (Sethi vd., 2016).

Dental radyograflar, diş hekimliği pratiğinde rutin teşhis prosedürleri için mevcut altın standarttır. Bite-wing ve periapikal radyograflar gibi intraoral teknikler, dental arkların yalnızca çok sınırlı bir alanındaki dişlerin kronları ve kökleri hakkında ayrıntılı bilgi sağlarken, OPGler üst ve alt çenenin eksiksiz bir genel görünümünü vermektedir (White & Pharoah, 2014).

Konik ışınlı bilgisayarlı tomografi (KIBT) iki boyutlu bir detektör üzerinde ortalanmış koni şeklinde bir x-ışını demetini kullanmaktadır. KIBT, görüntüsü elde edilecek olan nesnenin etrafında tek bir dönüş gerçekleştirmekte ve ardından 160 ila 599 temel görüntüden oluşan bir dizi yakalamaktadır (Sethi vd., 2016).

En çok kullanılan dental radyolojik tetkikler ağız içi radyograflar (periapikal ve bite-wing radyografi), ağız dışı radyograflar (OPG, lateral ve frontal sefalometri, temporomandibular eklem radyografisi), bilgisayarlı tomografi (BT) ve KIBT'tır. OPG ile yapılan radyografik muayene, tüm diş hekimliği uzmanlıklarında fayda sağlamaktadır. Bunların bazıları şunlardır (Decusara vd., 2017):



- a) Protetik diş tedavisinde, çekimden sonra alveol kemiğinde kalan kök parçalarını, gömülü dişleri, odontojenik kistleri veya diğer kemik patolojisi oluşumlarını keşfedebilmektedir. OPG, mandibulanın yapısını, maksiller sinüs tabanının alveoler krete göre topografisini, alveolar sırtların yapısını ve alveolar proçesi, alveolar kret boyutunu göstermektedir.
- b) Oral ve maksillofasiyal cerrahide, maksiller ve mandibular kırıkların, odontojenik tümörlerin, maksillanın enflamatuvar lezyonlarının (osteitis veya osteomyelit) teşhis edilmesine, çenelerin cerrahi tedavisine (osteotomi, alveolar kret elevasyonu, vb.) yardımcı olmaktadır.
- c) İmplantolojide, dental implantların uzunluğu için bir kriter olarak, mandibular kemik yüksekliğinin, mandibular kanal oranının, maksiller sinüsün yakınlığını hakkında klinisyene fikir sağlayabilmektedir.

İki boyutlu görüntüleme uygulamalarına ilişkin genel düzeyde bilgi verilmiş olmasına karşın periapikal radyografiler, bitewing radyografiler, OPG ve lateral sefalometrik radyografiler hakkında ayrıntılı bilgi vermek iki boyutlu görüntüleme uygulamalarını daha net bir biçimde tarif etmek için gereklidir.

Diş hekimliği pratiğinde rutin kullanılan 2 boyutlu görüntüleme yöntemleri:

### **Periapikal Radyografiler**

Periapikal sözcüğü etimolojik olarak peri ve apeks kelimelerinden türetilmiştir. Periapikal radyografiler dişlerin ve çevre dokuların ana hatlarını, konumunu ve meziodistal uzantısını kaydetmektedirler. Periapikal radyografiler dişler ve çevre kemikler hakkında önemli bilgiler sağlamaktadırlar (Gupta vd., 2014). Ağız içi radyografik muayenenin ana parçası olan periapikal radyografisi, çevredeki periapikal kemiğin en az 2 mm'si dahil olmak üzere bir dişin tamamını göstermektedir. (Ersan vd., 2016).

Periapikal radyografilerde dişlerin kron, kök ve periapikal dokular ile çürük, periapikal lezyon ve alveolar kemik kayıpları görüntülenebilmektedir. Restorasyonların durumu, gömülü dişler veya kırık diş parçaları, diş ve kemik anatomisindeki varyasyonlar gibi ek önemli bulgular da tespit edilebilmektedir (Gupta vd., 2014).

### **Bitewing Radyografiler**

Çürük lezyonlarının doğru teşhisinde, diş hekimliği pratiğinde kullanılan en etkili radyografi yöntemidir. Bununla birlikte inspeksiyon ile muayene interproksimal çürük tespitinde sınırlı başarıya sahiptir. Bu nedenle intraoral muayene ile belirlenemeyen interproksimal çürüklerin tespiti için sıklıkla bitewing radyografilere başvurulmaktadır. (Schwendicke & Göstemeyer, 2020). Bitewing radyografilerin kullanım alanları; (Schwendicke & Göstemeyer, 2020).

- Oklüzal ve proksimal yüzeylerde primer koronal çürük lezyonlarının erken tespiti
- Proksimal kök çürüklerinin tespiti.
- Restorasyonların kalitesinin değerlendirilmesi ve proksimal bölgede sekonder çürüklerin tespiti.
- Mine ve dentin çürük lezyonlarında lezyon uzantısının tespiti.
- Çürük lezyonlarının uzun süreli takibi

### **Ortopantomografi**

OPG minimum geometrik distorsiyon ve süperpozisyon ile hem dental arkların hem de detsekleyici yapıların tek bir tomografik görüntüsünün elde edilmesi ile sağlanan tekniktir. OPG, dişlerin ve çenelerin eksiksiz bir görünümünü sağladığından, genellikle diş hekimleri tarafından bir tarama aracı olarak değerlendirilmektedir (White & Pharoah, 2014).

OPG, değişik düzeylerdeki yapıların görüntülerinin üst üste düşmeleri önlenerek sadece görüntülenmesi istenen tabakanın (focal through, imaj tabakası) incelendiği tomografi prensibine dayanmaktadır ve görüntülenmek istenen yapılar, imaj tabakası olarak da tanımlanan at nalı şeklinde bu bölge içerisinde konumlandırılması koşuluyla tam olarak görüntülenebilmektedir. Bu bölge içerisinde konumlandırılan yapılar OPG'lerde net bir şekilde izlenmektedir. Tomografi tekniğinde hasta, ışın kaynağı veya filmde biri sabit tutulurken diğer iki komponent ters yönde ve eşit hızda hareket eder ve imaj tabakasının önünde veya arkasında kalan alanlar bulanıklaşır, görülebilirliği büyük oranda azalır veya distorsiyona uğrar. Günümüzde tek, iki ve üç rotasyon merkezli cihazlar yerini dental arklardaki boyut farklılıkları ve ırksal özelliklere bağlı magnifikasyon ve distorsiyonları minimize eden çok rotasyon merkezli cihazlara bırakmıştır.

Panoramik radyografide günümüzde konvansiyonel yöntemler yerini dijital radyografiye bırakmakta bu sayede minimum radyasyon ile görüntü elde etmenin yanı sıra görüntü iyileştirme algoritmaları sayesinde görüntüden maksimum diagnostik fayda sağlanabilmektedir. (White & Pharoah, 2014).

Radyografi çekimi sırasında hastanın başı sabit kalırken ışın kaynağı ve film kaseti eşit hızla ve birbiri ile ters yönde başın etrafında rotasyon hareketi yapmaktadır. Tüpten çıkan X ışınları, film kasetinin yerleştirildiği kısmın önündeki kurşun plakta bulunan küçük açıklıktan (kolimatör) hastanın baş ve çene kısmını geçerek filme ulaşır ve tüm rotasyon hareketi boyunca görüntüyü kesitler halinde oluştururlar. Çekim sırasında hastanın doğru bir şekilde pozisyonlandırılması, çene ve dişlerin imaj tabakası içinde yerleşebilmesi açısından büyük önem taşımaktadır. OPG çekilirken hastanın çenesi cihazın tablasına yerleştirilip, çene desteği ve ısırma çubuğu kullanılarak hastanın antero-posterior konumu ayarlanmaktadır. Bunun için hastadan ısırma bloğu üzerindeki çentiği alt ve üst kesici dişleri ile ısırması istenir. Hastanın mid hattı cihazın tam ortasında, ısırma çubuğunu üzerinde ve yere dik olmalıdır. Hastanın horizontal düzlemine düzlemi (tragus-gözün dış kantusu arası) yere paralel olmalıdır ve sefolastatla başı sabitlendikten sonra iki eli ile cihazın kollarını tutması ve ayaklarını 20 cm kadar öne getirmesi istenir (ski pozisyonu). Baş pozisyonunu ayarlanmasını takiben hastadan dilini damağına değdirecek şekilde durması ve yutkunması istenir. (White & Pharoah, 2014).

OPG endikasyonlarını özetlemek gerekirse (Rushton & Horner, 1996), (Ekströmer & Hjalmarsson 2014).

- İntraoral radyografi alınmasını imkansız kılan kusma refleksi olan hastalar
- Çenelerin geniş kapsamlı değerlendirilmesini gerektirecek diagnostik problemler ve diğer görüntülemelere olan ihtiyacı belirlemede
- İntraosseöz lezyonların değerlendirmesi ve takibinde
- Preoperatif ve postoperatif değerlendirme ile iyileşme takibinin yapılmasında
- Gömülü veya yarı gömülü dişlerin lokalizasyonlarının ve anatomik yapılarla ilişkilerinin belirlenmesinde

- Total/parsiyal protez öncesinde rezidüel kök varlıklarının değerlendirilmesinde.
- Başta karışık dişlenme olmak üzere diş gelişim ve sürme süreçlerinin incelenmesinde
- Sendromik ve sendromik olmayan gelişimsel anomaliler çene yüz bölgesine ait bulgularının tanımlanmasında
- Temporomandibular eklemin sert doku patolojilerinin araştırılmasında
- Maksillofasiyal fraktür araştırılmasında
- İmplant öncesi her iki çenenin karşılıklı ilişkisinin değerlendirilmesinde
- En büyük paranasal sinüs olan maksiller sinüsün değerlendirmesinde
- Nazal fossa tabanı ve nazal septum ile nazal konkaların değerlendirilmesinde
- Adli diş hekimliğinde kimlik tespiti, yaş tespiti gibi hukuki prosedürleride kullanımında

OPG'nin diğer dental görüntülemelere üstün olduğu durumlar özetlenirse (Ekströmer & Hjalmarsson, 2014).

- Alt ve üst çene ile çevre dokuları aynı görüntü üzerinde görüntüleyebilme yeteneğine sahiptir.
- Görüntülemenin uygulanma aşamaları hızlı ve kolaydır.
- Trismuslu veya çeşitli nedenlerle intraoral radyografi çekilemeyen hastalarda kısıtlamalarına rağmen iyi bir alternatiftir.
- Efektif radyasyon dozu oranı KIBT'a göre düşüktür.
- Periapikal serigrafide olduğu gibi aynı anatomik bölgelerin tekrarlayan X ışını maruziyeti söz konusu değildir.
- Bazı metabolik kemik hastalıklarında (osteoporoz gibi) sistemik sorunlarla oral sorunlar arasındaki ilişkinin kurulabilmesine olanak vermektedir.
- Daha geniş bir alanın görüntülenmesi sayesinde malpraktis olarak değerlendirilebilecek eksik ve/veya hatalı yaklaşım olasılığını düşürmektedir.
- Diş hekimlerinin yalnızca dental yapıları değil aynı zamanda da maksillofasiyal yapıları değerlendirebilmesine olanak sağlayarak anatomi

bilgisini geliştirerek normal ve patolojik durumlar arası ayırım yapma becerisini artırmaktadır.

- Hasta eğitimi ve olgu sunumlarında yararlı bir görsel yardımcıdır.

OPG'lerin bu avantajlarının yanısıra bazı dezavantajları da bulunmaktadır. Görüntüler intraoral radyografiler kadar yüksek uzaysal çözünürlüğe sahip değildir. Birden fazla birleştirilmiş görüntülerden oluştuğu için keskinlik ve netlik azalmaktadır. Azaltılmış keskinlik ve netlik nedeniyle çürük teşhisinde kullanımı tavsiye edilmemektedir. Aynı faktörler nedeniyle, süperpozisyonlardan kaynaklı olarak, interproksimal bölgede kemik kaybının belirlenmesinde yararlanılamamaktadır. Bu durumlara ek olarak periodontal ligament aralığındaki değişiklikler de yanıltıcıdır. Ayrıca, premolarlar bölgesinde sık olarak süperpozisyonlara rastlanmaktadır. Kesici ve premolar bölgelerinde OPG bulgularını doğrulamak için intraoral radyografi gerekmektedir (Pandula, 2020). Çekim tekniği nedeniyle anatomik ayrıntıları gizleyebilen patolojik değişiklikleri maskeleyen çift ve hayalet görüntüler oluşmaktadır. Orta hatta bulunan, rotasyon merkezinin dışında kalan ve X ışını tarafından iki kez yakalanan objelerin çift görüntüsü oluşmaktadır. Bu alanda hyoid kemik, epiglottis ve servikal vertebra bulunur ve her iki tarafta eşit dansitede görüntü vermektedir. X ışını kaynağı ile rotasyon merkezi arasında kalan bazı objeler ise hayalet görüntüler oluşturmaktadır. Hayalet görüntüler gerçek anatomik yerinin karşısında daha yukarıda, daha büyük ve bulanık gözlenmektedir. Maksiller sinüs, ramus, hyoid kemik, servikal vertebralar gibi bazı anatomik yapılar ile küpe, kolye gibi metal aksesuarlar bu tip görüntülere yol açmaktadır. Görüntü, gerçek görüntünün yanı sıra hayalet ve çift görüntülerin bir süperpozisyonu olduğundan anatomik ve patolojik ayrıntıların değerlendirilmesi dikkatli bir görselleştirme ve deneyim gerekmektedir. İntraoral radyografiye göre iyi detay vermeyen düşük çözünürlüklü bir görüntü sağlamaktadır. Bu nedenle küçük çürükler ve periapikal hastalıkların değerlendirilmesinde periapikal radyografinin yerini tutmamaktadır. (Fairozekhan vd., 2020). OPG'lerde bölgelere göre magnifikasyon oranları da değişmekte olduğu için kemik yüksekliği ölçümlerinde de güvenilir bir şekilde kullanılamamaktadır.

Uzaysal çözünürlük, dişlerin muayenesi için intraoral radyografler kadar ayrıntılı olmasa da, diş yapılarının kalsifikasyonundaki büyük değişiklikler ve altta yatan mandibula ve maksillanın kemikleşmesindeki değişiklikler, çürük, periodontal kemik kaybı, apse ve kist oluşumu gibi dental patolojilerin tanımlanmasında yardımcı olabilmektedir (Cosson, 2020). Kaliteli OPG, yanlış tanı ve tedavi planlamasına neden olan yanlış yorumlamaları önlemekte ve ayrıca radyasyon maruziyetini ve finansal maliyeti en aza indirerek hastaya faydayı en üst düzeye çıkarmaktadır (Fairozekhan vd., 2020).

OPG'nin elde edilmesi veya değerlendirilmesi sırasındaki bazı limitasyonlar göz önünde bulundurulmaktadır. Bu radyografik teknikte, dişlere ve alveoler kemik yapısına odaklanan net ve kabul edilebilir nihai görüntü için hastanın pozisyonu önemlidir. Başarılı bir OPG, hastanın dikkatli bir şekilde konumlandırılmasını ve uygun tekniği gerektirmektedir. Hatalar, genellikle ekipmanın doğasında olan sınırlamalardan değil, hasta konumlandırma ve işleme sırasında teknisyenler tarafından yapılan hatalardan kaynaklanmaktadır (Fairozekhan vd., 2020).

### **Lateral Sefalometrik Radyografler**

Lateral sefalometrik radyografinin 1931 yılında Broadbent tarafından tanıtılmasından bu yana, ortodontik değerlendirme ve tedavi planlamasında yaygın olarak kullanılmaktadır (Duraao vd., 2014). Lateral sefalometrik radyograflerde gerçekleştirilen açısal ve doğrusal ölçümler, ortodonti de rutin teşhiste çok önemli bir rol oynamaktadır. Geliştirildiği tarihten sonraki süreçte daha da geliştirilen lateral sefalometrik analiz, bugüne kadar ortodontik tedaviler için klinik rutinde standart yöntem olarak kullanılmaktadır (Heil vd., 2017).

Bu radyografler iskelet ve diş ilişkilerini değerlendirerek, çeşitli büyüme ve gelişme anomalilerinin teşhisine ve izlenmesine olanak tanımaktadır. Örneğin, ciddi iskeletsel maloklüzyonlarının değerlendirilmesi ve ortodontik apareylerin veya ortognatik cerrahinin planlanması için lateral sefalometrik analiz önemlidir. Görüntüleme yöntemlerinin tamamında X ışını kullanılarak görüntülerin elde edilmesi nedeni ile özellikle çocuk ve genç erişkinlerde daha dikkatli kullanılmaktadır. X ışınlarının sitokastik etkilerinin olması nedeni ile endikasyon dışı kullanımı ve hatalara bağlı olarak tekrar film çekimlerinin önüne

geçilmektedir. (Heil vd., 2017). Radyograflerin deęerlendirilmesi büyük oranda kiři baęımlıdır ve hekimin tecrübesi ile sınırlamaktadır. Bu sınırlamaların önüne geçilmesi ve kişisel farklılıkların ortadan kaldırılması için diř hekimlięi pratięinde de radyograflerin deęerlendirilmesinde yapay zeka programları kullanılmaktadır.

### **Yapay zeka**

Gündelik hayatta sıklıkla karřımıza çıkan ve yaygın kullanımı olan yapay zeka (YZ) kavramı genellikle öğrenme, anlama, akıl yürütme veya problem çözme gibi insan biliřsel işlevlerini taklit eden makineleri tanımlamak için kullanılsa da sayısız tanımlama yapılmaktadır:

- Yapay zeka, tüm endüstri ve sosyal faaliyetler yelpazesinde çok çeřitli ekonomik ve toplumsal faydalar saęlayabilen, hızla gelişen bir teknoloji ailesidir (Avrupa Komisyonu, 2021).
- Yapay zeka, öğrenme, planlama ve problem çözme gibi insani faaliyetlerde bulunan her türlü bilgisayar yazılımını ifade eden geniş ve genel bir terimdir (Uzialko, 2019).
- Yapay zeka, bir sistemin harici verileri doęru bir şekilde yorumlama, bu tür verilerden öğrenme ve bu öğrenmeleri esnek uyarlama yoluyla belirli hedeflere ve görevlere ulaşmak için kullanma yeteneęidir. (Haenlein vd., 2019).
- Yapay zeka, insanlar tarafından sergilenen doęal zekanın aksine, makine zekası veya makineler tarafından gösterilen zekadır (Delipetrev vd., 2020).
- Yapay zeka, insan zekası süreçlerinin makineler, özellikle bilgisayar sistemleri tarafından bir simülasyonudur (Ali vd., 2022).

Günümüzde YZ, günlük yaşamımızda kullanılmakta ve altı yakınsama faktörü nedeniyle tarihi bir ana ulaşmaktadır. Bunlar büyük veri, işlem gücü, baęlantılı dünya, açık kaynaklı yazılım ve veriler, geliştirilmiş algoritmalar ile geri dönüşleri hızlandırmaktadır. Bilgisayarlar, hem yapılandırılmış (veritabanlarında ve elektronik tablolarda) hem de yapılandırılmamış (metin, ses, video ve görüntüler gibi) çok büyük miktarda veriye erişmemizi saęlamaktadır. Yapay zeka destekli bu büyük verilerin işlenmesine, geçmiş kalıpları keřfetmemize, daha verimli tahminler yapmamıza ve daha etkili önerilerde bulunmamıza olanak saęlamaktadır (Herweijer & Houlin, 2018).

YZ, sergilediği zeka türlerine (bilişsel, duygusal ve sosyal zeka) bağlı olarak analitik, insandan ilham alan ve insanlaştırılmış YZ olarak veya evrim aşamasına göre yapay dar, genel ve süper zeka olarak sınıflandırılabilir (Haenlein vd., 2019).

Yapay zeka, yükselen sanayi devriminin "yeni elektriği" olarak kabul edilmektedir (Velarde, 2019). Yapay zekanın ortaya çıkışını sanayi devrimleri ile açıklamak mümkündür. 1760-1840 döneminde, buharlı lokomotif gücü ve mekanik tekstil üretimi ilk sanayi devrimini yaratmaktadır. 19. yüzyılın sonundan 20. yüzyılın başlarına kadar elektrik, seri üretim ve işbölümünün ortaya çıkışı, ikinci sanayi devrimini getirmiştir. Üçüncü sanayi devrimi 1980'lerin başında elektronik, bilgi teknolojileri ve otomatik üretimin başlangıcıyla gerçekleşmiştir (Levin, 2018). Günümüzde ise Dördüncü Sanayi Devrimi yaşanmakta ve dijital devrim inşa edilmektedir. Bu süreç, fiziksel, dijital ve biyolojik alanlar arasındaki çizgileri bulanıklaştıran teknolojilerin bir araya gelmesiyle karakterize edilmektedir (Schwab, 2015).

YZ, büyük veri nesnelere interneti, dijital platformlar, artırılmış ve sanal gerçeklik ve 3D baskı gibi endüstri 4.0 teknolojilerine giderek daha fazla güvenmektedir. Bu süreçte beşinci sanayi devrimi, öngörülemez şekillerde doğmaktadır. Süper akıllı toplum olarak bilinen Toplum 5.0, makine ve insan arasındaki son köprü olabilmektedir. Toplum 5.0 teknolojileri arasında en önemlileri yapay zeka, robotik, 3B baskı ve dijital platformlardır. Mevcut nesil, YZ algoritmalarının yakın zamanda benimsenmesi nedeniyle kendisini daha kişiselleştirilmiş bir geleceğe doğru yönlendirmektedir (Sarraf vd., 2021).

Endüstri devrimi (IR) 5.0, insanlar ve makineler arasındaki etkileşime odaklanmaktadır. Makinelerle birlikte çalışan ve cihazlar aracılığıyla akıllı üretim tesislerine bağlanan insanlar görülmektedir. IR 5.0'ın teknolojik olarak daha gelişmiş insan-makine arayüzlerine doğru ilerlemeye devam etmesi beklenmektedir. Bu, entegrasyonu iyileştirecek ve böylece insan zekasının gücüyle birlikte daha hızlı, üstün otomasyona olanak tanıyacaktır. Bu aynı zamanda robotların yakın zamanda üretim tesislerini devralmayacağı anlamına da gelmektedir. Ayrıca IR 4.0'dan IR 5.0'a geçiş, insan üreticilerine daha fazla odaklanmayı içermektedir. Ek olarak, hem insan hem de makine alanlarının en



iyilerini bir araya getiren bu deęişim, muhtemelen verimlilięin artmasıyla da sonuçlanmaktadır. (George & George, 2020).

Bulut bilişim ve grafik işlem birimleri gibi hızlanan teknolojiler, paralel işlemlerle karmaşık Yapay zeka destekli sistemlerle büyük hacimli verilerin işlenmesini daha ucuz ve daha hızlı hale getirmektedir. Sosyal medya platformları, bireylerin etkileşim biçimlerini temelden deęiştirmiş, artan bağlantı bilginin yayılmasını hızlandırmış ve bilgi paylaşımını teşvik etmiştir. Yapay zeka araçları geliştiren ve uygulamaları paylaşan açık kaynaklı topluluklar da dahil olmak üzere bir “kolektif Zeka”nın ortaya çıkmasına neden olmaktadır (Herweijer & Houlin, 2018). Yapay zekanın kullanım alanının genişliğine karşın sağlık hizmetleri sektöründe kullanımına özellikle odaklanmak, bu tez çalışması için elzemdir. Sağlık hizmetleri sektöründe sağlık verileri analitięi, uzaktan hasta izleme, eğitim, biyomedikal araştırma, elektronik tıbbi kayıtların yönetimi, ilaçlar ve farmasötik tedarik zinciri yönetiminde belirgin bir biçimde kullanılmaktadır. Beşinci sanayi devriminin ve gelecek neslin geleceęinin sırrı olan nanoteknoloji ve gelişmiş malzemeler, terapötiklerde, hızlı teşhiste, gözetim ve izlemede ve aşılarda çok önemli bir rol oynamaktadır (Sarraz vd., 2021).

YZ teknolojilerindeki sürekli gelişmelerin sağlık hizmetlerinin geleceęine yenilikler getirmesi beklenmektedir. Fiziksel alemlerle ilgilenen tipik teknolojilerin aksine, YZ teknolojisi, deneyim, Zeka ve uzmanların yargısı gibi daha psikolojik alemlerde etkileri olduęu için çığır açmaktadır. Özellikle, derin öğrenme teknolojisinin kullanıma girmesiyle örüntü tanıma için makine öğrenimi algoritmalarının performansındaki ciddi iyileşmeden bu yana, yapay zeka teknolojisinin veri modellerini analiz etme yeteneęi, belirli görevler için ortalama bir insan becerisine benzer hale gelmektedir. Derin öğrenme algoritmaları, insan beynindeki nöron aęına benzeyen yapay sinir aęını temel aldıęı ve doğrusal olmayan çok karmaşık ilişkileri öğrenebildięi için tıbbi verilerle ilgili görevlerde aktif olarak kullanılmaktadır. Bu doğrultuda Yapay zeka tabanlı teknolojilerin sağlık hizmetlerinde kullanımına yönelik bir dizi çalışma yürütölmektedir. Ayrıca, çeşitli araştırmalar sağlık hizmetlerinde Yapay zeka uygulamasının mevcut teknolojilere kıyasla daha iyi sonuçlar verdięini göstermektedir. Bu çalışmalardan bazıları a) Görüntüleri ayırt etmek ve tedavilerde kullanmak için yapay zeka

teknolojisiyle tıbbi görüntülerin analiz edilmesini; b) çeşitli tıbbi ve sağlık verileri aracılığıyla bir hastalığın seyrini tahmin etmek; c) tedaviler sırasında veya teşhis için karar vermeyi destekleyebilecek tıbbi cihazlar geliştirmek ve d) Tıbbi verileri şifrelemektir (Park vd., 2020).

Yapay zekanın sağlık hizmetleri sektöründe kullanımının birçok avantajı bulunmaktadır. Öne çıkan bazı avantajlar şunlardır (Sharma, 2021).

- Yüksek maliyetli ameliyatlara yerini robot kontrollü ameliyatlara alacak ve bu ameliyatlara hem uygun maliyetli olacak hem de hasta tedavisine fayda sağlayacaktır.
- Yapay zeka, sıkıcı bir iş olan hastane kayıtlarının yönetimine yardımcı olacak ve ancak Yapay zekanın yardımıyla bu iş daha hızlı ve verimli bir şekilde sağlanacaktır.
- Hastalıkların teşhisi, hızlı tedavide yardımcı olacak bir doktordan daha etkili ve daha erken olacaktır.
- Gerçek zamanlı verilerle klinik karar verme, yapay zeka yardımıyla çok daha kolaylaşacaktır.
- Tedaviye yardımcı olacak YZ yardımıyla belirli hasta verileri kolayca takip edilebilmektedir.
- YZ, insan işini azaltacak ve çok önemli olan hasta ruh sağlığıyla ilgilenmek gibi daha üretken işlere konsantre olmalarına yardımcı olmaktadır.
- Tüm idari işler, yapay zeka yardımıyla sağlık maliyetinin %30'unu oluşturmaktadır, idari işler çok daha hızlı ve etkin bir şekilde yapılacaktır ve böylece para tasarrufu sağlanmaktadır.
- Giyilebilir sağlık cihazlarında kullanılan Yapay zeka, sorunların geleneksel süreçlerden daha hızlı tespit edilmesini sağlamaktadır.
- YZ kullanımıyla sağlık hizmeti maliyeti azaltılarak temel sağlık tesisleri herkes tarafından kullanılabilir hale gelmektedir.
- Yapay zeka kullanımı ile tanı ve tedavi için gereken süre kısalmaktadır.

Sağlık hizmetlerinde yapay zekanın pek çok güncel uygulaması mevcuttur. Bu kullanım alanları robotik, dijital sekreterlik, makine öğrenme, görüntü işleme, doğal dil işleme, ses tanıma, istatistiksel analiz, büyük veri analizi ve tahmine

dayalı modellemedir. Tıbbi cihaz, sađlık bilişimi ve tanısal tıbbi görüntü alanlarında kullanılan bu uygulamalar hakkında kısaca bilgi vermek, sağladıkları faydaları somut biçimde ortaya koymak bakımından önem taşımaktadır.

Robotik, cerrahi prosedürlerin hassasiyetini ve doğruluğunu artırarak yüksek kaliteli tedavi sağlama alanında kullanılırken; dijital sekreter hasta durum göstergelerini sürekli izlemekte, gerektiğinde hemşireyi uyararak uygun müdahalenin ideal zamanını bulabilmektedir. Makine öğrenme, tedavi sonuçlarını etkileyen verilere dayalı kalıpları tahmin edebilmekte ve analiz edebilmektedir. Kendi kendine öğrenme yoluyla büyük hacimli tanı amaçlı tıbbi görüntüleri işleyerek tıbbi tedavi karar verme sürecindeki belirsizliği azaltmaktadır. Görüntü işleme, büyük miktarda tıbbi görüntüyü hızlı bir şekilde işlemekte, bulguları hastalık türü ile negatif ve pozitif test sonuçlarını değerlendirebilmektedir.

Dođal dil işleme, tıbbi çizelgeler gibi uzun yapılandırılmamış metin verilerini kolayca okunacak ve yorumlanacak şekilde dönüştürebilmektedir. Ses tanıma, hastanın sesini ve dilini yakalayarak önemli bilgileri elektronik tıbbi kayıtlarda saklama imkânı sunmaktadır. İstatistiksel analiz sağladığı öngörü imkânı ile öne çıkmaktadır. Büyük miktarda hasta sađlık kaydı verilerini hızlı analiz ederek hasta tedavi sonuçlarını tahmin edebilmektedir. Son olarak tahmine dayalı modellemede ise; matematiksel modeller uygulayarak riskli hastalıkları tahmin etmek gibi tedavi sonuçlarını tahmin etmek mümkün hale gelmektedir.

### **Yapay Zekanın Tarihçesi**

Yapay zekanın tarihi hakkında bilgi sahibi olmak için milattan önceki tarihlere gitmek gerekmektedir. Antik Yunan döneminde insansı robotlar hakkında çeşitli fikirlerin ortaya çıktığı kanıtlanmıştır. Bunun bir örneđi, yapay insanlar yaratmaya çalışmak için rüzgar mitolojisine hükmettiđi söylenen Daedalus'tur. Modern Yapay zeka, filozofların insan düşünce sistemini tanımlama amacı ile tarihte görülmeye başlanmıştır (Mijwel, 2015).

1206 yılında sibernetik biliminin öncülerinden Ebru İz Bin Rezzaz Al Jezeri, suyla çalışan otomatik kontrollü makineler yapmıştır. 1623'te Wilhelm Schickard dört işlem yapabilen bir hesap makinesi icat etmiştir. 1672 yılında Gottfried Leibniz, günümüz bilgisayarlarının soyut temelini oluşturan bir ikili sayma sistemi geliştirmiştir. 1822-1859 yıllarını kapsayan süreçte Charles

Babbage mekanik bir hesap makinesi bulmuştur. Bu, Ada Lovelace, Babbage'nin delikli kartlarıyla yaptığı çalışmalardan dolayı ilk bilgisayar programcısı olarak kabul edilmektedir. Lovelace'ın çalışmaları algoritmalar içermektedir. 1884 Yapay zeka için çok önemli bir yıl olmuştur. Charles Babbage, bu tarihte akıllı davranış sergileyecek mekanik bir makine üzerinde çalışmıştır. Bu çalışmalar sonucunda insan kadar zeki davranışlar sergileyecek bir makine üretemeyeceğine karar vermiştir (Mijwel, 2015).

Yüzlerce yıl geriye dayansa da yapay zekanın resmi doğuşu 1940'lara dayanmaktadır. Amerikan Bilim Kurgu yazarı Isaac Asimov'un kısa öyküsü Runaround'u yayınladığı 1942'ye kadar izlenebilmektedir. Asimov'un çalışması, robotik, yapay zeka ve bilgisayar bilimi alanında nesiller boyu bilim adamlarına ilham vermiştir. Aynı tarihlerde İngiliz matematikçi Alan Turing, çok daha az kurgusal konular üzerinde çalışmıştır. İkinci Dünya Savaşında Alman ordusu tarafından kullanılan *Enigma* kodunu deşifre etmek amacıyla İngiliz hükümeti için *The Bombe* adlı bir kod kırma makinesi geliştirmiştir. Yaklaşık bir ton ağırlığa sahip olan *The Bombe*, genellikle çalışan ilk elektro-mekanik bilgisayar olarak kabul edilmektedir. *The Bombe*'nin daha önce en iyi insan matematikçiler için bile imkânsız olan *Enigma* kodunu kırabilmesi, Turing'in bu tür makinelerin zekasını merak etmesine neden olmuştur. 1950'de, akıllı makinelerin nasıl yaratılacağını ve özellikle de zekalarının nasıl test edileceğini anlattığı ufuk açıcı makalesi "Computing Machinery and Intelligence"ı yayınlanmıştır. Bu Turing Testi, bugün hala yapay bir sistemin zekasını belirlemek için bir ölçüt olarak kabul edilmektedir: eğer bir insan başka bir insanla ve bir makineyle etkileşime giriyorsa ve makineyi insandan ayırt edemiyorsa, o zaman makinenin zeki olduğu kabul edilmektedir (Haenlein vd., 2019).

1965 ile 1970 yılları arası yapay zeka için karanlık dönem olarak adlandırılmaktadır. Bu dönemde yapay zeka ile ilgili gelişmeler test edilemeyecek kadar azdır. Ortaya çıkan gerçekçi olmayan beklentiler nedeniyle görülen aceleci ve iyimser tavır, yapay zekaya sahip makinelerin meydana getirilmesinin kolay olacağı düşüncesini doğurmuştur. Ancak bu dönem, sadece veri yükleyerek akıllı makineler yaratma fikri ile başarılı olamadığı için yapay zeka adına karanlık bir dönem olarak adlandırılmıştır. 1970 ile 1975 yılları

arasında yapay zeka ivme kazanmıştır ve hastalık teşhisi gibi konularda geliştirilen Yapay zeka sistemlerinde elde edilen başarı sayesinde günümüz Yapay zekasının temelleri atılmıştır. 1975-1980 döneminde ise yapay zekadan psikoloji gibi diğer bilim dallarında da yararlanabileceği fikri geliştirilmiştir (Mijwel, 2015).

1980, YZ'nin endüstri haline geldiği yıldır. Altı yıllık süreçte yapay sinir ağlarının tekrar popülerleştiği görülmektedir. 1987 yılında ise YZ bir bilim haline gelmiştir. 1997'de BM Deep Blue, dünyanın en iyi insan oyuncusu Garry Kasparov'a karşı satranç oyununu kazanmıştır. BM Deep Blue, DL veya en son YZ tekniklerinden herhangi birini kullanmamıştır. Sistem oynanabilecek tüm satranç oyunlarını öğrenmiş ve mevcut durumu değerlendirip bir sonraki hamleyi önerebilmişti. 1998'e gelindiğinde internet yaygınlaşmış ve YZ tabanlı pek çok program geniş kitlelere ulaşmıştır. 2000'de robot oyuncakların piyasaya sürüldüğü görülmüştür (Pirim, 2006).

Geleceğe yönelik düzenleme ihtiyacına ilişkin bir perspektif sunmak, gelişime açık bu alanı tarif etmek için önemlidir. Mikro perspektiften bakıldığında, algoritmalara ve organizmalara yönelik yasal bir düzenlemenin gerekliliği sorgulanmaktadır. Yapay zeka özünde nesnel ve önyargısız olsa da bu, yapay zekaya dayalı sistemlerin önyargılı olamayacağı anlamına gelmemektedir. Aslında, doğası gereği, bir YZ sistemini eğitmek için kullanılan girdi verilerinde mevcut olan herhangi bir sapma devam etmekte ve hatta güçlendirilebilmektedir. Yapay zekanın kendisini düzenlemeye çalışmak yerine, bu tür hatalardan kaçınmanın en iyi yolu yapay zeka algoritmalarının eğitimi ve test edilmesiyle mümkün olacaktır (Haenlein vd., 2019).

Ayrıca üretim süreçlerinin otomasyonu mavi yakalı çalışanların işlerinin kaybına neden olduğu gibi, yapay zekanın artan kullanımı beyaz yakalı çalışanlara ve hatta yüksek nitelikli profesyonel işlere daha az ihtiyaç duyulmasına neden olacaktır. YZ, görüntü tanıma araçları bazı hastalıkların saptanmasında ise hekimlerden daha iyi performans göstermekte bunun yanında hukukta ise e-keşif teknolojileri, milyonlarca belgeyi incelemek için büyük avukat ve yardımcı hukuk ekiplerine olan ihtiyacı azaltmaktadır. (Haenlein vd., 2019).

Makro perspektiften bakıldığında demokrasi ve barışa yönelik düzenlemeler odak noktası haline gelmektedir. YZ yalnızca firmalar veya özel

kişiler tarafından değil, devletler tarafından da kullanılabilir. Yüz tanıma sistemleri ya da sosyal kredi sistemi gibi uygulamalar yapılabilmektedir. Çin ve bir dereceye kadar Amerika Birleşik Devletleri, firmaların Yapay zekayı kullanması ve keşfetmesinin önündeki engelleri sınırlamaya çalışırken (Haenlein vd., 2019); Avrupa Komisyonu bu konuda bir yasa çıkarmıştır. Yasa, YZ uygulamalarını üç risk kategorisine ayırmıştır. İlk olarak, Çin'de kullanılan türden devlet tarafından yürütülen sosyal puanlama gibi kabul edilemez bir risk oluşturan uygulama ve sistemleri yasaklamıştır. İkincisi, işe başvuruları derecelendiren CV tarama aracı gibi yüksek riskli başvurular, belirli yasal gerekliliklere tabidir. Son olarak, açıkça yasaklanmayan veya yüksek riskli olarak listelenmeyen uygulamalar büyük ölçüde denetimsiz bırakılmaktadır (Avrupa Komisyonu, 2021).

## **Yapay Zeka Öğrenme Biçimleri**

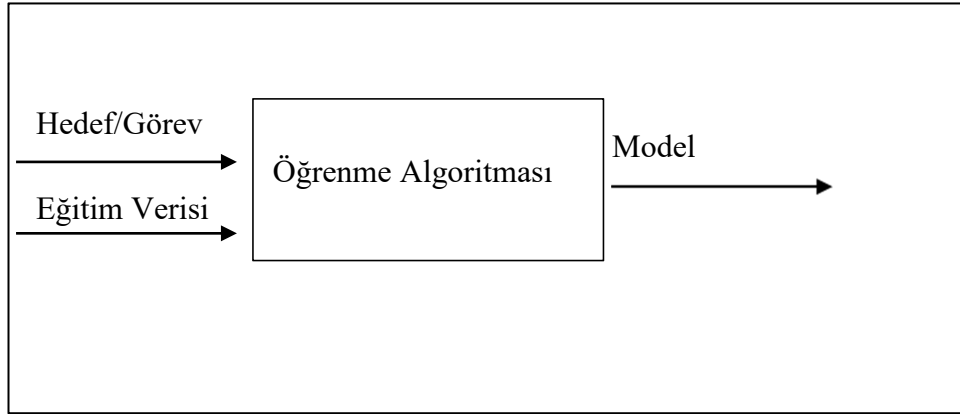
### **Makine Öğrenimi**

Makine öğrenimi, günümüzde iş amaçlı geliştirme için kullanılan en yaygın yapay zeka türlerinden biridir. Makine öğrenimi öncelikle büyük miktarda veriyi hızlı bir şekilde işlemek için kullanılmaktadır. Bu yapay zeka türleri, zaman içinde öğrendikleri ve daha sık yaptıkları işte daha iyi hale geldikleri görülen algoritmalarıdır (Uziarko, 2019).

Makine öğrenimi birçok şekilde görünebilir. Makine öğrenimi biliminin çoğu, bu sorunları çözmek ve çözümler için iyi garantiler sağlamaktır. Web sayfası sıralaması kavramı artık pek çok kişi tarafından bilinmektedir. Bir diğer deyişle, bir arama motoruna bir sorgu gönderme sürecinin akabinde sorguyla alakalı web sayfalarını bulmakta ve alaka sırasına göre görüntülemektedir. Bu hedefe ulaşmak için, bir arama motorunun hangi sayfaların alakalı olduğunu ve hangi sayfaların sorguyla eşleştiğini bilmesi gerekmektedir. Bu tür bilgiler web sayfalarının bağlantı yapısı, içerikleri, kullanıcıların bir sorguda önerilen bağlantıları takip etme sıklığı veya manuel olarak sıralanan web sayfalarıyla birlikte sorgu örnekleri gibi çeşitli kaynaklardan elde edilebilmektedir. İyi bir arama motoru tasarlama sürecini otomatikleştirmek için tahmin ve akıllı mühendislik yerine giderek daha fazla makine öğrenimi kullanılmaktadır (Smola & Vishwanathan, 2008).

Makine öğrenimi, veri sorunlarını çözmek için farklı algoritmalara dayanmaktadır. Veri bilimciler, bir sorunu çözmek için en iyi olan, her duruma uyan tek bir algoritma türü olmadığını belirtmektedirler. Kullanılan algoritmanın türü, çözmek istediğiniz sorunun türüne, değişken sayısına, ona en uygun modelin türüne bağlı olarak değişmektedir (Mahesh, 2019). Makine öğrenimi yaklaşımları, temsil ve uyarılma açısından ayırt edilebilmektedir. Bir makine öğrenimi sisteminin, öğrenilen bilgileri (tümevarımsal) hipotez adı verilen ve tipik olarak bir model biçiminde olan bilgi temsili yapısında saklaması gerekmektedir. Bir öğrenme algoritması, öğrenilen hipotezin yeni deneyimle (yani eğitim verileriyle) nasıl güncelleneceğini belirtmekte, böylece görevle ilgili performans ölçüsü optimize edilebilmektedir (Lawrynowicz & Tresp, 2014).

Şekil 1. Makine Öğrenme Modeli (Lawrynowicz & Tresp, 2014).



Sınıflandırma ve Regresyon, Eğitim Verileri, Modeller, Üretken ve Ayrımcı Modeller makine öğrenmesinin görevleri olarak tanımlanmaktadır. Bu görevler kısaca şunlara karşılık gelmektedir:

Sınıflandırma ve regresyon görevleri, diğer alanların (öznitelikler veya özellikler) değerlerine dayalı olarak bir alanın (hedef) değerinin tahmin edilmesiyle ilgilidir. Hedef ayrıysa (örneğin, nominal veya sıralı), o zaman verilen göreve sınıflandırma denmektedir. Hedef sürekli ise göreve regresyon denilmektedir. Sınıflandırma veya regresyon normalde denetimli prosedürler değildir. Önceden doğru şekilde etiketlenmiş eğitim örnekleri setine dayalı olarak, model yeni görünmeyen örnekleri doğru şekilde etiketlemeyi öğrenmektedir (Lawrynowicz & Tresp, 2014).

Eđitim verilerinde üç önemli geri bildirim sınıfı ayırt edilmektedir: etiketli örnekler biçimindeki geri bildirim, etiketlenmemiş örnekler biçimindeki geri bildirim veya pekiştirmeli öğrenmede olduğu gibi ödül ve ceza şeklindeki geri bildirim (Lawrynowicz & Tresp, 2014). Makine öğrenimi algoritmaları, algoritmanın istenen sonucuna göre taksonomi halinde düzenlenmektedir. Yaygın algoritma türleri şunları içermektedir (Ayodele, 2010).

- a) Denetimli öğrenmede algoritma, girdileri istenen çıktılara eşleyen bir işlev üretmektedir. Denetimli öğrenme görevinin standart bir formülasyonu, sınıflandırma problemidir.
- b) Denetimsiz öğrenme, bir dizi girdiyi modellemektedir ve etiketli örnekler mevcut değildir.
- c) Yarı denetimli öğrenme, uygun bir işlev veya sınıflandırıcı oluşturmak için hem etiketlenmiş hem de etiketlenmemiş örnekleri birleştirmektedir.

Farklı algoritmalar olsa da denetimsiz öğrenme genellikle büyük veri kümeleri için daha iyi performans ve sonuçlar vermektedir. Kolayca erişilebilen çok büyük bir veri kümesinin bulunması halinde, takviye öğrenme tekniklerinin kullanılması gerekmektedir (Mahesh, 2019).

Modellerde, makine öğrenimi hipotezleri, denklemler, karar ağaçları, kurallar, mesafeler ve bölümler, olasılıksal ve grafik modeller gibi çeşitli bilgi temsili biçimlerinde gelebilmektedir. Klasik olarak, bilgi temsili sembolik ve alt-sembolik biçimleri arasında bir ayırım yapılmaktadır. İlk kategori, atomik yapı taşlarının genellikle bir insan tarafından kolayca okunabilen resmi sembolik temsil sistemlerinden oluşmaktadır. Bu tür temsil sistemleri, bileşimsel sözdizimine ve anlambilime sahiptir ve bileşenlerine bir yorum atanabilmektedir (Lawrynowicz & Tresp, 2014).

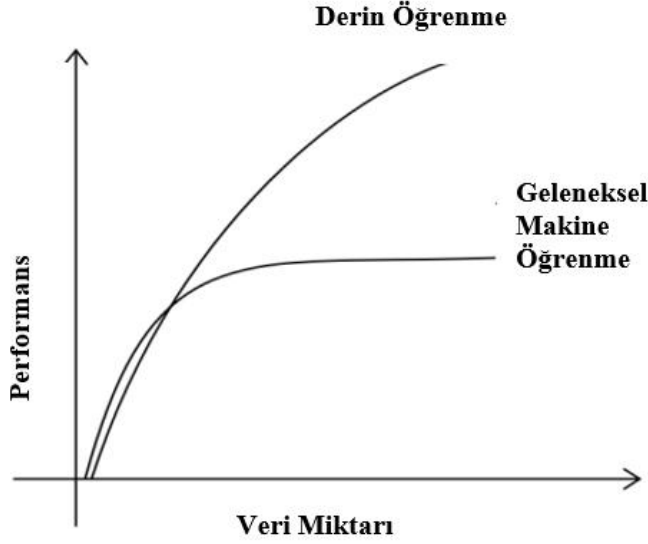
## **Derin Öğrenme**

Derin öğrenme, makine öğrenimi araştırmasının gelişmekte olan bir alanıdır. Yapay sinir ağlarının birden çok gizli katmanını içermektedir. Derin öğrenme metodolojisi, doğrusal olmayan dönüşümleri ve büyük veritabanlarında yüksek düzeyde model soyutlamalarını uygulamaktadır. Çok sayıda alanda derin



öğrenme mimarilerindeki son gelişmeler, yapay zekaya şimdiden önemli katkılar sağlamıştır (Vargas vd., 2017).

Şekil 2.2. Derin Öğrenmenin Yararı (Mathew vd., 2021).



Şekil 2. geleneksel makine öğrenimi algoritmalarının ve derin öğrenme algoritmalarının performansını göstermektedir. Geleneksel makine öğrenimi algoritmalarının performansı, eğitim verilerinin eşğine ulaştığında kararlı hale gelirken, derin öğrenme, artan veri miktarıyla performansını yükseltmektedir. Günümüzde derin öğrenme, *Google*'ın ses ve görüntü tanıma, *Netflix* ve *Amazon*'un öneri motorları, *Apple*'ın *Siri*'si, otomatik e-posta ve metin yanıtları, sohbet robotları vb. gibi pek çok uygulamada kullanılmaktadır (Mathew vd., 2021).

### Sinir Ağları

Bir sinir ağı, işlevselliği hayvan nöronuna dayanan basit işleme öğelerinin, birimlerin veya düğümlerin birbirine bağlı bir topluluğudur. Ağın işleme yeteneği, bir dizi eğitim modeline uyum sağlama veya bunlardan öğrenme süreciyle elde edilen, birimler arası bağlantı güçlerinde veya ağırlıklarında depolanmaktadır (Gurney, 1997).

Sinir ağlarının teknik yönünü açıklamaya başlamadan önce, sinir ağlarının biyolojisini ve canlı organizmaların bilişini kısaca tartışmak faydalı olacaktır.

Tüm bilgi işleme sistemi, yani omurgalı sinir sistemi, yalnızca ilk ve basit bir alt

bölüm olan merkezi sinir sistemi ve periferik sinir sisteminden oluşmaktadır (Kriesel, 2009). Diğer nöronlardan veya hücrelerden gelen sinyaller, özel bağlantılar olan sinapslarla bir nörona aktarılır. Bu tür bağlantılar genellikle bir nöronun dendritlerinde, bazen de doğrudan somada bulunabilmektedir. Elektriksel ve kimyasal sinapsları birbirinden ayıracak olursak, elektriksel sinaps daha basit bir varyanttır. Sinaps tarafından alınan, yani presinaptik taraftan gelen bir elektrik sinyali doğrudan hücrenin postsinaptik çekirdeğine aktarılmaktadır. Bu nedenle, sinyal iletilen ile sinyal alıcı arasında doğrudan, güçlü, ayarlanamayan bir bağlantı vardır; bu, örneğin canlı bir organizma içinde "sabit olarak kodlanması" gereken kısaltma reaksiyonlarıyla ilgilidir. Kimyasal sinaps daha belirgin varyanttır. Burada kaynak ve hedefin elektriksel eşleşmesi gerçekleşmemekte, bağlantı sinaptik yarıktan kesilmektedir. Bu yarıktan, presinaptik tarafı elektriksel olarak postsinaptik olandan ayırmaktadır (Kriesel, 2009).

Bir sinir ağı, deneyimsel bilgiyi depolamak ve onu kullanıma hazır hale getirmek için doğal bir eğilime sahip basit işlem birimlerinden oluşan büyük ölçüde paralel dağıtılmış bir işlemcidir. Beyne iki yönden benzemektedir (Haykin, 2008).

- a) Bilgi, ağ tarafından bir öğrenme süreci aracılığıyla çevresinden elde edilmektedir.
- b) Sinaptik ağırlıklar olarak bilinen nöronlar arası bağlantı güçleri, edinilen bilgileri depolamak için kullanılmaktadır.

Öğrenme sürecini gerçekleştirmek için kullanılan prosedüre, işlevi istenen bir tasarım amacına ulaşmak için ağı sinaptik ağırlıklarını düzenli bir şekilde değiştirmek olan öğrenme algoritması denilmektedir. Sinaptik ağların modifikasyonu, sinir ağlarının tasarımı için geleneksel yöntemi sağlamaktadır. Böyle bir yaklaşım, hali hazırda iyi kurulmuş ve birçok farklı alanda başarılı bir şekilde uygulanmış olan doğrusal uyarlamalı filtre teorisine en yakın olanıdır. Bununla birlikte, bir sinir ağının, kendi topolojisini değiştirmesi de mümkündür. Sinir ağlarının bazı özellikleri ve yetenekleri bulunmaktadır (Haykin, 2008).

**Girdi-Çıktı Eşleme:** Bir öğretmenle öğrenme veya denetimli öğrenme olarak adlandırılan popüler bir öğrenme paradigması, bir dizi etiketli eğitim örneği veya görev örneği uygulayarak bir sinir ağının sinaptik ağırlıklarının

değiştirilmesini içermektedir. Her örnek, benzersiz bir giriş sinyalden ve karşılık gelmesi istenen (hedef) yanıtta oluşmaktadır.

Uyarlanabilirlik: Sinir ağları, sinaptik ağırlıklarını çevreleyen ortamdaki değişikliklere uyarlamak için yerleşik bir yeteneğe sahiptir. Özellikle, belirli bir ortamda çalışmak üzere eğitilmiş bir sinir ağı, çalışma ortamı koşullarındaki küçük değişikliklerle başa çıkmak için kolayca yeniden eğitilebilmektedir.

Kanıtsal Yanıt: Örüntü sınıflandırması bağlamında, bir sinir ağı yalnızca hangi belirli modelin seçileceği hakkında değil, aynı zamanda verilen karara duyulan güven hakkında bilgi sağlamak için tasarlanabilmektedir.

Bağlamsal Bilgi: Bilgi, bir sinir ağının yapısı ve aktivasyon durumu ile temsil edilmektedir. Ağdaki her nöron, potansiyel olarak ağdaki diğer tüm nöronların küresel aktivitesinden etkilenmektedir. Sonuç olarak, bağlamsal bilgi doğal olarak bir sinir ağı tarafından ele alınmaktadır.

Hata Toleransı: Donanım biçiminde uygulanan bir sinir ağı, olumsuz çalışma koşulları altında performansının hafif bir şekilde düşmesi ile birlikte, doğası gereği hataya dayanıklı olma veya sağlam hesaplama yeteneği olma potansiyeline sahiptir.

Nörobiyolojik Analoji: Bir sinir ağının tasarımı, hataya dayanıklı paralel işlemenin yalnızca fiziksel olarak mümkün değil, aynı zamanda hızlı ve güçlü olduğunun canlı kanıtı olan beyinle analogi ile motive edilmektedir.

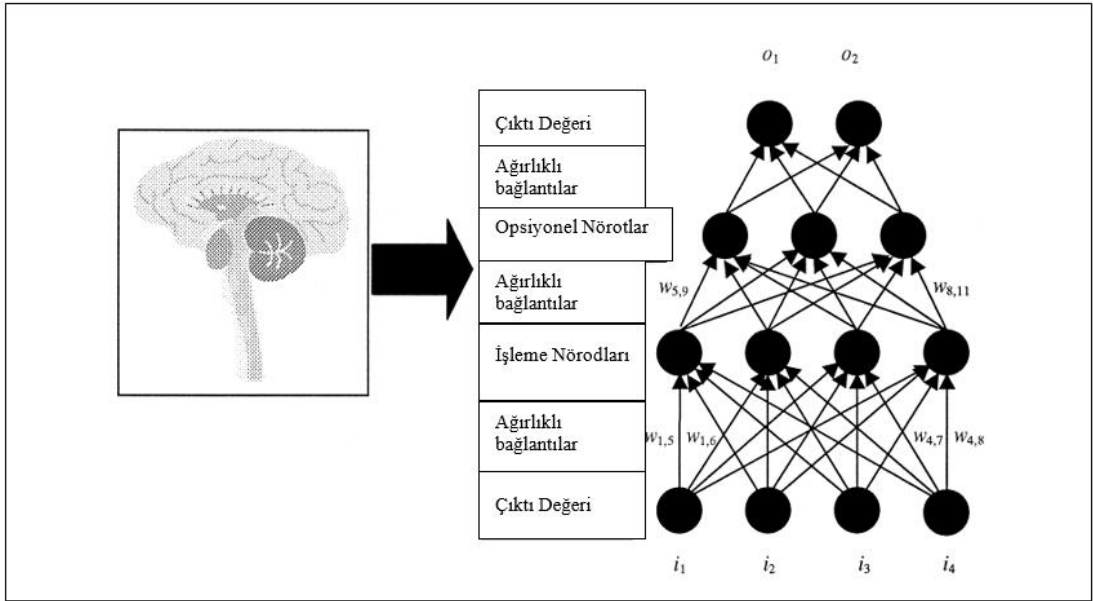
### **Yapay sinir ağları**

Yapay sinir ağları (YSA) en basit haliyle insan beyninin taklididir. Doğal bir beyin, yeni şeyler öğrenme, yeni ve değişen çevreye uyum sağlama yeteneğine sahiptir. Beynin, eksik ve net olmayan, belirsiz bilgileri analiz etme ve bunlardan kendi yargısını çıkarma konusunda inanılmaz bir yeteneği vardır. Örneğin, bir çocuk, topun ve portakalın şeklinin her ikisinin de daire olduğunu anlayabilmektedir ya da birkaç günlük bebek annesini dokunma, ses ve kokudan tanıma yeteneğine sahiptir. İnsanlar, bilinen bir kişiyi bulanık bir fotoğraftan bile teşhis edebilmektedir (Kukreja, 2016).

Yapay sinir ağları, beyin ve sinir sistemi üzerine yapılan çalışmalara dayanan bir teknolojidir. Bu ağlar, biyolojik sinir ağını taklit etmekte, ancak

biyolojik sinir sistemlerinden indirgenmiş bir dizi kavram kullanmaktadır. Spesifik olarak, YSA modelleri beynin ve sinir sisteminin elektriksel aktivitesini simüle etmektedir (Şekil 3.). İşleme öğeleri (bir nörot veya algılayıcı olarak da bilinmektedir) diğer işleme öğelerine bağlıdır. Tipik olarak nöronlar, bir katmanın çıktısı bir sonraki katmana ve muhtemelen diğer katmanlara girdi görevi görecektir şekilde bir katman veya vektör halinde düzenlenmektedir. Bir nörot, beynin sinaptik bağlantılarını simüle eden bu bağlantılar ile sonraki katmandaki tüm nörodlara veya bir alt kümesine bağlanabilmektedir. Bir sinir hücresinin elektriksel uyarımını ve sonuç olarak ağ veya beyin içindeki bilgi transferini simüle etmektedir. Bir işleme elemanına giriş değerleri,  $i_n$ , beyindeki nöral yolların güçlendirilmesini simüle eden bir bağlantı ağırlığı,  $w_{n,m}$  ile çarpılmaktadır. YSA'larda öğrenmenin benzetildiği bağlantı güçlerinin veya ağırlıklarının ayarlanması yoluyla olmaktadır (Walczak & Cerpa, 2003).

Şekil 3. Örnek Yapay Sinir Ağı Mimarisi (Walczak & Cerpa, 2003).



Yapay sinir ağları, hem kategorizasyon hem de zaman serisi (trend analizi) türlerindeki karmaşık örüntü odaklı problemlerle başa çıkmak için bir araç sağlamaktadır. Sinir ağlarının parametrik olmayan doğası, yaygın olarak kullanılan parametrik istatistiksel yöntemlerin gerektirdiği gibi, veri popülasyonunun dağılımı veya değişkenler arasındaki olası etkileşimler hakkında önceden bilgi sahibi olmadan modellerin geliştirilmesine olanak tanımaktadır. YSA mimarisi ve öğrenme algoritması, giriş değerinin türünü belirleyecektir. Bu

nedenle, YSA'ları tasarlarırken bir metodolojiyi veya iyi tanımlanmış bir adım dizisini takip etmek esastır. Bu adımlar aşağıda sıralanmıştır(Walczak & Cerpa, 2003).

- a) Kullanılacak veriler belirlenmektedir.
- b) Giriş değişkenleri belirlenmektedir.
- c) Veriler eğitim ve test kümelerine ayrılmaktadır.
- d) Ağ mimarisi tanımlanmaktadır.
- e) Bir öğrenme algoritması seçilmektedir.
- f) Değişkenler ağ girişlerine dönüştürülmektedir.
- g) YSA hatası kabul edilebilir değerin altına düşene kadar tekrarlanmaktadır.
- h) Test edilmektedir.

Bir yapay sinir ağı, nöron adı verilen işlem birimlerinden oluşmaktadır.

Yapay bir nöron, doğal nöronun yapısını ve davranışını kopyalamaya çalışmaktadır. Bir nöron girdilerden (dendritler) ve bir çıktıdan (akson aracılığıyla sinaps) müteşekkildir. Nöronun aktivasyonunu belirleyen bir işlevi bulunmaktadır. YSA, normal bir bilgisayar programından birçok yönden farklıdır. Özelliklerinden bazıları şunlardır(Kukreja, 2016).

- a) Uyarlanabilir öğrenme: YSA, öğrenirken görevleri nasıl yapacağını öğrendiği şekilde insan beynini kopyalamaktadır. Normal bir program diğer girdi türlerine uyum sağlayamamaktadır.
- b) Kendi kendine organizasyon: YSA öğrenirken kendi organizasyonunu oluşturabilmektedir. Normal bir program görevi için sabittir ve yapması amaçlanandan başka bir şey yapmamaktadır.
- c) Paralel çalışma: YSA, insan beyni gibi paralel çalışmaktadır. Bu, seri olarak çalışan bir bilgisayar programından farklıdır.
- d) Hata toleransı: Sinir ağlarının en ilginç özelliklerinden biri, eksik, gürültülü ve bulanık veriler temelinde bile çalışabilmeleridir. Normal bir program eksik, net olmayan verileri işleyememekte ve en ufak bir yanlış veriyle karşılaştığında çalışmayı durdurmaktadır.
- e) İnsan beynine kıyasla YSA, beyin işlem süresi daha yavaş olduğu için oldukça hızlıdır.

- f) Normal programla karşılaştırıldığında, YSA'nın çıktığı hesapladığı yöntem net değildir. Benzer olmalarına rağmen, farklı girdi kümeleriyle geçen süre değişmeye devam etmektedir.
- g) YSA, veri sınıflandırma, örüntü tanıma ve verilerin belirsiz olduğu uygulamalarda kullanılabilir. YSA, veri sınıflandırma, örüntü tanıma ve verilerin belirsiz olduğu uygulamalarda kullanılabilir.
- h) Girdi ve çıktının doğası tam olarak bilindiğinde ve yapılması gerekenler açıkça belirlenebildiğinde YSA kullanılmamaktadır.

Yapay sinir ağlarının geleneksel sistemlere göre avantajlarına rağmen, bu alandaki araştırmacıların en aza indirmeye çalıştıkları dezavantajları da bulunmaktadır (Dasters & Soori, 2021).

- a) İsteğe bağlı bir uygulama için bir ağ tasarlamaya yönelik özel kurallar veya talimatlar yoktur.
- b) Modelleme problemlerinde sinir ağları kullanılarak problemin fiziği tek başına anlaşılabilir. Başka bir deyişle, parametreleri veya ağ yapısını işlem parametrelerine bağlamak genellikle imkansızdır.
- c) Sonuçların doğruluğu büyük ölçüde eğitim setinin boyutuna bağlıdır.
- d) Ağ eğitimi zor hatta imkansız olabilmektedir.
- e) Ağın gelecekteki performansını tahmin etmek kolay değildir. Yani genelleme yapılamamaktadır.

### **Evrişimli Sinir Ağları**

İnsanın görme duyusu inanılmaz derecede gelişmiş olup saniyeler içinde, görüş alanımızdaki nesnelere düşünmeden veya tereddüt etmeden tanımlayabilmektedir. Baktığımız nesnelere adlandırmanın yanı sıra derinliklerini algılayabilmekte, cisimlerin kenarlarını ve nesnelere arka planlarından ayırabilmektedir (Buduma, 2017).

Evrişimli Sinir Ağları (Convolutional Neural Networks-CNN) esas olarak görüntüler için kullanılmaktadır. Görüntüdeki çeşitli nesnelere ağırlıklar ve önyargılar atamakta ve birini diğerinden ayırmaktadır. Diğer sınıflandırma algoritmalarına göre daha az ön işleme gerektirmektedir. CNN, bir görüntüdeki uzamsal ve zamansal bağımlılıkları yakalamak için ilgili filtreleri kullanmaktadır. Farklı CNN mimarileri arasında LeNet, AlexNet, VGGNet, GoogleNet, ResNet, ZFNet bulunmaktadır. CNN'ler ağırlıklı olarak nesne algılama, semantik

segmentasyon, altyazı oluşturma gibi uygulamalarda kullanılmaktadır (Mathew vd., 2021).

Evrişimli sinir ağının temelleri, 1959 yılında Hubel ve Wisel'in keşfiyle atılmıştır. Hubel ve Wisel'e göre, hayvan görsel korteksindeki hücreler ışığı küçük alıcı alanda tanımaktadır. Hubel ve Wiesel'in çalışmalarından esinlenerek 1980 yılında Kunihiro Fukushima, öğrenme yoluyla hiyerarşik olarak görsel örüntüleri tanıyabilen, çoklu katmanlar içeren, kendi kendini organize eden bir Sinir Ağı olan Neocognitron'u önermiştir ve bu ağ CNN'in ilk teorik modeli olarak kabul edilmektedir. 1990'da Le Cun ve diğerleri (2015) el yazısı rakamları tanımak için LeNet-5 adlı modern CNN çerçevesini geliştirmiştir. AlexNet'in başarısı, farklı CNN modelleri icat etmenin ve bu modelleri bilgisayarla görme ve doğal dil işlemenin farklı alanlarında uygulamanın yolunu açmaktadır. (Ghosh vd., 2020).

Modern CNN'ler tasarımlarını biyolojiden, grup teorisinden ve yeterli deneysel çalışmalardan elde edilen verilere borçludur. Doğru modeller elde etmedeki örnekleme verimliliğine ek olarak, CNN'ler, hem tamamen bağlı mimarilerden daha az parametre gerektirmesi hem de kıvrımların GPU çekirdekleri arasında paralelleştirilmesinin kolay olması nedeniyle, hesaplama açısından verimli olma eğilimindedirler. Sonuç olarak, uygulayıcılar genellikle mümkün olduğunda CNN'leri kullanmakta ve tekrarlayan sinir ağlarının geleneksel olarak kullanıldığı ses, metin ve zaman serisi analizi gibi tek boyutlu sıra yapısına sahip görevlerde bile giderek daha güvenilir rakipler olarak ortaya çıkmaktadır. CNN'lerin bazı akıllı uyarlamaları, onları grafik yapıları ve tavsiye sistemleri üzerinde de etkili kılmaktadır. (Zhang vd., 2019).

Evrişimli sinir ağı, derin ileri beslemeli mimariye sahip ve fokal katman katmanlarına sahip diğer ağlara kıyasla şaşırtıcı genelleme yeteneğine sahip bir yapay sinir ağı türüdür. Nesnelere, özellikle uzamsal verilerin yüksek düzeyde soyutlanmış özelliklerini öğrenebilmekte ve onları daha verimli bir şekilde tanımlayabilmektedir. Derin bir CNN modeli, birden çok soyutlama düzeyiyle girdi verilerinin (örneğin görüntü) çeşitli özelliklerini öğrenebilen sonlu bir dizi işleme katmanından oluşmaktadır. Başlatıcı katmanlar, yüksek seviyeli özellikleri (düşük soyutlama ile) öğrenmekte, çıkarmakta ve daha derin katmanlar, düşük


seviyeli özellikleri (yüksek soyutlama ile) öğrenerek çıkarmaktadır. (Ghosh vd., 2020).

Evrişimli sinir ağı, 2007 yılından itibaren örüntü tanıma ile ilgili görüntü işlemeden ses tanıma kadar çeşitli alanlarda çığır açan sonuçlar elde etmiştir. CNN'lerin en faydalı yönü, YSA'daki parametre sayısını azaltmaktadır. Bu başarı, hem araştırmacıları hem de geliştiricileri, klasik YSA'larıyla mümkün olmayan karmaşık görevleri çözmek için daha büyük modellere yaklaşmaya sevk etmektedir. CNN tarafından çözülen problemlerle ilgili en önemli varsayım, mekânsal olarak bağımlı özelliklere sahip olmamasıdır. Yani örneğin bir yüz tanıma uygulamasında yüzlerin görüntülerde nerede bulunduğu dikkat etmemize gerek kalmamaktadır. Tek endişe, verilen görüntülerdeki konumları ne olursa olsun onları tespit etmektir. CNN'nin bir diğer önemli yönü, girdi daha derin katmanlara doğru yayıldığında soyut özellikler elde etmektir (Albawi vd., 2017).

### Derin Evrişimsel Sinir Ağı Algoritmasının Mimarisi

Derin evrişimsel sinir ağı algoritması (derin öğrenme algoritmaları), biyolojik sinir sistemlerinin bilgi işleme yöntemlerinden esinlenerek yapay sinir ağları olarak bilinen algoritmaları kullanmaktadır (Şekil 4). Bu sayede, bilgisayarların her verinin neyi temsil ettiğini tanımlamasına ve modelleri öğrenmesine imkân tanımaktadır. Yapısal olarak yapay sinir ağlarından daha karmaşık olan derin öğrenme algoritmaları, insan beyninin işlevlerini taklit eden hesaplama sistemlerine dayanmaktadır.

Şekil 4. Derin evrişimsel sinir ağı algoritması şeması



### U Net Mimarisi



U-Net, bir tür evrişimli sinir ağı yaklaşımıdır ve medikal görüntülerdeki segmentasyonların daha iyi olması için kullanılır. 2015 yılında Ronneberger vd. tarafından önerilmiştir ve adı katmanlarının U şekline benzer mimarisinden gelmektedir. Ağın birinci kısmı genellikle kodlayıcı olarak tanımlanır ve konvolüsyon katmanları ile görüntünün özellikleri çıkarılır. İkinci kısım ise kod çözücü olarak adlandırılır ve dekonvolüsyon ve konvolüsyon katmanları kullanılır. U-Net'in popüler olmasının nedeni, semantik segmentasyon problemlerinde son katmanlara kadar özelliklerin aktarılmasına olanak tanıyan mimariye sahip olmasıdır.

### **Diş Hekimliğinden Yapay Zeka-Makine Öğrenimi ve Derin Öğrenme Uygulamaları**

Ağız ve diş hastalıkları, insanlığın en yaygın rahatsızlıkları arasındadır. Bu hastalıkları tedavi etmenin doğrudan maliyetleri ile dolaylı maliyetlerin toplamı 2015 yılı için 500 milyar Amerikan dolarının üzerindedir (Righolt vd., 2015). Demografik ve epidemiyolojik dinamikler göz önüne alındığında, ağız ve diş hastalıklarının maliyetinin artması beklenmektedir. Bu beklentiye karşın ağız ve diş bakımı sağlayacak işgücü sınırlı düzeydedir. Bu durum da hâlihazırda sorunlar yaşanan sağlık sistemlerini strese sokmakta, ağız ve diş bakımının karşılanabilirliğini ve erişilebilirliğini riske atmaktadır. Yaşanan bu sorunlara bir çözüm yolu olarak Yapay zeka gibi dijital teknolojilerin süreçleri daha verimli hale getirdiği veya kararların kalitesini artırdığı sıklıkla düşünülmektedir. Özellikle ağız ve diş hastalıklarının teşhis ve tedavisinde yapay zeka, daha fazla sayıda insana daha iyi bakım sağlanmasına olanak tanıyan daha yüksek etkinlik, güvenilirlik ve verimlilik potansiyeli olan bir sistem sunmaktadır (Ma vd., 2022).

Yapay zekanın sağlık hizmetlerini dönüştürme potansiyeli oldukça büyüktür. Diş hekimliğinde yapay zeka tabanlı uygulamalar, daha fazla insan için düşük maliyetle tedaviyi kolaylaştırabilecek araştırma, önleme, teşhis, karar verme ve rutin görevleri otomatikleştirmede yardımcı olabilmektedir. Böylelikle kişiselleştirilmiş, öngörücü, önleyici ve katılımcı diş hekimliğine olanak tanımaktadır (Rischke vd., 2022).

Diş hekimliğindeki klinik YZ uygulamaları için tam bir dijital iş akışı dönüşümü gerekmektedir. Hâlihazırda, dijital iş akışlarına dayalı olarak

geliştirilen dental teknolojilerin çeşitli örnekleri bulunmaktadır. Amaçları, sunulan hizmetlerin verimliliğini ve kalitesini artırmaktır. YZ uygulamaları, bu süreçlerin çoğunda yazılım araçlarındaki görünmez algoritmalarıdır. Yapay zekanın diş hekimliğinde kullanım amaçları (Thurzo vd., 2020).

- a) Radyografi ve diğer muayene yöntemleri ile çürük teşhisinde YZ
- b) İmplantolojide YZ
- c) Fotoğraf analizinde YZ
- d) Muayenehane yönetiminde, tele-diş hekimliği, hasta yönetiminde YZ
- e) Klinik tahminlerde YZ (sanal simülasyon, yaşlanma, büyüme)

Orhan vd. (2020) geliştirdikleri algoritma ile KIBT ile 153 periapikal lezyonun 142'sini YZ sistemi ile tespit edilebilmişler ve algoritmalarının doğruluk oranını %92,8 olarak bildirmişlerdir. Flores vd. (2022) KIBT görüntülerini kullanarak apikal granülomu radiküler kistlerden ayırmak için bir metodoloji oluşturmuşlardır. Bu çalışmalar klinik uygulamada oldukça değerlidir. Periapikal granümlü dişlerin ameliyata gerek kalmadan kök kanal tedavisi ile iyileşmesine olanak tanımaktadır. (Flores vd., 2022).

### **Yapay Zekanın Diş Hekimliğinde Kullanımı**

*Dental Eğitimde:* Akıllı ders verme sistemleri alanı, 1980'lerdeki başlangıcından bu yana önemli ölçüde ilerlemiştir. Hastalar üzerinde klinik çalışmayı taklit eden ve canlı bir hasta üzerinde eğitimle ilgili tüm komplikasyonları en aza indiren senaryolar oluşturmak için YZ, diş hekimliği eğitimi alanında sıklıkla kullanılmıştır. Sonuç olarak, öğrencilere verilen klinik öncesi sanal hasta geri bildirim önemli ölçüde iyileştirmektedir. Etkileşimli interfaz, öğrencilerin çalışmalarını değerlendirmelerine ve ideal olanla karşılaştırmalarına izin vererek, yüksek kaliteli öğrenme ortamları oluşturmaktadır. Bu sistemlerin etkinliği üzerine yapılan çok sayıda araştırma, öğrencilerin bu sistemlerle, geleneksel simülatör ünitelerine göre daha hızlı bir şekilde yetkinlik bazlı bir beceri düzeyi geliştirdiklerini göstermiştir (Agrawal & Nikhade, 2022).

*Hasta Yönetimi:* Yapay zeka ile güçlendirilmiş sanal diş hekimi asistanları, diş hekimi muayenehanesinde birçok görevi daha az hatayla yerine

getirebilmektedir. Üstelik bu işlevlerini yerine getirebilmeleri gerçek bir insandan daha az insan gücü gerektirmektedir ve hasta yönetiminde klinik teşhis, tedavi planlaması, ziyaretlerin planlanması, sigorta ve evrakların düzenlenmesi ve daha pek çok görevde yardımcı olabilmektedir. Diş hekimini hastanın tıbbi geçmişi ve sigara, içki gibi alışkanlıkları hakkında bilgilendirmede oldukça faydalıdır. Dental acil durumlarda, özellikle pratisyenin müsait olmadığı durumlarda, hastanın acil teleyardım seçeneği bulunmaktadır (Agrawal & Nikhade, 2022).

*Ağız, Diş ve Çene Cerrahisinde:* İnsan vücut hareketinin ve zekasının kopyalandığı robotik cerrahinin gelişimi, yapay zekanın ağız cerrahisindeki en yaygın kullanımınıdır. Dental implant uygulamaları, odontojenik tümörlerin ve yabancı cisimlerin çıkarılması, biyopsiler ve temporomandibular eklem cerrahisi, klinik ortamlarda başarılı olan görüntü kılavuzluğunda yapılan cerrahi prosedürlerinin örnekleridir. Oral implant cerrahisi ile ilgili karşılaştırmalı çalışmalar manuel yapılan prosedürle karşılaştırıldığında, YZ uygulamalarında doğruluğun önemli ölçüde arttığını göstermektedir (Schwendicke vd., 2020) Tecrübeli cerrahlarda, nispeten daha tecrübesiz diş hekimlere göre, daha kısa operasyon süresi, daha yüksek intraoperatif doğruluk ve hassas yapılar etrafında daha güvenli manipülasyon bildirilmektedir. Görüntü rehberliği ile daha kapsamlı cerrahi rezeksiyon mümkündür ve bu da potansiyel olarak tekrarlayan ameliyatlara olan ihtiyacı azaltmaktadır. YZ sayesinde cerrahi bir devrim geçirmiş ve artan verimlilikle, yetenekli bir cerrahın gözetiminde yarı otomatik cerrahi prosedürler uygulayan robotik cerrahlar bulunmaktadır (Agrawal & Nikhade, 2022).

### **Yapay Zekanın Ağız Kanseri Vakalarında Kullanımı**

Ağız kanseri, ölüm oranı en yüksek kanser türlerinden biridir (American Cancer Society, 2023). YZ'nin, ağız kanserini tespit etmek için mevcut tekniklere göre daha fazla tercih edilmesini sağlayan bazı avantajları bulunmaktadır. Erken tanının önemi dikkate alındığında dinamik veri kümelemesinin önemi daha da anlaşılmaktadır. YZ hesaplamaları yeni hastalardan bilgi aldıkça, bu bilgileri dinamik veri kümelerinde birleştirerek ileriye dönük tahminlerini geliştirebilmekte ve hastaların tedavi yükünü ve maliyetini azaltabilmektedir. Geç evre hastalığın prognozu kötü olduğundan ağız kanseri

hastalarında erken teşhis önemlidir. Sitoloji görüntüleri, floresan görüntüler, BT görüntüleri ve invazyon derinliğinden elde edilen veriler, YZ öğrenme araçlarında kullanılabilen ve ağız kanseri daha hızlı ve daha doğru bir şekilde teşhis edilebilmektedir (Khanagar vd., 2021).

Garcia-Pola vd., 2021 yılında yaptıkları çalışmada, oral potansiyel malign düzensizlikler ve oral kanserlerin teşhisinde kullanılan 36 DL tekniğini değerlendirmişlerdir. Yaptıkları çalışma sonucunda derin öğrenmeden türetilen araçların, yalnızca diş hekimleri için değil, aynı zamanda birinci basamak sağlık hizmeti uygulayıcıları için de erken tanıya yardımcı olduğunu ortaya koymuşlardır (Garcia-Pola vd.,2021).

### **Yapay Zekanın Ortodonti Alanında Kullanımı**

Yapay zeka bir süredir ortodontik tedavi planlamasına yardımcı olmak için kullanılmaktadır. Ortodontik planlamayı optimize etmek için YZ algoritmaları kullanılmakta ve ortodontistlerin bu süreçte zamandan tasarruf etmesi sağlanmaktadır. YZ, ortodontistlerin makineye nihai konumun nerede olması gerektiği talimatını verdikten sonra, örneğin bir dişi veya diş grubunu A noktasından B noktasına hareket ettirmenin en iyi yolunu seçmelerine yardımcı olan mükemmel bir araçtır. Ortodontinin tamamen geleneksel bir şekilde yapılması, yüksek el becerisi gerektirmekte ve pek çok profesyonel bu becerilerini geliştirebilecek eğitime sahip olamamaktadır. Bu nedenle YZ diş hekimleri için ortodontik tedavi planlamasında önemli bir yardımcı konumundadır (Faber vd., 2019).

Ortodontide tedavi, oklüzyonu değiştirmeye, dentoalveolar bileşenlerin gelişimini ve büyüme anomalilerini kontrol etmeye odaklanmaktadır. Bu sorunların etkin bir şekilde değerlendirilmesi tedavi ihtiyacının belirlenmesine ve önceliklendirilmesine olanak sağlamaktadır. Kesin teşhis, ilgili ve eksiksiz bilgi sunma, ortodontide başarılı bir tedavi uygulamanın anahtarıdır. Yapay zeka değerlendirmesinde önem arz etmektedir. Nitekim ortodontide en yaygın kullanılan makine öğrenimi algoritması, sinir ağı öğreniminin klinik muayene, ortodontik modeller ve radyografik ölçümlere dayalı olarak oluşturulduğu ortodontik çekimler hakkında klinik karar sağladığı için denetimli öğrenmedir (Palanivel vd., 2021).

Peilini vd. (2022) hastaların tedavi planlamalarında çekime ihtiyaç duyup duymadıklarını tahmin etmek için çalışmalarında bir YSA kullanmaktadır. Ayrıca, ankraj modellerini de dikkate almışlardır. Yapay sinir ağının tedavi planı başarısındaki doğruluğu ortodontik diş çekimler için %94.0, maksimum ankraj kullanımı tahmininde ise %92.8 olarak tespit edilmiştir (Peilini vd., 2022).

### **Yapay Zekanın Periodontoloji Alanında Kullanımı**

Periodontal hastalık, birden fazla nedensel faktörün eşzamanlı ve etkileşimli olarak katkıda bulunduğu karmaşık bir inflamatuvar hastalıktır. İnsanlığı etkileyen en yaygın ağız hastalıklarından biridir. Radyografların kullanıldığı derin öğrenme analizi, periodontal değişikliklerin erken saptanması ile periodontal hastalıkların teşhis ve tedavi planlamasına yardımcı olabilmektedir. Bu periimplantitis vakalarında da erken müdahaleye yardımcı olabilmektedir. YZ periodontolojide konvansiyonel göstergeleri, immünolojik ve mikrobiyolojik parametreleri periodontal tanıya dahil etmek için bir köprü görevi görmektedir (Sachdeva vd., 2021).

Ayrıca periodontolojide derin öğrenme, halitozis varlığıyla ilgili periodontal mikrobiyal paternlerin profilinin çıkarılmasında uygulanmıştır. (Corbella vd., 2020).

Somut uygulama alanları yakından incelendiğinde Periosim uygulaması ile karşılaşılmaktadır. Periodontoloji alanında Periosim, görsel monitörde görüntülenen yumuşak ve sert dokuları ayırt etmek için dokunma duyusunu kullanarak periodontal ceplerin değerlendirilmesinde yaygın olarak kullanılan bir robotik koldur. Ayrıca periodontal hastalıklarda biyobelirteçlerin saptanması için farklı hasta başı kitleri mevcuttur ve bu kitler sayesinde hastalık başlamadan önce bile risk faktörleri saptanabilmektedir. Aynı zamanda, kimyasal ve biyolojik reaksiyonu ölçerek ve temas halinde sinyaller üreterek periodontal hastalık için belirli biyobelirteçleri tespit etmek için kullanılmaktadır (Sood vd., 2022).

### **Yapay Zekanın Restoratif Diş Hekimliğinde Kullanımı**

Restoratif diş hekimliğinde sinir ağları birkaç klinik amaç için kullanılabilir. Sıklıkla yapılan tanı ve tedavi yöntemi seçimine yapay zeka yardımcı olabilmektedir. Yeni teknolojileri devreye sokmanın en yaygın yolu,

dental radyografların ve çürüğün analizi veya restorasyon ihtiyacı tespitinin yanı sıra en iyi tedavi seçeneği kararlarını vermek için sinir ağları tarafından desteklenebilen mikrobiyoloji gibi diğer alanlarda da kullanılabilir. Yeni teknolojileri günlük pratiğe tanıtmak için daha fazla çalışma yapılması gerekmektedir. (Ossowska vd., 2022).

YZ modelleri, çürük ve vertikal diş kırığı teşhisine yardımcı olmak, diş preperasyon marjını tespit etmek ve restorasyon başarısızlığını tahmin etmek için güçlü bir araç sağlama potansiyeline sahiptir. Bununla birlikte, restoratif diş hekimliğinde yapay zeka modellerinin klinik performansını değerlendirmek için daha ileri çalışmalar gerektiği konusunda temkinli yaklaşımlarla karşılaşmak da mümkündür (Revilla-Leon vd., 2021).

### **Yapay Zekanın Endodonti Alanında Kullanımı**

Periapikal lezyonların ve kök fraktürlerinin saptanmasında, kök kanal sistemi anatomisinin değerlendirilmesinde, dental pulpa kök hücrelerinin canlılığının tahmininde, çalışma uzunluğu ölçümlerinin belirlenmesinde ve yeniden tedavi prosedürlerinin başarısının tahmin edilmesinde faydalı olabilmektedir (Ossowska vd., 2022). YZ, endodontide kanal boyunun hesaplaması, apikal lezyonun saptanması ve patoloji tahmini açısından yüksek doğrulukla kullanılmaktadır. (Aminoshariae vd., 2021).

Yapay sinir ağları, apikal foramenin radyografilerde yerinin belirlenmesi için bir karar verme sistemi olarak kullanılabilir. Saghiri vd. (2021) yapay sinir ağları kullanılarak ve kullanılmadan radyolojik görüntüler üzerinde kanal uzunluklarının belirlenmesi için yaptıkları çalışmaların, ölçümler dişlerin çekiminden önce ve çekimden sonra stereomikroskopi kullanılarak yapılmıştır. Apikal foramenin lokalizasyonunun belirlenmesinde YSA'nın klinisyenlere göre daha başarılı olduğu gösterilmiştir. (Saghiri vd., 2021).

YZ, endodontik tedavi sonuçlarının başarısında bir artışa yol açabilmekte, teşhis ve tedavinin iyileştirilmesine katkıda bulunabilmektedir. Bununla birlikte, bu modelleri günlük klinik uygulamaya aktarmadan önce YZ modellerinin güvenilirliğini, uygulanabilirliğini ve maliyet etkinliğini daha fazla doğrulamak gerekmektedir. (Aminoshariae vd., 2021).

## **Yapay Zekanın Diğer Uygulama Alanları**

Derin öğrenme teknikleri, dental implantlarının sınıflandırılması gibi diğer durumlarda da yaygın olarak kullanılmaktadır. İmplant tanımlama için transfer öğrenme ve periapikal radyografiler kullanıldığında, %98'lik bir doğruluğa ulaşılmıştır (Carrillo-Perez vd., 2022).

Dental tasarımlar açısından değerlendirildiğinde; gelişmekte olan ağız içi tarayıcı ve 3B baskı, ortodontik uygulama iş akışını iyileştirmektedir. Bugüne kadar, dijital yüzey modelinin kullanımı teşhisten tedavi planlamasına, örneğin ortodontik plak tedavisine kadar dramatik bir genişleme göstermektedir. Dental arktan otomatik diş segmentasyonu, halihazırda restorasyonların tasarımı, diş dizilimi ve pozisyonlanması, kişiselleştirilmiş tedavi ve hasta merkezli sonuç değerlendirmesi için fayda sağlamaktadır (Kov d., 2021).

## **Ağız, Diş ve Çene Radyolojisi'nde Yapay Zeka Uygulamaları**

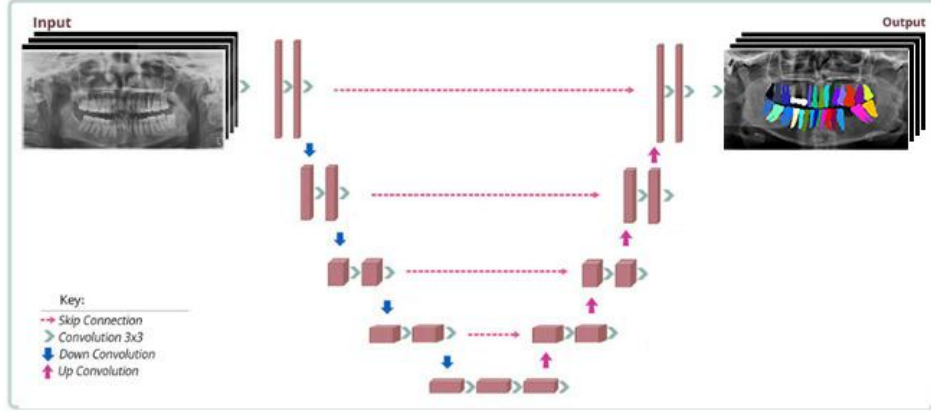
Günümüzde sağlık uygulamaları ile teknoloji neredeyse bütünleşmiş ve büyük miktarda tıbbi veri dijital olarak saklanmaya başlanmıştır. Buna bağlı olarak bilgisayar destekli algılama sistemlerine sahip derin YSA'lar birçok tıbbi alana uygulanabilmektedir. Diş hekimliğinde, YSA'ların ve daha somut olarak CNN'lerin kullanımı ile özellikle radyoloji ve patolojide teşhis ve tahminde ilginç sonuçlara ulaşılmaktadır (Carrillo-Perez vd., 2022).

Hastalık tanımlaması: Çürüklerin YSA'ları ile periapikal radyografik görüntülerden başarıyla yararlanmıştır. Benzer şekilde, ağız kanseri teşhisi, fotoğrafik veya farklı tıbbi görüntüleme türlerinden ve klinik verilerin kullanımı yoluyla derin öğrenme kullanımından fayda sağlamaktadır (Carrillo-Perez vd., 2021).

Diş hekimliği alanında hem fotoğrafik hem de radyografik görüntüler sıklıkla kullanılmakta, çoğunlukla hastaların değerlendirilmesi ve teşhis süreçlerindeki ilk adımlardan birini oluşturmaktadır. Özellikle radyografik görüntüler (periapikal, OPG veya KIBT görüntüleri) hem pratisyen hekimler hem de uzmanlar tarafından yaygın olarak kullanılmaktadır. Diş hekimliğinde CNN'ler, görüntüler üzerinde analiz gerektiren farklı noktaların anatomik yapılarını veya

patolojik durumlarını tanımak, sınıflandırmak (Şekil 5.) ve segmentlere ayırmak için eğitilmektedir (Corbella vd., 2021).

Şekil 5. Görüntü Bölütleme İşlemi.



*Dental görüntü segmentasyonu ve uygulamaları:* CNN modelleri, 3B değerlendirmeler için KIBT taramaları kullanılarak diş sınıflandırması ve numaralandırma dahil olmak üzere 2B ve 3B diş segmentasyonu için yaygın olarak kullanılmaktadır (Carrillo-Perez vd., 2022).

*Üretken çekişmeli ağlar yoluyla görüntü düzeltme:* Üretken çekişmeli ağlar (GAN'lar), iki oyuncunun (üretici ağ ve ayırmacı ağ) birbirine karşı oynadığı bir oyun teorisi senaryosuna dayanan bir YSA çerçevesidir. Jeneratör ağı, eğitim verilerinden öğrendiklerine dayalı olarak örnekler üretirken, ayırmacı ağ, doğrudan eğitim verilerinden alınan örnekler ile üretici tarafından üretilenler arasında ayırım yapmaya çalışmaktadır. Ayırmacı, o örneğin eğitim verilerinden alınması veya üreteç tarafından üretilmesi için bir olasılık yaymaktadır. Bu nedenle, ayırmacının amacı, numuneleri gerçek veya sahte olarak doğru bir şekilde sınıflandırmaktır. Diş hekimliğinde GAN'lar, düşük çözünürlüklü veya kusurlu görüntüleri iyileştirmek için kullanılmaktadır. CNN yaklaşımı BT görüntülerini geliştirerek kök kanalının boyutu, şekli ve eğriliği gibi özelliklerin daha iyi tespit edilmesini sağlamaktadır. Benzer şekilde, Wasserstein GAN'larından, düşük dozlu dental BT görüntülemenin artefakt düzeltilmesinde yararlanılmaktadır (Carrillo-Perez vd., 2022).

Yapay zeka uygulamaları, radyografik analizde de kullanılmaktadır. Diş hekimliğinde yapay zeka kullanılarak yapılan görüntü analizi, diş segmentasyonu veya lokalizasyonu, kemik kalitesi (osteoporoz) değerlendirmesi, el-bilek



radlyografileri kullanılarak kemik yaşı deęerlendirmesi ve sefalometrik yer iřareti lokalizasyonu gibi eřitli gevlere uygulanmıřtır. Dental alanda CNN yapılarını kullanan derin ęrenme sistemleri geliřtirmiř ve 2B grntlerin yanı sıra 3B KIBT grntleri de kullanan bir sistem uygulanmıřtır. (Heo vd., 2021).

İnsan diř yapısının tahmin edilebilir bir geliřim sırasını takip etmesine baęlı olarak yapay zeka, adli diř hekimlięi, yař tahmini, cinsiyet belirleme ve bilinmeyen kiřilerin kimlik tespiti iin yaygın olarak kullanılmaktadır. (Heo vd., 2021).

YZ'nin, aęız, diř ve ene radyolojisinde geniř kullanım alanları mevcuttur. Bu kullanım alanlarını kısaca ifade etmek gerekirse (Yaji vd., 2019).

- a) Yapay zeka, radyologların uygulama modelinin ayrıntılarını belirlemesine ve geliřmiř bir radyoloji raporu oluřturmak iin kapsamlı verileri kategorize etmesine olanak saęlayabilmektedir.
- b) Bazı programlar diř hekimlerine proksimal rklerin tespiti ve karakterizasyonunda yardımcı olabilmektedir.
- c) Endodontik tedavi grmř ve saęlıklı diřlerin KIBT grntlerinde dikey kk fraktrlerinin teřhisine yardımcı olan algoritmalar geliřtirilmiřtir.
- d) Bilgisayar destekli grnt analizi, kemik yapısını doęrudan dental panoramik radyografiden grselleřtirmek ve deęerlendirmek iin kullanıřlı olmaktadır.
- e) Hasta modelleri ve OPG'ler kullanılarak 3 boyutlu ortodontik grselleřtirme yapabilmektedir.
- f) zelleřtirilmiř modeller kullanılarak osteoporozu tahmin etmek iin kemik yoęunluęu deęerlendirilebilmektedir.
- g) Adli diř hekimlięinde dental radyolojiden faydalanılmaktadır. rneęin OPGler zerinden kiřisel tanımlama sistemleri geliřtirilmiřtir ve bu sistemler %97,7'ye kadar yksek kesinliklerde bařarılarla ulařmıřtır.

Yapay zeka, grnt paraziti ve/veya dřk kontrast nedeniyle kimi zaman radyografilerde insan gz tarafından fark edilemeyen proksimal rkler ve periapikal patolojiler gibi bazı patolojileri tanımak iin ek olanaklar saęlayabilmektedir. Birka arařtırmacı, klinisyenlerin diř rklerini

radyografilerde otomatik olarak tanımlamasına yardımcı olabilecek yapay zeka modelleri geliştirmiştir. Devito vd., (2008) bite-wing radyografilerinde proksimal çürüklerin teşhis yeteneğini geliştirmek için çok katmanlı bir algılayıcı sinir ağı olan bir YZ modeli uygulamıştır. Sonuçlar, sinir ağlarının uygulanmasına karşılık gelen proksimal çürük tespitinde %39.4'lük bir iyileşme göstermiştir (Devito vd. 2008). Makine öğrenimi sınıflandırıcıları tarafından takip edilen çeşitli görüntü işleme tekniklerini kullanan birçok çalışma, radyografilerde diş çürüklerinin sınıflandırılmasında yüksek performanslı sonuçlar (% 86 ila 97 doğruluk) ortaya koymuştur. Periapikal radyografilerde diş çürüklerini sadece sınıflandırmak için değil, aynı zamanda tespit etmek için de DL tabanlı bir CNN yöntemi geliştirilmiş ve umut verici sonuçlara ulaşılmıştır (Prados-Privado vd., 2020), (Lian vd., 2021), (Hardani vd., 2022), (Kang vd., 2022).

Yasa vd. (2021) tasarladıkları CNN sistemi ile 109 bite-wing radyografıda dişlerin tespiti ve numaralandırılmasını amaçlamışlardır.0.95 doğruluk ve 0.97 hassasiyet değerlerine ulaştıkları çalışmalarını sayesinde dental chartların oluşturulması için diş hekimlerinin klinikte zaman kazanacaklarını ifade etmişlerdir.

### **Yapay Zeka Kullanımı ile İlgili Limitasyonlar**

Yapay zeka tabanlı uygulamalar, dental iş gücünü zahmetli rutin görevlerden kurtararak, daha geniş bir nüfus için daha düşük maliyetlerle sağlığı artırarak ve nihayetinde kişiselleştirilmiş, öngörücü, önleyici ve katılımcı diş hekimliğini kolaylaştırarak bakımı kolaylaştırmaktadır. Bununla birlikte, yapay zeka, çoğunlukla şu nedenlerden dolayı rutin diş hekimliği pratiğine girmemektedir (Schwendicke vd., 2020).

- a) Sınırlı veri mevcudiyeti, erişilebilirliği, yapısı ve kapsamlılığı,
- b) Geliştirmelerinde metodolojik titizlik ve standartların olmaması,
- c) Bu çözümlerin değeri ve yararlılığının yanı sıra etik ve sorumlulukla ilgili pratik sorular.

Dijitalize tıbbi hasta verilerinin toplanması, saklanması ve analiz edilmesinde çeşitli engeller bulunmaktadır. Yapay zeka teknolojileri, potansiyellerine rağmen henüz tıbbi uygulamada önemli bir etkiye sahip değildir. Diş hekimliğinde evrişimli sinir ağları şu anda geliştirilmektedir. Belirli sorunların üstesinden

gelmek, dental Yapay zeka teknolojisini daha iyi hale getirmeye ve klinik bakımda kullanımlarını kolaylaştırmaya yardımcı olmaktadır. Yorumlama için diş hekimliği, belirli bir süre boyunca sıklıkla toplanan görüntüleme verilerini kullanmaktadır. Tıp ve dişhekimliği verileri, diğer veriler gibi hazır ve erişilebilir değildir. Veriler genellikle kişiselleştirilmiş ve yalnızca genel olarak birlikte çalışabilir sistemlerde saklanmaktadır (Babu vd., 2021).

Her hastanın verileri karmaşık ve hassastır. Bunları yorumlamak veya doğrulamak için çok az seçenek vardır. Elektronik tıbbi kayıtlardan elde edilen veriler, düşük düzeyde değişken eksiksizliğine sahiptir ve veriler rastgele yerine sistematik olarak eksiktir. Veriler doğası gereği çarpık olduğundan, örnekleme sıklıkla önyargıya yol açmaktadır. Veri işleme, ölçüm ve doğrulama sıklıkla yetersiz bir şekilde yeniden üretilebilir ve sağlamdır. Veri kümelerinin nasıl seçildiği, düzenlendiği ve önceden işlendiği hâlâ bir muammadır. Veriler sıklıkla hem eğitim hem de test için kullanılmakta ve bu da veri gözetleme yanlılığı olarak bilinen bir olguya yol açmaktadır. Mevcut dişhekimliği Yapay zeka uygulamalarının çoğu tarafından sunulan tek veriler, gerekli ve karmaşık klinik karar verme sürecini yalnızca kısmen bilgilendirmektedir. Ayrıca, hesap verebilirlik ve şeffaflık konusunda hala endişeler bulunmaktadır (Babu vd., 2021).

Diş hekimliği eğitiminde yapay zeka kullanımının avantajlarına karşın eğitim, yapay zekanın sınırlılıklarını gösterdiği alanlardan biri olarak karşımıza çıkmaktadır. Yapay zeka verimliliği artırmasına ve bu sosyal mesafe döneminde öğrencilerin öğrenmeye devam etmesine izin vermesine rağmen, fiziksel bir manken üzerinde çalışmayı ve yüksek ve yavaş hızlı el aletlerini tutmayı asla gerçek anlamda taklit edememektedir. Operatif ve restoratif diş hekimliği eğitiminde bilgisayar simülasyonunun kavite hazırlama ve polimerizasyon gibi operatif becerileri öğretmede etkili olduğu bulunmuştur. Yapay zeka diş hekimliği eğitiminde umut verici bir araç olmasına rağmen, standarda entegre edilmeden önce daha fazla veri ve araştırma yapılması gerekmektedir.(Lee vd., 2021).

Diş hekimliğindeki herhangi bir yapay zeka uygulaması, bakıma erişimi ve kaliteyi iyileştirerek, hizmetlerin etkinliğini ve güvenliğini artırarak, hastaları güçlendirerek ve etkinleştirerek, tıbbi araştırmaları destekleyerek veya sürdürülebilirliği artırarak bir somut değer göstermektedir. Bireysel mahremiyet,

haklar ve özerklik ön plana ve merkeze konulmalıdır; merkezileştirilmiş/birleşik öğrenime geçiş, ölçeklenebilirliği ve sağlamlığı geliştirirken bunu ele alabilmektedir. Son olarak, dental YZ çözümlerinin güvenilirliği ve genellenebilirliği garanti edilmelidir; sürekli insan gözetiminin ve kanıta dayalı diş hekimliğine dayanan standartların uygulanması gerekmektedir. (Schwendicke vd., 2020).

### **Yapay Zeka ve Diş Hekimliğinin Geleceği**

Bununla birlikte, yapay zeka potansiyel olarak dikkate alınması gereken yeni riskler getirmektedir. Yapay zeka algoritmalarının tasarımı ve karmaşıklığı nedeniyle, bunların çıktıları genellikle açıklanamamakta, bu da bu yöntemlerin kabulünü ve dolayısıyla kullanımını sınırlamaktadır. Açıklanabilir Yapay zeka, tam olarak bu etkiyle karşılaşılabilecek çözümler bulmakla ilgilenen, hızla gelişen bir araştırma alanıdır. Sağlık hizmetlerinde ve özellikle diş hekimliğinde Yapay zeka çözümlerinin güvenli kullanımını garanti etmek için farklı kuruluşlar, yapay zeka uygulamalarının güvenliğini, performansını ve güvenilirliğini sağlamak için yeni standartlar ve araçlar geliştirmektedir (Ma vd., 2022).

YZ'nin her alandaki uygulamaları gün geçtikçe artmaktadır. Diş hekimliği pratiği hastalığın teşhisi ile ilgili olmadığı, ancak çeşitli klinik bulgularla korelasyon içerdiği ve hastaya tedavi sağladığı için hiçbir YZ programı diş hekiminin yerini tutamamaktadır. Bununla birlikte, yapay zeka teknikleri ve kavramlarının net bir şekilde anlaşılması, gelecekte kesinlikle bir avantaja sahip olacaktır. Şu anda Yapay zeka kullanımının sınırlaması, yetersiz ve yanlış verilerin mevcudiyetidir. Bu nedenle, yakın gelecekte diş hekimliğinde Yapay zeka için tamamen kullanılacak olan gerçek verileri toplamaya ve veri tabanlarına girmeye odaklanmak diş hekimlerinin ve klinisyenlerin sorumluluğundadır (Tandon & Rajawat, 2020).

Diş hekimleri, tedaviyi bir manuel çizelge sistemi aracılığıyla oluşturdukları girdi ve verilerle uyumlu hale getirirken patolojileri, semptomları ve hasta geçmişlerini teşhis etmek için neredeyse tamamen kendi profesyonel gözlemlerine güvenmektedirler. Diş klinikleri, teşhisin hemen hemen her alanında teknolojiyi kullanırken, bu teknoloji, ilk etapta bu değerlendirmeleri ve kayıtları mümkün kılan araçlarla sınırlanmaktadır. Bu, bir röntgen görüntüsünün kontrastı

veya parlaklığının ayarlanması ile tespit edilebilecek veya edilemeyecek durumların analizinde insan hatası unsurunu ortadan kaldırmak için kullanılabilir. Geleneksel tanımanın bu tür manuel temel taşları, bir Yapay zekanın otomatikleştirilmiş algoritması içindeki binlerce veya milyonlarca veri noktası arasında tek veri noktaları haline gelmektedir. Bu, yapay zekanın daha önce görünmeyen veya başka bir şekilde algılanmayan belirtileri ortaya çıkarabilecek kalıpları algılamasına olanak tanırken teşhis doğruluğu hakkında ikinci bir görüş sunmaktadır (Hillen, 2021).

Yapay zekanın diş hekimliğinde kullanılması, kişiselleştirilmiş tanılama ile daha hızlı çözümler sunma potansiyeline sahip olabilmektir. Doktorlar ve hastalar arasındaki iletişimi geliştirecek ve hasta testlerinin doğru bir şekilde analiz edilmesini sağlamaktadır. Yapay zeka platformu, hastalara teşhis koymak için çok daha uygun alternatifler sunmaktadır. Mevcut ortodontik Computer Aided Diagnosis (CAD), ortodontistin talimatlarına göre bir operatör tarafından manuel olarak yapılırken ve insan hatası içerebilirken, yapay zeka tabanlı analiz, ortodontik tedavi öncesi ve sonrasında kesin teşhis ve prognoz ile doğru bir kurulumla sahip olabilmektedir (Janapala, 2020).

Kısacası, yapay zeka, insan davranışını taklit eden yöntemlerin incelenmesidir. Bir hastanın anamnezini alma temel adımından veri işlemeye ve ardından teşhis için verilerden bilgi çıkarmaya kadar, yapay zekanın diş hekimliği ve tıp biliminde birçok uygulaması bulunmaktadır. Bu, gelecekte diş hekimliği pratiğinin iyileştirilmesi ve bu teknolojinin ilerlemesini birleştirmek için zamana ihtiyaç vardır. (Tandon & Rajawat, 2020).

## **BÖLÜM III**

### **Yöntem**

Araştırmanın örneklemini Yakın Doğu Üniversitesi, Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı arşivinden elde edilen toplam 8138 adet OPG görüntüsünden oluşmaktadır. Çalışma retrospektif veri tarama çalışması olarak planlanmıştır.

## **Etik Kurul Onayı**

Bu tez çalışması Yakın Doğu Üniversitesi Sağlık Bilimleri Etik Kurulu tarafından YDÜ/2022/108-1651 sayılı kararı ile onaylanmıştır (Ek-1). Araştırma protokolü Helsinki Bildirgesi'nin etik standartlarına uygundur.

## **Veri Setinin Oluşturulması**

Araştırmaya dahil etme kriterleri arasında;

- a) Hastaların 13-100 yaş aralığında bulunması (13 yaştan önce karışık dişlenme devam etmektedir)
- b) OPG görüntülerinin radyolojik olarak değerlendirilebilir olması
- c) İncelenecek bölgelerde herhangi bir morfolojik bozukluk (dental anomaliler gibi) olmaması
- d) Maksillofasiyal cerrahi geçirmemiş hastalar

Dahil edilmeme kriterleri arasında

- a) Görüntüleme alanlarında büyük asimetrisi olan hastalar
- b) Maksillofasiyal patolojilerin yer aldığı OPG'ler,
- c) Cerrahilerin neden olduğu maksillofasiyal bozukluklar
- d) Hasta veya cihaz nedenli artefaktların bulunduğu görüntüler
- e) Süt dişlerinin hala ağızda bulunması
- f) Total dişsiz hastalar

## **OPG Görüntülerinin Elde Edilmesi**

Çalışmada kullanılan OPG birimleri aşağıdaki gibidir:

- Orthophos SL 3D (Dentsply Sirona, Bensheim, Almanya) (60-90 kV, 3-16 mA)
- Orthophos XG (Dentsply Sirona, Bensheim, Almanya) (60-90 kV, 3-16 mA)
- PM 2002 CC Proline (Planmeca, Helsinki, Finland) (60-70 kV, 2-7 mA)


Görüntüler, Yakın Doğu Üniversitesi Diş Hekimliği Fakültesi Ağız Diş ve Çene Radyolojisi bölümünde bulunan OPG cihazlarından elde edilmiştir. OPG görüntüleri, çalışmanın yürütüldüğü birimlerde standart tarama protokolüne göre

elde edilmiştir. Görüntüler klinikte DICOM formatında elde edilmesinin ardından, PNG dosyalarına dönüştürülmüş ve segmentasyon işlemi için segmentasyon aracının veritabanı olan Computer Vision Annotation Tool'a (CVAT) aktarılmıştır. Her görüntüye numara ataması yapılarak anonim hale getirilmiştir.

### **OPG Görüntülerinden İncelenecek Yapıların Tespit Edilmesi**

Tüm dişler, kron ve köprü restorasyonları, dental implantları, kompozit ve amalgam dolgular, diş çürükleri, artık kökler ve kök kanal dolguları manuel semantik segmentasyon tekniği ile segmentlere ayrılmıştır. Tüm görüntüler, kenar boşlukları oluşturma noktaları ile belirlenerek bölümlere ayrılmış ve model bu segmentasyonlarla eğitilmiştir (Şekil 6).

Şekil 6. Dental İmplantların Manuel Segmentasyon İşlemi



### **Semantik Segmentasyon**

Semantik segmentasyon bir görüntüdeki her bir pikselin bir etiketle sınıflandırılmasıdır. Veri kümesindeki tüm görüntüler 512 \* 1280 piksele yeniden boyutlandırılmış ve her piksel diş yapıları ve arka plan olarak sınıflandırılmıştır. Bu sınıflandırma için python bilgisayar dilinin U Net yorumuyla algoritma oluşturulmuştur. Tüm segmentasyonlar; %80 eğitim seti, %10 doğrulama seti ve %10 test seti olarak üçe ayrılmış ve test setindeki en başarılı model tüm ölçümler arasından seçilmiştir. İstatistiksel analiz için Dice Similarity Score (DSC) ve doğruluk değerleri hesaplanmıştır.

### **Sınıflandırma Modellerinin Performans Ölçütleri**

Algoritma performansı hesaplanırken çeşitli ölçütler mevcuttur. Modelin dış yapıları segmentasyon yeteneğini ölçmek için DSC ve doğruluk ölçütleri kullanılmıştır.

Algoritmanın değerlendirilmesi, nesnelerin ne kadar benzer olduğunun bir ölçüsü olan DSC ile hesaplanmıştır. DSC, iki nesnenin toplam boyutuna bölünen iki segmentasyonun örtüşme oranıdır. DSC sadece kaç tane gerçek pozitif bulunduğu bir ölçüsü değil, aynı zamanda yöntemin bulduğu yanlış pozitifleri de çıkarır, hassasiyetle benzerleri ayıklar. DSC'nin sensitivite benzediğini söylemek doğru olur. Tek fark, yalnızca yöntemin bulduğu pozitifler yerine toplam pozitif sayısına sahip olunan paydadır. Bu nedenle, DSC, algoritmanın yöntemin bulamadığı pozitifler için de çıkarma doğrulaması yapar. Doğruluk, sınıflandırma modellerini değerlendirmek için kullanılan bir ölçümdür. Diğer bir deyişle, doğruluk, modelin doğru tahminlerinin oranını ifade eder.

### **Dice Similarity Coefficient Hesaplanması**

Görüntü işleme ve görüntü analizinde kullanılan bir metrik olan Dice Similarity Coefficient (DSC), iki görüntünün benzerliğini ölçmek için kullanılır. DSC, görüntü segmentasyonu ve bölümlendirme problemleri gibi uygulamalarda sıklıkla kullanılır ve benzerliği belirlemek için birçok alternatif metrikten daha yüksek bir performans gösterir. DSC, Jaccard benzerlik indeksi ile benzerdir ve iki görüntünün ortak bölümünün toplam bölümleri üzerinden hesaplanır (Fan, 2020). Formül olarak şu şekildedir:

$$DSC = 2|A \cap B| / (|A| + |B|)$$

Burada A ve B, iki görüntünün ortak bölüm sayısını gösterir. DSC, sıfır ve bir arasında bir sayı üretir ve benzerliğin oranını gösterir. Eğer iki görüntü tamamen aynı ise, DSC değeri 1 olacaktır. Eğer görüntüler tamamen farklı ise, DSC değeri 0 olacaktır. DSC'nin en önemli avantajı, farklı boyutlardaki görüntüler için doğru sonuçlar verebilmesidir. DSC, görüntü segmentasyonu, bölümlendirme, eşleme ve benzerliği ölçme gibi uygulamalarda sıklıkla kullanılır.



## **BÖLÜM IV**

### **Bulgular ve Yorumlar**

Tüm OPG'lerde segmentasyonlar için hesaplanan DSC ve doğruluk değerleri sırasıyla dişler için 0.85 ve 0.95, diş çürükleri için 0.88 ve 0.99, amalgam/kompozit dolgu restorasyonları için 0.87 ve 0.99, kron köprü restorasyonları için 0.93 ve 0.99, dental implantlar için 0.94 ve 0.99, kök kanal



dolguları için 0.78 ve 0.99, kök kalıntıları için 0.78 ve 0.99 olarak bulunmuştur (Tablo 1).

**Tablo 1.** Tüm OPG'lerde hesaplanan DSC ve doğruluk değerleri

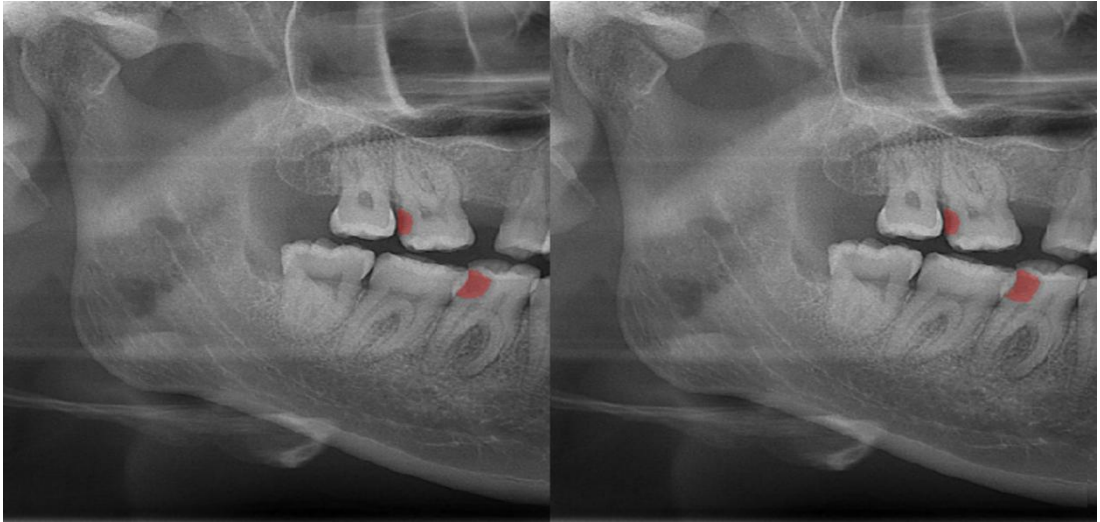
<b>Yapı</b>	<b>Doğruluk</b>	<b>DSC</b>
Diş Segmentasyonu	0.99	0.95
Diş Çürükleri	0.99	0.88
Dental Restorasyonlar	0.99	0.87
Kron-Köprü Restorasyonları	0.99	0.93
Diş İmplantları	0.99	0.94
Kök-Kanal Dolgusu	0.99	0.78
Rezidüel Kökler	0.99	0.78

Modelin otomatik segmentasyonu ile yaptığımız manuel segmentasyonlar Şekil 7'de verilmiştir.


Şekil 7. Dişlerin Manuel (üst) ve Otomatik (alt) Segmentasyonu.



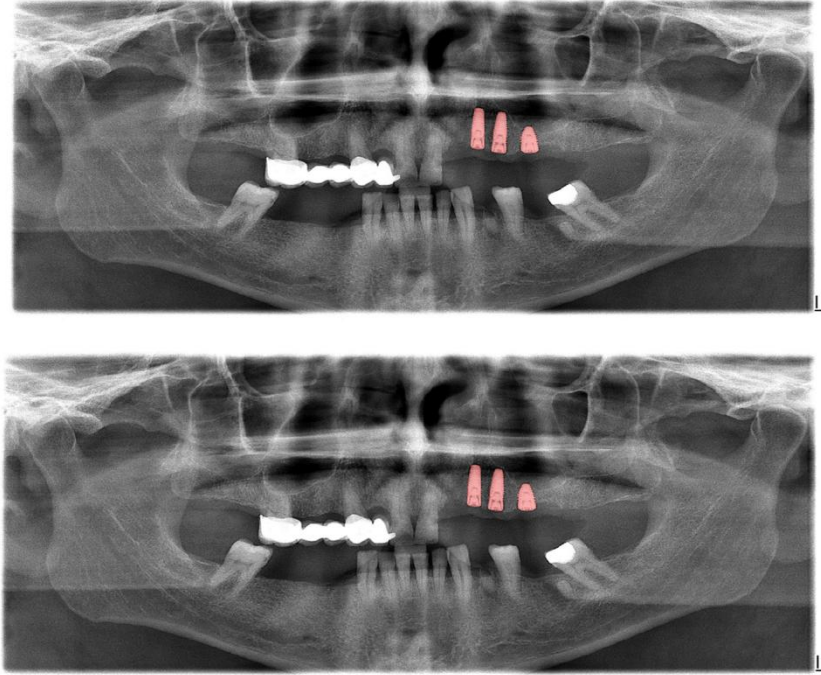
Şekil 8. Sağ Üst İkinci Molarda ve Sağ Alt Birinci Molarda Çürük Lezyonların Manuel (sol) ve Otomatik (sağ) Segmentasyonu




Şekil 9. Köprü Restorasyonlarının Manuel (üst) ve Otomatik (alt) Segmentasyonu.




Şekil 10. Sol Maksiller Premolar ve Molar Bölgelerdeki Dental İmplantların Manuel (üst) ve Otomatik (alt) Segmentasyonu.



Şekil 11. Sağ ve Sol Mandibuler 1. Molar Dişlerdeki Kök Kanal Tedavilerinin Manuel (üst) ve Otomatik (alt) Segmentasyonu.



Şekil 12. Artık Köklerin Manuel (üst) ve Otomatik (alt) Segmentasyonu.




Diş segmentasyonunda, özellikle vertikal pozisyonda gömülü olan maksiller üçüncü molar dişlerin kök apekslerinin maksiller sinüs tabanı ile üst üste geldiği durumlarda, kök apekslerinin hatalı olarak otomatik segmentasyona uğradığı gözlemlenmiştir.


Şekil 13'te 18 numaralı dişte 28 numaralı dişe göre daha başarılı bir otosegmentasyon ve çentik şeklinde eksik segmentasyon alanı görülmektedir.

Çalışmamızda az da olsa DSC skorumuzu düşüren hatalı bölütlemenin nedenlerinden biri de budur. OPG'lerde özellikle premolar bölgede gördüğümüz süperpozisyon (Şekil 14) aslında modelimizin bir eksikliğini değil, OPG'lerin bir kısıtlılığını göstermektedir.

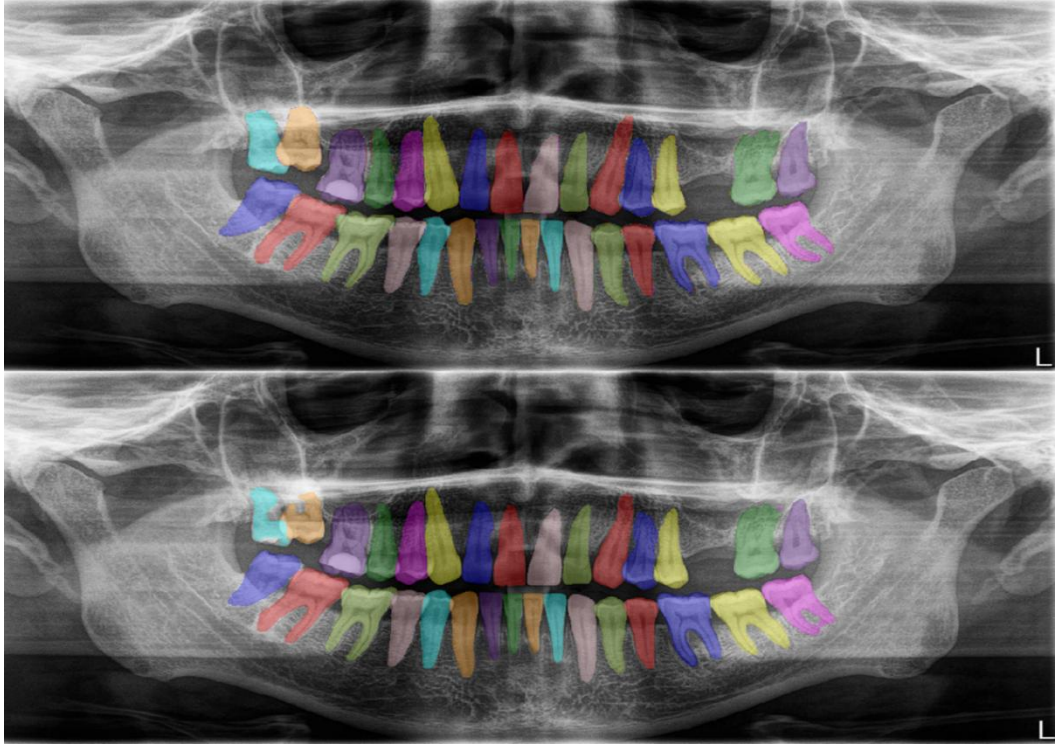
Şekil 13. Maksiller 3.Molar Dişlerin Maksiller Sinüs Tabanı Arasındaki Süperpozisyona Bağlı Segmentasyon Hatası



Şekil 14. Mandibular sol birinci ve ikinci premolar diş arasındaki süperpozisyona bağlı segmentasyon hatası



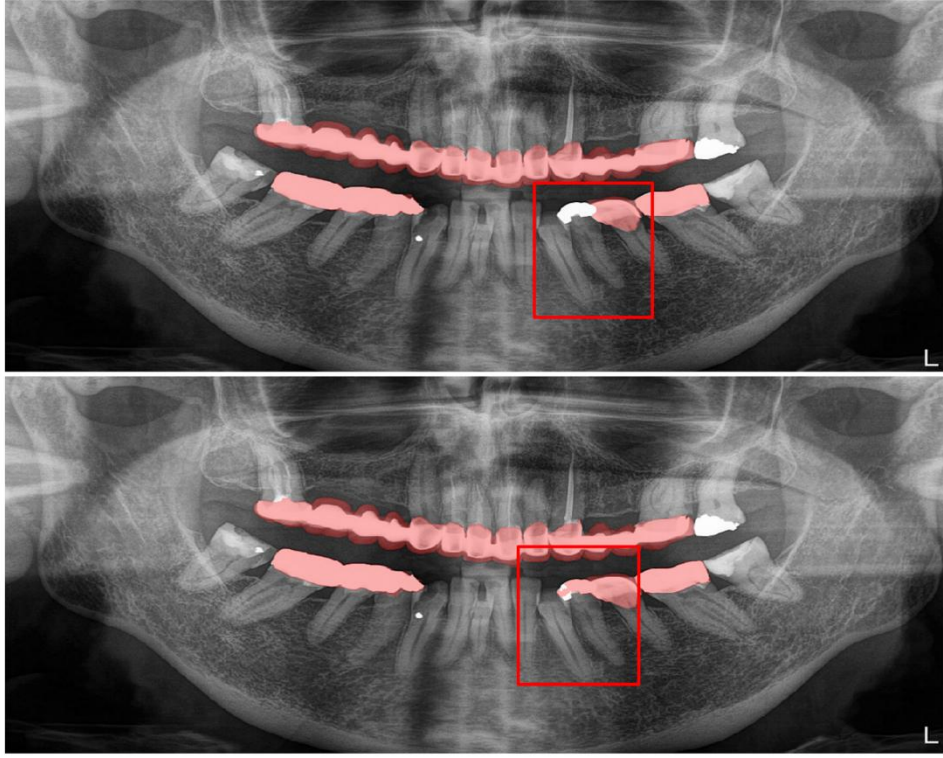
Şekil 15. Sağ Maksiller İkinci ve Üçüncü Molar Dişlerin Süperpozisyonlara Bağlı Olarak Eksik Segmentasyonu.



Sağ maksiller ikinci ve üçüncü molar dişlerin süperpozisyonlara bağlı olarak eksik segmentasyonları izlenmektedir. Süperpozisyonun mevcut olmadığı diğer tüm dişler tüm sınırlarıyla başarılı bir şekilde segmente edilmiştir (Şekil 15)

Kron-köprü segmentasyonlarında, birkaç büyük amalgam dolgu, bazı durumlarda hem genişlikleri hem de metalik opasiteleri nedeniyle kron restorasyonları olarak yanlış segmentlere ayrılmıştır. Şekil 16'da mandibular sol 1. premolar dişteki geniş amalgam restorasyonun kron restorasyonu olarak yanlış segmente edildiği görülmektedir.

Şekil 16. Mandibuler Sol Birinci Premolar Dişte Geniş Amalgam Restorasyonun Kron-Köprü Segmentasyonu Olarak Hatalı Etiketlenmesi.




Şekil 17. (A) Mandibular Sağ Birinci Molar Dişteki Geniş Amalgam Dolgusunun Kron Restorasyonu Olarak Hatalı Segmentasyonu




(B) Maksiller Sağ İkinci Molar Dişteki Geniş Amalgam Dolgusunun Kron Restorasyonu Olarak Hatalı Segmentasyonu

(C) Maksiller Sol Kanin Dişin Distalinde Bulunan Distal Metalik Uzantının (protez resti), Kron-Köprü Restorasyonu Olarak Hatalı Segmentasyonu.




İmplant segmentasyonlarında, implant abutmentlarının farklı bir etiket ile segmente edilmediği durumlarda, abutment ve implantın aynı etiket ile otomatik olarak segmente edildiği izlenmiştir (Şekil 17). OPG’de implant abutmentlarının ve protez barının hatalı segment edilmediği ve implantlardan model tarafından ayırt edilebildiği görülmektedir (Şekil 18).

Şekil 18. OPG’de İmplant Abutmentlarının ve Protez Barının Düzgün Olarak Segment Edildiği ve İmplantların Model Tarafından Ayırt Edilebildiği Görülmektedir.




Şekil 19. İmplant, İmplant Abutmanı ve İmplantı Üstü Kronun Bölümleri İle Segmentasyonlar Arasındaki Fark



Kök kanal dolgu segmentasyonlarında; birden fazla sınırlama olduğu için hatalı durumların sayısı diğer segmentasyonlardan daha fazla bulunmuştur. Kök kanal dolgularının otomatik segmentasyonundaki hatalar; tek veya birkaç güta-perka ile yapılan yetersiz dolgular, komşu diş kökü ile superpoze olmuş çok köklü dişlerin kanal dolguları, tüm kanal boyunca uzanmayan güta-perkalar (Şekil 20) ve pulpa odasındaki restorasyonun yanlış yorumlandığı ve güta-perka olarak segmentlere ayrıldığı vakalar gözlemlenmiştir.

Şekil 20. Tek Güta-perka İle Yapılmış Kanal Tedavisi Bulunan Sol Mandibuler 1. Molar Dişin Hatalı Segmentasyonu.



## BÖLÜM V

### Tartışma

OPG olarak da bilinen panoramik radyografi, diş hekimleri tarafından yaygın olarak kullanılan değerli bir teşhis aracıdır. Tek bir görüntüde dişleri, çene kemiklerini ve çevresindeki dokuları dahil olmak üzere tüm dental yapıyı görüntülemeyi sağlayan teknik dentomaksillofasyal yapının, kapsamlı görüntüsünü sağlar ve bu nedenle birçok diş hekimi tarafından dental uygulamalarında sıklıkla tercih edilir. OPG'nin en önemli avantajlarından biri, dental ve maksillofasiyal patolojilerin hızlı ve kolay bir şekilde değerlendirilmesine olanak tanımasıdır. Diş hekimleri genellikle OPG'yi geniş çürük kaviteleri, periapikal lezyon, ilerlemiş periodental hastalık, gömülü dişler ve diğer dental anomalileri teşhis etmek için kullanırlar. OPG, diş hekiminin, üçüncü molar dişler gibi sürmemiş dişlerin pozisyonunu değerlendirerek, gelecekte dental sorunlara neden olup olmayacağını belirlemesine olanak tanır. Ayrıca, OPG, periodental hastalığı olan hastalarda kemik grefti gibi tedavi kararlarını yönlendirebilir. OPG'nin diğer bir önemli faydası, çene kemiği ve diğer komşu yapıları etkileyen patolojilerin tespitinde kullanılabilmesidir. OPG, diğer görüntüleme modaliteleri ile teşhis etmenin zor olabileceği çene tümörlerini, kırıklarını ve gelişimsel anomaliyi tanımlamada ve sınırlarının belirlenmesinde özellikle yararlıdır. Ayrıca, temporomandibular eklemde osseöz yapılarını değerlendirmek ve özellikle sağ sol TME'nin karşılaştırmasını yapmak için kullanılabilir. OPG, görece düşük iyonizan radyasyon dozuna sahip bir görüntüleme tekniği olduğundan, hem hastalar hem de diş hekimleri için güvenli ve etkili bir görüntüleme modalitesi haline gelmiştir. Bu özellik, radyasyon maruziyetine daha duyarlı olabilen pediatrik hastaların yönetiminde daha dikkatli kullanım gerektirmektedir. Çocuk hastalarda özellikle diş sürme sürecinin hem pozisyon hemde zamanlama olarak normal olup olmadığının değerlendirilmesinde son derece faydalıdır.

Diş hekimliği pratiğinde sıklıkla kullanılan bir görüntüleme tekniği olan OPG'ler üzerinde teşhis ve tedavi yöntemlerinin doğruluğunu artıracak birçok çalışma yapılmıştır ve yapılmayada devam etmektedir. OPGler diş hekimliği radyolojisinde periapikal radyograflar ile beraber en çok faydalanılan

görüntüleme modaliteleri olsalar da belirli avantajlara ve dezavantajlara sahiptir.

OPG cihazında x-ışını demeti hafif yukarı eğilim göstermektedir. Bu nedenle istenen yapıların görüntülerinde geometrik distorsiyonlar görülür. Dolayısıyla objeler arası vertikal boyuttaki uzaysal ilişkiler doğru anatomik ilişkileri yansıtmayabilir. OPG iki boyutlu bir görüntüleme tekniği olup bukkolingual değerlendirmeler yapılamamaktadır. Bu nedenle 3 boyutun gerekli olduğu değerlendirmelerde tek başına görüntüleme yöntemi olarak kullanımı uygun değildir. Yumuşak dokular ve hava yolunun oluşturduğu gölgeler, sert dokularda değerlendirilmesi gereken yerleri maskeleyebilmektedir. Panoramik radyografi tekniğinde, iskeletsel düzeyde maksilla mandibula ilişkisi şiddetli bozuk olduğu durumlarda ve fasiyal asimetride görüntüde distorsiyon artmaktadır. Ön bölgelerde vertebra süperpozisyonuna bağlı anterior bölge dişleri net izlenememektedir. Bu da segmentasyon sırasında etiketlenen bölgelerin konturlarının belirlenmesinde bazı olgularda kısıtlamalara neden olmaktadır. Özellikle premolar dişlerin aproksimal yüzeylelerinde, süperpozisyona bağlı değerlendirmeler yapılamamaktadır. Aynı sorun ilgili dişlerdeki arayüz çürüklerinin segmente edilmesi ve iki dişin ayrı ayrı segmente edilmesi gibi işlemlerde kısıtlamalara sebep olup DSC değerini düşürebilmektedir.

Tüm bu dezavantajların yanında çalışmamızda OPG kullanımının en büyük iki avantajı segmentasyon işleminin çok daha uygulanabilir ve kolay olması ile alt ve üst çene ile çevre dokuları kapsayan geniş görüntüleme alanına KIBT'tan daha düşük bir efektif doz ile görüntüleme özelliğidir.

Çalışmamızdaki çıktı (output) görselleri incelendiğinde özellikle arayüz çürüklerinin ve süperpozisyon durumundaki dişlerin segmentasyonunda hatalara neden olması OPG'nin geometrik sınırlandırmalarından kaynaklanmaktadır. Orhan vd. (2019) yaptıkları çalışmada 2 farklı KIBT cihazı, periapikal radyograf ve OPG'nin diş çürüklerini teşhis etme başarısını karşılaştırmışlardır. Çürük tespiti KIBT cihazları için 0.927 ve 0.896 ROC (area under curve – eğri altında kalan alan) değerine sahipken, periapikal radyografiler için bu değer 0.875, OPG için 0.693 olarak bulunmuştur. Bu çalışmanın sonuçlarından yola çıkarak söylenebilir ki; OPGler üzerinde yapılan herhangi bir çalışmada diş ve dental çürük segmentasyonları için elde edilen DSC değerleri kullanıcıların ve

algoritmaların hataları kadar OPG'nin de sınırlamaları nedeniyle hiçbir zaman 1.00 değeri olamayabilir (Orhan vd., 2019)

Her ne kadar yüksek DSC ve doğruluk oranları otomatik segmentasyonun yüksek uygulanabilirliğini gösterse dahi; OPG'nin hem sınırlamalarını hem de 2B görüntülerdeki otomatik segmentasyonu detaylandırmak için tartışılması gereken çok sayıda engel bulunmaktadır. Sınırlandırmaların çoğu, 2B görüntülerin geometrik sınırlamalarıyla ilişkili olmakla beraber, her bir segmentasyon işlemi için detaylı değerlendirme yapılabilir.

Çalışmamızda karşılaştığımız sınırlamalardan ilki veri modelimizin diş segmentasyonunda mükemmel bir sonuç elde edememesinin başlıca nedeni OPG'lerde özellikle premolar dişlerde süperpozisyonlardan kaçınmanın neredeyse imkansız olması ve ayrıca çapraşıklığı olan hastaların çalışmaya dahil edilmesidir. Abdalla-Aslan vd. (2020) ile Kuwada vd. (2020) tarafından yapılan çalışmalar gibi literatürde bulunan bazı çalışmalarda ortodontik sorunları olan hastaları çalışmalarına dahil etmemiştir; ancak asıl hedeflerimizden biri, dental klinikleride hasta görüntülerinde herhangi bir dahil edilmeme kriteri olmayacağı için modelimizin başarısını genel popülasyonda değerlendirmektir. Bu, çalışmamızda DSC'yi az miktarda da olsa azaltan hatalı segmentasyonun nedenlerinden biridir. Özellikle OPG'ler üzerindeki premolar bölgede görülen süperpozisyon, aslında geliştirilen modelin bir eksikliğini değil, OPG'lerin bir sınırlamasını göstermekte ve daha yüksek DSCler elde etmiştir (Abdalla-Aslan vd., 2020),(Kuwada vd., 2020).

Öncül bir çalışma değerine sahip olan ve Tuzoff vd. tarafından 2019 yılında basılan bu makalede ise, araştırmacılar dişlerin tespiti için 0.99, dişlerin numaralandırılması için 0.98 skorlarına ulaşmışlardır. Aynı değerlendirme diş hekimleri tarafından yapıldığında diş tespiti 0.998, diş numaralandırılması için 0.989 skorları bulunmuştur. Karaoğlu vd. (2023) OPG üzerinde farklı modelleri kullanarak diş segmentasyonları ile ilgili yaptıkları çalışmalarında en başarılı modellerinde çalışmamıza benzer olarak 0.958 F skoruna ulaşmışlardır.

Bayraktar & Ayhan (2022) arayüz çürüklerini bitewing radyografında tespit etmek için yaptıkları çalışmada 0.94 doğruluk değerine ve 0.87lik bir AUC değerine ulaşmışlardır. (AUC değeri, 0 ile 1 arasında değer alır ve 1'e ne kadar yakınsa model de bir o kadar başarılıdır) Yaptıkları çalışmada bitewing

radyograf kullandıkları için herhangi bir süperpozisyon durumu ile karşı karşıya kalmamışlardır. Çalışmamız OPGler üzerinde yapıldığı için başarı değerimiz 0.87 gibi yüksek bir noktaya ulaşmamıştır.

Fontenele vd. (2022) KIBT görüntüleri üzerinden yaptıkları benzer bir çalışmada diş dolgularını otomatik segmente etmek istemişlerdir. KIBT ile modelleri 0.95-0.97 arasında bir DSC değerine ulaşmıştır. Bayrakdar vd. (2022) bitewing radyografları kullanarak Cranio Catch ile yaptıkları çalışmada çürük tespitinde 0.78, çürük segmentasyonunda ise 0.81lik F skorları elde etmişlerdir. Çalışmamızda ise çürük segmentasyonu başarısı OPGlerde 0.88 olarak belirlenmiştir. Çalışmamızda süperpozisyonlarında olmasına rağmen 0.88lik bir başarısı olması oldukça başarılı bir sonuç olarak kabul edilebilir.

Lin vd. (2022) 600 periapikal radyografi kullandıkları çalışmalarında CNNler ile periapikal radyograflardaki arayüz çürüklerini otomatik tespit etmeyi amaçladıkları çalışmalarında, 0.606 skoruna sahip bir otomatik segmentasyon sonucuna ulaşmışlardır. Çürük tespit etmede 0.82 gibi yüksek bir skora ulaşmalarına rağmen segmentasyondaki bu anlamlı fark arayüzlerdeki süperpozisyonlar ile açıklanmıştır. Çalışmamızda çürük lezyonları oklüzal çürük, arayüz çürüğü şeklinde ayırma sahip olmadığı için benzer değerlendirmeyi yapamamaktayız ancak output dosyaları incelendiğinde arayüz çürüklerinin segmentasyonunun önündeki en büyük engel süperpozisyonlar olarak çalışmamızda da görülmüştür.

Arı vd. (2022) periapikal radyograflarda çürük, kron, pulpa, dolgu, kök-kanal tedavisi ve apikal lezyonları segmente ettikleri çalışmalarında, kök-kanal dolgularında 0.98 gibi oldukça başarılı bir F1 skoru elde etmişlerdir. Çalışmamızda bu parametre için bulunan DSC skoru 0.78 olup bu anlamlı farkın görüntüleme modalitesi ile ilgili olduğunu düşünmekteyiz.

Kron-köprü restorasyonlarında, genişliği ve metalik opaklıkları nedeniyle bazı vakalarda büyük amalgam dolguların da hatalı bir biçimde kron restorasyonu olarak segmente edildiği görülmüştür. Bu tür hataların önüne geçebilmek için daha ileri çalışmalarda amalgam ve kompozit dolgular ayrı ayrı etiketlerle segmente edilip DSC'ları değerlendirilmelidir.

Revilla-Leon vd. (2021) tarafından yapılan sistematik bir derlemede literatürde dental implantların Yapay zeka modelleri ile otomatik olarak

tanınmasının %93,8-%98 arasında deęiřtięi bildirilmiřtir. Bu derlemede dental implantlarla ilgili 17 adet makaleyi deęerlendirmiřlerdir. Bu 17 alıřmanın 7'si implant markasını tanımak iin, 7'si implant bařarısını tahmin etmek iin, kalan 3'ü ise implant tasarımları hakkında alıřmalardır. İmplant bařarısı iin üretilen modellerin bařarısı ise 0.624 ile 0.805 arasında eřitlilik göstermiřtir. (Revilla-Leon vd., 2021) Literatüre benzer řekilde, modelimiz 0.94 DSC deęerleri ile bařarılı olmuřtur. Hem yivli dıř yapıları hem de metalik opasiteleri nedeniyle, dental implantları herhangi bir anatomik yapı veya restorasyon olarak hatalı segmente edilmemiřtir ve bu yapının otomatik segmentasyonun neredeyse mükemmel bir doęrulukla belirlenebildięi bulunmuřtur. Dental implant segmentasyonunda doęruluk oranlarına göre nispeten daha dūřuk DSC'nin nedenleri incelendięinde, modelimizin implant abutmentını bazı OPG'lerde rastgele segmentlere ayırdıęı ve dięerlerinde ise segmente etmedięi gürölmüřtür. Bu nedenle, daha ileri alıřmalarda, dental implantların, implant abutmentlarının ve implantların üzerindeki kron veya körpü restorasyonlarının 3 ayır etiket ile segmentasyonunun, abutment ve implant arasındaki yanlış segmentasyonun önüne geeceęi iin daha yüksek DSC sonuçları elde etmenin mümkün olabileceęi dūřünölmektedir.

Kök kanal dolgusu segmentasyonlarında; hatalı durumların sayısı, birden fazla sınırlama olduęu iin segmentasyonların geri kalanından daha yüksek bulunmuřtur. Kök kanal dolgularının otomatik segmentasyonundaki sınırlandırmalar; Tek tek veya birkaç gütaaperka ile yapılan yetersiz dolgular, ok köklü komřu bir diřin kökleri ile farklı bir diřteki kök-kanal dolgusunun süperpoze olduęu durumlar, kök kanalının tamamı boyunca uzanmayan, kısa kalmıř kök kanal tedavileri, pulpa odasındaki restorasyonun kök kanal dolumu olarak hatalı yorumlandıęı olgulardır. Ancak bu dört sınırlamaya raęmen, modelimizin otomatik segmentasyonunun piksel hassasiyetinde segmentasyonlara sahip olduęu gürölmüřtür. Uygun kök-kanal tedavilerinde segmentasyonlarda ok az hata gürölmektedir. Uygun yapılmıř kök-kanal dolgusu segmentasyonlarında tek sınırlama, komřu yapılarla süperpoze olan köklerin modelimiz tarafından otomatik olarak segmentlere ayrılamamasıdır.

alıřmamızda sadece ideal yapılmıř olan restorasyonların dahil edilmesi ile daha yüksek bir DSC deęeri elde etmek mümkün olsa bile rutin diř hekimlięi



pratiğinde her zaman ideal yapılmış tedavi ve bunların görüntüleri ile karşılaşılammamaktadır. Bu nedenle modelimiz başarısı hiçbir anormalliğin ve ideal olmayan tedavilerin dışlanmadığı veri kümesinde test edilmiştir. Aynı zamanda bu çalışma ile YZ algoritmalarının mükemmel DSC'ye ulaşamamasındaki sınırlandırmalar belirlenmiş ve pratikte daha rahat kullanılabilen bir model oluşturulmuştur. Literatürde bu konuda yapılan, çalışmalar mevcuttur ve bu çalışmalarda farklı görüntüleme teknikleri kullanılarak daha yüksek DSC değerleri elde etmişlerdir. Bayraktar & Ayhan (2022), bitewing radyograflar üzerinde çürük tespiti yaptıkları çalışmalarında süperpozisyon kaynaklı herhangi bir sınırlama yaşamadıkları için daha yüksek DSC skorları elde etmişlerdir. Fontenele vd. (2022) ise çürük tespiti için KIBT görüntülerinden metal / hareket artefaktları olan vakaları hariç tutarak benzer bir çalışma yapmıştır. Zhu vd. 2022 yılında yaptıkları çalışmada ektopik erüpsiyonlar için bir diş segmentasyonu gerçekleştirmiş ve diş çekimi öyküsü, apikal periodontitis, kistik lezyonların varlığı olan olguları çalışma dışı bırakmıştır.

Çalışmamızda otomatik segmentasyonunu sağladığımız yapıların KIBT ile değerlendirildiği çalışmalar da mevcuttur. Wang vd. 2019 yılında yapmış oldukları çalışmada KIBT kullanarak dişleri ve kök kanallarını semantik segmentasyon ile işaretledikleri çalışmalarında baseline-p adını verdikleri yöntem ile 0.882 DSC değerine ulaşmışlardır. Çalışmalarında veri sayısı yetersizliği nedeniyle yalnızca tek köklü dişleri segmente ettiklerini ifade eden araştırmacılar daha fazla veri ve çok köklü dişlerde de bu çalışmaların tekrarlanması gerektiğini ifade etmişlerdir. Lee vd. (2018) OPG yerine periapikal radyograflar üzerinde diş çürüklerini segmente ettikleri çalışmalarında derin evrişimli sinir ağları kullanmışlardır ve premolar dişler için 0.89, molar dişler için 0.88, her iki dişin aynı zamanda değerlendirildiği durumda da 0.82lik doğruluk değerleri bildirmişlerdir. Lahoud vd. 2021 yılında yaptıkları çalışmada KIBT üzerinde yaptıkları segmentasyonlar sonucunda 0.93 DSC değerine ulaşmışlardır fakat çalışmalarında hiçbir molar dişi segmente etmemişlerdir. Tuzoff vd. (2019) Dent. AI şirketi ile yaptıkları çalışmada OPGler kullanılarak diş segmentasyonunda 0.98 doğruluk değerine ulaşmışlardır. Çalışmalarında yalnızca diş segmentasyonu yapan araştırmacılar neredeyse

mükemmele yakın bir DSC değeri yakalamışlardır. Miki vd. 2017 yılında diş segmenasyonunu KIBT üzerinde yapan rehber çalışmalardan birini yayımlamışlardır. Çalışmalarında derin evreşimli sinir ağlarını kullanarak %91'lik doğruluk oranına erişmişlerdir. Bu çalışmada önerdikleri diş numaralandırma tablolarının oluşturulması günümüzde birçok yazılım tarafında rutin olarak kolaylıkla yapılabilmektedir. Fontenele vd. (2022) KIBT görüntüleri üzerinde restorasyonu olan ve olmayan dişlerin segmentasyonu üzerine çalışmışlardır. Yaptıkları çalışmada restorasyonsuz dişlerin segmentasyon DSC değeri 0.98-0.99 iken restorasyonlu dişlerin segmentasyon DSC değeri 0.95-0.97 olarak bulunmuştur. Çalışmalarında sonuç olarak da dişlerdeki restorasyon varlığının KIBT görüntüleri üzerindeki segmentasyon başarısını etkilediğini ifade etmişlerdir. Restorasyonların, özellikle anterior dişler için YZ modelinin performansını etkilediği fakat buna rağmen her iki durumda da 0.95 ve üzerinde DSC değerlerinin bulunduğunu bildirmişlerdir. Fontenele vd. (2022) bu durumun dolguların oluşturduğu artefaktlara bağlı olduğunu belirtmişlerdir.

Ying vd. (2022) ise modellerinde tek bir OPG cihazından faydalanmışlardır, ancak YZ modelleri her görüntüleme ünitesi için karakteristik olan kalıpları öğrenme eğiliminde olduklarından bu durum sonuçlarda yanlılığa (bias) neden olabilmektedir. Bu yanlılığı ortadan kaldırmak için çalışmamız, farklı görüntüleme parametrelerine sahip 3 farklı OPG ünitesi ile gerçekleştirilmiştir.

Revilla-Leon vd. (2021) literatürde YZ modelleri tarafından diş implantlarının otomatik olarak tanınmasının %93.8-%98 arasında olduğu bildirilmiştir. Literatüre benzer şekilde modelimiz 0.99 doğruluk ve 0.94 DSC değerleri ile başarılı olmuştur.

Çalışmamızın en büyük limitasyonu, 3 farklı OPG cihazından faydalanılmış olsa bile, YZ modelimizin başarısının piyasada bulunan tüm OPG cihazları için genelleştirilebilirlik iddiasına sahip olmamasıdır. Bu tip bir iddianın olası olması için piyasada bulunan tüm cihazlardan elde edilmiş OPGler ile yukarıda belirtilen birleştirilmiş öğrenme (federated learning) çalışmalarının yapılmasıdır.

Çalışmamızda oluşturduğumuz YZ modelinin OPGler üzerinde çoklu görevlerdeki başarısı, sınırlamaları tartışılarak vurgulanmıştır. Dentomaksillofasiyal radyoloji alanındaki herhangi bir YZ uygulaması için; hem 2B hem de 3B görüntülemeler kullanılmalıdır, daha büyük bir veri kümesi

işlenmelidir (>1000), birden fazla kurumdan kamuya açık veri setleri elde edilmelidir, daha yüksek hesaplama gücüne sahip bilgisayarlar kullanılmalıdır, denetimli öğrenme yerine denetimsiz/yarı denetimli (unsupervised) öğrenme tercih edilmelidir, retrospektif çalışmalar yerine prospektif çalışmalar tercih edilip mükemmele yakın bir standardizasyon sağlanmalıdır.

YZ tabanlı diş hekimliği uygulamalarının verimli ve güçlü olması için büyük ve yüksek kaliteli veri kümeleri gerekmektedir, ancak bu veriler genellikle çeşitli kaynaklardan (örneğin farklı klinik enstitülerden) dağıtılmış veri havuzlarında bulunur. Gizlilik kısıtlamaları nedeniyle bu veri havuzlarının sınırlarının ötesinde doğrudan paylaşım yapılamadığından işbirliği sınırlıdır. “Federated Learning” yani birleştirilmiş öğrenme, veri paylaşımı olmadan YZ modellerinin ortak eğitimini ölçeklendirilebilir ve gizlilik koruyucu bir çerçevedir, burada bilgi veri üzerinden öğrenilen bilgelik şeklinde değiş tokuş edilir. Rischke vd. 2022 yılında, diş hekimliği araştırma topluluğu içinde YZ tabanlı uygulamalar üzerinde iş birliği geliştirme şanslarını ve zorluklarını sunarak kurulmuş “federated learning” kavramını tanıtmışlardır. Gelecekte diş hekimliğinin nasıl sunulacağını değiştiren dijital teknoloji fırsatlarını benimseme, personel ve hastaların bu yeni dijital ortamda güvenle ilerleyebilmelerine olanak verecektir (Dickenson vd., 2022).

Agrawal & Nikhade (2022) ve Thurzo vd. (2022) çalışmaları, YZ teknolojisinin diş hekimliği ve diğer sektörlerde önemli bir rol oynadığını ve endodonti alanında insan zekasını taklit edebilecek şekilde karmaşık tahminler ve karar verme işlemleri yapabileceğini belirtmektedir. YZ modelleri, endodonti alanında kök kanal sisteminin anatomisini çalışmaya, kök kanalı ve pulpa hücrelerinin canlılığını tahmin etmeye, çalışma uzunluklarını ölçmeye, kök kırıklarını ve periapikal lezyonları tespit etmeye ve retreatment işlemlerinin başarısını tahmin etmeye yönelik çeşitli uygulamalar göstermiştir. Gelecekte, bu teknolojinin randevu planlaması, hasta bakımı, ilaç etkileşimleri, prognostik tanı ve robotik endodontik cerrahi gibi alanlarda da kullanılabileceği düşünülmektedir. Endodonti açısından, hastalık tespiti, değerlendirme ve prognozu konusunda, YZ doğruluk ve hassasiyet göstermiştir ve endodontik tanı ve tedavi ilerlemesine yardımcı olabilir. Ancak, bu modellerin rutin klinik işlemlerin bir parçası haline getirilmeden önce, bunların maliyet etkinliği,

güvenilirliği ve uygulanabilirliğinin daha fazla doğrulanması gerektiği de vurgulanmaktadır. Carrillo-Perez vd. (2022) diş hekimliğinde YZ ve makine öğrenimi (MÖ) kullanımının kapsamlı bir incelemesini yapmak ve bu teknolojilerin ürettiği farklı ilerlemeler hakkında topluluğa geniş bir bakış sunmak amacıyla sistematik bir derleme yazmıştır. Çalışmada özellikle estetik diş hekimliği ve renk araştırma alanlarına dikkat çekilmiştir. Bu kapsamlı inceleme, son 20 yıl içinde İngilizce olarak yayınlanan makaleler için MEDLINE/PubMed, Web of Science ve Scopus veritabanlarında yapılmıştır. 3871 uygun makaleden, son değerlendirme için 120 tanesi çalışmalarına dahil edilmiştir. Öğrenme yöntemleri, derin öğrenme (DL; n=76), “fuzzy logic” (FL; n=12) ve diğer makine öğrenimi teknikleri (n=32) olarak sınıflandırılmış ve bu çalışmaların çoğunlukla hastalık tanımlama, görüntü segmentasyonu, görüntü düzeltme ve biomimetik renk analizi ve modelleme gibi alanlarda uygulandığı belirlenmiştir. Sonuç bu alandaki çalışmalarda YZ'nin yüksek performanslı karar destek sistemlerinin tasarımında önemli sonuçları olduğunu rapor etmişlerdir (Carrillo-Perez vd., 2022).

Scott vd. (2023) yaptıkları sistematik derleme çalışmasında dişlerin destekleyici dokularının bozulmasını tanımlayan periodontitisin tedavisinde YZ teknolojisinin etkinliğini değerlendirmişlerdir. YZ ve MÖ (Makine Öğrenme) periodontitis hastalarının değerlendirilmesi, tanımlanması, yönetimi veya tedavisinde bağımsız değişken olarak kullanıldığı çalışmalar dahil olmak üzere, geniş bir tarama yapılmıştır. Bu çalışmada, girdi veri alanı (input) olarak görsel görüntüleme kullanan çok sayıda makale dahil edilmiştir, bu makalelerde ortalama kullanılan görüntü sayısı 1666 (medyan 499) olmuştur (Scott vd., 2023). Son on yıl içinde bu alanda yayınlanan çalışmaların sayısında belirgin bir artış olmuştur, ancak sonuçlar hâlâ çeşitlilik göstermektedir. Son olarak Ma vd. (2022) tıbbi ve diş hekimliği alanlarında YZ teknolojisinin kullanımının, kullanıcıların ve YZ güvenini arttırarak, uygulamasını, kabul edilebilirliğini, ulaşılabilirliğini ve sürdürülebilirliğini arttırmak için standartlaştırma yöntemlerinin kullanılabilirliğini önermiştir. Standartlaştırma, YZ'nin güvenilirliğini ve birçok özelliğin kalitesini arttıran kalite standartlarının bir stratejisidir.

Dentomaksillofasiyal Radyolojide Yapay zeka Uygulamaları Erken

evresinde olağanüstü bir başarıya sahip, hızlı gelişen bir branştır. 2B ve 3B dental görüntülerde daha hızlı ve otomatik tanı ile, diş hekimleri daha kısa sürede daha yüksek tanı başarısına sahip olabilmektedir. Yapay zeka uygulamaları diş kliniklerinde rutin olmasa da, gelecekteki kliniklerin bu uygulamaların çoğuyla entegre olacağı düşünülmektedir.

## BÖLÜM VI

### Sonuç ve Öneriler

- Çalışmamızda OPG kısıtlamaları nedeniyle yüksek sayıdaki segmentasyona rağmen DSC skorumuzun 0.90 in üzerinde izlenmediği yapılar vardır.
- Dental implantlar gibi hem morfolojik hemde radyoopasite olarak karakteristik olan yapılarda modelimizin son derece başarılı iken rezidüel kökler ve kök kanal dolumları gibi diğer yapılara göre morfolojisi daha az kesinlikle izlenen ve yüksek farklılık gösteren yapılar da DSC skorumuz daha düşük olmuştur.
- Çalışma sonuçlarımızda görülen düşük DSC değerlerinin bazıları kullanılan görüntüleme yönteminin kısıtlamalarına bağlı oluşurken önlenmesi mümkün olmamaktadır.
- OPG cihazı kaynaklı kısıtlamaların önüne geçilmesi ancak üretici firmaların ve biyomedikal sektörünün çözebileceği bir durum iken YZ çalışmalarına katılmak isteyen hekimlerin dikkat etmesi gereken birçok aşama vardır.
- Çalışmamızda oluşturduğumuz YZ programının farklı cihazlarla ve parametrelerle alınmış OPG görüntüleri üzerindeki etkinliğinin değerlendirilmesi için iş birlikleri yapılarak ileri çalışmalar yapılabilir.

## Kaynakça

- 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>
- Agrawal, P. & Nikhade, P. (2022). Artificial intelligence in dentistry: Past, present, and future. *Cureus*, 14(7), 1-10.  
<https://doi:10.7759/cureus.27405>.
- Albayrak, B., Özdemir, G., Ölçer Us, Y. & Yüzbaşıoğlu, E. (2021). Artificial intelligence technologies in dentistry. *Journal of experimental and clinical medicine*, 38(2), 188-194.  
<https://doi:10.52142/mujecm.38.si.dent.18>.
- Albawi, S., Mohammed, T.A. & Al-Zawi, S. (2017). Understanding of a neural convolutional neural network. 2017 International Conference on Engineering and Technology (ICET), Antalya, Turkey, pp. 1-6, doi: 10.1109/ICEngTechnol.2017.8308186.
- Ali, S.H., Ayad, H. & Rubaie, M.T. (2022). Fifth industrial relolution (New Perspectives). *International journal of business, management, and economics*, 3(3), 196-212.  
<https://doi.org/10.47747/ijbmev3i3.694>.
- American Cancer Society. Facts & Figures 2023.
- Aminoshariae, A., Kulild, J., & Nagendrababu, V. (2021). Artificial Intelligence in Endodontics: Current Applications and Future Directions. *Journal of endodontics*, 47(9), 1352–1357.  
<https://doi.org/10.1016/j.joen.2021.06.003>
- Ari, T., Sağlam, H., Öksüzoğlu, H., Kazan, O., Bayrakdar, İ.Ş., Duman, S.B., Çelik, Ö., Jagtap, R., Futyma-Gąbka, K., Różyło-Kalinowska, I. & Orhan, K. (2022). Automatic Feature Segmentation in Dental

- Periapical Radiographs. *Diagnostics (Basel, Switzerland)*, 12(12), 3081. <https://doi.org/10.3390/diagnostics12123081>
- Arsan, B., Büyük, C. & Erdem, T.L. (2019). Konik Işınli Bilgisayarlı Tomografi Raporlama ve Beklentiler. Kamburoğlu K, editör. Dentomaksillofasiyal Konik Işınli Bilgisayarlı Tomografi: Temel Prensipler, Teknikler ve Klinik Uygulamalar. 1. Baskı. Ankara: *Türkiye klinikleri*, p.158-161.
- Ateş, E.C. (2021). Derin Öğrenme (Deep Learning). Akdemir, N. & Tuncer, C.O. (Eds), *Siber Ansiklopedi: Siber Ortama Çok Disiplinli Bir Yaklaşım* (p. 127-131). Pegem Akademi.
- European Commission (2021). Proposal for regulation of the European Parliament and of The Council Laying Dawn harmonised rules on artificial intelligence (Artificial Intelligence Action) and amending certain union legislative acts. <https://eurlex.europa.eu/legal-content/EN/TXT/?uri=CELEX:52021PC0206>.
- Ayodele, T. (2010). Types of machine learning algorithms. Zhang, Y. (Ed), *New Advances in Machine Learning*. InTech. doi: 10.5772/9385
- Babu, A., Onesimu, A. & Sagayam, M.K. (2021). Artificial intelligence in dentistry: Concepts, applications and research challenges, The 4th International Conference of Computer Science and Renewable Energies (ICCSRE'2021) 297, <https://doi:10.1051/e3sconf/202129701074>.
- Bayrakdar, I.S., Orhan, K., Çelik, Ö., Bilgir, E., Sağlam, H., Kaplan, F.A., Görür, S. A., Odabaş, A., Aslan, A.F., & Różyło-Kalinowska, I. (2022). A U-Net Approach to Apical Lesion Segmentation on Panoramic Radiographs. *BioMed research international*, 2022, 7035367. <https://doi.org/10.1155/2022/7035367>.
- Bayrakdar, I.S., Orhan, K., Akarsu, S., Çelik, Ö., Atasoy, S., Pekince, A., Yasa, Y., Bilgir, E., Sağlam, H., Aslan, A.F., & Odabaş, A. (2022). Deep-learning approach for caries detection and segmentation on



- dental bitewing radiographs. *Oral radiology*, 38(4), 468–479.  
<https://doi.org/10.1007/s11282-021-00577-9>
- Bayraktar, Y., & Ayan, E. (2022). Diagnosis of interproximal caries lesions with deep convolutional neural network in digital bitewing radiographs. *Clinical oral investigations*, 26(1), 623–632.  
<https://doi.org/10.1007/s00784-021-04040-1>
- Bernal, J. & Mazo, C. (2022). Transparency of artificial intelligence in healthcare: Insights from professionals in computing and healthcare worldwide. *Applied sciences*, 12(20), 10228.  
<https://doi.org/10.3390/app122010228>.
- Buduma, N. & LAcascio N. (2017). *Fundamentals of Deep Learning: Designing Next-Generation Machine Intelligence Algorithms*. O'Reilly Media, Inc
- Corbella, S., Srinivas, S., & Cabitza, F. (2021). Applications of deep learning in dentistry. *Oral surgery, oral medicine, oral pathology and oral radiology*, 132(2), 225–238.  
<https://doi.org/10.1016/j.oooo.2020.11.003>
- Cosson, J. (2020). Interpreting an orthopantomogram. *Australian journal of general practice*, 49(9), 550–555.  
<https://doi.org/10.31128/AJGP-07-20-5536>
- Dasters, R. & Soori, M. (2021). Artificial neural network systems. *International journal of imaging and robotics (IJIR)*, 21(2), 13-25.
- Decusara, M., Gabriel, V., Popa, T. & Şincar, C.D. (2017). The Relevance of orthopantomograms use in orthodontic practice, *Journal of medical reseach and practice*, 6(6), 189–194 .<https://doi.org/10.20936/jmrp/06/06/01>.
- Delipetrev, B., Tsinarakli, C. & Kostic, U. (2020). AI watch historical evolution of artificial intelligence analysis of the three main paradigm shifts in AI. EUR 30221EN, Publications Office of the European Union. <https://doi:10.2760/801580>.

- Devito, K.L., de Souza Barbosa, F., & Felipe Filho, W.N. (2008). An artificial multilayer perceptron neural network for diagnosis of proximal dental caries. *Oral surgery, oral medicine, oral pathology, oral radiology, and endodontics*, 106(6), 879–884.  
<https://doi.org/10.1016/j.tripleo.2008.03.002>
- Dickenson, A., Tebbutt, J., & Abdulhussein, H. (2022). An overview of digital readiness in dentistry - are we ready?. *British dental journal*, 233(2), 87–88. <https://doi.org/10.1038/s41415-022-4449-6>
- Durão, A. R., Alqerban, A., Ferreira, A. P., & Jacobs, R. (2015). Influence of lateral cephalometric radiography in orthodontic diagnosis and treatment planning. *The angle orthodontist*, 85(2), 206–210.  
<https://doi.org/10.2319/011214-41.1>
- Ekströmer, K., & Hjalmarsson, L. (2014). Positioning errors in panoramic images in general dentistry in Sörmland County, Sweden. *Swedish dental journal*, 38(1), 31–38.
- Ersan, N., Dölekoğlu, S., Fişekçioğlu, E. & İlgü, D. (2016). Evaluation of digital periapical radiographs obtained by dental students. *Yeditepe dental journal*, 12(3), 7-10.  
<https://doi:10.5505/yeditepe.2016.96168>
- Faber, J., Faber, C. & Faber, P. (2019). Artificial intelligence in orthodontics. *APOS trends in orthodontics*, 9(4), 201-209.  
[https://doi 10.25259/APOS\\_123\\_2019](https://doi 10.25259/APOS_123_2019).
- Fairozekhan, A.T., Mohammed, F. Jameela, R.V., Khan, A.M., Mubarak, S. Sharma, S. Shetty, A.C. (2020). Positional Errors in Orthopantomograph. A Comparative Systematic Review with analysis of 1014 additional cases, *European journal of molecular & clinical medicine*, 7(9), 1711-1723.
- Fontenele, R. C., Gerhardt, M. D. N., Pinto, J. C., Van Gerven, A., Willems, H., Jacobs, R., & Freitas, D. Q. (2022). Influence of dental fillings and tooth type on the performance of a novel artificial intelligence-driven tool for automatic tooth segmentation

- on CBCT images - A validation study. *Journal of dentistry*, 119, 104069. <https://doi.org/10.1016/j.jdent.2022.104069>
- García-Pola, M., Pons-Fuster, E., Suárez-Fernández, C., Seoane-Romero, J., Romero-Méndez, A., & López-Jornet, P. (2021). Role of Artificial Intelligence in the Early Diagnosis of Oral Cancer. A Scoping Review. *Cancers*, 13(18), 4600. <https://doi.org/10.3390/cancers13184600>
- George, S.A. & George, A.S.H. (2020). Industrial revolution 5.0: The transformation of the modern manufacturing process to enable man and machine to work hand in hand. *Journal of seybold report*, 15(9), 214-234. <https://doi:10.5281/zenodo.6548092>.
- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., De, D. (2020). Fundamental Concepts of Convolutional Neural Network. Balas, V., Kumar, R., Srivastava, R. (Eds) *Recent Trends and Advances in Artificial Intelligence and Internet of Things*. Intelligent Systems Reference Library, vol 172. Springer, Cham. [https://doi.org/10.1007/978-3-030-32644-9\\_36](https://doi.org/10.1007/978-3-030-32644-9_36)
- Gupta, S. & Jain, S. (2012). Orthopantomographic Analysis for Assessment of Mandibular Asymmetry. *The journal of Indian orthodontic society*, 46(1), 33- 37. <https://doi.org/10.5005/jp-journals-10021-1054>
- Gupta, A., Devi, P., Srivastava, R. & Jyoti, B. (2014). Intra oral periapical radiography – basics yet intrigue: A review. *Bangladesh journal of dental research & education*, 4(2), 83-87. <https://doi.org/10.3329/bjdre.v4i2.20255>.
- 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>
- Haenlein, M., Kaplan, A., Tan, C.W. & Zhang, P. (2019). Artificial intelligence (AI) and management analytics. *Journal of*

*management analytics*, 6(4), 341-343.

<https://doi.org/10.1080/23270012.2019.1699876>.

- Chen, Z., Haykin, S., Eggermont, J. J., & Becker, S. (2008). *Correlative learning: A basis for brain and adaptive systems*. John Wiley & Sons.
- Heil, A., Lazo Gonzalez, E., Hilgenfeld, T., Kickingereder, P., Bendszus, M., Heiland, S., Ozga, A. K., Sommer, A., Lux, C. J., & Zingler, S. (2017). Lateral cephalometric analysis for treatment planning in orthodontics based on MRI compared with radiographs: A feasibility study in children and adolescents. *PloS one*, 12(3), e0174524. <https://doi.org/10.1371/journal.pone.0174524>
- 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), 20200375. <https://doi.org/10.1259/dmfr.20200375>
- Herweijer, C. & Houlin, Z. (2018). Artificial intelligence for global good. Innovation and Sustainability Leader, PWC. Everyone is starting to see the business value.
- Hosny, A., Parmar, C., Quackenbush, J., Schwartz, L. H., & Aerts, H.J.W.L. (2018). Artificial intelligence in radiology. *Nature reviews. Cancer*, 18(8), 500–510. <https://doi.org/10.1038/s41568-018-0016-5>
- Kang, I.-A., Ngnamsie Njimbouom, S., Lee, K.-O., & Kim, J.-D. (2022). DCP: Prediction of Dental Caries Using Machine Learning in Personalized Medicine. *Applied sciences*, 12(6), 3043. <https://doi.org/10.3390/app12063043>
- Karaoglu, A., Ozcan, C., Pekince, A. & Yasa, Y. (2023). Numbering teeth in panoramic images: a novel method based on deep learning and heuristic algorithm. *Engineering science and technology, an*

*international journal*, 37, 101316.

<https://doi.org/10.1016/j.jestch.2022.101316>

Khanagar, S.B., Naik, S., Al Kheraif, A.A., Vishwanathaiah, S., Maganur, P.C., Alhazmi, Y., Mushtaq, S., Sarode, S.C., Sarode, G.S., Zanza, A., Testarelli, L., & Patil, S. (2021). Application and Performance of Artificial Intelligence Technology in Oral Cancer Diagnosis and Prediction of Prognosis: A Systematic Review. *Diagnostics (Basel, Switzerland)*, 11(6), 1004.

<https://doi.org/10.3390/diagnostics11061004>

Ko, C-C., Shen, D. & Wang, L. (2021). *Machine learning in dentistry*.

Springer cham. <https://doi.org/10.1007/978-3-030-71881-7>.

Kriesel, D. (2009). A brief introduction to neural networks.

<https://www.dkriesel.com/media/science/neuronale-netze-en-zeta2-1-co-1-drieselcom.pdf>.

Kukreja, H., Bharath, N., Siddesh, C.S. & Kuldeep, S. (2016). An Introduction To Artificial Neural Network. *International journal of advance research and innovative ideas in education*, 1(5), 27-30.

Kuwada, C., Ariji, Y., Fukuda, M., Kise, Y., Fujita, H., Katsumata, A., & Ariji, E. (2020). Deep learning systems for detecting and classifying the presence of impacted supernumerary teeth in the maxillary incisor region on panoramic radiographs. *Oral surgery, oral medicine, oral pathology and oral radiology*, 130(4), 464–469. <https://doi.org/10.1016/j.oooo.2020.04.813>

Lahoud, P., EzEldeen, M., Beznik, T., Willems, H., Leite, A., Van Gerven, A., & Jacobs, R. (2021). Artificial Intelligence for Fast and Accurate 3-Dimensional Tooth Segmentation on Cone-beam Computed Tomography. *Journal of endodontics*, 47(5), 827–835. <https://doi.org/10.1016/j.joen.2020.12.020>

Lawrynowicz, A. & Tresp, V. (2014). Introducing machine learning.

Lehmann, J. & Voelker J. (Eds) *Perspectives On Ontology Learning*, 35-50. <https://doi:10.1007/s10462-007-9052-3>.

- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Lee, E., Chin, B., Roh, J., Liang, Y.S., Wang, A. & Lee, T.J. (2021). Artificial intelligence in dentistry and dental education. *Dental research: an international journal*, 4(3), 1-6. <https://doi:10.3390/ijer-ph-9063449>.
- Lee, J. H., Kim, D. H., Jeong, S. N., & Choi, S. H. (2018). Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *Journal of dentistry*, 77, 106–111. <https://doi.org/10.1016/j.jdent.2018.07.015>
- Leonardi, R., Lo Giudice, A., Farronato, M., Ronsivalle, V., Allegrini, S., Musumeci, G., & Spampinato, C. (2021). Fully automatic segmentation of sinonasal cavity and pharyngeal airway based on convolutional neural networks. *American journal of orthodontics and dentofacial orthopedics*, 159(6), 824–835.e1. <https://doi.org/10.1016/j.ajodo.2020.05.017>
- Levin, S. (2018). World Economic Forum and the fourth industrial revolution in South Africa. Trade & Industrial Policy Strategy. Pretoria: TIPS. <https://www.thedtic.gov.za/wp-content/uploads/World-Economic-Forum-and-the-fourth-industrial-revolution-in-South-Africa>.
- Lian, L., Zhu, T., Zhu, F., & Zhu, H. (2021). Deep Learning for Caries Detection and Classification. *Diagnostics (Basel, Switzerland)*, 11(9), 1672. <https://doi.org/10.3390/diagnostics11091672>
- Lin, X., Hong, D., Zhang, D., Huang, M., & Yu, H. (2022). Detecting Proximal Caries on Periapical Radiographs Using Convolutional Neural Networks with Different Training Strategies on Small Datasets. *Diagnostics (Basel, Switzerland)*, 12(5), 1047. <https://doi.org/10.3390/diagnostics12051047>
- Ma, J., Schneider, L., Lapuschkin, S., Achtibat, R., Duchrau, M., Krois, J., Schwendicke, F., & Samek, W. (2022). Towards Trustworthy AI in

- Dentistry. *Journal of dental research*, 101(11), 1263–1268.  
<https://doi.org/10.1177/00220345221106086>
- Mahesh, B. (2020). Machine learning algorithms- a review. *International journal of science and research*, 9(1), 381-385.  
<https://doi:10.21275/ART2020395>.
- Mathew, A., Amudha, P. & Sivakumari, S. (2021). Deep Learning Techniques: An overview. Hassanien, A., Bhatnagar, R., Darwish, A. (Eds) *Advanced Machine Learning Technologies and Applications*. AMLTA 2020. Advances in Intelligent Systems and Computing, vol 1141. Springer, Singapore.  
[https://doi.org/10.1007/978-981-15-3383-9\\_54](https://doi.org/10.1007/978-981-15-3383-9_54)
- Mijwil, M. (2015). History of Artificial Intelligence. *Computer science, college of science*. 1-6. <https://doi.10.131406/RG.2.2.16418.15046>.
- Miki, Y., Muramatsu, C., Hayashi, T., Zhou, X., Hara, T., Katsumata, A., & Fujita, H. (2017). Classification of teeth in cone-beam CT using deep convolutional neural network. *Computers in biology and medicine*, 80, 24–29.  
<https://doi.org/10.1016/j.combiomed.2016.11.003>
- 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., Ozemre, M.O., Koseoglu Secgin, C., Atalay Vural, S., Gur, G. & Kamburoglu, K. (2019). Comparison of periapical radiography, panoramic, and cone-beam CT in the detection of dental caries in dog teeth. *Ankara üniversitesi veterinerlik fakültesi dergisi*, 66, 379-384. <https://doi.org/10.33988/auvfd.544263>.
- Ossowska, A., Kusiak, A., & Świetlik, D. (2022). Artificial Intelligence in Dentistry-Narrative Review. *International journal of*

- environmental research and public health*, 19(6), 3449.  
<https://doi.org/10.3390/ijerph19063449>
- Palanivel, J., Davis, D., Srinivasan, D., Sushil Chakravarthi N.C., Kalidass, P., Kishore, S. & Suvetha, S. (2021). Artificial Intelligence- Creating the Future in Orthodontics - A Review. *Journal evolution medicine dental science*, 10(28), 2108-2114.  
<https://doi.org/10.14260/jemds/2021/431>.
- Park, C.W., Seo, S.W., Kang, N., Ko, B., Choi, B.W., Park, C.M.... & Yoon, H.J. (2020). Artificial intelligence in health care: Current applications and issues. *Journal of Korean medical science*, 35(42), e379. <https://doi.org/10.3346/jkms.2020.35.e379>.
- Pirim, H. (2006). Yapay Zeka. *Yaşar üniversitesi E-dergisi*, 1(1), 81-93.  
<https://doi:10.19168/jyu.72783>.
- Prados-Privado, M., García Villalón, J., Martínez-Martínez, C. H., Ivorra, C., & Prados-Frutos, J. C. (2020). Dental Caries Diagnosis and Detection Using Neural Networks: A Systematic Review. *Journal of clinical medicine*, 9(11), 3579.  
<https://doi.org/10.3390/jcm9113579>
- Putra, R. H., Doi, C., Yoda, N., Astuti, E. R., & Sasaki, K. (2022). Current applications and development of artificial intelligence for digital dental radiography. *Dentomaxillofacial radiology*, 51(1), 20210197.  
<https://doi.org/10.1259/dmfr.20210197>
- Revilla-León, M., Gómez-Polo, M., Vyas, S., Barmak, A. B., Özcan, M., Att, W., & Krishnamurthy, V. R. (2022). Artificial intelligence applications in restorative dentistry: A systematic review. *The journal of prosthetic dentistry*, 128(5), 867–875.  
<https://doi.org/10.1016/j.prosdent.2021.02.010>
- Righolt, A., Jedjevic, M., Marce, K. & Listl, S. (2018). Global, regional, and country-level economic impacts of dental diseases in 2015. *Journal dental research*, 97(5):501–507.  
<https://doi:10.1177/0022034517750572>.



- Rischke, R., Schneider, L., Müller, K., Samek, W., Schwendicke, F., & Krois, J. (2022). Federated Learning in Dentistry: Chances and Challenges. *Journal of dental research*, 101(11), 1269–1273. <https://doi.org/10.1177/00220345221108953>
- Ronneberger, O., Fischer, P., Brox, T. (2018). U-Net: Convolutional Networks for Biomedical Image Segmentation. *Computer vision and pattern recognition*, arXiv:1505.04597. <https://doi.org/10.48550/arXiv.1505.04597>.
- Rushton, V.E., & Horner, K. (1996). The use of panoramic radiology in dental practice. *Journal of dentistry*, 24(3), 185–201. [https://doi.org/10.1016/0300-5712\(95\)00055-0](https://doi.org/10.1016/0300-5712(95)00055-0)
- Sachdeva, S., Mani, A., Vora, H., Saluja, H., Mani, S. & Manka, N. (2021). Artificial intelligence in periodontics: A dip in the future. *Journal of cellular biotechnology*, 7(2), 119-124. <https://doi:10.3233/JCB-210041>.
- Saghiri, M. A., Garcia-Godoy, F., Gutmann, J. L., Lotfi, M., & Asgar, K. (2012). The reliability of artificial neural network in locating minor apical foramen: a cadaver study. *Journal of endodontics*, 38(8), 1130–1134. <https://doi.org/10.1016/j.joen.2012.05.004>
- Sarfraz, Z., Sarfraz, A., Iftikar, H. M., & Akhund, R. (2021). Is COVID-19 pushing us to the Fifth Industrial Revolution (Society 5.0)? *Pakistan journal of medical sciences*, 37(2), 591–594. <https://doi.org/10.12669/pjms.37.2.3387>
- Schneider, L., Arsiwala-Scheppach, L., Krois, J., Meyer-Lueckel, H., Bressemer, K. K., Niehues, S. M., & Schwendicke, F. (2022). Benchmarking Deep Learning Models for Tooth Structure Segmentation. *Journal of dental research*, 101(11), 1343–1349. <https://doi.org/10.1177/00220345221100169>
- Schwab, K. (2015). The Fourth Industrial Revolution: What it means and how to respond. World Economic Forum.

- Schwendicke, F. & Göstemeyer, G. (2020). Conventional bitewing radiography. *Clinical dentistry reviewed*, 4, 22. <https://doi.org/10.1007/s41894020-00086-8>.
- Schwendicke, F., Samek, W., & Krois, J. (2020). Artificial Intelligence in Dentistry: Chances and Challenges. *Journal of dental research*, 99(7), 769–774. <https://doi.org/10.1177/0022034520915714>
- Scott, J., Biancardi, A. M., Jones, O., & Andrew, D. (2023). Artificial Intelligence in Periodontology: A Scoping Review. *Dentistry journal*, 11(2), 43. <https://doi.org/10.3390/dj11020043>
- Sethi, P., Tiwari, R., Das, M., Singh, M.P., Agarwal, M. & Ravikumar A.J. (2016). Two dimensional versus three dimensional imaging in endodontics - An updated review. *Journal of evolution of medical and dental sciences*, 5(84), 6287-6293. <https://doi.org/10.14260/jemds/2016/1420>
- Siribaddana, P.A. (2020). Research Trajectory in Digital Health A Retrospective Study on Masters Programme in Biomedical Informatics in Sri Lanka. *Sri Lanka journal of biomedical informatics*, 11(2), 1-6. <https://doi.org/10.4038/sljbm.v11i2.8101>.
- Smola, A. & Vishwanathan, S. (2008). *Introduction to Machine Learning*. Cambridge University Press, Cambridge.
- Sood, R., Sharma, E., Garg, R., Kaur S., & Anshul, C. (2022). Artificial intelligence (AI) and recent advancements in periodontology. *IP international journal of periodontology and implantology*, 7(3), 99-102. <https://doi.org/10.18231/j.ijpi.2022.022>
- Tandon, D. & Rajawat, J. (2020). Present and future of artificial intelligence in dentistry, *Journal of oral biology and craniofacial research*, <https://doi.org/10.1016/j.jobcr.2020.07.015>.
- Thurzo, A., Urbanová, W., Novák, B., Czako, L., Siebert, T., Stano, P., Mareková, S., Fountoulaki, G., Kosnáčová, H., & Varga, I. (2022). Where Is the Artificial Intelligence Applied in Dentistry? Systematic Review and Literature Analysis. *Healthcare (Basel*,

- Switzerland*), 10(7), 1269.  
<https://doi.org/10.3390/healthcare10071269>
- Tuzoff, D.V., Tuzova, L.N., Bornstein, M.M., Krasnov, A.S., Kharchenko, M.A., Nikolenko, S.I., Sveshnikov, M.M., & Bednenko, G.B. (2019). Tooth detection and numbering in panoramic radiographs using convolutional neural networks. *Dentomaxillofacial radiology*, 48(4), 20180051. <https://doi.org/10.1259/dmfr.20180051>
- Vargas, R., Mosavi, A. & Ruiz, L. (2017). Deep learning: A review. *Advances in intelligent systems and computing*, preprint. <https://doi:10.20944/preprints,201810.0218.v1>.
- Velarde, G. (2019). Artificial Intelligence and its Impact on the Fourth Industrial Revolution: A Review. *International journal of artificial intelligence & applications*, 10(6), 41-48. <https://doi:10.5121/ijaia.2019.10604>.
- Walczak, S. & Cerpa, N. (2003). Artificial Neural Networks. Meyers R.A. (ed). *Encyclopedia of Physical Science and Technology*, 631-645. <https://doi:10.1016/B012227410-5/00837-1>.
- Wang, L., Li, J.P., Ge, Z.P., & Li, G. (2019). CBCT image based segmentation method for tooth pulp cavity region extraction. *Dentomaxillofacial radiology*, 48(2), 20180236. <https://doi.org/10.1259/dmfr.20180236>
- White, S.C. & Pharoah, M.J. (2014). *Oral Radiology: Principles and Interpretation*. Elsevier, 41-63.
- Wong, S. H., Al-Hasani, H., Alam, Z., & Alam, A. (2019). Artificial intelligence in radiology: how will we be affected?. *European radiology*, 29(1), 141–143. <https://doi.org/10.1007/s00330-018-5644-3>
- Yasa, Y., Çelik, Ö., Bayrakdar, I. S., Pekince, A., Orhan, K., Akarsu, S., Atasoy, S., Bilgir, E., Odabaş, A., & Aslan, A. F. (2021). An artificial intelligence proposal to automatic teeth detection and numbering in dental bite-wing radiographs. *Acta odontologica*

*Scandinavica*, 79(4), 275–281.

<https://doi.org/10.1080/00016357.2020.1840624>

Ying, S., Wang, B., Zhu, H., Liu, W., & Huang, F. (2022). Caries segmentation on tooth X-ray images with a deep network. *Journal of dentistry*, 119, 104076.

<https://doi.org/10.1016/j.jdent.2022.104076>

You, K., Long, M., Wang, J. & Jordan, M.I. (2019). How does learning rate decay help modern neural networks?

<https://doi.org/10.48550/arXiv.1908.01878>

Zhang, A., Lipton, Z.C., Li, M. & Smola, A.J. (2019). *Dive into deep learning*, <https://doi.org/10.48550/arXiv.2106.11342>

Zhu, H., Yu, H., Zhang, F., Cao, Z., Wu, F., & Zhu, F. (2022). Automatic segmentation and detection of ectopic eruption of first permanent molars on panoramic radiographs based on nnU-Net. *International journal of paediatric dentistry*, 32(6), 785–792.

<https://doi.org/10.1111/ipd.129>




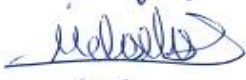


**Ekler**

**Ek 1**

## Onay Sayfası


### Onay

Emel Gardiyanoglu tarafından hazırlanan Ortopantomografiler Üzerinde Dişlerin, Çürüklerin, Dental Restorasyonların ve Kök Artıklarının Yapay Zekâ Tabanlı Otomatik Segmentasyonu” başlıklı tez, kapsam ve nitelik açısından kalite standartlarına uygunluğu ile ilgili Ağız, Diş ve Çene Radyolojisi Anabilim Dalında Doktora Tezi olarak 02/05/2023 tarihinde kabul edilmiştir.

Jüri Üyeleri	Adı – Soyadı	İmza
Jüri Başkanı:	Prof. Dr. Kaan Orhan	
Jüri Üyesi:	Prof. Dr. İ. Hakan Avsever	
Danışman:	Prof. Dr. Seçil Aksoy	
Jüri Üyesi:	Yrd. Doç. Dr. Melis Mısırlı Gülbeş	
Jüri Üyesi:	Yrd. Doç. Dr. Gürkan Ünsal	
Anabilim/ Anasanat Dalı Başkanı Onayı		 02/05/2023 Prof. Dr. Seçil Aksoy Ağız, Diş ve Çene Radyolojisi Anabilim Dalı Başkanı
Lisansüstü Eğitim Enstitüsü Onayı		02/05/2023 Prof. Dr. Kemal Hüsnü Can Başer Enstitü Müdürü

## Ek 2

### Etik kurul raporu

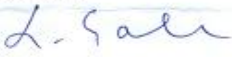


**YAKIN DOĞU ÜNİVERSİTESİ**  
**BİLİMSEL ARAŞTIRMALAR ETİK KURULU**

**ARAŞTIRMA PROJESİ DEĞERLENDİRME RAPORU**

**Toplantı Tarihi** :30.11.2022  
**Toplantı No** :2022/108  
**Proje No** :1651

Yakın Doğu Üniversitesi Diş Hekimliği Fakültesi öğretim üyelerinden Doç. Dr. Seçil Aksoy'un sorumlu araştırmacısı olduğu, YDU/2022/108-1651 proje numaralı ve **"Ortopantomograflar Üzerinde Dişlerin Kron-Köprü Restorasyonları, İmplantları, Dolguları, Çürükleri, Kök Kalıntıları ve Kanal Dolgularının Yapay Zeka Tabanlı Otomatik Segmentasyonu"** başlıklı proje önerisi kurulumuzca değerlendirilmiş olup, çalışmanın yapılacağı kurumdan izin alınması şartıyla onay verilmiştir.



Prof. Dr. Şanda Çalı  
Yakın Doğu Üniversitesi  
Bilimsel Araştırmalar Etik Kurulu Başkanı

Kurul Üyesi	Toplantıya Katılım	Karar
	Katıldı(✓)/ Katılmadı(X)	Onay(✓)/ Ret(X)
Prof. Dr. Tamer Yılmaz	✓	✓
Prof. Dr. Şahan Saygı	✓	✓
Prof. Dr. Mehmet Özmenoglu	✓	✓
Prof. Dr. İlker Etikan	✓	✓
Doç. Dr. Mehtap Tmazlı	X	X
Prof. Dr. Nilüfer Galip Çelik	✓	✓
Yrd. Doç. Dr. Dilek Sarpkaya Güder	✓	✓

<https://etikkurul.neu.edu.tr/>

## Ek 3

### İntihal raporu

2/15/23, 3:57 PM

Similarity Report

**Emel Tez**

**By: Emel Gardiyanoğlu**

As of: Feb 15, 2023 4:52:46 PM  
15,094 words - 77 matches - 49 sources

Similarity Index

**9%**

Mode: Similarity Report

paper text:

KUZEY KIBRIS TÜRK CUMHURİYETİ YAKIN DOĞU ÜNİVERSİTESİ SAĞLIK BİLİMLERİ ENSTİTÜSÜ  
ORTOPANTOMOĞRAFLAR ÜZERİNDE

19

; DİŞLERİN, KURON- KÖPRÜ RESTORASYONLARININ, DENTAL İMPLANTLARIN, DOLGULARIN, DİŞ ÇÜRÜKLERİNİN, KÖK KALINTILARININ VE KÖK KANAL DOLUMLARININ YAPAY ZEKÂ TABANLI OTOMATİK SEGMENTASYONU EMEL GARDİYANOĞLU

DOKTORA TEZİ AĞIZ, DİŞ VE ÇENE RADYOLOJİSİ ANABİLİM DALI DANIŞMAN DOÇ. DR

38

. SEÇİL AKSOY 2023-LEFKOŞA i ii

TEZ ONAYI Sağlık Bilimleri Enstitüsü Müdürlüğü'ne , "... " başlıklı çalışma jürimiz tarafından ...  
Programında

13

Yüksek Lisan

Tezi olarak kabul edilmiştir . Jüri Başkanı: ONAY: Bu tez, Yakın Doğu Üniversitesi Lisansüstü Eğitim - Öğretim ve Sınav Yönetmeliği'nin ilgili maddeleri uyarınca yukarıdaki jüri üyeleri tarafından uygun görülmüş ve Enstitü Yönetim Kurulu kararıyla kabul edilmiştir. Prof. Dr. K. Hüsnü Can BAŞER Sağlık Bilimleri Enstitüsü Müdürü

17

i TEZ SINAV TUTANAĞI ii BEYAN "Ortopantomograflar Üzerinde; Dişlerin, Kuron-Köprü Restorasyonlarının, Dental İmplantların, Dolguların, Diş Çürüklerinin, Kök Kalıntılarının ve Kök Kanal Dolumlarının Yapay zekâ Tabanlı Otomatik Segmentasyonu" başlıklı

## Özgeçmiş

<b>Adı</b>	Emel	<b>Soyadı</b>	Gardıyanoğlu
<b>Doğum Yeri</b>	Ankara	<b>Doğum Tarihi</b>	01.03.1970
<b>Uyruğu</b>	TC/KKTC	<b>Tel</b>	+905488716666
<b>E-mail</b>	<a href="mailto:emel.gardiyanoglu@neu.edu.tr">emel.gardiyanoglu@neu.edu.tr</a>		

<b>Eğitim Düzeyi</b>	<b>Mezun Olduğu Kurumun Adı</b>	<b>Mezuniyet Yılı</b>
<b>Doktora/Uzmanlık</b>	YDÜ Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı	
<b>Yüksek Lisans</b>	Ankara Üniversitesi Diş Hekimliği Fakültesi	1994
<b>Lisans</b>	Ankara Üniversitesi Diş Hekimliği Fakültesi	1994
<b>Lise</b>	Balıkesir Lisesi	1988

## İş Deneyimi

<b>Görevi</b>	<b>Kurum</b>	<b>Süre (Yıl - Yıl)</b>
<b>Araştırma Görevlisi</b>	Yakın Doğu Üniversitesi Diş Hekimliği Fakültesi	2017- 2023



<b>Yabancı Dilleri</b>	<b>Okuduğunu Anlama*</b>	<b>Konuşma*</b>	<b>Yazma*</b>
İngilizce	İyi	İyi	İyi

### **Bilgisayar Bilgisi**

<b>Program</b>	<b>Kullanma becerisi</b>
Microsoft Word, Powerpoint, Excel	İyi

**EK:** Diğer Bilimsel faaliyetler (yayın, kongre bildirisi vs.)