

**ERDOĞAN
KIBCAK**

**DERİN ÖĞRENME TABANLI DENTAL İMPLANT SEGMENTASYONU VE
ORTOPANTOMOGRAFİLERDE PERİ-İMLANTİTİS TESPİTİ: YENİLİKÇİ BİR TANIM ARACI**

**DOKTORA TEZİ
2025**



**YAKIN DOĞU ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
AĞIZ DIŞ VE ÇENE CERRAHİSİ ANABİLİM DALI**

**DENTAL İMPLANT SEGMENTASYONU VE PERİ-İMLANTİTİS
TANISINDA DERİN ÖĞRENME TABANLI YAPAY ZEKA MODELİNİN
KULLANIMI**

DOKTORA TEZİ

ERDOĞAN KIBCAK

2025



YAKIN DOĞU ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
AĞIZ DIŞ VE ÇENE CERRAHİSİ ANABİLİM DALI

DENTAL İMPLANT SEGMENTASYONU VE PERİ-İMPLANTİTİS
İNİSİNDA DERİN ÖĞRENME TABANLI YAPAY ZEKA MODELİNİN
KULLANIMI

DOKTORA TEZİ



ERDOĞAN KIBCAK

Tez Danışmanı
Doç. Dr. OĞUZ BUHARA

2025

Onay

Erdoğan Kıbeak tarafından hazırlanan “**DENTAL İMPLANT SEGMENTASYONU VE PERİ-İMPLANTİTİS TANISINDA DERİN ÖĞRENME TABANLI YAPAY ZEKA MODELİNİN KULLANIMI**” başlıklı tez, kapsam ve nitelik açısından kalite standartlarına uygunluğu ile ilgili Ağız Diş ve Cerrahisi Anabilim Doktora Tezi olarak 15/04/2025 tarihinde kabul edilmiştir.

Jüri Üyeleri	Adı – Soyadı	İmza
Jüri Başkanı:	Prof. Dr. R. Gürkan BAYAR	
Jüri Üyesi:	Doç. Dr. L. Onur UYANIK	
Jüri Üyesi:	Yrd. Doç. Dr. Ceren M. Dönmezer Birand	
Jüri Üyesi:	Doç. Dr. M. Gagari CAYMAZ	
Danışman:	Doç. Dr. Oğuz BUHARA	

Anabilim Dalı Başkanı Onayı


15.04.2025

Doç. Dr. L. Onur Uyanık
Anabilim Dalı Başkanı

Lisansüstü Eğitim Enstitüsü Onayı

...../...../ 2025

Prof. Dr. Kemal Hüsnü Can Başer



Etik İlkelerle Uygunluk Beyanı

Bu tezin içinde sunduğum verileri, bilgileri ve belgeleri akademik ve etik kurallar çerçevesinde elde ettiğimi; tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu; çalışmada bana ait olmayan tüm veri, düşünce, sonuç ve bilgilere bilimsel etik kurallar gereği olarak eksiksiz şekilde uygun atıf yaptığımı ve kaynak göstererek belirttiğimi beyan ederim.

Dt. Erdoğan Kıbcak

15/04/2025

Teşekkür

Her an yanımda olan, sevgi ve desteğini her zaman hissettiğim, hakkını hiçbir zaman ödeyemeyeceğim babam Mehmet KIBCAK'a, annem Cemaliye Kıbcak'a, kardeşim Tahir Kıbcak'a ve tez çalışmam boyunca yanımda olup desteğini esirgemeyen aynı yolda yürüdüğüm vdadaşlarım, meslektaşlarıma;

Fakültemizde göreve başladığım günden beri yanımda olup engin tecrübeleriyle bana yol gösterip her konuda desteğini ve sevgisini hissettiğim Anabilim Dalı Başkanımız Doç. Dr. Lokman Onur UYANIK'a

Tüm çalışma süresince bana desteğini hiç esirgemeyen, yoğun geçen çalışma sürecinde heyecanıma ortak olan, tüm doktora eğitimim boyunca ne zaman başım sıkışsa yanımda olan, bana yol gösterip her konuda desteğini ve sevgisini hissettiğim, bazen bir hoca bazen de bir abi olan, hocam tez danışmanım Doç. Dr. Oğuz BUHARA'ya

Tüm çalışma süresince her zaman yanımda olan, en büyük desteği ortaya koyan, akademik ve klinik tecrübelerinden yararlandığım, Doç. Dr. Gürkan ÜNSAL'a;

Tüm çalışma süresince bana yardımcı olan hocam Yrd.Doç.Dr. Ceren Melahat Dönmezer Birand'a, ve aynı odayı paylaştığım asistan vdadaşlarım Dt. Beste Erişmen'e, Dt. Berk Bozdoğan'a ve Dt. Zeki Besim'e;

Kardeşim gibi gördüğüm gerek klinik gerekse tüm zamanımı beraber geçirdiğim Dr. Ali Temelci'ye teşekkür ederim.

Dt. Erdoğan Kıbcak

İçindekiler

Onay	i
Etik İlkelerle Uygunluk Beyanı	ii
Teşekkür	iii
Tablolar Listesi	xiii
Şekiller Listesi	xiv
Resim Listesi	xvi
Kısaltmalar	xvii

BÖLÜM I

Giriş	1
--------------------	----------

BÖLÜM II

Genel Bilgiler.....	2
Dental İmplant Tarihçesi	2
Dental İmplantlar.....	4
Endosseöz implantlar	5
Subperiosteal implantlar	5
İntramukozal implantlar	6
Transmandibuler implantlar.....	6
Transdental implantlar.....	7
Dental İmplant Materyalleri.....	7
Metal-Metal Alaşımları	7

Titanyum.....	7
Ti-6al-4v (Grade 5)	9
Diğer Metal İmplant Materyalleri	11
Zirkonyum	11
Seramikler ve Karbon.....	12
Polimer Ve Kompozitler.....	13
Osseointegrasyon.....	13
Dental İmplantların Başarı Kriterleri	14
Dental İmplantların Başarısızlık Kriterleri	15
Kemik Tipleri Ve Sınıflandırılması	16
İMLANTLARIN GÖRÜNTÜLENME TEKNİKLERİ	18
Ortopantomograf.....	18
Periapikal Radyografiler.....	20
Konvansiyonel Tomografi.....	21
Anjiografi.....	21
Ultrasonografi	21
Manyetik Rezonans	21
Bilgisayarlı Tomografiler	21
Periapikal Radyografiler.....	21
Konik Işın Hüzmeli Bilgisayarlı Tomografi (KIBT)	22
Periodontal ve Periimplant Dokular	24
Periodontal dokular	24
Periimplant dokular	Error! Bookmark not defined.
Periodontal dokular ile periimplant dokular arasındaki fvdlılıklar.....	25
Periimplant Hastalıklar	Error! Bookmark not defined.

Peri-implanter mukozitis	Error! Bookmark not defined.
Sağlıklı periimplant mukozadan peri-implanter mukozitise geçiş.....	27
Peri-implanter mukozitisin etiyolojik olan risk faktörleri	28
Genel risk faktörleri	28
Lokal risk faktörleri	28
Kötü ağız hijyeni	28
Periimplantitis	30
Periimplantitisin mikrobiyolojik özellikleri.....	34
Periimplantitis için etiyolojik risk faktörleri.....	34
Periodontitis geçirilmiş olması	34
Sigara kullanımı	35
Diyabet.....	35
İatrojenik faktörler	37
Hatalı oklüzal yükleme.....	37
Yapay zeka	38
Yapay Zekanın Tarihçesi.....	43
Yapay zeka Öğrenme Biçimleri.....	46
Makine Öğrenimi	46
Derin Öğrenme.....	48
Sinir Ağları	49
Yapay sinir ağları.....	51
Evrişimli Sinir Ağları	54
Derin Evrişimsel Sinir Ağı Algoritmasının Mimarisi	56
U NET MİMARİSİ	57
Transfer Öğrenme	57

GoogleNet.....	58
VGGNet.....	58
AlexNet.....	59
Dvdnet	59
ResNet	60
Diş Hekimliğinde Yapay Zekâ ve Kullanım Alanları	60
Yapay Zekanın Diş Hekimliğinde Kullanımı	61
Yapay Zeka Kullanımı ile İlgili Limitasyonlar.....	62
Yapay Zeka ve Diş Hekimliğinin Geleceği	64

BÖLÜM III

Yöntem	67
Etik Kurul Onayı.....	67
Hasta Seçimi ve Çalışma Materyali	67
Veri Setinin Oluşturulması	67
OPG Görüntülerinin Elde Edilmesi	68
OPG Görüntülerinin İmplantları Tespit Etmesi.....	69
Semantik Segmentasyon.....	69
Periimplantitis Sınıflandırma Süreci	71
Sınıflandırma Modellerinin Performans Ölçütleri	72
Dice Similarity Coefficient Hesaplanması	73

BÖLÜM IV

Bulgular ve Yorumlar	75
Sınıflandırma Performansı.....	78
En Çok Hata (False Positive) Görülen Durumlar	82

BÖLÜM V

Tartışma	84
-----------------------	-----------

BÖLÜM VI

Sonuç ve Öneriler.....	99
-------------------------------	-----------

Kaynakça.....	100
----------------------	------------

ÖZET

DENTAL İMPLANT SEGMENTASYONU VE PERİ-İMPLANTİTİS TANISINDA DERİN ÖĞRENME TABANLI YAPAY ZEKA MODELİNİN KULLANIMI

Öğrencinin adı: Kıbcak, Erdoğan

Doktora, Ağız Diş ve Çene Cerrahisi Anabilim Dalı

Mart, 2025, 12 sayfa

Günümüzde peri-implantitisin tanısında kullanılan yöntemler, subjektif yorum ve zaman alıcı işlemler gibi zorluklarla karşı karşıyadır. Derin öğrenme tabanlı yaklaşımımız, bu sınırlamaları aşmayı hedefleyerek daha doğru ve etkili bir çözüm sunmaktadır. Bu çalışmanın amacı, ortopantomografilerde (OPG) dental implantların segmentasyonu ve peri-implantitisin tespiti için derin öğrenme tabanlı bir yöntem geliştirerek tanısal doğruluk ve verimliliği artırmaktır. Dışlama kriterlerinin uygulanmasının ardından, Yakın Doğu Üniversitesi Etik Kurulu tarafından etik onay alınan bu çalışmada 7696 ortopantomografik görüntü (OPG) kullanıldı. Python ile uygulanan U-Net mimarisi kullanılarak DICOM formatındaki görüntüler segmentasyon işlemine tabi tutuldu ve PNG formatına dönüştürüldü. Sınıflandırma modeli, sağlıklı implantlar ile peri-implantitis etkisi altındaki implantlar arasındaki fvdı ayırt etmek için evrişimli sinir ağı (CNN) kullandı ve segmentasyon işlemiyle elde edilen bölgelerden çıkarılan özellikleri kullanarak tanısal doğruluğu artırdı. Model, Adam optimizasyon algoritması ile 500 epoch boyunca eğitildi; veri seti %70 eğitim, %15 doğrulama ve %15 test gruplarına ayrıldı. Segmentasyon performansını değerlendirmek için Dice Benzerlik Katsayısı (DSC) ve doğruluk ölçütleri kullanıldı. Segmentasyon sonrası sınıflandırma modelinin değerlendirilmesi, üç klinisyen tarafından kesinlik (precision), duyarlılık (recall) ve F1 skoru kullanılarak yapıldı ve implantların peri-implantitis belirtileri gösterip göstermediği belirlendi. Segmentasyon modeli test aşamasında %99,9 doğruluk, 0,986 Dice Benzerlik Katsayısı (DSC) ve 0,974 Kesişim Birleşim Oranı (IoU) elde etti. Sınıflandırma aşamasında, 3693 implantın 638'i klinik olarak peri-implantitis tanısı aldı. Model, bunların 576'sını doğru bir şekilde tanımlıvden 165 yanlış pozitif sonuç verdi. Modelin performans metrikleri, 0,777 kesinlik, 0,903 duyarlılık ve 0,835 F1 skoru olarak hesaplandı. OPG'lerde dental implantların ve peri-implantitisin

segmentasyonu ve sınıflandırmasına yönelik derin öğrenme tabanlı bu yaklaşım, klinik tanı ve tedavi planlamasını geliştirmek için son derece etkili ve güvenilir bir yöntem olarak umut vericidir.

Anahtar kelimeler: Bilgisayar destekli radyografik görüntü yorumlama, Dental implantlar, Panoramik radyografi, Peri-implantitis.

ABSTRACT

THE USE OF DEEP LEARNING-BASED ARTIFICIAL INTELLIGENCE MODEL IN DENTAL IMPLANT SEGMENTATION AND DIAGNOSIS OF PERI-IMPLANTITIS

Student's name: Kıbcak, Erdoğan

MA/ PhD, Department of Oral and Maxillofacial Surgery

March, 2025, 12 pages

Dental implants are well-established for restoring partial or complete tooth loss, with osseointegration being essential for their long-term success. Peri-implantitis, mvded by inflammation and bone loss, compromises implant longevity. Current diagnostic methods for peri-implantitis face challenges such as subjective interpretation and time consumption. Our deep learning-based approach aims to address these limitations by providing a more accurate and efficient solution. This study aims to develop a deep learning-based approach for segmenting dental implants and detecting peri-implantitis in orthopantomographs (OPGs), enhancing diagnostic accuracy and efficiency. After applying exclusion criteria, 7696 OPGs were used in the study, which was ethically authorized by the Near East University Ethics Review Board. Using the Python-implemented U-Net architecture, the DICOM-formatted images were segmented and converted into PNG files. The classification model used a convolutional neural network (CNN) for distinguishing between healthy implants and those affected by peri-implantitis, leveraging features extracted from the segmented regions to enhance diagnostic accuracy. The model was trained for 500 epochs using the Adam optimizer, with the dataset split into training (70%), validation (15%), and test (15%) sets. Dice similarity coefficient (DSC) and accuracy were used to assess segmentation performance. Three medical professionals used precision, recall, and F1-score to assess the classification model after segmentation, which determined whether implants were showing signs of peri-implantitis. The segmentation model achieved a test accuracy of 0.999, Dice Similarity Coefficient (DSC) of 0.986, and Intersection over Union (IoU) of 0.974. For classification, out of 3693 implants, 638 were clinically identified as having peri-implantitis. The model correctly identified 576 of these, with 165 false positives. Performance metrics included a precision of 0.777, recall of 0.903, and F1-score of 0.835. The deep learning-based approach for segmentation and classification of dental

implants and peri-implantitis in OPGs is highly effective, providing reliable tools for enhancing clinical diagnosis and treatment planning.

Keywords: Computer assisted radiographic image interpretation, Dental implants, Panoramic radiography, Periimplantitis.

Tablolar Listesi

Tablo 1. Ti-6Al-4V İmplantların spesifik özellikleri.

Tablo 2. CpTi ve Ti-6Al-4V implant karşılaştırması.

Tablo 3. Fvdlı çalışmalardaki peri-implantitis tanı kriterleri.

Tablo 4: OPG'ler üzerindeki peri-implantitis tespitinde derin öğrenme modelinin segmentasyon ve sınıflandırma görevleri için performans metrikleri.

Tablo 5. Çenelere Göre Performans Dağılımı. TP (True Positive): Modelin gerçek peri-implantitisli vakaları doğru sınıflandırması, FP (False Positive): Sağlıklı olduğu hâlde modelin peri-implantitis diye sınıflandırdığı vakalar, TN (True Negative): Sağlıklı olup, modelin de sağlıklı dediği vakalar, FN (False Negative): Gerçekte peri-implantitisli olup, modelin kaçırdığı (sağlıklı dediği) vakalar

Şekiller Listesi

Şekil 1: ilk yiv yapısına sahip implant.

Şekil 2: Blade tarz endosseöz implant.

Şekil 3. Transmandibular İmplant.

Şekil 4. Titanyum dental implant.

Şekil 5. Seramik dental implant

Şekil 6. Lekholm ve Zarb sınıflaması

Şekil 7. Misch'in kemik yoğunluk sınıflaması

Şekil 8. Periimplant dokular ile periodontal dokuların karşılaştırılması

Şekil 9. Periimplantitis ve Periimplanter mukozitis fvdı

Şekil 10: Makine Öğrenme Modeli

Şekil 11: Derin Öğrenmenin faydaları

Şekil 12. Derin evrışimsel sinir ağı algoritması şeması

Şekil 13. GoogleNet mimarisi

Şekil 14. VGG16 mimarisi

Şekil 15. AlexNet mimarisi

Şekil 16. YOLO sistem mimarisi

Şekil 17. ResNet mimarisi

Şekil 18. Dental implantların segmente edilmesi

Şekil 19. U-Net mimarisi, görüntü segmentasyonu için kullanılan bir yapıdır. Ağ, özellik çıkarımı amacıyla sol tarafta bir daralma yolu ve hassas konumlandırma için sağ tarafta bir genişleme yolu içerir. Daralma yolundaki her aşama, iki adet 3x3 evrişim (mor), ReLU aktivasyonları ve 2x2 maksimum havuzlama (kırmızı) içerir. Buna karşın, genişleme yolu, mekansal çözünürlüğü geri kazandırmak için 2x2 yukarı evrişimler (yeşil) kullanır. İki yolun eşlenen katmanları arasındaki atlama bağlantıları (gri oklar), çıktıda detaylı bir segment haritası yeniden oluşturulmasına olanak tanır.

Şekil 20. OPG üzerindeki implantların manuel segmentasyonu, implant sınırlarını belirleme sürecinin detaylı gösterilmesi. (b) OPG üzerindeki implantların model yardımı ile otomatik segmentasyonu.

Şekil 21 a)OPG üzerindeki implantların manuel segmentasyonu.(b) Modelin OPG üzerindeki implantların otomatik segmentasyonu. Manuel ve otomatik segmentasyonlar arasında minimal fvdlılıklar gözlemlenmiştir; bu durum, protetik restorasyonlar ve implantlardan kaynaklanan üst üste binmeler nedeniyle meydana gelmiş ve DSC değerini düşürmüştür.

Şekil 22. Modelin, periimplantitis bulunan implantların sınıflandırmasına örnekler.

Şekil 23. A)Sınıf II maloklüzyonlu bir hastanın mandibulası, fokal alandan uzak bir şekilde konumlanmış olup, OPG de hem implantın hem de mandibular dişlerin yatay büyütülmesi gösterilmiştir. (B-C-D) Maksiller alveolar kemik üzerindeki hava yolu üst üste binmesi, hastanın dilinin maksiller dişlerin palatinal yüzeyine karşı konumlandırılmaması sonucunda oluşmuş ve implantların etrafında radyolüsent bir alan meydana getirmiştir. Model, bu implantlarda peri-implantitis için yanlış pozitif bir tahmin üretmiştir. (E) Bir çekim soketinde hemen implant yerleştirilmesi, peri-implantitise benzer bir kemik kaybı modeli oluşturmuş ve bu durum, peri-implantitis için bir yanlış pozitif tahminine yol açmış olabilir. (F) Alveolar kemik bölgesindeki zayıflama, kemiğin beklenenden daha radyolüsent görünmesine neden olmuş ve bu durum, peri-implantitis olarak yanlış yorumlanma olasılığını artırmıştır.

Şekil 24. Model, peri-implantitis olmayan kemik kaybı bulunmayan durumları tespitine örnekler.

Resim Listesi

- Resim 1.** Bilinen İlk İmplant (Mayalar)
- Resim 2.** Subperiosteal implant ve protetik tasarım örneği
- Resim 3.** Perimukozitisin a) klinik ve b) radyografik görünümü
- Resim4.** Periimplantitisin a) klinik ve b) radyografik görünümü
- Resim 5.** Periimplantitiste pü varlığı
- Resim 6.** Segmentasyon için kullanılan CVAT sistemi

Kısaltmalar

OPG: Ortopantomografi

YZ: Yapay zeka

M. Ö: Millattan önce

Al: Aleminyum

Cocrmo: Kobalt-Kromolibden

Cpti: Alaşım Durumunda Olmayan Saf Titanyum

Cr: Krom

BT: Bilgisayarlı Tomografi

Ir: İridyum

Mo: Molibden

MRI: Manyetik Rezonans Görüntüleme

Ni: Nikel

TAV: Titanyum-Alüminyum Vanadyum

YDÜ: Yakın Doğu Üniversitesi

Mg: Magnezyum

Au: Altı

Ag: Gümüş

Sn: Kalay

Nm: Nano metre

Zr: Zirkonyum

mm: Milimetre

KIBT: Konik Işınlı Bilgisayarlı Tomografi

3D: 3 boyut

TME: Temperomandibuler Eklem

2D: 2 Boyut

DL: Derin Öğrenme

RF: Rastgele Orman

AP: Ortalama Kesinlik

CVAT: Computer Vision Annotation Tool

GB: GigaByte

ICC: Intraclass Correlation Coefficient

DSC: Dice Similarity Coefficient

BÖLÜM I

Giriş

Diş hekimliğinde implantlar, eksik dişlerin giderilmesinde en sık kullanılan tedavi seçeneklerinden biri haline gelmiştir. Tedavinin başarılı olarak gerçekleşmesi için cerrahi kısımdan protetik restorasyona kadar biyomekanik prensiplere uyulması gerekmektedir. Son gelişmeler ışığında implantasyondaki başarı oranı % 95 ve üzerine kadar çıkmaktadır.

İmplant tedavisinde hedeflenen, intraosseöz olarak yerleştirilen materyalin kemiğe osteointegrasyonunu sağlayıp kök yapısını taklit edip üst protetik yapısıyla kaybolan fonasyonu ve fonksiyonu sağlamaktır. İmplantın yerleştirilmesiyle beraber hedeflenen osteointegrasyon kavramı, implant ve kemik arasında güçlü bir bağlantının oluşturulmasını sağlamaktır.

Bunun yanı sıra implantalar başarıyla yaygın bir şekilde kullanılsa da, uzun süreli kullanım bazen implant kaybına yol açabilmektedir. Geç dönem başarısızlıklarının en büyük nedeni periimplantitis olup implant çevresindeki doku ve çevreleyen kemiği kapsayan iltihaplanma ile karakterize biyolojik bir komplikasyondur, yaklaşık olarak hastaların %28 ila %77'sinde görüldüğü bildirilmiştir (Massaki vd., 2024).

Yapay zeka ise içeriğinin çok geniş olması sebebiyle tanımlanması zor bir kavramdır. Temelde teknolojiyle insan becerilerinin harmanlanması esasına dayanmaktadır. Doğru ve hızlı tahmin yapmayı, büyük veri kümelerinin sınıflandırılmasından analizine kadar pek çok alanda kullanıma sahiptir. Bu bağlamda sağlık alanında sıklıkla kullanılmakta olup hekimin karar mekanizmasını destekleyici en önemli teknolojik silahlardan biri haline gelmiştir (Gardiynoğlu vd., 2023).

Bu araştırmanın amacı, OPG üzerinde YZ tabanlı otomatik segmentasyonu sağlamak için geliştirilen, ticari olmayan bir algoritma kullanılarak implantların otomatik segmentasyonun yapılması ve bu segmentasyon sonucunda peri-implantitis gözlenen alanların tespit edilmesi ve bu süreçteki klinik sınırlamalar ve klinisyenlerin bu programı kullanırken dikkat etmesi gereken hususları tartışmaktır.

BÖLÜM II

Genel Bilgiler

Dental İmplant Tarihçesi

Asırlar boyunca eksik dişlerin yerine, estetik ve çiğnemedeki fonksiyonu geri kazandırmak için kök yapısını taklit eden çeşitli materyallere ihtiyaç duyulmuştur. implantoloji, çene cerrahisinde diş çekiminin ardından en çok gelişen ikinci disiplindir. Antik Mısırlılar, MÖ 5500'lü yıllarda diş ağrısını tedavi etmek için çeşitli yöntemler geliştirmiş, Sümerliler ise MÖ 2500'lü yıllarda benzer şekilde diş sağlığına yönelik çalışmalar yapmışlardır. (Garg, 2010)

Bambu çubukları MÖ 4000 yıllarında Çin'de kök yapısını taklit etmek amacıyla kemik içerisine yerleştirilmiştir. (Misch, 2007). Maya uygarlığında da kurşun intraosseöz implantları taklit etmek amacıyla kemik içine yerleştirilmiştir. (Garg, 2010).

19. yüzyılda çeşitli elementlerde gelişmenin yaşanılması sonucu Avrupada bu malzemelerden çeşitli implant materyalleri üretilmeye çalışılmıştır. 1809'da Maggiolo, altın materyalinden yapılmış bir implantla diş kökünü taklit etmeyi amaçlamıştır. 1900'lü yıllardarda Lambotte Al, Ag, Cu-Zn alaşım, Cu, MG, Au, Au veya Ni elementleri ile kaplı implant materyali üretmiştir. Ancak bu elementlerin zaman içinde korozyona uğradığı ortaya çıkmıştır. (Misch, 2007).

Greenfield 1913 de, silindirik iridyum platin çubuğundan oluşan bir implant tasarımı ortaya çıkarttı. İki parçalı olduğu düşünülen bu implant, hazırlanan soket boşluğuna implant kemik teması maksimum olacak bir şekilde yerleştirilmiştir. (Misch, 2007).

İnsan ve köpeklerdeki kayıp dişleri tedavi etmek amacıyla Vitalium adlı malzemeyi kullanan Alvin ve Moses Strock, insan dokusuna en uyumlu biomateryali bulmak için çalışmalar yapmışlardır. Çekim soketlerine yivli bir tasarımla oluşturdukları implantları yerleştirmişler ve soket ve implanta arasındaki boşluğun tamamen kemikle dolduğunu gözlemlemişlerdir. (Şekil 1) (Garg, 2010). Bu implant

1938 yılında yerleştirilmiş olup hasta bu implantı 1955 yılına kadar kullanmıştır. (Garg, 2010).



Şekil 1: ilk yiv yapısına sahip implant

İntraosseöz veya subperiosteal olarak yerleştirilen plaka şeklindeki ‘blade’ tipi implantlar 1960 yılına kadar yaygın kullanım alanı bulmuştur. Branemvd’ın ortaya koyduğu çalışmalar sonucunda günümüzde kullanılan implant tasarımı oluşturulmuştur. Branemvd hazırlamış olduğu inraosseöz sokete Ti (titanyum) içerikli bir materyal yerleştirmiş, ve materyal üzerindeki kan akımının oluşturduğu etkileri araştırmıştır. Yerleştirdiği titanyum materyal ile kemik arasında sıkı bir temas oluştuğunu ve bu materyalin kemikten ayrılmadığını gözlemlemiştir. Bu güçlü

temasa osteointegrasyon adını vermiş olup, günümüz implantolojisindeki en temel kavramların biri olan bu terimin kabul görmesini sağlamıştır (Buser vd., 2017; Garg, 2010; Guglielmotti vd., 2019).

Piyasada çok sayıda fvdli implant tasarımı, yüzey yapısı ve mvdasının bulunması nedeniyle hangi implant yapısının ve tasarımının hastalar için en uygun olduğu konusunda problem teşkil etmektedir.

Dental İmplantlar

Diş hekimliği tarihinde ilk dental implant örneği, Mayalara ait mezardan bulunan bir alt çenenin üzerinde tespit edilmiştir. Mısır kaynaklarında da implantla ilgili çalışmaların yer aldığı bildirilmiş olup ilk implant patenti 1908 senesinde Greenfield tarafından içi boş bir örgü kafes tasarımıyla alınmıştır (Greenfield, E. J. (1991)).




Resim 1. Bilinen İlk İmplant (Mayalar)

İmplantın yaygın kullanımı tavşan kemiklerinde yapılan araştırmalar sonucu osteointegrasyonun net bir şekilde görüldüğü kemik ve implant arasındaki sıkı temas ‘canlı kemik ve implant yüzeyi arasındaki direkt yapısal ve fonksiyonel bağlantı’ sonucu yaygınlaşmıştır. (Carranza, 2011). Alveolar kemiğe yerleştirilen implantlar Uysal tarafından (2005) şu şekilde sınıflandırılmıştır:

Endoosseöz implantlar

Çekim boşluğuna veya dişsiz sahalara kemik içine hazırlanan sokete yerleştirilen implantlardır (Şekil 2) (Ölçüler vd., 2020).



Şekil 2. Blade tarz endoosseöz implant (Mehmet tez)

Subperiosteal implantlar

Periostun altına yerleştirilen ve taşıyıcı parçaların kemik üzerinde olduğu sistemdir. (Resim 2) (Ölçüler vd., 2020).



Resim 2. Subperiosteal implant ve protetik tasarım örneği

İntramukozal implantlar

Tutuculuğun artırılması amacıyla bölümlü hareketli protezlerde kullanılan buton şeklinli implantlardır (Ölçüler vd., 2020).

Transmandibuler implantlar

Le fort kırıklarında ve maksillofasiyal kırıklarda kullanılmakta olan mini plaklar ve subperiosteal implantları fikse etmek için kullanılan ‘‘transkortikal implantlar’’ adı da verilen mini implant vidalar bu gruba girer (Şekil 8) (Ölçüler vd., 2020).



Şekil 3. Transmandibular İmplant.

Transdental implantlar

Dişin kök yapısının içerisinden çene kemiğine kadar uzanan implantlardır (Uysal, 2005). Cerrahisinde ise daha önce yapılan uygulamalarda iki aşamalı cerrahi yöntem kullanılmıştır. İmplantta direkt gelen kuvvetleri kırmak ve çevre dokulardaki enfeksiyon riskini azaltmak bu tekniğin en önemli avantajlarıdır. En büyük dezavantaj ise; ikinci uygulamaya ihtiyaç oluşudur. Tek aşamalı cerrahide iyileşme başlığı yerleştirilmektedir böylelikle ikinci bir aşamaya gerek kalmamaktadır (Duymuş ve Güngör, 2013).

Dental İmplant Materyalleri

Diş hekimliğinde implantlar, içerdiği materyallere göre, titanyum ve titanyum alaşımları, krom-kobalt alaşımları, Fe-Cr-Ni-Mo çelikler, Ta, Ir ve zirkonyum alaşımları, değerli metaller, seramikler ve polimerik materyaller gibi başlıklar altında sınıflandırılabilir.(Jain, 2015).

Metal-Metal Alaşımları

Bu materyallerin taşınması gereken özellikler;

- Sterilizasyona uygunluk
- cilalanma
- işlenme
- biyomekanik uyumluluk gibi faktörlere sahip olmalıdır.

Şu ana kadar altın, paslanmaz çelik, krom kobalt gibi metal ve alaşımlar kullanılmıştır. En büyük dezavantajları ise alerjik reaksiyona neden olmaları ve uzun süre sağ kalım oranlarının düşük oluşudur. Tüm bunların sonucu olarak yapılan araştırmalarda en biyouyumlu materyalin titanyum olduğu sonucuna varılmıştır. (Sykaras vd., 2000)

Titanyum

Günümüzde titanyum, mekanik ve kimyasal stabilitesi ve mükkemel derecedeki biouyumunu ile implantolojide en güvenilir materyal olarak kabul

edilmesine neden olmuştur.(Steinemann, 1998).

Alaşımlara eklendiğinde sertlik kazandıran parlak hafif ve gri renkli yapıda olan titanyum, koroziv etkilere oldukça dirençlidir.

Günümüzde en fazla kullanılmakta olan Titanyumun özellikleri şunlardır (Şekil 4) (Ölçüler vd., 2020):

- Titanyum dokuda inert bir yapıya sahip olup, doku ile temas halindeki tabakada çözünme gerçekleşmez, bunun sonucunda organik moleküller ile reaksiyon verebilecek iyonlar oluşmaz. (Brânemvd, 1969).
- Kortikal kemik ve dentinden daha sert olan mükkemel bir dayanma kuvveti sergileyen Titanyum oldukça iyi mekanik özelliklere sahiptir. Reaktif bir material olan titanyumun yüzeyinde oksit tabakasının oluşması bu materyali korozyona karşı dirençli kılmaktadır.bu tabakanın kalınlığı 1 sn’ de 2-10 nm’ye ulaşır (Steinemann, S. G. (1998)).



Şekil 4. Titanyum dental implant (birke tez)

Ti-6al-4v (Grade 5)

Titanyum alaşımlarından biri olan titanyum-alüminyum vanadyum (Ti6Al4V) korozyona direnç, mekanik stabilite açısından en iyi biyouyumlu materyaldir. Aleminyum dayanıklılığı artırıp alaşımın yoğunluğunu düşürürken, vanadyum korozyon karşısındaki direnci yükseltir.(Fenton, A. (1996))

Bu alaşımlar saf titanyuma göre fiziksel özellik bakımından daha üstündür. Bazı araştırmacılar, Ti-6Al-4V (TAV) alaşımının korozyon ürünlerinin, özellikle vanadyumun, kromozom hasarı oluşturabilecek sitotoksik etkilerine dikkat çekmiştir.(Altamirano-Lozano, 2003).

Ancak yapılan bir çalışmada vanadyumun herhangi bir sitotoksiteye neden olduğu saptanmamıştır (Kisnisci, 2014).

Ti-6Al-4V alaşımasının spesifik özellikleri aşağıdaki tabloda gösterilmektedir (Tablo 1) (Yalçın vd., 2007).

Tablo 1. Ti-6Al-4V İmplantların spesifik özellikleri

Karakteristik Özellik	Değer
Akma dayanımı (Mpa)	800-1100
Çekme dayanımı (Mpa)	900-1200
Elastik modül (Gpa)	110-140
Ergime sıcaklığı (°C)	1630-1650
Isıl iletkenlik (W/m.K)	6,7
Yoğunluk (g/cm³)	4,43

Ti-6Al-4V implant alaşımı saf titanyuma (CpTi) göre daha yüksek dirence sahiptir. Mekanik özellikleri ve çalışma koşullarının daha optimal özelliklerde oluşu nedeniyle diğer titanyum alaşımlarına göre kullanıma daha uygundur. İşlenmiş titanyum implantlar kompakt kemiğe göre yaklaşık 1,5 kat, Ti-6Al-4V alaşımı ise 6 kat daha sağlam yapıdadır. (Tablo 2) (Duymuş & Güngör, 2013).

Tablo 2. CpTi ve Ti-6Al-4V implant karşılaştırması

Özellik	CpTi	Ti-6Al-4V
Yoğunluk (g/cm ³)	4,5	4,5
Döküm sıcaklığı (°C)	1700	1700
Çekme mukavemeti (MPa)	520	1000
Oransal sınır (MPa)	350	920
Elastisite modülü (GPa)	110	85-115
Sertlik (VHN)	200	-
Esneklik (%)	20	14

Diğer Metal İmplant Materyalleri

Döküm halinde kullanılan kobalt alaşımlar, elementel bileşim olarak, kobalt, molibden ve kromdan oluşur. Kobalt, sürekli faz için; Kobalt, krom, molibden, nikel ve karbon içerikli ikincil fazlar, yüzeydeki aşınmalara karşılık direnç oluşturur; Krom oksit yüzey korozyona karşı yüzey sağlar, molibden dayanıklılık ve korozyona karşı direnç oluşturur (Panov, V. (2016)).

Demir içeren alaşımlar Ti, Co, Zr veya Zr ile reaksiyona girdiğinde galvanik bir bağlantı oluşturup korozyona neden olabilir (Griffin, C.D (1982)).

Subperiosteal implantların içeriğinde temel olarak kobalt-kromolibden (CoCrMo) alaşımı bulunurken, endosseöz implantlarda titanyum, alüminyum, vanadyum (Ti6Al4V), demir-krom-nikel (FeCrNi) veya sertleştirilmiş paslanmaz çelik 316L (1997) sıkça kullanılmaktadır (Pesun, I. J. (1997)).

Zirkonyum

İmplant etrafındaki mukozanın ince olması zirkonyumun gri renginin yansımaya neden olur ve estetik açıdan dezavantaj yaratır. Yumuşak dokunun yetersiz olduğu ve dişeti regresyonu olan vakalarda kullanışsızdır. Titanyuma karşı alerjik reaksiyonların bildirildiği nadir vakalarda izlenmiştir. Bu sebeplerden dolayı

seramik implantlarla ihtiyaç duyulmuştur. Zirkonyum kronlarla benzerliği, biyo mekanik özellikleri ve biyouyumluluğu nedeniyle dental implant olarak kullanımı uygundur (Handsichel, J. (2008)).

Zirkonyum implantın avantajları,

- Absorbe olmayan biyo-inert metal oksit,
- Korozyona karşı direnci (Lausmaa, 1994),
- Yüksek kırılma direnci (Maccauro, 1999),
- Biyouyumluluk,
- Doğal rengi ile sağladığı üstün estetik özelliktir.

Son çalışmalar göz önüne alındığında zirkonyumun osseointegrasyon hızında artış olduğu ve titanyuma göre fvdı olmadığı ortaya koyulmuştur (Kamayama, K. (1998)). İtiryum içerikli zirkonyum oksit tabak, yüksek mekanik ve biyolojik özelliğe sahip oluşundan ilk kez ortopedi alanında kalça protezi üretiminde kullanılıp, başarılı bir sonuç vermiştir. Dental olarak ilk kez ise, 1990'lı yıllarda endodontik postlarda, braketlerde ve implantlarda kullanıma başlanmıştır (McLaren, E. A. (1998)).

Seramikler ve Karbon

Bu grup alümina, karbon ve karbon-silikon kompozit seramikleri içerir. En yaygın kullanılan formları, kemiğe kimyasal bağlanan hidroksiapatit, trikalsiyum fosfat ve biyocamdır (Şekil 5) (Ölçüler vd., 2020).katı bir malzeme olan hidroksiapatit implantın yüzeyini kaplar. Çekme kuvvetlerine karşı direncinin düşük oluşu ve çözünme gibi problemlerin izlenmesi nedeniyle kullanımı tercih edilmemektedir (Blue vd., 2003; Sadeq vd., 2003).



Şekil 5. Seramik dental implant (Mehmet tez)

Polimer Ve Kompozitler

Elastikiyet özelliklerinin yüksek oluşu nedeniyle periodontal ligamentte mikro hareketliliğe imkian tanınması ve dolayısıyla doğal dişte gözlemlenen bir bağlantı oluşturulması hedeflenmiştir. Fakat stress iletimi bakımından, rijit implantlara göre istatistiksel bir fvd izlenmemiştir. Günümüzde kullanım alanı sadece implantasyonu takiben üst yapı kısmında kullanım bulmuştur (Carranza, 2011).

Osseointegrasyon

Osseointegrasyon, kemik ile implant arasında elektron mikroskobu altında görülen sıkı bağlantıdır. İmplant ile kemik yüzeyi arasındaki yapısal bağlantı diye de

tanımlanabilir. İmplant etrafındaki kemik oluşumu ankiloiz ile meydana gelir. Osseointegrasyon, primer ya da direkt iyileşme olarak gerçekleşebilir. İmplantın klinik açıdan fonksiyonel kuvvetler altında stabil olması gerekmektedir. İmplantın kemikle osseointegrasyonu için aralarında sıkı bir bağ olmalıdır. Böylelikle fibrokartilajenöz iyileşme engellenir. Ayrıca osteointegrasyon ile kırık kemiğin iyileşmesi arasında temel bir fvd bulunmaktadır, bu fvd kırıkta fragmanlar arası bir kaynaşma olurken osteointegrasyonda ise yabancı bir materyalle kemik arasında gerçekleşmektedir. (Schenk & Buser, 1998).

Osseointegrasyonun sağlanması için önemli hususlar vardır. Bunlar (Hupp vd., 2019):

- Biyouyumlu materyal seçimi
- Primer Stabilité (implantın kemikle sıkı teması)
- İmplantın hareketsizliğinin sağlanması
- Doku hasarı oluşturmeyen atravmatik bir cerrahi teknik

Asepsi ve antisepsi prensiplerine uyup, optimum hız ve optimum uzunluk ve çaptaki frezler ile implant yuvası hazırlanmalıdır. Osteotomi yapılırken kuvvet devamlı bir şekilde verilmemeli ve bol miktarda irrigasyon ile desteklenmelidir. İrrigasyondaki temel amaç, yuva oluşturulurken kemikteki sıcaklığı 47 OC'nin altında tutmaktır. 47 OC'yi geçen sıcaklıklarda nekroz riski artar, bu da osseointegrasyonu negatif şekilde etkiler (Chen vd., 2016; Hupp vd., 2019).

Dental İmplantların Başarı Kriterleri

Harvard Üniversitesinde yapılan çalışmaya göre dental iplantlardaki başarı kriterleri şunlardır; (Schnitman & Shulman, 1979):

1. 1 mm den az mobilitenin gözlenmesi
2. Parastezi veya anestezi gözlenmemeli
3. İmplant ve çevre dokularda enfeksiyon gözlenmemeli
4. Nasal kavite, mandibular kanal ve sinüse zarar verilmemeli
5. implantasyon sonrası sağ kalım süresinin 5 yıldan fazla olması

Albrektsson vd.'nin yaptığı araştırma günümüzde daha çok kabul görmüştür. Bu kriterler şöyledir (Albrektsson vd., 1986):

1. Mobilite konusunda her implantın ayrı ayrı ele alınması
2. İmplant çevresinde radyografi üzerinde radyolüsen siye rastlanmaması
3. Postoperatif ilk senede kemik kaybının 0.2 mm yi geçmemesi
4. Ağrı, nöropati,anestezi,enfeksiyon izlenmemeli, mandibuler sinere zarar verilmemeli
5. postoperatif implantasyon sonrası 5 yıl sonunda implantların %85'inde, 10 yıl sonunda ise %80 oranda sağ kalım olması.

Dental İmplantların Başarısızlık Kriterleri

Esposito vd. göre yapılan bir çalışma implantın başarısızlık kriterlerini şöyle sıralamıştır(Esposito vd., 1998):

1. Biyolojik başarısızlığa bağlı

- a. Erken(primer) dönem

Osteointegrasyon aşamasındaki başarısızlığa bağlı

- b. Geç(sekonder) dönem

İmplant osseointegrasyonu tamamlamış ama bunu koruyamamış olma durumu.

2. Mekanik başarısızlığa bağlı

İmplantın kronal kısmı veya implant kırığı olma durumu

3. İatrojenik hatalara bağlı

Sinir hasarı, hatalı konumlandırma

4. Hastaya bağlı kooperasyon veya uyum bozukluğu

Chrcanovic ve vdadaşlarının çalışmasına göre başarısızlık durumunu artıracak olan faktörler şunlardır (Chrcanovic vd., 2014):

1. Erken dönem implantasyon veya immediat implantasyondan düşük primer torkun alınması
2. Klinisyenin yetersiz cerrahi tecrübesi
3. Çenedeki posterior alanlar ve maksillaya implant yerleştirilmesi
5. tip 3 veya tip 4 kemiğe implantasyon
6. Kemik miktarının yetersiz olduğu durumlar
7. Kısa boy ve dar çap implant uygulanması
8. Primer stabilitenin düşük olması
9. Hastaların aşırı miktarda sigara tüketmesi
10. Yıvsız tasarımlı implant uygulanması
12. İmplantın üzeri protez kısmının mobil olması

Kemik Tipleri Ve Sınıflandırılması

İmplantasyondaki kemik kalitesi implantasyondaki en önemli başarı faktörüdür. Kemiğin gösterdiği kuvvet ve mukavvemet, implant kemik arası temas miktarı ve implant kemik arası kuvvet dağılımı kemik yoğunluğuyla ilişkilidir. Kemiğin yumuşak yapısı implantın uzun süre fonksiyonda kalma şansını azaltmaktadır (Esposito vd., 1998; Friberg & Jemt, 2010; Friberg vd., 1991; Morris vd., 2004).

Linkow ve vdadaşlarına göre yapılan çalışmada kemik sınıflaması şu şekildedir (Linkow vd., 1970):

Sınıf 1: En ideal kemik tipidir. Küçük süngerimsi boşluklara sahip, eşit aralıklı trabeküllerden oluşur.

Sınıf 2: Kemikte biraz daha büyük kansellöz boşluklar bulunur ve kemik paternin homojenitesi daha azdır.

Sınıf 3: Kemik trabekülleri arasında geniş boşluklarla dolu alanlar mevcuttur.

Linkowa göre, sınıf 1 ve sınıf 2 tipteki başarı oranı daha yüksektir (Linkow & Cherchève, 1970).


Lekholm ve Zarb'ın yaptığı çalışmada anterior kemik sınıflandırmasını şu şekildedir (Şekil 6) (Adell, 1985).

Q1: Kompakt homojen kemik

Q2: Çevresindeki kemik kalın ve kortikal, trabekülasyon yoğun

Q3: Çevresindeki kemik ince ve kortikal, trabekülasyon yoğun

Q4: Çevresindeki kemik ince ve kortikal, trabekülasyon yoğunluğu az



Şekil 6. Lekholm ve Zarb sınıflaması

1988 yılında Misch, yaptığı çalışmada kemik yoğunluğunu 4 sınıfa ayırmış ve implantasyondaki optimum başarıyı sağlamak için fvdli kemiklere ait implantasyonda uyulması gereken fvdli tedavi yöntemleri oluşturmuştur(Misch, 2007; Misch & Degidi, 2003; Misch vd., 1999; Misch vd., 1998).

Misch'e ait kemik sınıflaması şu şekildedir (Şekil 7):


D1: Homojen kompakt yapıdaki kemik neredeyse hiç trabekül yapısı içermez. Yoğun kortikal yapıda olduğundan, çenede en az vaskülarite gösteren en sert kemiktir. Sınırlı kan akımı nedeniyle, bu kemik çok zayıf kemik rejenerasyon kapasitesi gösterir. Isı oluşumunu ve kemik nekrozunu azaltmak için osteotomi daha düşük devirde ve yeni frez kullanılarak, maksimum miktarda serum fizyolojik irrigasyonu altında yapılmalıdır. Bu kemik tipi en yaygın olarak mandibular anterior bölgede bulunur

D2: Bu kemik, yoğun bir trabeküler yapıya sahip bir kemik merkezini çevreleyen kalın bir kompakt kemik yapısı gösterir. Bu kemik mükemmel vaskülarite ve iyileşme kapasitesine sahiptir. En fazla alt anterior da izlenip, üst anterior ve alt posteriorda da izlenebilir.

D3: Kretin merkezinde trabeküllerin arasındaki boşluk artmış ve kret tepinde daha az kortikal kemiğin olduğu durumdur. En fazla maksiller anterior bölgede görülür. Bunun yanı sıra tüm bölgelerde de gözlemlenebilir

D4: Geniş trabeküler boşluklar ve kret tepesindeyse neredeyse kortikal tabakanın izlenmediği durumdur. En fazla maksiller posterior bölgede gözlemlenir.

Mineralizasyonu tamamlanmamış çok yumuşak bir kemik olan D5 tip kemik varlığından da bahsedilmektedir. Sinüs ogmentasyonu sonucu oluşan kemiğin yapısı buna örnektir. (Şekil 7) (Misch, 2007)



Şekil 7. Misch'in kemik yoğunluk sınıflaması

İMLANTLARIN GÖRÜNTÜLENME TEKNİKLERİ

Ortopantomograf

OPG minimum distorsiyon ve süperpozisyonun gözlendiği dental vdlar ve ilişkili yapıların tek bir filmde görüldüğü bir radyograf çeşitidir. OPG'ler, diş ve dişler arası ilişkiyi net bir biçimde ortaya koyması nedeniyle diş hekimleri için primer bir diagnostik dental radyografilerden en çok tercih edilenidir (White, S.C. ve Pharoah, M.J. 2014).

Radyografi esnasında hastanın başı etrafında rotasyon hareketi yapan bir ışın kaynağı yer almaktadır. 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. Baş pozisyonunu ayarlanmasını takiben hastadan dilini damağına değdirecek şekilde durması ve yutkunması istenir. (White, S.C. ve Pharoah, M.J. 2014, Özcan, 2020).

OPG endikasyonları aşağıda belirtilmiştir (Rushton ve Horner, 1996, Ekströmer ve Hjalmarsson 2014, Özcan, 2020):

- Kusma refleksi görülen hastalarda dental radyografiye ihtiyaç olan durumlarda
- İntraosseöz lezyonların tespit ve takip sürecinde
- İşlem öncesi ve sonrası ilgili işlemin kontrolünde
- Gömüşü dişlerin vital yapılarla olan ilişkisi ve gömülülük derecesinin belirlenmesinde
- Çekim sonrası kalan kök varlığının tespitinde
- Dentisyon gelişiminin takibinde
- Temporomandibular eklemi ilgilendiren kemik yapıdaki değişikliklerin araştırılmasında
- Maksillofasiyal bölgede kırık araştırılmasında
- Nazal konka, nazal septum ve fossanın değerlendirilmesinde
- Diş hekimliğinde hukuki ve adli nedenlerle ilgili delillerde

OPG'nin diğer görüntüleme yöntemlerine göre daha başarılı olduğu durumlar özetlenirse(Ekströmer ve Hjalmarsson 2014, Özcan, 2020):

- Aynı görüntü üzerinde maksilla ve mandibuladaki dişlerin izlenebilmesi.
- Radyografinin elde edilmesi kolay ve hızlıdır.
- Radyasyon oranının KIBT'a göre düşük oluşu.
- Osteoporoz gibi bazı sistemik rahatsızlıklarla oral sorunların teşhisinde yardımcı olması
- Olgu sunumlarına ve hasta eğitimine yardımcı olan görseller sunması.

OPG'lerin dezavantajları da mevcuttur. Bunlar ise:

- 1.Görüntülerin çözünürlüğü intraoral filmlerdeki kadar yüksek değildir.
- 2.Görüntülerdeki keskinlik ve netlik düşüktür. Bu nedenle çürük teşhisinde kullanılmaz.
- 3.Süperpozisyonlardan kaynaklı olarak, interproksimal alanlardaki kemik kaybı, süperpozisyonlar nedeniyle tespiti zordur.
- 4.Premolarlar bölgesinde süperpozisyonlara yaygın olarak rastlanılmaktadır. Keser ve premolar bölgedeki teşhisi doğrulamak için intraoral radyografiler alınmalıdır. (Pandula, 2020).
- 5.Patolojik değişimleri gizleyen hayalet veya çift görüntüler oluşabilir.X ışınıyla iki kez ışınlanan objelerin çift görüntüsü oluşurken, rotasyon merkezi ve ışın kaynağı arasında kalan bazı objelerin hayalet görüntüsü oluşabilmektedir.
- 6.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.
- 7.Magnifikasyon oranı vdlardaki bölgelere göre değişiklik arz ettiğinden dolayı kemik ölçümünde yanlış sonuçlar vermektedir. (Özcan, 2020).

Periapikal Radyografiler

Diş ve dişi çevreleyen yapılar hakkında önemli bilgiler sunan periapikal filmler ağız içi muayenenin önemli bir parçasını oluşturmaktadır.Bu radyografilerle çürük,kök ve periapikal dokular,kron,apikal lezyonlar,gömülü dişler, kırık diş parçaları,kistler ve alveolar kemikte oluşan kayıplar görülebilmektedir (Gupta, vd., 2014).

Konvansiyonel Tomografi

Konvansiyonel tomografi, seçilen düzlemdeki tek bir doku yapısını, düzlem üzerinde gösteren 3D radyografilerdir. Seçilen yapı harici kalan yapıların net izlenememesi, en büyük dezavantajdır (Frederiksen, 2009).

Anjiografi

Paranasal sinüslerde bulunan, vasküler kaynaklı patolojilerin tespitinde, kullanılan bir yöntemdir. Bunun haricindeki patolojilerin tespitinde kullanılmamaktadır (KOÇAK, N. (2018).

Ultrasonografi

Ultrasonografi, boyun ile ilgili patolojik değişikliklerin değerlendirilmesinde, tükürük bezi, baş ve boyunu ilgilendiren hastalıkların teşhisinde kullanılan bir yöntemdir. Sinüs patolojilerinde ve maksillofasiyal kemiklere ait patolojilerin tespitinde yaygın kullanımı bulunmamaktadır (KOÇAK, N. 2018).

Manyetik Rezonans

Manyetik Rezonans Görüntüleme (MRG) yumuşak dokuyu ilgilendiren değişiklikleri tespit etmek için kullanılan bir tekniktir. MR görüntüleme, sinüslerin fvdli kesitler kullanılarak değerlendirilmesi imkianını sunar. Sinüs ve çevresine infiltre neoplazik değişikliklerin teşhisinde önemli bir görüntüleme tekniğidir (Fişekçioğlu, E., & El-Zuki, M. 2015).

Bilgisayarlı Tomografiler

Bilgisayarlı tomografi (BT) paranasal sinüs patolojilerinin diaagnozunda altın standart olan yöntemdir. BT kemik ve yumuşak doku görüntülenmesinde tercih edilmektedir. Baş ve boyun bölgesinde malign ve benign tümörler, inflamasyon ve kistlerin değerlendirilmesinde kullanılır. Dental implant uygulamaları, TME hastalıkları, maksillofasiyal ve ortognatik cerrahi öncesi planlamalarda kullanılır (Koçak, 2007).

Periapikal Radyografiler

Bu radyografik yöntem ile; (Van, M. D. (1993)).

- Mevcut kretin yüksekliği
- Maksiller sinüs ile kret arasındaki subantral mesafe
- Mental foramen ile mandibular kanal
- Kemik yoğunluğu ve trabekülasyon değerlendirilebilir.

Periapikal radyografilerin ebatlarının küçük oluşu, kullanım alanlarını kısıtlamaktadır. Bu sebeple büyük yapıdaki anatomik oluşumlar izlenemez (Wang, I. C. (1999)). Dişsiz alanlarda radyografin yerleştirilmesi zorlaştığından görüntünün elde edilmesi daha zordur. Diğer sınırlandırmalara bakılacak olunursa sık damak kubbesi, dil ve ağız tabanı gibi oluşumlar radyografi çekimini kısıtlamaktadır (Misch, C. E. (2008)). Her ne kadar paralel yöntemle radyografi çekimi sonucun doğruluğunu artırsa da, kemik yüksekliğinin ölçümü hatalı sonuçlara yol açabilmektedir (Richardson, A. C. (1995)).

Konik Işın Hüzmeli Bilgisayarlı Tomografi (KİBT)

Görüntüsü istenen yapının etrafında 360 derecelik bir rotasyonun yeterli olduğu konik şekilli x ışınlarının görüntüyü elde etmede kullanıldığı görüntüleme yöntemidir. Medikal BT'ler de birden fazla rotasyon merkezi mevcuttur.

- Elektrik enerjisinin daha az kullanılması nedeniyle tasarruf edilir.
- Daha az hacim kaplayıp daha az maliyete sahip X-ışını komponentleri kullanılır.

Görüntü, dedektör ve X-ışını kaynağının rotasyon hareketi yaptığı bir gantri kullanarak sağlanır.

KİBT'in diş hekimliğindeki kullanım alanları ise; Ortognatik cerrahi, kist ve tümör, implant planlaması, damak yarığı olan vakalar, TME incelemesi, gömülü dişleri değerlendirme, ortodontik tedavi ihtiyacı olan olgularda, travma ve paranasal sinüslerin değerlendirilmesinde kullanılır.

KIBT Avantajları ve Dezavantajları

KIBT tekniği pek çok avantajı olsa da bir takım dezavantajlara da sahiptir. KIBT sisteminin avantajları şu şekilde sıralanabilir;

- Radyasyon:

Primer X ışını, ışınlanan alanının boyutuna göre kolimasyon küçültülebileceğinden radyasyon boyutu düşürülebilir (Shanbhag ve diğerleri, 2013). Radyasyon dozunun 4-15 panoramik radyografi dozuna eşdeğer olduğu efektif radyasyon dozunun ise BT'den ortalama %85-%98 oranında daha az olduğunu belirtilmektedir. KIBT cihazları kullanılarak fvdli boyutlardaki alanlar seçilebilmektedir. Böylece sadece görüntüsü istenen alanının görüntüsü elde edilerek hastanın maruz kaldığı doz miktarı düşer (Koçak, 2007).

- Görüntü kalitesi:

Görüntü üzerindeki patolojik ve anatomik yapıların netlik düzeyi o görüntünün kalitesini ortaya koyar. Görüntü kalitesi; gürültü, çözünürlük ve artefakla ile alakalıdır. KIBT'nin çözünürlüğü BT'ye göre daha üstündür. KIBT yüksek çözünürlük ve muazzam bir görüntü kalitesine sahiptir (Hodez ve diğerleri, 2011). Voksel boyutu azaldıkça çözünürlük o oranda artmaktadır. KIBT'in sahip olduğu milimetrenin altındaki uzaysal çözünürlük nedeni ile diagnostik özelliği daha yüksek olup küçük yapılara kadar detayların ayırt edilmesini sağlar. En modern spiral BT cihazının voksel boyutu 0.35 mm iken, KIBT'da minimum voksel boyutu 0.1 mm'dir (Carter ve diğerleri, 2008). Ayrıca konvansiyonel BT'ler anizotropiktir ve dikdörtgenler prizması şeklinde voksellere sahiptir. KIBT'in kontrastı düşük olduğundan yumuşak dokuyu gösterme kalitesi düşüktür.. Medikal BT cihazlarında ise yumuşak dokunun görüntü kalitesi daha yüksektir (Mah ve diğerleri, 2003).

- Hızlı tarama süresi:

X ışını görüntüsü istenen alan etrafında tek bir rotasyon hareketi yapar (180 veya 360 derece).. Tarama süresi ortalama 10-70 saniyedir (Koçak, 2018). Sürenin az olması nedeniyle harekete bağlı oluşan artefak miktarı da az olmaktadır (White ve Pharoah, 2008).

KIBT sisteminin dezavantajları;

- **Metalik artifaktlar:**

KIBT görüntülerinde oluşan metalik artifakt, BT görüntülerine göre daha az oluşmaktadır. Bu artefaktlar, implant gibi cerrahi ve protetik malzemelerin etrafında, sinüs içerisinde metalik yabancı cisimler ve diş kronu gibi yapıların etrafında belirgindir. (Scarfe ve Farman, 2008).

- **Maliyet:**

KIBT cihazları BT cihazlarına göre maliyeti daha az olup daha az yer kaplar (Mah ve diğerleri, 2003). KIBT' ın maliyetinin yüksek olması, muayenehanede bulundurulmasını zorlaştırmıştır. (Howerton ,2008).

Periodontal ve Periimplant Dokular

Periodontal dokular

Periodonsiyum; periodontal ligament, alveolar kemik, sement ve diş etinden oluşan ve dişlerin fonksiyon görmesinde dişlere destek sağlayan yapılardan oluşur (Schroeder, 2012). İnterdental, marjinal ve yapışık diş eti olmak üzere 3 yapıdan oluşur (Ainamo ve Talari, 1976). Periodontal ligament, dişin kök kısmını alveolar kemiğe bağlar, hücreli bağ ve vasküler dokudan meydana gelir. Diş etinin bağ dokusu ile devamlılık gösterir (Itoiz ve vd., 1964). Sement, kökün dış yüzeyini saran avasküler, mezenkimal, kalsifiye bir dokudur. Hücreli (ikincil) ve hücreli (birincil) sement olarak 2'ye ayrılır (Gottlieb, 1942). Alveolar kemik, dişlerin soket kısımlarını oluşturan dişlerin konum, şekil, boyut ve fonksiyonunu belirleyen dokudur (Sodek ve Mckee, 2000).

Periimplant dokular


Periimplant dokular, implant çevresindeki sert ve yumuşak dokulardan oluşmaktadır. Yumuşak doku; "periimplanter mukoza" olarak isimlendirilir ve protetik kısımda abutment implant bağlantısı yapılır yapılmaz implant çevresindeki iyileşme aşamasında şekillenir. Sert doku; implant yerleştirilmesinin hemen ardından implanta stabilite kazandırmak için implant ile osseoentegrasyon oluşumu sağlar. İmplantın dış mukoza kısmı, ortokeratinize epitel ile çevrelenmiştir. Abutment kısmına bakan mukoza iki bölüme ayrılır; 1) ince bir bariyer epitel, bağlantı epiteline benzer ve

"koronal" kısım olarak adlandırılır, 2) implant yüzeyinin direkt temasta olduğu "apikal" kısım.

Keratinize mukoza, Periimplant mukozadan hareketli mukozaya kadar olan kısmı kapsar. Ortokeratinize skuamöz epitel ile örtülü, fibroblastlar, tip I ve tip III kolajen içeren fibröz bir bağ dokusu olan lamina propriadan oluşur. Dişlerin bukkal alanlarındaki keratinize doku miktarı karşıt taraflı implant bölgelerindeki doku miktarından ortalama 1 mm daha çoktur. Diş çekiminden sonra oluşan kemik kaybının keratinize dokuda azalması sebep olduğu düşünülmektedir (Chang ve vd., 1999). Peri-implant sağlığı sürdürmek için gerekli minimum keratinize mukoza miktarı, tartışmalı bir konudur (Wennström ve Derks, 2012). Yapılan bir takım araştırmalarda minimum keratinize dokunun olmadığı bölgelerde enflamasyon tespit edilmediğini göstermiştir (Krekeler ve vd., 1985; Schrott ve vd., 2009), bazı çalışmalarda ise 2 mm'den az keratinize dokuya sahip implantlarda plak birikimi nedeniyle marjinal bölgede enflamasyonun sıklıkla görüldüğü ortaya koyulmuştur (Chung ve vd., 2006; Rocuzzo ve vd., 2016). Periodontal dokular ile periimplant dokular arasındaki farklılıklar

Periodontal olarak sağlıklı dişlerde, diş eti, mine sement sınırıyla aynı düzlem içinde ilişkiyken, implantlarda mukozal kenar, komşu dişin bağdokusunu takip ederken, birden fazla yapılmış implantlarda ise krestal kemiği takip eder.

İmplant etrafındaki epitel, keratinize ve keratinize olmayan epitelden meydana gelir. Bağlantı epitelinin boyutu yaklaşık olarak 2 mmdir. Hemidesmozomlar aracılığıyla implant ve diş etrafındaki bu bağlantı epitellerine bağlanmaktadır (Berglundh ve vd., 1991). İmplantlardaki bağ dokusundaki kollajen lifler paralelken, doğal dişlerde ise kök yüzeyine dik seyreder (Salimi ve vd., 2011). Ayrıca implant çevresinde periodontal ligamentin bulunmaması ve kollajen liflerin implanta paralel seyri ve biyolojik bir bariyerin mevcut olmaması sebepleriyle bakteriyel invazyonlar implant çevresi dokularda oluşabilmektedir. Bu yüzden bu dokular enfeksiyona daha yatkındır (Belibasakis, 2014). Ayrıca sharpey lifleri doğal dişlerde mevcutken implant etrafında bulunmazlar (Şekil 8). Ayrıca dişler soket içerisinde gelen yüklere karşı hareket yeteneğine sahipken implantlara gelen kuvvetler kuvveti direk kemiğe iletir (Carranza ve vd., 2012). Bu yüzden alveolar kemikte kayıp görülmektedir (Gotfredsen ve vd., 2002).



Şekil 8. Periimplant dokular ile periodontal dokuların karşılaştırılması

Doğal dişlerde vaskülarizasyon, suprapariosteal ve periodontal ligament kaynaklıdır. Periimplant dokularda ise suprapariosteal kaynaklıdır çünkü periodontal ligamente sahip değildir (Berglundh ve vd., 1994).


Periimplant Hastalıklar

İmplantı etrafında dokularda meydana gelen hastalıklar ilk kez 1. Avrupa Periodontoloji kurulunda, peri-implantitis ve peri-implanter mukozitis olarak gruplandırılmıştır. (Albrektsson, 1985).

Peri-implanter mukozitis

Perimukozitis, periimplantitisin başlangıcı olarak düşünülmekte ve implant etrafında bakteriyel kaynaklı plak birikimine bağlı oluşan, alveolar kemikte kaybın görülmediği, peri-implant mukozasını enflamasyonu olarak tanımlanır (Albrektsson T, 1994; Lindhe ve Meyle, 2008). Peri-implanter mukozitis, plak birikiminin kaldırılmasıyla bu hastalık ortadan kalkabileceğinden bu hastalık geri dönüşümlü bir hastalıktır. Bu hastalığa ait peri-implanter mukozitis prevalansı, hastaların etkilenme oranına bağlı olarak %80 (Zitzmann ve Berglundh, 2008), %63,4 (Atieh ve vd.,

2013), %64,4 (Konstantinidis ve vd., 2015), %48 (Daubert ve vd., 2015); implant materyaline bağlı %50 (Zitzmann ve Berglundh, 2008), %30,7 (Atieh ve vd., 2013), %57 (Konstantinidis ve vd., 2015), %33 (Daubert ve vd., 2015) ve %35,6 (Schwarz ve vd., 2017) olarak bildirilmiştir. Türkiye’deki bir çalışmaya göre 655 implantın etrafındaki dokuların %36,5’inde peri-implanter mukozitis tanısı koyulmuştur (Elemek, 2016). Klinik olarak ele alındığında, mukozada sondalama esnasında kanama, süpürasyon, eritem, ödem gözlenir (Lindhe ve Meyle, 2008; Zitzmann ve Berglundh, 2008; Meyer ve vd., 2017). Radyografik olarak herhangi bir bulgu ve kemik kaybı izlenmez (Lindhe ve Meyle, 2008) (Resim 3).



Resim 3. Peri-implanter mukozitisin a) klinik ve b) radyografik görünümü

Sağlıklı periimplant mukozadan peri-implanter mukozitise geçiş

Sağlıklı periimplant mukoza, dental implant veya abutment yüzeyiyle etkileşimde bulunan oral epiteldeki non-keratinize bağlantı epitelinin bazal laminası ve hemidezmozomları sayesinde oluşur (Listgarten ve vd., 1991). Bağlantı epiteli, enflamatuvar hücrelerin varlığıyla birlikte, sağlıklı periimplant dokuların ağız boşluğundan izole edilmesini sağlayan yumuşak doku sızdırmazlığını oluşturur (Tonetti ve vd., 1994; Zitzmann ve vd., 2002). Dental implantlar etrafında bakteriyel biyofilm birikimi gerçekleştiğinde, bu durum sağlıklı periimplant mukozanın peri-implanter mukozitise dönüşmesine neden olabilir. Bağlantı epiteline bitişik bağ dokuda, bakterilere karşı savunma mekanizmasını oluşturan enflamatuvar hücrelerin yoğunluğu artmaktadır. Bakteriyel biyofilm birikimi, bağ dokusunda T ve B lenfositlerinin sayısını artırırken, klinik tabloda periimplant mukozada kanama

gözlemlenir. Bu süreç, implant çevresinde güçlü bir enflamatuvar yanıtın tetiklenmesine neden olur. (Zitzmann ve vd., 2001).

Düzenli olarak uygulanan destekleyici tedavi ve etkili ağız hijyeni yöntemleri, bakteriyel biyofilmin azaltılmasında yardımcı olur. Bu tedbirler, sağlıklı periimplant mukozanın, perimukozitise ve bu durumun ilerleyerek peri-implantitise dönüşümünü önlemek adına kritik bir öneme sahiptir.

Peri-implanter mukozitisin etiyolojik olan risk faktörleri

Genel risk faktörleri

Radyasyon tedavisi, diyabet ve sigara gibi etmenlerin perimukozitis riskini artırdığına dair çeşitli çalışmalar mevcuttur (Karch ve vd., 2009; Rinke ve vd., 2011). Ayrıca, son dönemlerde yapılan bir araştırma, peri-implanter mukozitis ile bireyin yaşı ve protezlerin işlevsel süreleri arasında bir ilişki olduğunu ortaya koymuştur (Serino ve Ström, 2009).

Lokal risk faktörleri

Kötü ağız hijyeni

Ağız hijyeni yetersiz olduğunda, periodontal hastalığın başlıca nedeni kabul edilen bakteriyel dental plak, diş ve diş etleri de dahil olmak üzere implant yüzeyi ve periimplant dokularda da birikmektedir (Lindhe ve Meyle, 2008). Bu biyofilm içinde bulunan patojen mikroorganizmalar, konak sağlığının yanıtı ve mikroorganizmaların virülans faktörleri ile birlikte periimplant mukozada iltihaplanmaya neden olmaktadır (Lindhe ve vd., 1992). 9 ila 14 yıllık fonksiyon süresi olan 999 implantı içeren bir çalışmada ise, plak skorları ile peri-implanter mukozitisin varlığı arasında önemli bir ilişki olduğu tespit edilmiştir (Roos-Jansåker ve vd., 2006).

Destekleyici periodontal tedaviye hasta uyumu veya uyumsuzluğu

Periimplant hastalıklarının tedavisi sonrasında , hastaların plak kontrolü konusundaki fvdındalığı, motivasyonu ve bu alandaki davranışsal değişimlerin izlenmesi açısından destekleyici periodontal tedavi son derece önemlidir (Tonetti ve vd., 2015). 9 ila 14 yıl boyunca takip edilen hastalar arasında, destekleyici periodontal tedaviye düzenli olarak uymayanlarda peri-implanter mukozitis

prevalansı %48 olarak bildirilmiştir (Roos-Jans ker ve vd., 2006).

İmplant par alarının malzemeleri ve y zey  zellikleri

İmplant y zey  zellikleri  zerine ger ekle tirmi  bir  alı mada, minimal y zey p r zl l   ne sahip implantların, orta p r zl l   ne sahip implantlardan daha fazla marjinal kemik kaybına yol a tı ı bildirilmi tir (Wennstr m ve Derks, 2012). Bununla birlikte, ba ka bir ara tırmada, implant y zeyindeki fvd lılıkların, implant  evresindeki marjinal kemik seviyesindeki de i imle arasında anlamlı bir ili ki bulunmadı ı ortaya konulmu tur (Wennstr m ve vd., 2004).

Protez tasarımı

İmplant destekli protezlerin etrafındaki biyofilmin uzakla tırılması, periimplant hastalıklarının  nlenmesi ve y netimi a ısından kritik bir rol oynamaktadır. Yapılan bir  alı mada, supramukozal restorasyon sınırına sahip implantların, submukozal restorasyon sınırına sahip implantlarla kar ıla tırıldı ında, peri-implanter mukozitis tedavisi sonrasında sondalama derinliklerinde daha belirgin bir azalma sa ladı ı bildirilmi tir (Heitz-Mayfield ve vd., 2011).

Keratinize periimplant mukozanın boyutları

Keratinize doku yetersizli inin peri-implanter mukozitis a ısından bir risk fakt r  olup olmadı ı,  e itli ara tırmalarla incelenmi tir. Bazı  alı malar, keratinize mukozanın 2 mm'den az oldu u durumlarda daha y ksek perimukozitis prevalansı g zlemlendi ini bildirmi tir (Bouri ve vd., 2008; Boynue ri ve vd., 2013). Bununla birlikte, di er  alı malarda bu durum ile ilgili olarak anlamlı bir ili ki bulunmamı tır (Zigdon ve Machtei, 2008; Frisch ve vd., 2015). Yeterli biyofilm kontrol n n sa landı ı durumlarda, periimplant sa lı ın korunması a ısından keratinize mukozanın olu turulmasının gereksiz oldu u belirtilmektedir (Heitz-Mayfield ve Salvi, 2018).

Siman artı ı


Dental implantlarda  st yapılar, simantasyon ya da vidalama y ntemleriyle sabitlenebilir. Simantasyon uygulamasının ardından yapılan kontroller, periimplant olu unda siman kalıntılarının bulundu unu ortaya koymu tur (Linkevicius ve vd.,

2013). Başka bir araştırmada, siman kalıntısı bırakılan tek üye restorasyonlara sahip hastaların, siman kalıntısı bırakılmayan hastalara göre daha fazla peri-implanter mukozitis belirtileri gösterdiği rapor edilmiştir (Wilson, 2009).

Periimplantitis

Peri-implantitis, implant etrafındaki mukozada iltihaplanma ile birlikte kemik kaybının da görüldüğü, geri dönüşümsüz bir hastalık olarak tanımlanmaktadır (Lindhe ve Meyle, 2008). Periimplant mukozasındaki iltihabi durumu değerlendirmek için klinik olarak, sondalamada kanama ve/veya süpürasyon varlığı, radyografik olarak kemik kaybı tespit edilmelidir (Lindhe ve Meyle, 2008) (Resim 4). Perimukozitisten periimplantitise geçişine neden olan histopatolojik ve klinik faktörler henüz tam olarak anlaşılamamıştır. Diğer klinik belirtiler göz ardı edilse bile, kemik kaybı periimplantitisin başlangıcı için tek başına yeterli bir bulgu olarak görülmektedir (Derks ve vd., 2016).

Süpürasyon, enflamasyon sonucu oluşan, ölü hücre artıkları ve bakterileri içeren sıvı anlamına gelir (Heitz-Mayfield, 2008). Periimplant hastalıklarında süpürasyonun mevcut olması, aktif bir lezyonun belirtisi olarak dikkate alınan önemli bir kriterdir (Resim 5). 999 implant içeren 218 hastayla yapılan bir çalışma, 9 ila 14 yıl süreyle ağızda kalan implantlar etrafında periimplantitis görülen durumlarda kemik kaybı ile süpürasyon arasında pozitif bir ilişki olduğunu ortaya koymuştur (Roos-Jansaker ve vd., 2006). Altıncı Avrupa Periodontoloji Çalıştay'ında peri-implantitis, periimplant mukozada görülen sondalamada kanama ve/veya süpürasyon gibi klinik belirtilere ilave olarak destek kemik kaybının da görüldüğü geri dönüşümlü enfeksiyöz bir hastalık olarak kabul edilmiştir (Lindhe ve Meyle, 2008). Ancak Sanz ve Chapple'in (Sanz ve Chapple, 2012) .8. Avrupa Periodontoloji Çalıştay'ında ortaya koydukları ortak görüş birliği raporunda bu tanımlama üzerinde düzenleme yapmıştır. Buna göre hastaların başlangıç radyografilerinin bulunmadığı durumlarda peri-implantitisin tanısı, "sondalamada kanama ve/veya süpürasyon gibi klinik bulgulara ilave olarak görülen 2 mm ve daha fazla kemik kaybı varlığı" olarak belirlenmiştir (Renvert ve vd., 2014).



Resim 4. Periimplantitisin a) klinik ve b) radyografik görünümü



Resim 5. Periimplantisteste pü varlığı

Tablo 3 de farklı çalışmalara ait tanı kriterleri gösterilmiştir.

Tablo 3. Farklı çalışmalardaki peri-implantitis tanı kriterleri

Çalışma	Peri-implantitis tanımı	Peri-implanter Mukozit tanımı
Daubert et al. (2015) ⁵¹	Yeniden şekillenme sonrası kemik seviyesi değişimi > 2 mm sondalamada kanama ve/veya + sondalama derinliği (PD) ≥ 4 mm	Sondalamada kanama ve veya gingival inflamasyon buna ek kemik kaybı yok
Ferreira et al. (2015) ⁵²	Yeniden şekillendirme sonrası kemik seviyesi değişimi > 2 mm Sondalamada kanama (BOP) ve/veya süpürasyon + Prob derinliği (PD) ≥ 4 mm	Sondalamada kanama ve kemik kaybı yok

Frisch et al. (2015) ⁵³	Yeniden şekillendirme sonrası kemik seviyesi değişimi ≥ 2 mm + sondalamada kanama (BOP) + sondalama derinliği (PD) ≥ 5 mm	Sondalamada kanama yok
Konstantinidis et al. (2015) ⁵⁴	Platform seviyesinden itibaren > 2 mm kemik seviyesi değişimi (doku seviyesi implantlarda alüminyum yüzeyden itibaren > 2 mm) + sondalamada	Sondalamada kanama yok
Rinke et al. (2015) ⁵⁵	Platform seviyesinden itibaren $\geq 3,5$ mm kemik seviyesi değişimi.	Tanımlanmamış
Papantonopoulos et al. (2015) ⁵⁶	Platform seviyesinden itibaren ≥ 3 mm kemik seviyesi değişimi + sondalamada kanama ve/veya süpürasyon + cep derinliği ≥ 5 mm	Tanımlanmamış
Trullenque-Eriksson et al. (2015) ²⁵	Platform seviyesinden itibaren ≥ 3 mm kemik seviyesi değişimi + sondalamada kanama ve/veya süpürasyon + cep derinliği ≥ 5 mm	Sondalamada kanama + platformdan itibaren kemik seviyesindeki değişim < 3 mm
van Velzen et al. (2015) ⁵⁷	Fonksiyonda geçen ilk yıldan sonra $>1,5$ mm kemik seviyesi değişimi + sondalamada kanama	Tanımlanmamış
Dalago et al. (2017) ⁵⁸	Abutment yerleştirilmesinden itibaren >2 mm kemik seviyesi değişimi + cep derinliği >5 mm + sondalamada kanama / süpürasyon.	Tanımlanmamış
Rokn et al. (2017) ⁵⁹	Platform seviyesinden itibaren >2 mm kemik seviyesi değişimi + sondalamada kanama ve/veya süpürasyon.	Sondalamada kanama + platformdan itibaren kemik seviyesindeki değişim ≤ 2 mm
Tenenbaum et al. (2017) ⁶⁰	Platform seviyesinden itibaren $>4,5$ mm kemik seviyesi değişimi + sondalamada kanama + cep derinliği ≥ 5 mm.	Sondalamada kanama ve kemik kaybı yok

Peri-implantitisin varlığını tespit etmek için gerekli klinik ve radyografik bulgular ile klinik muayene adımları şu şekildedir: (Renvert vd., 2018)

1. **Görsel Muayene:** Klasik inflamasyon belirtileri olan kızarıklık, şişlik, ağrı ve sondalamada kanama gibi semptomların değerlendirilmesi. (Bu belirtilerin

özellikleri, peri-implanter mukozitis için tanımlananlarla benzer olup peri-implantitis tanısında da geçerlidir.)

2. **Ayırıcı Tanı:** Peri-implant mukozitis ve peri-implantitis arasındaki ayırıcı tanı, başlangıçtaki iyileşme ve kemik remodelingi sonrasında alveolar kemik kaybının varlığına dayanır. Bu durumun tespiti, dental implantların çevresindeki kemik seviyesinin zaman içindeki radyografik değerlendirmesini gerektirir. Bunun yanında, ilgili bölgede inflamatuvar değişiklikler ve sondalamada kanama (BOP) da göz önünde bulundurulmalıdır.
3. **Kemik Kaybı ve Klinik Bulgular:** İmplantın fonksiyona girmesinden sonra meydana gelen ilk remodelinge bağlı krestal kemik seviyesi değişikliklerini aşan kemik kaybı varlığı, sondalamada kanama (BOP) ile birlikte değerlendirildiğinde peri-implantitis için belirleyici bir işaret olarak kabul edilmelidir.
4. **Radyografik Değerlendirme:** Klinik bulgulara dayalı olarak radyografilerin alınması, klinik karar sürecine göre şekillendirilmelidir. İmplantın fonksiyona girdiği zamana ait referans radyografilerle karşılaştırma yapılabilmesi için standartlaştırılmış radyografilerin alınması önemlidir.

Peri-implantitis tanısı için şu kriterlerin sağlanması gereklidir: (Renvert vd., 2018)

1. Peri-implant yumuşak dokularda gözle görülebilir inflamatuvar değişikliklerin, sondalamada kanama (BOP) ve/veya süpürasyon ile birlikte varlığı;
2. Üst yapı yerleştirildiğinde alınan ölçümlerle karşılaştırıldığında sondalama cep derinliklerinde artış;
3. İmplant destekli protez tedavisi tesliminden 1 yıl sonra yapılan radyografik değerlendirmeye kıyasla ilerleyici kemik kaybı;
4. Başlangıç radyografileri ve sondalama derinliklerinin mevcut olmadığı durumlarda, ≥ 3 mm kemik seviyesi kaybı ve/veya ≥ 6 mm sondalama derinliği ile birlikte aşırı kanama varlığı, peri-implantitis tanısını destekler.

Periimplantitisin mikrobiyolojik özellikleri

Periimplantitis, sağlıklı implant bölgelerine kıyasla, *Tannerella forsythia* ve *Porphyromonas gingivalis*'in de bulunduğu 19 fvdli bakteri türü ile ilişkilendirilmiştir (Persson ve Renvert, 2014). Ayrıca, periimplantitisin, *Staphylococcus aureus* ve *Pseudomonas aeruginosa* gibi fırsatçı patojenler ile *Penicillium spp.*, *Candida albicans*, *Rhodotorula laryngis*, *Paecilomyces* ve *Candida boidinii* gibi maya ve mantar organizmaları (Leonhardt ve vd., 1999; Albertini ve vd., 2015; Schwarz ve vd., 2015) ile birlikte Epstein Barr ve Human citomegalovirüs gibi virüsleri de içerdiği gösterilmiştir (Jankovic ve vd., 2011). Bu bulgular, periimplantitisin son derece heterojen ve karmaşık bir enfeksiyon olduğunu ortaya koymaktadır (Padial-Molina ve vd., 2016; Rakic ve vd., 2016). Periimplantitis ve perimukozitis mikrobiyota çeşitliliği benzerlikler taşırken, sadece üç mikroorganizma türünde fvdlilik söz konusudur; *Tannerella forsythia* periimplantistide daha yüksek oranda gözlenirken, *Campylobacter ochracea* ve *Actinomyces gerencseriae* perimukozitistide daha fazla oranda tespit edilmiştir (Maximo ve vd., 2009).

Periimplantitis için etiyolojik risk faktörleri

Periodontitis geçirilmiş olması

Aggregatibacter actinomycetemcomitans, *Porphyromonas gingivalis* ve *Tannerella forsythia* periodontistide rol oynayan ana mikroorganizmalardır (Haffajee ve Socransky, 1994) ve bu bakteriler periimplant hastalık gelişiminde de yer almaktadır (Mombelli ve vd., 1987). Periopatojenlerin varlığı periimplant hastalıkların gelişmesinde önemli rol oynamaktadır (Renvert ve Polyzois, 2015). Yapılan bir sistematik derlemede, en az 5 yıl boyunca fonksiyonda olan implantların etrafındaki periimplant hastalık prevalansına bakıldığında periodontitis nedeniyle diş kaybı yaşayan ve implant uygulanan hastalarda marjinal kemik kaybının ve peri-implantitis insidansının daha yüksek olduğu bulunmuştur (Schou ve vd., 2006). Periodontal hastalık geçmişinin peri-implant hastalık gelişmesinde risk faktörü olduğunu destekleyen pek çok çalışma bulunmaktadır (Ferreira ve vd., 2006; Daubert ve vd., 2015).

Sigara kullanımı

Sigaranın patojenik etkileri, içindeki 4000'den fazla toksik madde ile açıklanabilir. Nikotin, kan akışını azaltarak vazokonstriktör bir etki gösterir. Bu durum, sigara içmenin damarlanmayı olumsuz etkilediği ve iyileşmeyi zorlaştırması gibi hem doğal hem de edinilmiş konak cevabını da sekteye uğrattığı anlamına gelir (Lambert ve vd., 2000). Lindquist ve vdadaşları, sigara içen bireylerde sigara içmeyenlere göre daha fazla kemik kaybı yaşandığını belirlemişlerdir (Lindquist ve vd., 1997). 10 yıllık bir kohort çalışmasında, Karoussis ve ekibi sigara içen bireylerdeki implantlarının %18'inde periimplantitis geliştiğini, bu oranın sigara içmeyenlerde sadece %6 olduğunu bulmuşlardır (Karoussis ve vd., 2003). Ayrıca başka bir araştırmada, periimplantitisin sigara içen kişilerde (%9,2) sigara içmeyenlere (%5,3) göre daha yaygın olduğu kaydedilmiştir (Rodriguez-Argueta ve vd., 2011).

Diyabet

Diyabet, yara iyileşmesinde gecikmelere yol açan, enfeksiyon riskini artıran, kolajen metabolizmasını olumsuz etkileyerek periimplant ceplerin oluşumuna neden olan, hızla kemik kaybına ve implant kaybına neden olabilen bir hastalıktır (Fiorellini ve Nevins, 2000; Heitz-Mayfield, 2008). Daubert ve vdadaşlarının gerçekleştirdiği bir çalışmada, 225 implanta sahip 96 hastayı inceledikleri çalışmada, implant kaybı ile diyabet arasında olumlu bir ilişki tespit etmişlerdir (Daubert ve vd., 2015).

Kötü ağız hijyeni ve destekleyici tedaviye düzenli devam edilmemesi

İmplant bölgelerinde oral hijyeninin sağlanması, periimplant hastalıklarının önlenmesinde kritik bir rol oynamaktadır. Protetik yapının tasarımı, hastaların implant çevresinde temizlik yapmasını zorlaştırabilir. Plak kontrolü yetersiz olduğunda, bakteriyel plağın içindeki mikroorganizmaların virülans faktörleri, konak yanıtıyla birlikte periimplant hastalıklarına neden olabilir (Lindhe ve vd., 1992). Araştırmalar, kötü ağız hijyeni ile periimplant kemik kaybı arasında bir ilişki olduğunu göstermektedir (Lindquist ve vd., 1997; Ferreira ve vd., 2006). Bu nedenle, plak kontrolü alışkanlığının geliştirilmesi ve fvdındalığın artırılması amacıyla destekleyici tedavilere düzenli olarak devam etmek önemlidir (Tonetti ve vd., 2015).

Keratinize mukoza yetersizliği

Doğal dişlerin etrafındaki keratinize mukoza, bariyer görevi görerek periodonsiyumu dış etkenlerden korur. Periodontal hastalıklara karşı korunmada keratinize mukozanın genişliğinin en az 2 mm ve yapışık diş etinin en az 1 mm olması gerektiği belirtilmektedir (Chung ve vd., 2006). Doğal dişler etrafındaki keratinize mukozanın önemi, implantlar için de benzer şekilde kabul edilmektedir. Her ne kadar implant çevresindeki keratinize mukozanın eksikliğinin doğrudan periimplantitise neden olmadığı düşünülse de, uzun dönemde yapışık keratinize diş eti genişliğinin periimplant sağlık için önemli bir unsur olduğu vurgulanan araştırmalar bulunmaktadır (Wennström ve Lindhe, 1983; Kim ve vd., 2009).

Genetik faktörler

Gen polimorfizmlerinin periimplant hastalıklar üzerindeki etkisiyle ilgili hem olumlu hem de olumsuz görüşler mevcuttur (Heitz-Mayfield, 2008). Lachmann ve vdadaşları (2007), yayımladıkları çalışmada interlökin-1 genotipi ile periimplantitis arasında bir ilişki olduğunu ifade etmişlerdir. Buna karşın, Wilson ve Nunn (1999) tarafından gerçekleştirilen bir araştırma, interlökin-1 genotipi ile implant kaybı veya implant çevresindeki kemik kaybı arasında bir bağlantı bulunmadığını ortaya koymuştur.

Siman artığı

İmplantların protetik restorasyonunda sıkça kullanılan simantasyon yöntemleri ile ilgili yapılan kontrollerde, periimplant oluklarda siman artıklarının bulunduğu tespit edilmiştir (Linkevicius ve vd., 2013). Wilson (2009), periimplant hastalıklar ile siman artıkları arasındaki ilişkiyi dental endoskop yardımıyla araştırmıştır. Bu çalışmada, siman kalıntıları bulunan implantların %81'inde periimplant hastalık semptomları gözlemlenmiş; simanların uzaklaştırılmasının ardından implantların %74'ünde bu semptomların ortadan kalktığı belirlenmiştir.

Sistemik hastalıklar

Sistemik hastalıkların periimplantitis ile ilişkisi, diyabet dışındaki durumlar için pek fazla incelenmemiştir ve bu nedenle belirsizlik göstermektedir. Bununla birlikte, yapılan bir araştırma, romatoid artrit ve kardiyovasküler hastalık teşhisi olan hastaların periimplantitis riski açısından daha yüksek bir risk grubunda yer aldığını

göstermiştir (Renvert ve vd., 2014).

İatrojenik faktörler

7. Avrupa Çalıştay'ında, periimplantitisin başlangıcı ve ilerleyişi açısından bazı iatrojenik faktörlerin etkili olabileceği kabul edilmiştir. Bu faktörler arasında "Restorasyonların aşırı konturlanması, implantın yanlış konumu ve dayanak ve restorasyon arasında açıklık bulunması" yer almaktadır (Lang ve Berglundh, 2011).

Titanyum partikülleri


Olmedo ve vd. (2013), 30 hastanın hem sağlıklı hem de periimplantitisli periimplant mukozasından aldıkları örneklerin sitolojik analizini yapmışlardır. Bu analiz sonucunda metal benzeri partiküller bulduklarını ve periimplantitisli bölgelerde titanyum konsantrasyonunun daha yüksek olduğunu belirtmişlerdir (Olmedo ve vd., 2013).

Hatalı oklüzal yükleme

Oklüzal uyumun ve protetik restorasyon tasarımının implant başarısı üzerinde önemli etkileri vardır. Oklüzal düzlemin veya tüberküllerin gereğinden fazla yüksek olması ve karşıt diş veya implantla geniş bir yüzey alan teması, artan oklüzal yükler sonucu implantların kırılmasına ve çevresindeki kemikte mikro kırıklara sebep olabilir (Gittelson, 2002). Tüberkül yüksekliği, rehberlik ile oklüzal düzlemde yapılacak düzenlemeler, oklüzal kuvvetlerin dengelenmesinde kritik rol oynar (Weinberg, 1998). Oklüzal yüklerin implantın uzun eksen boyunda kemiğe doğru iletilmesi ideal bir durumdur. Aksiyal ve lateral olmayan kuvvetlerin azaltılması önemlidir; aksi takdirde, oklüzal yükler krestal kemik ve implantın boyun kısmında yoğunlaşabilir (O'Mahony ve vd., 2000).

Hatalı oklüzal yüklemeler, implantların osseoentegrasyonunu kaybetmesine ve kırılmasına yol açabilir. Bu durum, implant yuvasıyla ilgili mikrokırıklara ve marjinal ya da periapikal kemik kaybına neden olma riski taşımaktadır (Piattelli ve vd., 1998). Periimplantitisin klinik ve radyografik bulgularla değerlendirildiği çeşitli çalışmalarda, periimplantitisin hasta bazında görülme sıklığı %28 (Fransson ve vd., 2005), %12 (Máximo ve vd., 2008), %6 (Dierens ve vd., 2012), %19 (Atieh ve vd., 2013), %13,3 (Konstantinidis ve vd., 2015) ve %26 (Daubert ve vd., 2015) olarak

rapor edilmiştir. İmplant bazında ise bu oranlar %12,4 (Fransson ve vd., 2005), %7 (Máximo ve vd., 2008), %5 (Dierens ve vd., 2012), %9,6 (Atieh ve vd., 2013), %6,2 (Konstantinidis ve vd., 2015), %16 (Daubert ve vd., 2015) ve %7,6 (Schwarz ve vd., 2017) şeklindedir. Türkiye’de gerçekleştirilen bir çalışma ise, 200 hastada ortalama $53,52 \pm 36,76$ ay süreyle işlev gören toplam 655 implantın çevresinde %60 oranında periimplantitis tespit etmiştir (Elemek, 2016).



Şekil 9. Periimplantitis ve Periimplanter mukozitis fvdı

Yapay zeka

Günlük hayatta sıkça yaygın olarak kullanılan "yapay zeka" (YZ) terimi, genellikle insan bilişsel fonksiyonlarını (problem çözme, akıl yürütme, anlama, öğrenme gibi) taklit eden makineler anlamına gelse de, birçok fvdı şekilde tanımlanabilir

- **Hızla Gelişen Bir Teknoloji:** Yapay zeka, tüm sektörleri ve sosyal alanları etkileyen, hızlı bir gelişim gösteren ve çeşitli ekonomik ve toplumsal faydalar sunan bir teknoloji ailesidir (Avrupa Komisyonu, 2021).

- **Geniş Kapsamlı Tanım:** Planlama, problem çözme ve öğrenme gibi insani yetenekleri taklit eden bilgisayar yazılımlarını kapsayan genel bir terimdir (Uzialko, 2019).
- **Veriye Dayalı Öğrenme ve Uyarlama:** YZ sistemleri, dışarıdan gelen verileri yorumlayarak öğrenir ve bu öğrenmeyi esnek şekilde kullanarak belirli hedeflere ulaşır (Haenlein ve Kaplan, 2019).
- **İnsan Zekasına Karşı Makine Zekası:** Yapay zeka, insan zekasından fvdli olarak makinelerin gösterdiği zeka olarak tanımlanabilir (Delipetrev, Tsinarakli ve Kostic, 2020).
- **İnsan Zekasının Bilgisayar Sistemleri Tarafından Taklidi:** İnsan bilişsel süreçlerinin, özellikle bilgisayar sistemleri aracılığıyla taklit edilmesi olarak tanımlanabilir (Ali, Ayad ve Rubaie, 2022).

Yapay zeka (YZ), günümüzde günlük hayatımızın ayrılmaz bir parçası haline gelmiş ve altı önemli faktörün bir araya gelmesiyle tarihsel bir dönüm noktasındadır. Bu faktörler gelişmiş algoritmalar, açık kaynaklı yazılım, birbirine bağlı dünya ve veriler, artan işlem gücü ile gelişmiş veriler, YZ'nin hızlı gelişimini ve yaygınlaşmasını desteklemektedir. Bilgisayarlar, yapılandırılmış (elektronik tablolar, veritabanları) ve yapılandırılmamış (video,görüntü,ses, metin) devasa veri kümelerine erişim sağlamaktadır. Bu büyük verilerin yapay zeka ile işlenmesi, geçmiş kalıpların keşfedilmesini, daha doğru tahminler yapılmasını ve daha etkili önerilerde bulunulmasını mümkün kılmaktadır (Herweijer ve Waughay, 2018: 5). YZ, sergilediği zeka türlerine (sosyal zeka, duygusal ve bilişsel) bağlı olarak insandan ilham alan, analitik ve insanlaştırılmış YZ olarak veya evrim aşamasına göre Yapay Dar, Genel ve Süper Zeka olarak sınıflandırılabilir (Haenlein ve Kaplan, 2019).

Yapay zeka, günümüz sanayi devriminin "yeni elektriği" olarak kabul edilmektedir (Velarde, 2019: 44-45). Tarihsel olarak, yapay zekanın yükselişi sanayi devrimleriyle açıklanabilir: Mekanik tekstil üretimi ve Buhar gücüyle şekillenen Birinci Sanayi Devrimi (1760-1840), iş bölümü,seri üretim ve elektrik ile karakterize İkinci Sanayi Devrimi (19. yüzyıl sonu - 20. yüzyıl başı) ve otomasyon,bilgi teknolojileri ve elektronik gelişmelerin ön plana çıktığı Üçüncü Sanayi Devrimi (1980'ler başı) takip etmiştir (Levin, 2018: 5). Günümüzde ise, biyolojik, dijital ve fiziksel alanlar arasında

sınırları bulanıklaştıran teknolojilerin birleşmesiyle şekillenen Dördüncü Sanayi Devrimi, yani dijital devrim yaşanmaktadır (Schwab, 2015: 1).

Endüstri 4.0 teknolojileri olan Büyük Veri, dijital platformlar, Nesnelerin İnterneti, artırılmış ve sanal gerçeklik ile 3D baskı, yapay zekanın (YZ) giderek daha fazla dayandığı temel unsurlardır. Bu gelişmeler, öngörülemeyen şekillerde ortaya çıkan beşinci bir sanayi devrimini tetiklemektedir. "Süper Akıllı Toplum" olarak da bilinen Toplum 5.0, insan ve makine arasındaki köprü görevi görebilir. Bu toplumun temel teknolojileri arasında yapay zeka, dijital, robotik, 3D baskı ve platformlar yer alır. YZ algoritmalarının hızlı benimsenmesi, mevcut nesli daha kişiselleştirilmiş bir geleceğe yönlendirmektedir (Sarfraz, Sarfraz, Iftikar ve Akhund, 2021).

Endüstri Devrimi 5.0 (IR 5.0), insanların makinelerle etkileşiminde yenilikçi bir yaklaşım sergilemektedir. Bu aşamada, makinelerle birlikte çalışan ve akıllı üretim tesislerine bağlı olan bireyler ön plandadır. IR 5.0'ın, daha sofistike insan-makine arayüzlerine yönelmesi beklenmektedir. Bu gelişme, entegrasyonu artırarak insan zekasının gücünü kullanarak daha hızlı ve etkili otomasyonu mümkün kılacaktır. Ayrıca, robotların yakın gelecekte üretim süreçlerini tamamen devralmayacağı anlamına geliyor. IR 4.0'dan (Endüstri Devrimi 4.0) IR 5.0'a geçiş, insan üreticilerine daha fazla odaklanmayı öngörmektedir. İnteraktif bu dönüşüm, insan ve makine özelliklerini birleştirerek verimliliği artırma potansiyeline sahiptir. (George ve George, 2020).

Gelişen teknolojiler, özellikle bulut bilişim ve grafik işlem birimleri, karmaşık yapay zeka destekli sistemlerin büyük veri setlerini hızla ve maliyeti uygun bir şekilde işlemesini sağlamaktadır. Sosyal medya platformları ise bireylerin etkileşim biçimlerini köklü bir biçimde değiştirmiş, bağlantı hızındaki artış bilginin yayılmasını kolaylaştırmış ve bilgi paylaşımını artırmıştır. Bunun yanı sıra, yapay zeka araçları geliştiren ve uygulamaları paylaşan açık kaynak toplulukları, kolektif bir zeka oluşumuna katkıda bulunmaktadır (Herweijer ve Waughay, 2018: 5).

Yapay zeka teknolojilerinin çok çeşitli alanlarda kullanılması söz konusu olsa da, sağlık hizmetleri sektöründeki uygulamalara odaklanmak bu tez çalışması açısından önem arz etmektedir. Sağlık hizmetleri alanında, elektronik tıbbi kayıt yönetimi, uzaktan hasta izleme sistemleri, biyomedikal araştırmalar, eğitim ve sağlık

verileri analitiği gibi çeşitli alanlarda yapay zeka kullanımı belirgin bir şekilde yaygınlaşmıştır. Ayrıca, nanoteknoloji ve gelişmiş malzemelerin, beşinci sanayi devriminin ve gelecek neslin potansiyelini şekillendirmede kritik bir rol oynadığı, hızlı teşhis yöntemleri, terapötik uygulamalar izleme ve gözetim süreçleri ile aşı geliştirme gibi alanlarda kendini göstermektedir (Sarraz, Sarraz, Iftikar ve Akhund, 2021).

Yapay zeka (YZ) teknolojilerinin sürekli olarak gelişmesi, sağlık hizmetlerinin geleceğinde yenilikler getireceği öngörülmektedir. Geleneksel teknolojilerin daha çok fiziksel varlıklarla ilgilenmesine karşın, YZ teknolojisi deneyim, zeka ve uzmanlık yargısı gibi psikolojik nüanslarla bağlantılı olarak devrim niteliğinde bir etki yaratmaktadır. Özellikle derin öğrenme teknolojilerinin ortaya çıkmasıyla, makine öğrenimi algoritmalarının örüntü tanıma konusundaki başarısında önemli bir ilerleme kaydedilmiştir. Bu durum, yapay zekanın veri modellerini analiz etme yeteneğinin, belirli görevlerde ortalama bir insanın becerisine yakın bir seviyeye geldiği anlamına gelmektedir.

Derin öğrenme algoritmaları, insan beynindeki nöron yapısını taklit eden yapay sinir ağları kullanarak karmaşık doğrusal olmayan ilişkileri öğrenme kapasitesine sahiptir. Bu özellikleri nedeniyle, bu algoritmalar tıbbi verilerle ilgili görevlerde aktif bir şekilde uygulanmaktadır. Bu bağlamda, yapay zeka tabanlı teknolojilerin sağlık sektöründeki kullanımı üzerine birçok araştırma sürdürülmektedir. Çeşitli çalışmalar, sağlık alanında yapay zeka uygulamalarının mevcut teknolojilere göre daha etkili sonuçlar verdiğini ortaya koymaktadır. Bu çalışmalar arasında;

- a) Tıbbi görüntülerin analizinde yapay zeka teknolojilerinden faydalanarak görüntüleri ayırt etme
- b) Fvdlı sağlık verileri kullanılarak hastalığın seyrinin tahmin edilmesi
- c) Teşhis süreçleri veya tedavi aşamalarında karar vermeyi destekleyebilen tıbbi cihazların geliştirilmesi
- d) Tıbbi verilerin şifrelenmesi gibi konular yer almaktadır (Pvd, vd., 2020).

Yapay zekanın sağlık hizmetleri alanındaki uygulamaları birçok fayda sağlamaktadır. Bu bağlamda öne çıkan bazı avantajlar şunlardır (Sharma, 2021):

- Robotik kontrollü ameliyatlar, yüksek maliyetli cerrahilerin yerini alarak daha uygun fiyatlı ve etkili tedavi yöntemleri sunacaktır.
- Yapay zeka, hastane kayıt yönetimini daha hızlı ve etkili bir hale getirerek bu sıkıcı işlerin üstesinden gelinmesine yardımcı olacaktır.
- Hastalıkların teşhisi, yapay zeka desteğiyle, geleneksel yöntemlere göre daha hızlı ve etkili bir biçimde gerçekleşecektir.
- Yapay zeka, gerçek zamanlı verilerle klinik karar alma süreçlerini büyük ölçüde kolaylaştıracaktır.
- Hasta verileri, yapay zeka yardımıyla rahatlıkla takip edilerek tedavi süreçlerine destek olacaktır.
- Yapay zeka, insan iş gücünü azaltarak hasta ruh sağlığı gibi önemli konulara daha fazla odaklanmalarına olanak tanıyacaktır.
- İdari işler, yapay zekanın yardımıyla sağlık hizmetleri maliyetinin %30'unu temsil etmekte olup, bu süreçler daha hızlı ve verimli bir şekilde yürütülerek tasarruf sağlanacaktır.
- Giyilebilir sağlık cihazlarında kullanılan yapay zeka, sorunların geleneksel yöntemlere göre daha hızlı tespit edilmesine yardımcı olmaktadır.
- Yapay zeka kullanımı, sağlık hizmetlerinin maliyetini düşürerek temel sağlık tesislerinin herkes tarafından erişilebilir hale gelmesini sağlamaktadır.
- Yapay zeka uygulamaları, tanı ve tedavi süreçlerinde gereken süreyi kısaltmaktadır.

Robotik sistemler, cerrahi işlemlerin hassasiyetini ve doğruluğunu artırarak yüksek kaliteli sağlık hizmetleri sunmaktadır. Dijital sekreterler, hasta durum göstergelerini sürekli olarak takip ederek gerektiğinde hemşireleri bilgilendirir ve müdahale için en uygun zamanı belirlemede yardımcı olur. Makine öğrenimi, tedavi sonuçlarını etkileyen verilerle ilgili kalıpları analiz edebilme kapasitesine sahiptir. Kendi kendine öğrenme süreçleri sayesinde, tanı amacıyla büyük hacimlerde tıbbi görüntüleri işleyerek tedavi karar alma süreçlerindeki belirsizliği azaltmaktadır.

Görüntü işleme teknolojileri, büyük miktardaki tıbbi görüntüleri hızla işleyerek hastalık türlerini ve negatif-pozitif test sonuçlarını değerlendirir. Doğal dil işleme, tıbbi çizelgeler gibi uzun ve yapılandırılmamış metinleri, anlaşılır ve yorumlanabilir bir hale dönüştürebilir. Ses tanıma teknolojileri, hastanın sesi ve dili aracılığıyla önemli bilgileri elektronik tıbbi kayıtlarda saklamak için kullanılmaktadır. İstatistiksel analiz ise, büyük hasta veri setlerini hızlı bir şekilde inceleyerek tedavi sonuçlarını tahmin etme imkanı sunmaktadır. Tahmine dayalı modelleme ise, matematiksel yaklaşımlar kullanarak riskli hastalıkları belirlemede ve tedavi sonuçlarını öngörmede önemli bir yöntem haline gelmiştir.

Yapay Zekanın Tarihçesi

Yapay zekanın tarihine dair bilgilerin elde edilmesi, milattan önceki dönemlere kadar uzanmayı gerektirir. Antik Yunan'da, insansı robotlar hakkında çeşitli düşünceler ortaya atılmıştır. Bu bağlamda, rüzgar mitolojisini kontrol ettiği söylenen Daedalus, yapay insanlar yaratma çabasıyla dikkat çekmektedir. Modern yapay zeka, tarih boyunca filozofların insan düşünce sistemlerini anlamaya yönelik çabalarıyla ortaya çıkmıştır (Mijwel, 2015).

1206 yılında Ebru İz Bin Rezzaz Al Jezeri, sibernetik biliminin öncülerinden biri olarak su gücüyle çalışan otomatik makineler üretmiştir. 1623'te, Wilhelm Schickard dört temel matematiksel işlemi gerçekleştirebilen bir hesap makinesi icat etmiştir. 1672 yılında ise Gottfried Leibniz, günümüz bilgisayarlarının temelini oluşturan bir ikili sayı sistemi geliştirmiştir. Ardından, 1822-1859 yılları arasında Charles Babbage mekanik bir hesap makinesi tasarlamıştır; bu süreç içinde Ada Lovelace, Babbage'nin delikli kartlarla yaptığı çalışmaları sayesinde ilk bilgisayar programcısı olarak kabul edilmektedir. Lovelace'ın çalışmaları algoritma içermektedir.

1884 yılı, yapay zeka açısından son derece önemli bir dönüm noktasıdır. Bu tarihte Charles Babbage akıllı davranışlar sergileyebilen bir mekanik makine üzerinde çalışmalar yapmış ancak insan kadar zeki bir makine üretmenin mümkün olmayacağına karar vermiştir (Mijwel, 2015).

Yüzyıllar süren gelişmelere rağmen yapay zekanın resmi doğuşu 1940'lara tekabül etmektedir. Bu, Amerikan bilim kurgu yazarı Isaac Asimov'un 1942'de

yayımladığı "Runaround" adlı kısa öykü ile başlayabilir. Asimov'un bu eseri, robotik, yapay zeka ve bilgisayar bilimi alanında sonraki nesillere ilham kaynağı olmuştur. Aynı dönemde, İngiliz matematikçi Alan Turing de daha somut konular üzerinde çalışıyordu. İkinci Dünya Savaşı sırasında, Alman ordusu tarafından kullanılan Enigma kodunu çözmek için İngiliz hükümeti adına The Bombe adında bir kod kırma makinesi geliştirmiştir. Yaklaşık bir ton ağırlığında olan The Bombe, genellikle ilk elektro-mekanik bilgisayar olarak kabul edilir. Turing'in bu makinenin Enigma kodunu çözme yeteneği, onun benzer makinelerin zekası üzerine düşünmesine zemin hazırlamıştır. 1950'de, akıllı makinelerin nasıl yaratılacağı ve zekalarının hangi yöntemlerle test edileceği üzerine önemli bir makale yayınlarak Turing Testi'ni tanıtmıştır. Bu test, hala yapay bir sistemin zeki olup olmadığını belirlemenin önemli bir ölçütü olarak kabul edilmektedir; eğer bir birey bir insanla ve bir makineyle etkileşime geçerken makineyi insandan ayırt edemiyorsa, o makine zeki kabul edilmektedir (Haenlein ve Kaplan, 2019).

1965 ile 1970 yılları arasında yapay zeka alanında karanlık bir dönem yaşanmıştır. Bu süreçte, yapay zeka ile alakalı gelişmeler o kadar sınırlıdır ki, test edilemeyecek kadar azalmıştır. Ortaya çıkan gerçekçi olmayan beklentiler, bu alanda aceleci ve iyimser bir tavır oluşturmuş ve yapay zeka destekli makinelerin yapımının kolay olacağı düşüncesini doğurmuştur. Ancak bu dönem, yalnızca veri yükleyerek akıllı makineler yaratma fikrinin başarısız olması nedeniyle karanlık bir dönem olarak adlandırılmıştır. 1970 ile 1975 yılları arasında yapay zeka tekrar gelişmeye başlamış ve hastalık teşhisi gibi konularda elde edilen başarılarından dolayı günümüz yapay zeka sistemlerinin temelleri atılmıştır. 1975-1980 döneminde, yapay zekanın psikoloji gibi diğer bilim dallarından da yararlanabileceği fikri gelişmiştir (Mijwel, 2015).

1980 yılı, yapay zekanın endüstriyel bir olgu haline geldiği yıl olarak tarihe geçmiştir. Bu dönemde, yapay sinir ağlarının popüleritesi yeniden artmıştır. 1987 yılına gelindiğinde ise yapay zeka, saygın bir bilim dalı olarak kabul edilmiştir. 1997'de IBM'in geliştirdiği Deep Blue, dünyaca ünlü satranç oyuncusu Garry Kasparov'a karşı kazandığı zaferle büyük bir dönüm noktası yaratmıştır. Deep Blue, derin öğrenme gibi güncel yapay zeka tekniklerini kullanmamakla birlikte, oynanabilecek tüm satranç oyunlarını öğrenerek mevcut durumu değerlendirip bir

sonraki hamleyi önerebilmiştir. 1998’de internetin yaygınlaşmasıyla birlikte, yapay zeka tabanlı birçok program geniş kitlelere ulaşma imkanı bulmuştur. 2000 yılında ise robot oyuncakların piyasaya sürüldüğü gözlemlenmiştir (Pirim, 2006).

Geleceğe yönelik düzenleme ihtiyacı üzerine bir perspektif geliştirmek, bu gelişmelere açık alanın tanımını yapmak açısından hayati önem taşımaktadır. Mikro düzeyde incelendiğinde, algoritmalara ve organizmalara yönelik hukuksal bir düzenlemenin gerekliliği gündeme gelmektedir. Yapay zeka, özünde nesnel ve önyargısız bir teknoloji olsa da, bu durum yapay zeka uygulamalarının önyargısız olacağı anlamına gelmez. YZ sistemlerini eğitmek için kullanılan verilerde mevcut olan önyargılar devam edebilir ve hatta bu önyargılar güçlenerek sürüp gidebilir. Dolayısıyla, yapay zekanın kendisini düzenlemeye çalışmak yerine, en iyi yaklaşım, yapay zeka algoritmalarını eğitmek ve test etmektir (Haenlein ve Kaplan, 2019).

Ayrıca, üretim süreçlerinin otomasyonu, mavi yakalı iş gücünün iş kaybına yol açtığı gibi, yapay zekanın artan kullanımı beyaz yakalı çalışanlara ve yüksek nitelikli profesyonellere olan talebi de azaltacaktır. Örneğin, görüntü tanıma sistemleri, birçok hastalığın tespitinde doktorlardan daha başarılı performans sergilemekte; hukuk alanında ise e-keşif teknolojileri, büyük avukat ve hukuk ekiplerine duyulan ihtiyacı azaltmaktadır (Haenlein ve Kaplan, 2019).

Makro düzeyde bakıldığında, demokrasi ve barışa yönelik düzenlemeler önem kazanır. YZ, yalnızca özel sektör için değil, devletler için de kullanılmaktadır. Yüz tanıma sistemleri veya sosyal kredi sistemleri gibi uygulamalar bu durumu yansıtmaktadır. Çin, ve kısmen Amerika Birleşik Devletleri, firmaların yapay zeka kullanımını geliştirmek adına karşılaştıkları engelleri azaltmaya çalışırken, Avrupa Komisyonu bu konuda yeni bir yasa çıkarmıştır. Bu yasa, yapay zeka uygulamalarını üç ana risk kategorisine ayırmaktadır. İlk olarak, Çin’deki sosyal puanlama uygulamaları gibi kabul edilemez olanlar yasaklanmıştır. İkinci olarak, işe alım sürecindeki başvuruları değerlendirirken kullanılan CV tarama araçları gibi yüksek riskli uygulamalar için belirli yasal gereklilikler getirilmiştir. Son olarak, açıkça yasaklanmayan veya yüksek riskli olarak sınıflandırılmayan uygulamalar geniş ölçüde denetimsiz bırakılmaktadır (Avrupa Komisyonu, 2021).


Yapay zeka Öğrenme Biçimleri

Makine Öğrenimi

Makine öğrenimi, günümüzde iş geliştirme alanında en çok tercih edilen yapay zeka türlerinden biridir. Bu teknoloji, esasen büyük veri setlerini hızlı bir şekilde işlemek için tasarlanmıştır. Makine öğrenimi algoritmaları, zaman geçtikçe edindikleri bilgilerle çalıştıkları alanda daha yetkin hale geldikleri gözlemlenmektedir (Uzialko, 2019).

Makine öğrenimi çeşitli biçimlerde karşımıza çıkabilir. Bu alandaki çalışmaların büyük bir kısmı, belirli sorunları çözmek ve sağlam çözümler sunmak üzerine odaklanmaktadır. Günümüzde, web sayfası sıralaması kavramı birçok insan tarafından bilinmektedir. Bu, bir arama motoruna bir sorgu iletildiğinde, sorguyla ilgili web sayfalarının bulunması ve bunların alaka sırasına göre görüntülenmesi sürecini içerir. Bunun için, bir arama motorunun hangi sayfaların ilgili olduğunu ve hangi sayfaların sorguya uygun olduğunu anlaması gerekir. Bu bilgiler, web sayfalarının bağlantı yapıları, içerikleri, kullanıcıların önerilen bağlantılara tıklama sıklıkları ve manuel sıralama gibi çeşitli kaynaklardan elde edilebilir. Etkili bir arama motoru geliştirme sürecini otomatikleştirmek adına tahmin ve akıllı mühendislik yöntemleri yerine giderek daha fazla makine öğrenimi tekniklerinden yararlanılmaktadır (Smola ve Vishwanathan, 2008).

Makine öğrenimi, veri ile ilgili problemleri çözmek için çeşitli algoritmalara dayanır. Veri bilimcileri, her duruma uygun tek bir ideal algoritmanın olmadığına dikkat çekmektedir. Kullanılan algoritmanın tipi, çözülecek problemin niteliğine, değişken sayısına ve en uygun model türüne bağlı olarak değişir (Mahesh, 2019). Makine öğrenimi yöntemleri, temsil etme ve uyum sağlama yönünden fvdnlılık gösterir. Bir makine öğrenimi sistemi, öğrendiği bilgileri hipotez adı verilen ve genellikle bir model şeklinde olan bir bilgi temsil yapısında saklamalıdır. Öğrenme algoritmaları, bu hipotezin yeni verilerle (yani eğitim verileriyle) nasıl güncelleneceğini belirterek, böylece ilgili görev için performans ölçütlerinin optimize edilmesine olanak tanır (Lawrynowicz ve Tresp, 2014).



Şekil 10: Makine Öğrenme Modeli (Lawrynowicz ve Tresp, 2014).

Makine öğreniminde, sınıflandırma ve regresyon, eğitim verileri ve modeller ile üretken ve ayırıcı modeller gibi çeşitli görevler tanımlanır. Bu görevler kısaca şu kavramlarla ilişkilidir:

Sınıflandırma ve regresyon görevleri, diğer alanlardaki (özellikler veya öznitelikler) değerlerin yardımıyla bir hedef alanın (hedef) değerini tahmin etmekle ilgilidir. Eğer hedef ayrı bir değer ise (örneğin, sıralı veya nominal), bu durumda işlem sınıflandırma olarak adlandırılır. Hedef değer sürekli olduğunda ise bu işlem regresyon olarak adlandırılır. Genellikle sınıflandırma ve regresyon, denetimli yöntemler değildir. Model, daha önce doğru bir şekilde etiketlenmiş eğitim örnekleri üzerinde çalışarak, yeni ve görülmemiş örnekleri doğru bir biçimde etiketlemeyi öğrenmektedir (Lawrynowicz ve Tresp, 2014).

Eğitim verilerinde üç ana geri bildirim türü bulunmaktadır: pekiştirmeli öğrenmeye özgü olan, ceza ve ödül şeklindeki geri bildirim, etiketlenmemiş örnekler biçimindeki geri bildirim ve etiketli örnekler (Lawrynowicz ve Tresp, 2014). Makine öğrenimi algoritmaları, istenen sonuçlara göre taksonomik bir düzende sınıflandırılmaktadır. Yaygın olarak kullanılan algoritma türleri şunları kapsamaktadır (Ayodele, 2010): Denetimli öğrenmede algoritma, girdileri istenen çıktılara eşleyen bir işlev üretmektedir. Denetimli öğrenme görevinin standart bir formülasyonu, sınıflandırma problemidir.

a) Denetimsiz öğrenme, etiketli örneklerin bulunmadığı durumlarda bir dizi girdi verisini modellemektedir.

b) Yarı denetimli öğrenme, etkili bir işlev veya sınıflandırıcı oluşturmak amacıyla hem etiketli hem de etiketlenmemiş örnekleri bir araya getirmektedir.


Farklı algoritmaların varlığına rağmen, denetimsiz öğrenme genellikle büyük veri setleri için daha etkili performans sergilemektedir. Eğer ulaşılabilir çok büyük bir veri kümesi mevcutsa, takviye öğrenme yöntemlerinin kullanılması da önemli bir gereklilik haline gelmektedir (Mahesh, 2019).

Modellerde, öğrenenme hipotezleri çeşitli biçimlerde bilgi temsili yapabilmektedir; bunlar arasında olasılıksal ve grafiksel modeller, karar ağaçları, mesafeler ve bölümler, kurallar ve denklemler bulunmaktadır. Geleneksel olarak, bilgi temsili iki ana şekilde sınıflandırılmaktadır: sembolik ve alt-sembolik. İlk kategori, genellikle insanlar tarafından kolaylıkla okunabilen resmi sembolik temsil sistemlerinden oluşan atomik yapı taşlarını içermektedir. Bu tür temsiller, bileşimsel bir sözdizimi ve anlambilim barındırmakta ve bileşenlerine anlam yüklenmesine imkân tanımaktadır (Lawrynowicz ve Tresp, 2014).

Derin Öğrenme

Derin öğrenme, makine öğreniminin hızla gelişen bir alt dalıdır. Bu alan, birden fazla gizli katmandan oluşan yapay sinir ağlarını kullanmaktadır. Derin öğrenme metodolojisi, doğrusal olmayan dönüşümler gerçekleştirerek büyük veri setlerinde yüksek seviyede model soyutlamaları elde etmektedir. Son zamanlarda derin öğrenme mimarilerindeki ilerlemeler, yapay zekaya önemli katkılarda

bulunmuştur (Vargas, Mosavi ve Ruiz, 2017).



Şekil 11: Derin Öğrenmenin faydaları (Mathew, Amudha ve Sivakumari, 2021).

Şekil 11, geleneksel makine öğrenimi algoritmalarının ve derin öğrenme algoritmalarının performansını göstermektedir. Geleneksel makine öğrenimi algoritmalarının performansı, eğitim verileri belirli bir eşik değerine ulaştığında sabitlenirken, derin öğrenme algoritmaları daha fazla veri ile birlikte sürekli olarak performanslarını artırmaktadır. Günümüzde derin öğrenme, birçok alanda yaygın olarak kullanılmakta, örneğin Google'ın ses ve görüntü tanıma sistemlerinde, Netflix ve Amazon'un öneri motorlarında, Apple'ın Siri sanal asistanında, otomatik e-posta yanıtlama sistemlerinde ve sohbet robotlarında önemli bir rol oynamaktadır (Mathew, Amudha ve Sivakumari, 2021).

Sinir Ağları

Sinir ağı, işlevselliğini hayvan nöronlarından alan, birbirleriyle ilişkili basit işlem birimlerinden, düğümlerden veya birimlerden oluşan bir yapıdır. Ağın işlem yapabilme kapasitesi, eğitime veya bu süreçten öğrenme yoluyla elde edilen birimler arasındaki bağlantı güçleri ya da ağırlıklarla depolanır (Gurney, 1997). Sinir ağlarının teknik özelliklerini açıklamadan önce, bu yapıların biyolojik kökenlerini ve canlı organizmalardaki bilişsel işlevlerini kısaca ele almak faydalı olacaktır. Tüm bilgi işleme sistemi, omurgalı sinir sistemini, merkezi sinir sistemi ve periferik sinir sistemi olarak iki ana alt kümeye ayırmaktadır (Kriesel, 2009).

Bir nöron, diğer nöronlar veya hücreler tarafından iletilen sinyalleri özel bağlantı noktaları olan sinapslar aracılığıyla alır. Bu bağlantılar genellikle nöronun dendritlerinde, bazen de doğrudan hücrenin soma bölümünde bulunabilir. Elektriksel ve kimyasal sinapslar, bu bağlantılarda önemli bir rol oynamaktadır. Elektriksel sinaps, daha basit bir yapı sunarak, presinaptik taraftan gelen elektrik sinyalini doğrudan postsinaptik hücreye iletir. Bu durum, iletici ile alıcı arasında güçlü, doğrudan bir bağlantı kurar ve organizmalarda otomatik tepkiler için sabit kodlamalarla ilişkilidir. Öte yandan, kimyasal sinapslar, elektriksel bağlantının kesildiği bir sinaptik boşluk içerir ve burada kaynak ile hedef arasında doğrudan bir elektriksel eşleşme gerçekleşmez (Kriesel, 2009).

Sonuç olarak, sinir ağı, deneyimsel bilgiyi depolama ve kullanılabilir hale getirme yeteneğine sahip, basit işlem birimlerinden oluşan geniş paralel dağıtılmış bir işlemci olarak çalışır. Bu yapı, beynin işlevleriyle iki ana yönden benzerlik göstermektedir (Haykin, 2008):

- a) Ağ, çevresinden bilgi edinimini bir öğrenme süreci vasıtasıyla gerçekleştirmektedir.
- b) Edinilen bilgileri depolamak için nöronlar arasındaki bağlantı güçleri, sinaptik ağırlıklar olarak adlandırılmaktadır.

Öğrenme sürecinin yürütülmesi için kullanılan yöntem, ağın sinaptik ağırlıklarını düzenli bir şekilde değiştirerek istenen bir tasarım amacına ulaşmayı hedefleyen öğrenme algoritması denir. Sinaptik ağların modifikasyonu, sinir ağlarının tasarımında geleneksel bir yöntem sunmaktadır. Bu yaklaşım, hali hazırda iyi bir şekilde oluşturulmuş ve çeşitli alanlarda başarıyla uygulanmış olan doğrusal uyarlamalı filtre teorisine en yakın olanıdır. Bununla birlikte, bir sinir ağının topolojisini değiştirmesi de mümkündür. Sinir ağlarının bazı temel özellikleri ve yetenekleri şunlardır (Haykin, 2008):

- **Girdi-Çıktı Eşleme:** Denetimli öğrenme olarak da adlandırılan bu popüler öğrenme yöntemi, bir sinir ağının eğitilmesi için etiketlenmiş eğitim örneklerinin kullanılmasını içerir. Her eğitim örneği, belirli bir giriş sinyaliyle birlikte, bu sinyale karşılık gelen hedef çıktıyı içerir.


- **Uyarlanabilirlik:** Sinir ağıları, çevredeki değişimlere yanıt olarak sinaptik ağırlıklarını ayarlayabilme yeteneğine sahiptir. Özellikle, belirli bir ortamda eğitim alan bir sinir ağı, bu ortamdaki küçük değişikliklerle başa çıkmak için kolaylıkla yeniden eğitim alabilir.
- **Kanıtsal Yanıt:** Örüntü sınıflandırma bağlamında, bir sinir ağı yalnızca belirli bir modelin seçimi için değil, aynı zamanda bu seçimin güvenilirliği hakkında bilgi vermek üzere tasarlanmış olabilir.
- **Bağlamsal Bilgi:** Bir sinir ağı, bilgiyi kendi yapısı ve aktivasyon durumu üzerinden temsil eder. Ağdaki her nöron, diğer nöronların toplam aktivitesinden etkilenebilir, bu da bağlamsal bilgiyi doğal olarak bir sinir ağı tarafından işlenmesini sağlar.
- **Hata Toleransı:** Donanım tabanlı bir sinir ağı, kötü çalışma koşulları altında hafif bir performans düşüşü yaşayabilirken, hatalara karşı dayanıklı olma veya sağlam hesaplamalar yapma yeteneğine sahiptir.
- **Nörobiyolojik Analoji:** Sinir ağıları, beyin gibi, paralel işlemenin yalnızca fiziksel olarak mümkün olduğunu değil, aynı zamanda hızlı ve etkili bir şekilde gerçekleştirilebileceğini gösteren bir tasarım anlayışına dayanmaktadır.

Yapay sinir ağları

Yapay sinir ağları (YSA), en basit tarif ile insan beyninin bir imitasyonudur. Doğal bir beyin, yeni bilgileri öğrenme ve değişen çevre koşullarına adapte olma yeteneğine sahiptir. Ayrıca, belirsiz ve eksik bilgilerle başa çıkma ve bu bilgileri analiz ederek kendi çıkarımlarını yapma konusunda dikkate değer bir kabiliyete sahiptir. Örneğin, bir çocuk hem topun hem de portakalın şeklinin dairesel olduğunu anlama yetisine sahiptir; bir bebek, annesini dokunma, ses ve koku gibi duyularıyla tanıma kapasitesine sahiptir. İnsanlar, bulanık bir fotoğraftan bile tanıdık birini ayırt edebilir (Shiruru, 2016).

Yapay sinir ağları, biyolojik sinir ağları üzerinde yapılan çalışmalara dayanan bir teknolojidir. Bu ağlar, biyolojik sinir sistemlerini taklit ederken, onlardan türemiş çeşitli kavramları kullanmaktadır. Özellikle YSA modelleri, beynin ve sinir sisteminin elektriksel faaliyetlerini simüle etmektedir (Şekil 11). İşlem birimleri, bazıları nörot veya algılayıcı olarak bilinen, birbirine bağlıdır. Genellikle nöronlar,

bir katman şeklinde düzenlenmiş olup, bir katmanın çıktısı bir sonraki katmana ve başka katmanlara giriş sağlar. Bir nöron, sinaptik bağlantıları simüle eden bu bağlantılar ile sonraki katmandaki tüm nöronlarla veya bir alt kümesiyle bağlantı kurabilir. Bu durum, bir sinir hücresinin elektriksel uyarımını ve dolayısıyla bilgi iletimini taklit eder. Bir işlem birimine gelen değerler, nöral yolların güçlendirilmesini yansıtan bağlantı ağırlıklarıyla çarpılır. YSA'larda öğrenme, bu bağlantı güçlerinin veya ağırlıklarının ayarlanması ile gerçekleşir (Walczak ve Cerpa, 2003).



Şekil 11: Örnek Yapay Sinir Ağı Mimarisi (Walczak ve Cerpa, 2003).

Yapay sinir ağları, karmaşık örüntü odaklı sorunların yanı sıra hem kategorizasyon hem de zaman serisi (trend analizi) üzerinde çalışmalar yapmak için etkili bir araç sunar. Sinir ağlarının parametrik olmayan yapısı, yaygın olarak kullanılan parametrik istatistiksel yöntemlerin ihtiyaç duyduğu gibi, veri popülasyonunun dağılımı veya değişkenler arasında potansiyel etkileşimler konusunda önceden bilgi sahibi olunmaksızın modellerin geliştirilmesine olanak tanır. YSA'nın mimarisi ve öğrenme algoritması, giriş verisinin türünü belirleyecektir. Bu yüzden, YSA'ları tasarımdan belirli bir metodoloji ya da net bir adım dizisi izlemek son derece önemlidir. Aşağıda yer alan adımlar bu süreci açıklamaktadır (Walczak ve Cerpa, 2003): Kullanılacak veriler belirlenmektedir.

a) Ağ mimarisi tanımlanmaktadır.

- b) Giriş değişkenleri belirlenmektedir.
- c) Veriler eğitim ve test setlerine ayrılmaktadır.
- d) Uygun bir öğrenme algoritması seçilmektedir.
- e) Test aşamasına geçilmektedir.
- f) YSA, hata seviyesinin kabul edilebilir bir değerin altına inene kadar tekrar edilmektedir.
- g) Değişkenler ağ girişlerine dönüştürülmektedir.

Yapay sinir ağları, nöronlar olarak bilinen işlem birimlerinden oluşmaktadır. Yapay bir nöron, doğal nöronun yapısını ve işlevini örnek alma amacı taşımaktadır. Bir nöron, girdilerden (dendrit) meydana gelir ve çıktısını akson üzerinden sinaps aracılığıyla iletir. Ayrıca, nöronun aktivasyonunu belirleyen belirli bir işlev bulunmaktadır. YSA, standart bir bilgisayar programından fvdli yönlere sahiptir. Bu yapıların bazı özellikleri aşağıdaki gibidir (Shiruru, 2016):

- a) **Kendi kendine organizasyon:** YSA, öğrenme sürecinde kendi iç yapısını şekillendirebilir. Standart bir yazılım ise belirli bir görevin gereklilikleriyle sınırlıdır ve bu amaç dışında işlev göstermez.
- b) **Paralel çalışma:** YSA, insan beyninin özelliklerini yansıtarak paralel bir şekilde çalışmaktadır. Bu durum, seri çalışan geleneksel bir bilgisayar programından belirgin şekilde fvdllik gösterir.
- c) **Hata toleransı:** Sinir ağlarının dikkat çekici özelliklerinden biri, eksik, gürültülü ve belirsizlik içeren verilerle dahi işlev görebilmeleridir. Normal bir yazılım, eksik veya belirsiz verilerle karşılaştığında işlevini sürdürememekte ve en küçük bir hata durumunda durmaktadır.
- d) **Uyarlanabilir öğrenme:** YSA, öğrenme süreciyle birlikte görevleri yerine getirmeyi öğrenerek insan beynini taklit etmektedir. Geleneksel bir program, fvdli girdi türlerine adapte olamamaktadır.
- e) **Yavaş beyin işlem süresine kıyasla YSA'nın hızı:** YSA, insan beyninin işlem süresinin daha yavaş olması dolayısıyla oldukça hızlı sonuçlar verebilmektedir.

f) **Çıktı hesaplama yönteminin belirsizliği:** YSA, çıktıları hesaplama biçimi bakımından net bir yapı sunmamakla birlikte, benzer girdi gruplarında süre fvdhlılıkları gösterebilir.

g) **Uygulama alanları:** YSA, veri sınıflandırma, örüntü tanıma ve belirsiz veri uygulamaları gibi çeşitli alanlarda kullanılabilmektedir.

h) **Girdi ve çıktının doğası:** YSA, girdi ve çıktının net bir şekilde bilindiği ve yapılacak işlemlerin belirgin olduğu durumlarda etkili bir şekilde kullanılamamaktadır.

Yapay sinir ağlarının klasik sistemlere göre sunduğu birçok avantaj bulunurken, bu alandaki araştırmacılar dezavantajlarını da en aza indirmeye yönelik bir takım çalışmalar yapmaktadırlar. Bu dezavantajlar (Dasters ve Soori, 2021):

- a) Gelecekteki performansı tahmin etmek, genellikle zor bir süreçtir. Yani, genelleme yapmak mümkün olmayabilir.
- b) Eğitim setinin büyüklüğü, elde edilen sonuçların doğruluğu üzerinde önemli bir etkiye sahiptir.
- c) Sinir ağları kullanılarak modelleme problemlerinin fiziksel yönleri tek başına anlaşılamaz. Başka bir deyişle, parametrelerin veya ağın yapısının işlem parametreleriyle bağlantısını kurmak çoğu zaman imkansızdır.
- d) Belirli bir uygulama için bir ağ tasarlıyndan, takip edilmesi gereken özel kurallar veya yönergeler bulunmamaktadır.
- e) Ağ eğitimi süreci, bazı durumlarda zorlu veya neredeyse imkansız hale gelebilir.

Evrişimli Sinir Ağları

Evrişimli Sinir Ağları (CNN), temelde görüntü işleme uygulamaları için geliştirilmiştir. Bu ağlar, görüntülerdeki nesnelere ağırlıklar ve önyargılar atayarak onları birbirinden ayırır. Diğer sınıflandırma yöntemlerine göre daha az ön işleme gerektirmeleri, onları cazip kılmaktadır. CNN, çeşitli filtreler kullanarak bir görüntüdeki uzamsal ve zamansal bağımlılıkları yakalayabilmektedir. Bu alandaki fvdhlı mimariler arasında LeNet, AlexNet, VGGNet, GoogleNet, ResNet ve ZFNet

bulunmaktadır. CNN'ler, nesne tanıma, semantik segmentasyon ve altyazı oluşturma gibi birçok uygulamada kullanılmaktadır (Mathew, Amudha ve Sivakumari, 2021).

Evrişimli sinir ağlarının temelleri, 1959 yılında Hubel ve Wiesel tarafından atılmıştır. Bu araştırmacılara göre, hayvanların görsel korteksindeki hücreler, belirli bir alandaki ışığı algılamaktadır. Hubel ve Wiesel'in çalışmalarından esinlenerek, 1980 yılında Kunihiko Fukushima, hiyerarşik görsel örüntüleri öğrenebilen ve çok katmanlı yapıya sahip kendi kendini organize eden bir sinir ağı modeli olan Neocognitron'u tanıtmıştır; bu model, CNN'in ilk teorik temeli olarak kabul edilmektedir. 1990 yılında LeCun ve ekibi, el yazısıyla yazılmış rakamları tanımak için LeNet-5 adındaki modern CNN yapısını geliştirmiştir. Daha sonra, Krizhevsky ve vdadaşları 2012 yılında AlexNet adında derin bir CNN ortaya koymuşlardır (Lecun vd. 2015). AlexNet'in başarısı, fvdli CNN modellerinin geliştirilmesine ve bu modellerin bilgisayarla görme ve doğal dil işleme gibi fvdli alanlarda kullanılmasına kapı aralamıştır (Ghosh vd. 2021).

Modern CNN'ler, tasarımlarını biyolojik verilere, grup teorisine ve yeterli deneysel çalışmalara dayalı verilere borçludur. Doğru modeller elde etmede sağlanan örnekleme verimliliğinin yanı sıra, CNN'ler, tamamen bağlı mimarilere kıyasla daha az parametre gerektirmekte ve kıvrımların GPU çekirdekleri arasında kolayca paralelleştirilmesi sayesinde hesaplama verimliliği göstermektedir. Bu nedenle, uygulayıcılar mümkün olan her durumda CNN'leri tercih etmekte ve geleneksel olarak tekrarlayan sinir ağları ile kullanılan ses, metin ve zaman serisi analizi gibi tek boyutlu sıra yapısına sahip görevlerde dahi güvenilir alternatifler olarak değerlendirilmektedir. Ayrıca, CNN'lerin çeşitli akıllı adaptasyonları, onları grafik yapıları veriler ve öneri sistemlerinde de etkili hale getirmektedir (Zhang, Lipton ve Smola, 2019).


Evrişimli sinir ağları, derin ileri beslemeli mimarilerle ve fokal katmanlara sahip diğer ağlarla kıyaslandığında etkileyici bir genelleme yeteneğine sahiptir. Yüksek seviyede soyutlama özelliğine sahip olan bu ağlar, nesnelerin yanı sıra uzamsal verilerin belirgin özelliklerini hızlı ve etkin bir şekilde öğrenebilir. Derin CNN modeli, bir dizi işlem katmanından oluşarak, girdi verilerinin (örneğin görüntülerin) çeşitli özelliklerini öğrenme yeteneği taşımaktadır. İlk katmanlar,

düşük soyutlama düzeyi ile üst düzey özellikleri çıkarmakta, derin katmanlar ise yüksek soyutlama ile alt düzey özellikleri öğrenmektedir (Ghosh vd. 2021).

Evrişimli sinir ağları, 2007 yılından itibaren ses tanımadan görüntü tanıma ile ilgili görüntü işlemesine kadar birçok alanda çığır açan sonuçlar elde etmiştir. CNN'lerin en önemli avantajlarından biri, yapay sinir ağlarındaki parametre sayısını azaltabilmesidir. Bu durum, araştırmacıların ve geliştiricilerin, klasik yapay sinir ağlarının sınırlarının ötesine geçerek karmaşık görevleri çözebilecek daha büyük modellere yönelmesine neden olmaktadır. CNN'ler tarafından ele alınan sorunlarla ilgili temel bir varsayım, mekânsal olarak bağımlı özelliklerin bulunmamasıdır. Örneğin, bir yüz tanıma uygulamasında, yüzlerin görüntüdeki konumlarına dikkat etmemiz gerekmemektedir. Önemli olan, görüntülerdeki yüzleri tespit etmektir, hangi konumda olduğuna odaklanmak gerekli değildir. Ayrıca, CNN'lerin bir diğer dikkat çekici yönü, girdiler derin katmanlara yayıldıkça soyut özellikleri öğrenebilme yetenekleridir (Albawi, Mohammed ve Al-Zawi, 2017).

Derin Evrişimsel Sinir Ağı Algoritmasının Mimarisi

Derin evrişimsel sinir ağı (DCNN) mimarisi, görsel verilerin işlenmesi ve analizi amacıyla özel olarak tasarlanmıştır. Bu yapılar, temel olarak görüntülerin konum, yön ve aydınlatma koşullarına karşı dayanıklı özellikler öğrenme kapasitesine sahiptir (Krizhevsky, Sutskever & Hinton, 2012) (Şekil 12). DCNN'ler, görüntülerdeki nesneleri tanıma, segmentasyon ve sınıflandırma gibi işlemlerde yaygın biçimde kullanılmaktadır (Simonyan & Zisserman, 2014). (Şekil 4).



Şekil 12. Derin evrişimsel sinir ağı algoritması şeması

U NET MİMARİSİ

U-Net, özellikle biyomedikal görüntü segmentasyonu uygulamaları için geliştirilmiş derin öğrenme tabanlı bir mimaridir (Ronneberger ve diğ., 2015). Bu yapı, tipik olarak hücresel, organ veya diğer biyolojik yapıların görüntülerindeki nesnelerin daha net bir şekilde ayırt edilmesini sağlar. U-Net, 2015 yılında Olaf Ronneberger ve ekibi tarafından önerilmiştir ve mimarisi temel olarak aşağıdaki bileşenlerden oluşmaktadır.

U-Net Mimarisi:

1. **Genişleme Aşaması (Encoding):** U-Net'in sol tarafında, bir dizi evrişim katmanı uygulanarak görüntüdeki özellikler çıkarılır. Bu katmanların ardından, her bir evrişimden sonra bir havuzlama katmanı (max pooling) bulunur; bu sayede uzamsal boyutlar azaltılır (Ronneberger et al., 2015).
2. **Daralma Aşaması (Decoding):** U-Net'in sağ tarafında, görüntü yeniden oluşturulurken daraltılmış uzamsal boyutlar artırılır. Bu aşamada her evrişim katmanına, önceki aşamadaki özellik haritalarından gelen bilgiyi bağlayan atlama bağlantıları (skip connections) eklenir. Bu, ağın detayları kaybetmeden yeniden yapılandırmasına olanak tanır (Ronneberger et al., 2015).
3. **Son Katman:** U-Net mimarisinin çıkış katmanı, piksel bazında sınıflandırma için kullanılan bir softmax aktivasyon fonksiyonu içerir. Bu katman, her piksel için en olası sınıf tahminini üretir (Ronneberger et al., 2015).

U-Net'in Kullanım Alanları:

U-Net, genellikle tıbbi görüntüleme alanında kullanılır. Hedef uygulamalar arasında MR görüntüleri, CT taramaları ve mikroskop görüntüleri gibi sağlık alanındaki çeşitli görüntülerin segmentasyonu bulunmaktadır (Çiçek et al., 2016).


Transfer Öğrenme

Derin evrişimli sinir ağlarının eğitimi sırasında karşılaşılan en büyük zorluk, veri setlerinin yetersiz kalmasıdır. Transfer öğrenme, bu sorunu aşmak için daha önce eğitilmiş bir CNN modelinin yeni bir hedefe uyum sağlaması amacıyla yeniden düzenlenmesi ve mevcut parametrelerin yeni veri setine aktarılması sürecidir (Han ve

vd., 2018).

GoogleNet


GoogleNet mimarisi, 22 katmanlı derin bir ağıdır ve ILSVRC 2014 yarışmasında birincilik elde etmiştir. Bu model, hesaplama maliyetini düşük tutmadan ağı hem derinliğini hem de genişliğini artırmayı başarmaktadır. Diğer derin öğrenme mimarilerinin genelinden farklı olarak, bu yapıda katmanlar üst üste yerleştirilmek yerine paralel bir şekilde görüntü işlenmektedir. GoogleNet'in mimarisi Şekil 13'de görülmektedir (Szegedy ve vd., 2015).



Şekil 13. GoogleNet mimarisi

VGGNet


Oxford Üniversitesi'nde yer alan görsel geometri grubunun geliştirdiği VGG16, 2014 yılında ImageNet yarışmasında birincilik kazanmış bir evrişimli sinir ağıdır (Deng ve vd., 2009). VGGNet modelleri, AlexNet mimarisine kıyasla daha derin bir yapıdadır. Bu model, 13 evrişim katmanı, 5 maksimum havuzlama katmanı ve 3 tam bağlantılı katmandan oluşmaktadır. Toplamda 16 öğrenilebilir ağırlık parametresine sahip katmanı olduğu için VGG16 ismi verilmiştir. VGG16'nın genişletilmiş versiyonu ise VGG19 olarak adlandırılmaktadır. VGG16 mimarisi, Şekil 14'de gösterilmektedir (BAŞARAN, 2020).



Şekil 14. VGG16 mimarisi

AlexNet

AlexNet, derin öğrenme alanında önemli bir kilometre taşı olan bir evrişimli sinir ağıdır. 2012 yılında ImageNet Large Scale Visual Recognition Challenge (ILSVRC) yarışmasında birincilik elde ederek büyük bir dikkat çekmiştir (Krizhevsky, Sutskever & Hinton, 2012). Bu model, görüntü sınıflandırma alanında devrim niteliğinde bir gelişme sağlamış ve derin öğrenmeye olan ilgiyi artırmıştır. AlexNet mimarisi Şekil 15’de gösterilmiştir (BAŞARAN, 2020).




Şekil 15. AlexNet mimarisi

Dvdnet

DvdNet19 mimarisi, toplamda 64 katmandan oluşan bir yapıdır. Bu katmanlar arasında bir giriş katmanı bulunmakta ve ardından 19 evrişim katmanı, 18 Batch Normalizasyon katmanı, 18 Leaky ReLU katmanı, 5 maksimum havuzlama katmanı, 1 global ortalama havuzlama katmanı, 1 softmax katmanı ve bir çıkış katmanı yer almaktadır (He ve vd., 2015). YOLO ise, ImageNet üzerinde eğitim almış 53 katmanlı bir DvdNet varyasyonunu kullanmaktadır. YOLO, etkili bir ağ yapısı


sunvden yeniden eğitim gerektirmemekte ve hızlı bir performans sergilemektedir; ancak bu hız, doğruluk açısından bazı kısıtlamalar getirebilmektedir. YOLO'nun mimarisi Şekil 16'da gösterilmektedir (Redmon ve vd., 2016).



Şekil 16. YOLO sistem mimarisi

ResNet

ResNet mimarisinin belirgin bir özelliği, katman sayısının fazlalığıdır ve bu yapı; "Residual" bloklar içermektedir (Wu ve vd., 2018). Bu bloklar sayesinde ağ, optimize edilerek önceki modellere kıyasla daha yüksek bir doğruluk oranına ulaşmıştır (Li ve vd., 2019). ResNet mimarisi, Şekil 17'de gösterilmektedir (Wu ve vd., 2018).



Şekil 17. ResNet mimarisi

Diş Hekimliğinde Yapay Zekâ ve Kullanım Alanları

Ağız, diş, çene ve yüz hastalıklarının tanısında derin öğrenme tekniklerini uygulayan çalışmalar, kraniyo-maksillofasiyal cerrahiden adli diş hekimliğine kadar birçok fvdli diş hekimliği alanını kapsamaktadır; bunlar arasında endodonti,

periodontoloji ve restoratif diş hekimliği gibi alanlar da bulunmaktadır (Hung ve vd., 2020).

Yapay zeka (YZ), karmaşık ağız hastalıklarıyla ilgili olarak, özellikle hastalık etiolojisinin çoklu faktörlerin etkisinde olduğu durumlarda ve oral prekanser veya oral kanser riski taşıyan bireylerde etkili bir tanı aracı olarak öne çıkmaktadır. Aynı zamanda temporomandibular eklem düzensizlikleri gibi sorunların teşhisinde de hekimlerin hata olasılığını azaltmalarına yardımcı olmaktadır (Khanna & Dhaimade, 2017).

Görüntü işleme ile YZ'nin entegrasyonu, radyoloji alanında yeni araştırmalara kapı açmıştır. Bu bağlamda, YZ, normal veya anormal olarak etiketlenmiş birçok görüntüyü analiz ederek, baş ve boyun bölgesindeki lenf düğümlerinin anormal veya normal olduğunu röntgen sonuçlarında tespit etme yeteneğine sahiptir (Tan ve vd., 2016).

Ayrıca, MRG ve KIBT gibi görüntüleme yöntemleriyle entegre edildiğinde, insan gözünün algılamadığı, normalden çok küçük sapmaları bile tespit etme kapasitesine sahip olmaktadır (Bush, 2018).

Son yıllarda diş hekimliğinde YZ teknolojisiyle entegre çalışan sanal asistanlar ortaya çıkmıştır. Bu asistanlar, insanlarla karşılaştırıldığında daha az iş gücü ile daha yüksek hassasiyet sağlamak ve daha az hata payıyla çeşitli işlevleri yerine getirmektedir. Klinikte, hastaların alerjileri hakkında bilgi verme, randevu takibi, kontrol muayenesi hatırlatmaları ve evrak ile sigorta süreçlerinin yönetimi gibi görevleri üstlenmektedir (Khanna & Dhaimade, 2017).

Yapay Zekanın Diş Hekimliğinde Kullanımı

Dental Eğitim: Akıllı ders verme sistemleri, 1980'lerin başlangıcından bu yana önemli bir ilerleme kaydetmiştir. Derin öğrenme teknikleri, hastalar üzerinde klinik çalışmaların simüle edilmesini ve gerçek hastalarla eğitim sürecinde karşılaşılacak tüm komplikasyonların en aza indirilmesini sağlamak için diş hekimliği eğitiminde kullanılmaktadır. Sonuç olarak, sanal hasta geri bildirimleri, öğrencilere sunulan klinik öncesi eğitimde önemli derecede iyileşme sağlamaktadır. Etkileşimli arayüzler, öğrencilerin çalışmalarını değerlendirebilmelerine ve bu

değerlendirmeyi ideal standartlarla karşılaştırabilmelerine olanak tanıyarak, kaliteli öğrenim ortamları oluşturmaktadır. Yapılan araştırmalar, bu sistemler kullanıldığında öğrencilerin, geleneksel simülatör ünitelerine oranla yetkinlik temelli becerileri daha hızlı geliştirdiklerini göstermektedir (Agrawal ve Nikhade, 2022).

Hasta Yönetimi: Yapay zeka destekli sanal diş hekimi asistanları, diş muayenehanelerinde çeşitli görevleri daha az hata ile gerçekleştirebilir. Bu asistanların işlevleri, gerçek insanlara kıyasla daha az insan gücü gerektirir ve klinik teşhis, tedavi planlaması, randevuların organize edilmesi, sigorta işlemleri gibi pek çok alanda desteğe olanak tanır. Ayrıca, diş hekimine hastaların tıbbi geçmişleri ve alışkanlıkları hakkında bilgi sunma konusunda oldukça kullanışlıdır. Dental acil durumlarda, pratisyenin bulunmadığı durumlarda hastalar için acil yardım seçenekleri de mevcuttur (Agrawal ve Nikhade, 2022).

Ağız, Diş ve Çene Cerrahisi: İnsan hareketlerinin ve zekasının taklit edildiği robotik cerrahi uygulamaları, yapay zekanın ağız cerrahisindeki en yaygın kullanım biçimlerinden biridir. Dental implant yerleştirme, odontojenik tümörlerin veya yabancı cisimlerin çıkarılması, biyopsi işlemleri ve temporomandibular eklem cerrahisi gibi uygulamalarda, görüntü rehberliği kullanarak başarılı cerrahi işlemler gerçekleştirilmektedir. İmplant cerrahisi üzerine yapılan araştırmalar, manuel yöntemlere kıyasla yapay zeka uygulamalarının doğruluğunu önemli ölçüde artırdığını ortaya koymaktadır (Schwendicke ve vdadaşları, 2020). Tecrübeli cerrahlar, deneyimsiz diş hekimlerine göre daha kısa operasyon süreleri, daha yüksek intraoperatif doğruluk ve hassas yapılar etrafında daha güvenli bir manipülasyon sağlamaktadır. Ayrıca, görüntü rehberliği ile yapılan daha kapsamlı cerrahi rezeksiyonlar, tekrar eden ameliyat ihtiyacını azaltma potansiyeli taşımaktadır. YZ, cerrahi alandaki uygulamaları dönüştürerek, deneyimli cerrahların denetiminde yarı otomatik cerrahi prosedürler uygulayan robotik sistemlerin artmasına yol açmıştır (Agrawal ve Nikhade, 2022).

Yapay Zeka Kullanımı ile İlgili Limitasyonlar

Yapay zeka tabanlı uygulamalar, diş hekimliği iş gücünü zahmetli ve rutin görevlerden kurtararak, sağlık hizmetlerini daha geniş bir kitleye düşük maliyetlerle sunmayı hedeflemektedir. Bu sayede kişiselleştirilmiş, öngörücü, önleyici ve

katılımcı diş hekimliği yöntemleri daha erişilebilir hale gelmektedir. Ancak yapay zeka, çoğunlukla aşağıdaki nedenlerden dolayı günlük diş hekimliği uygulamalarında yer bulamamaktadır (Schwendicke, Samek ve Krois, 2020):

- a) Veri mevcudiyeti ve erişilebilirliği, yapısının yanı sıra kapsamı sınırlı kalmaktadır.
- b) Geliştirme süreçlerinde metodolojik titizlik ve standartların eksikliği söz konusudur.
- c) Çözümlerin değerleri ve yararları ile etik ve sorumluluk konusundaki pratik sorular belirlemektedir.

Hasta verilerinin dijitalize edilmesi, toplanması ve saklanması sürecinde birçok engel ile karşılaşmaktadır. Yine de yapay zeka teknolojileri, potansiyellerine rağmen, tıbbi uygulamalarda henüz önemli bir etkiye sahip değildir. Diş hekimliğinde evrimsel sinir ağları şu an geliştirilmektedir ve bu sistemler belirli sorunları aşmak, dental yapay zeka teknolojisini daha etkili hale getirmek ve klinik uygulamalara dahil etmek amacıyla kullanılmaktadır. Diş hekimliğinde, belirli bir süre zarfında toplanan görüntüleme verileri yorumlanmakta ve bu veriler sıklıkla kullanıma sunulmaktadır. Tıbbi ve diş hekimliği ile ilgili veriler, diğer verilerle kıyaslandığında sıkça erişilebilir ve hazır durumda değildir. Genellikle, bu veriler kişisel olarak düzenlenmekte ve genel sistemlerle etkileşime geçmekte zorluklar yaşamaktadır (Babu, Onesimu ve Sagayam, 2021).

Her hastanın verileri, karmaşıklığı ve hassasiyeti nedeniyle işlenmesi veya doğrulanması güç olmaktadır. Elektronik tıbbi kayıtlara dayanan veriler, sıklıkla eksik değişkenlerle karşılaşmakta ve veri analizinde sistematik eksiklikler göstermektedir. Ayrıca, veri örnekleme çoğu zaman önyargılara yol açmaktadır. Veri işleme, ölçüm ve doğrulama süreçleri çoğu zaman yeterli bir düzeyde yeniden üretilebilirlik sunmamaktadır. Veri setlerinin nasıl düzenlendiği, seçildiği ve ön işlemeden geçtiği hala belirsizliğini korumaktadır. Bu nedenle, hem eğitim hem de test amaçlı kullanılan veriler, veri gözetimi yanlılığı olarak bilinen bir duruma yol açmaktadır. Mevcut diş hekimliği yapay zeka uygulamalarının çoğu, karmaşık klinik karar verme süreçlerine sadece kısmi bir görüş sunmaktadır. Aynı zamanda hesap

verebilirlik ve şeffaflık konularlarında endişeler de bulunmaktadır (Babu, Onesimu ve Sagayam, 2021).

Diş hekimliği eğitiminde yapay zekanın getirdiği birçok avantaj bulunmakla birlikte, bu alandaki eğitim, yapay zekanın sınırlılıklarını gösterdiği bir alan olarak dikkat çekmektedir. YZ, verimliliği artırarak öğrencilerin öğrenim süreçlerini desteklese de, gerçek bir manken üzerinde çalışmayı veya el aletlerini kullanmayı tam anlamıyla taklit edememektedir. Operatif ve restoratif diş hekimliği eğitiminde bilgisayar simülasyonları, kavite hazırlama ve polimerizasyon gibi becerilerin öğretilmesine yardımcı olmaktadır. Yapay zeka diş hekimliği eğitiminde umut verici bir araç olsa da, standardizasyon öncesinde daha fazla veri ve araştırma yapılması gerekmektedir (Lee vd., 2021).

Diğer tüm yapay zeka uygulamaları gibi, diş hekimliğindeki yapay zeka çözümleri de bakım erişimini ve kalitesini artırarak, hizmetlerin etkinliğini ve güvenliğini geliştirir. Bu uygulamalar, hastaları güçlendirerek ve etkinleştirerek, tıbbi araştırmaları desteklerken sürdürülebilirliği de artıran somut değerler sunmaktadır. Ayrıca, bireysel mahremiyet, haklar ve özerklik konuları dikkatle ele alınmalı ve merkezde yer almalıdır. Merkezileştirilmiş veya birleşik öğrenim sistemlerine geçiş, ölçeklenebilirliği artırmanın yanı sıra sistemin sağlamlığını da geliştirebilir. Son olarak, dental yapay zeka çözümlerinin güvenilirliği ve yenellenebilirliği sağlanmalıdır; bu doğrultuda sürekli insan gözetiminin yanı sıra, kanıta dayalı diş hekimliği standartlarının uygulanması gerekmektedir (Schwendicke, Samek ve Krois, 2020).

Yapay Zeka ve Diş Hekimliğinin Geleceği

Yapay zeka, beraberinde dikkate alınması gereken yeni riskler getirme potansiyeline sahiptir. Algoritmaların karmaşık yapısı, sonuçların genellikle anlaşılabilir olmamasına neden olur; bu durum, bu yöntemlerin benimsenmesini ve dolayısıyla uygulanabilirliğini kısıtlamaktadır. Açıklanabilir Yapay Zeka, bu gibi açıklanamayan sonuçlara çözümler bulmaya odaklanan, hızla gelişen bir araştırma alanıdır. Sağlık sektöründe ve özellikle diş hekimliği alanında, yapay zeka uygulamalarının güvenli bir şekilde kullanılmasını sağlamak için çeşitli kuruluşlar,

güvenilirliği, performansı ve güvenliği artıracak yeni standartlar ve araçlar geliştirmektedir (Ma vd., 2022).

Yapay zeka teknolojilerinin tüm alanlardaki kullanımı sürekli olarak artış göstermektedir. Diş hekimliği uygulamaları, hastalıkların teşhisinin ötesinde, klinik bulgularla bağlantı kurmakta ve hastalara tedavi sağlamaktadır. Bu yüzden mevcut yapay zeka çözümleri diş hekimlerinin yerini alamamaktadır. Bununla birlikte, yapay zeka teknikleri ve onların kavramları iyi bir şekilde anlaşılırsa, gelecekte büyük bir avantaj sağlayacaktır. Mevcut sınırlamalar, yetersiz ve yanlış verilerin bulunmasından kaynaklanmaktadır. Bu nedenle, diş hekimleri ve klinik uzmanların yaklaşan dönemde yapay zeka uygulamaları için gerçek verileri toplamak ve veri tabanlarına dahil etmek üzere çalışmaları önemlidir (Tandon ve Rajawat, 2020).

Diş hekimleri, tedavi süreçlerini manuel sistemler aracılığıyla elde ettikleri verilerle uyumlu hale getirirken, hasta geçmişi, patolojiler ve semptomlar hakkında neredeyse tamamen kendi gözlemlerine güvenmektedir. Diş klinikleri, neredeyse her teşhis alanında teknolojiyi kullanırken, bu teknoloji, genel olarak, ilgili kayıtların ve değerlendirmelerin yapılmasını sağlayan araçlarla sınırlıdır. Örneğin, bir röntgen görüntüsünün parlaklığının veya kontrastının ayarlanması, insan hatalarını ortadan kaldırarak analiz yapılmasına yardımcı olabilir. Geleneksel tanılamaların bu tür manuel aşamaları, yapay zekanın otomatik algoritmaları içinde çok sayıda veri noktalarına dönüşmektedir. Bu sayede, yapay zeka, daha önce fvd edilmeyen veya başka şekillerde algılanmayan belirtileri saptayabiliyor ve teşhis doğruluğuna dair ikinci bir bakış açısı sunmaktadır (Hillen, 2021).

Yapay zekanın diş hekimliğinde entegrasyonu, kişiye özel tanılamalar yaparak daha hızlı çözümler sunma kapasitesine sahiptir. Bu teknoloji, hekimler ile hastalar arasındaki iletişimi artıracak ve hastaların test sonuçlarının doğru bir şekilde değerlendirilmesini sağlayacaktır. Yapay zeka platformu, hastalara teşhis koymak için alternatif seçenekler sunma amacındadır. Mevcut ortodontik Bilgisayar Destekli Tanı (CAD) uygulamaları, ortodontistin talimatlarına uyarak bir operatör tarafından elle gerçekleştirilmekte ve bu durum insan hatası riskini taşımaktadır; buna karşın yapay zeka destekli analiz, ortodontik tedavi öncesi ve sonrası kesin teşhis ve prognostik bilgi sağlama kabiliyetine sahip olmaktadır (Janapala, 2020).

Kısacası, yapay zeka, insan davranışlarını taklit eden yöntemlerin incelenmesini içerir. Bir hastanın anamnezini alma aşamasından başlayarak, veri işleme ve ardından bu verilerden bilgi çıkarmak gibi birçok alanda yapay zekanın diş hekimliği ve tıp alanındaki uygulamaları bulunmaktadır. Gelecekte diş hekimliği uygulamalarını geliştirmek ve bu teknolojinin ilerlemesine katkıda bulunmak için zamana ihtiyaç duyulmaktadır (Tandon ve Rajawat, 2020).

BÖLÜM III

Yöntem

Etik Kurul Onayı

Bu tez çalışması, Yakın Doğu Üniversitesi Sağlık Bilimleri Etik Kurulu tarafından, Aralık 2023 tarihinde YDÜ/2023/119-1793 numaralı karar ile onaylanmıştır (Ek-1). Araştırma protokolü, Helsinki Bildirgesi'nin etik standartlarına uygun olarak hazırlanmıştır.

Hasta Seçimi ve Çalışma Materyali

Genelleştirmeyi etkileyebilecek önyargıları azaltmak adına, araştırmanın örneklemini, Yakın Doğu Üniversitesi, Diş Hekimliği Fakültesi, Ağız, Diş ve Çene Radyolojisi Anabilim Dalı arşivi ve özel bir muayeneye ait tüm veri tabanı kullanılmıştır. Bu veri seti, üç fvdli OPG cihazıyla elde edilen toplam 8138 OPG içermektedir. Dışlama kriterleri uygulandıktan sonra, veri setinden 442 OPG çıkarılmış ve analiz için uygun 7696 görüntü kalmıştır.

Veri Setinin Oluşturulması

Araştırmaya dahil edilme kriterleri arasında ;

a) Hastaların 18 yaşında büyük olması (Çocuklar hastalarda dental implant uygulaması yapılmamaktadır).

b) Ağızda en az 1 adet dental implantın mevcut olması

c) OPG görüntülerinin radyolojik olarak değerlendirilebilir olması

Harici tutulma kriterleri arasında;

a) Görüntüleme alanlarında büyük asimetrisi olan hastalar

b) Maksillofasiyal patolojilerin yer aldığı OPG'ler,

c) Cerrahilerin neden olduğu maksillofasiyal bozukluklar

d) Cihaz nedenli artefaktların bulunduğu görüntüler

e) Hastanın hareketine bağlı oluşan artefaktlar


f) Hastanın sahip olduđu takıp çıkarılabilir protezler, sabit ortodontik aparatlar, işitme cihazları, hastanın baş pozisyonundan kaynaklanan hatalı radyografiler

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)


Yakın Doğu Üniversitesi Diş Hekimliği Fakültesi Ağız Diş ve Çene Radyolojisi bölümünden ve özel bir muayeneden, standart tarama prosedürlerine uygun olarak elde edilmiş OPG görüntüleri DICOM formatında toplandıktan sonra PNG dosya biçimine dönüştürülerek segmentasyon işlemleri için Computer Vision Annotation Tool (CVAT) sistemine yüklenmiştir. Her bir görüntüye numara atanarak görüntülerin anonimleştirilmesi sağlanmıştır.(Resim 6)



Resim 6. Segmentasyon için kullanılan CVAT sistemi

OPG Görüntülerinin İmplantları Tespit Etmesi

Dental implantlar manuel semantik segmentasyon yöntemi ile segmente edilmiştir. CVAT programı kullanılarak implantın tüm yüzeylerini içerecek şekilde noktalarla implantların etrafı çizilerek bölümlere ayrılmış ve model bu segmentasyonlar sonucunda eğitilmiştir. (Şekil 18)




Şekil 18. Dental implantların segmente edilmesi.

Semantik Segmentasyon

Semantik segmentasyon, bir görüntüdeki piksellerin belirli kategorilere atanması işlemidir. Bu işlem sayesinde, her piksel, görüntüdeki nesne veya alanın hangi sınıfa ait olduğunu belirtmek için etiketlenir. Segmentasyon işlemi, iki maksillofasiyal cerrah ile bir oral radyolog tarafından Computer Vision Annotation Tool (CVAT) kullanılarak manuel olarak gerçekleştirilmiştir. Bu yöntem, özellikle üst üste binen anatomik yapıların bulunduğu zorlu durumlarda, implant sınırlarının hassas bir şekilde tanımlanmasını sağlamıştır. Değerlendiriciler arasındaki fikir ayrılıkları, çoğunlukla üst üste binen anatomik yapılarla ilgili implantları içeren durumların sadece %5'inde meydana gelmiştir. Bu uyumsuzluklar, konsensüs

görüşmeleri ile çözülmüş ve finaldeki inter-rater güvenilirliği 0,97 olarak belirlenmiştir. Bu süreç, tüm segmentasyon sürecini kapsamaktadır. İmplant yivleri gibi detayların yüksek hassasiyetle belirlenebilmesi için nokta oluşturma yöntemi kullanılarak kesin sınırlar tanımlanmıştır. Görüntüler, 512×1024 piksel boyutuna yeniden boyutlandırılmıştır. Segmentasyon algoritması, Python dilinde uygulanan U-Net mimarisi kullanılarak geliştirilmiştir. U-Net mimarisi, özellikle implant segmentasyonu gibi hassas sınır belirleme gerektiren tıbbi görüntü segmentasyonu görevlerindeki etkinliği nedeniyle tercih edilmiştir (Şekil 19). Atlama bağlantıları aracılığıyla mekansal bilgiyi koruma yeteneği, bu çalışmada DeepLab gibi alternatif yöntemlere kıyasla daha uygun hale getirmiştir. Veri seti, test (yüzde 15), doğrulama (yüzde 15) ve eğitim (yüzde 70) olarak üç parçaya ayrılmıştır. Model, yaklaşık 500 epok tamamlamak için 12 saat süren bir eğitim sürecinde NVIDIA RTX 3090 GPU üzerinde eğitilmiştir. Eğitim sırasında sistem, 24 GB GPU belleği kullanmış ve her bir görüntü için sonuç çıktısı 80 ms de olmuştur. Bu kurulum yüksek performans sağlasa da, bu donanım gereksinimleri, özel bilgisayar kaynaklarına sahip olmayan daha küçük kliniklerin erişimini kısıtlayabilir. Gelecek uygulamalar, özel kliniklerin maddi yükünü azaltmak ve daha geniş kitlelerin kullanımını kolaylaştırmak amacıyla bulut tabanlı platformlardan yararlanabilir.



Şekil 19. U-Net mimarisi, görüntü segmentasyonu için kullanılan bir yapıdır. Ağ, özellik çıkarımı amacıyla sol tarafta bir daralma yolu ve hassas konumlandırma için sağ tarafta bir genişleme yolu içerir. Daralma yolundaki her aşama, iki adet 3x3 evrişim (mor), ReLU aktivasyonları ve 2x2 maksimum havuzlama (kırmızı) içerir. Buna karşın, genişleme yolu, mekansal çözünürlüğü geri kazandırmak için 2x2 yukarı evrişimler (yeşil) kullanır. İki yolun eşlenen katmanları arasındaki atlama bağlantıları (gri oklar), çıktıda, detaylı bir segment haritasının yeniden oluşturulmasına olanak tanır.

Periimplantitis Sınıflandırma Süreci

Segmentasyon sonrası, her bir implant segmentasyon çıktısından yararlanılarak OPG'den kırılmıştır. Üç klinisyen veri tabanındaki tüm kırılmış implantları peri-implantitis var veya yok olarak sınıflandırmıştır. Klinisyenler arasındaki tutarlılık intraclass correlation coefficient (ICC) kullanılarak değerlendirilmiş ve bu katsayı 0,97 olarak mükemmel bir güvenilirlik sergilemiştir.

Sınıflandırma modeli, kesilmiş implant görüntülerine dayanarak peri-implantitin otomatik olarak tespit edilmesini amaçlamaktadır. Bu model, peri-implantitise sahip implantlarla sağlıklı olan implantları ayırt etmek için AlexNet mimarisini kullanmaktadır. AlexNet'in hiyerarşik yapısı, daha temel kenar ve şekillerden başlayarak, karmaşık özelliklere kadar olan unsurları aşamalı bir şekilde öğrenmesine olanak tanır. Segmentasyondan sonra, her implant bölgesi kesilmiş ve AlexNet'e giriş olarak aktarılmış; model bu verilere dayanarak implantları peri-implantit belirteçlerine göre sınıflandırmıştır. Ayrıca, sınıflandırma doğruluğunu artırmak için kemik yoğunluğu değişimleri ve implant-kemik arayüzü özellikleri gibi ek özellikler de çıkarılmaktadır. AlexNet'in ReLU aktivasyonları ve max pooling katmanları, özellik haritalarını yeniden inceleyerek ve ölçeklendirerek modelin fvdli implant türleri ve peri-implantitis şiddetleri arasında daha iyi genelleme yapmasını sağlar. Bu yapı, radyografik görüntüleme ile elde edilen yüksek boyutlu veriler için AlexNet'i özellikle elverişli hale getirir ve sağlıklı durumlarla etkilenmiş implantlar arasında belirgin bir ayrım yapılmasını sağlar. Modelin performansı, güvenilirliği artırmak amacıyla çeşitli ölçütlerle değerlendirildi. Bu ölçütler; modelin tahmin ettiği tüm pozitif sonuçlar arasındaki gerçek pozitif sonuçların oranını ölçen kesinlik (precision), tüm gerçek pozitif durumlar arasındaki gerçek pozitif sonuçların oranını değerlendiren hatırlama (recall) ve kesinlik ile hatırlamanın harmonik ortalamasını vererek modelin doğruluğunun tek bir ölçüsünü sunan F1 skoru gibi unsurları içerir.

Sınıflandırma Modellerinin Performans Ölçütleri

Algoritma performansının hesaplanmasında çeşitli ölçütler kullanılmaktadır. Dış yapılarının segmentasyon becerisini değerlendirmek amacıyla DSC (Dice Similarity Coefficient) ve doğruluk ölçütleri tercih edilmiştir. Algoritmanın etkinliği, nesnelerin birbirine ne kadar benzediğini gösteren DSC ile belirlenmiştir. DSC, iki segmentasyon arasındaki örtüşme oranını, toplam boyuta bölerek hesaplar. Bu ölçüt, yalnızca gerçek pozitif sayısını dikkate almakla kalmaz; aynı zamanda yöntemin bulduğu yanlış pozitifleri de hesaba katarak daha hassas bir değerlendirme yapar. DSC, hassasiyet parametresinin bir benzeri olarak değerlendirilebilir; ancak temel fvd, yalnızca algoritmanın tespit ettiği pozitifler yerine toplam pozitif sayısının kullanılmasıdır. Bu nedenle, DSC, algoritmanın gözden kaçırdığı pozitifleri de çıkarma doğrulaması yapma fırsatı sunar. Doğruluk ise sınıflandırma modellerinin

değerlendirilmesinde kullanılan bir başka ölçüttür ve modelin doğru tahminlerinin toplam tahminlere oranını ifade eder. Ek olarak, performansı daha iyi ölçmek amacıyla doğruluk da hesaplanmıştır. modelin tahmin ettiği tüm pozitif sonuçlar arasındaki gerçek pozitif sonuçların oranını ölçen kesinlik (precision), tüm gerçek pozitif durumlar arasındaki gerçek pozitif sonuçların oranını değerlendiren hatırlama (recall) ve kesinlik ile hatırlamanın harmonik ortalamasını vererek modelin doğruluğunun tek bir ölçüsünü sunan F1 skoru gibi unsurları içerir. Bu ölçütler, peri-implantiti tespit etme konusunda modelin performansını değerlendirmektedir. Bu süreçleri birleştirerek, çalışma, diş implantlarının segmentasyonu ve OPG'lerde peri-implantit tespiti için kapsamlı bir derin öğrenme tabanlı yaklaşım geliştirmeyi amaçlamış ve bu sayede klinik tanı ve tedavi planlamasını geliştirmeyi hedeflemiştir.

Dice Similarity Coefficient Hesaplanması

Dice Coefficient (DSC), iki küme arasındaki benzerliği ölçen bir istatistiksel ölçüttür ve özellikle görüntü segmentasyonu alanında sıklıkla kullanılır. DSC, iki segmentasyonun ne kadar örtüştüğünü değerlendirmek için kullanılır ve aşağıdaki formülle hesaplanır:

$$[DSC = \frac{2 \times |A \cap B|}{|A| + |B|}]$$

Burada:

- (A) ve (B), karşılaştırılan iki kümedir (örneğin, modelin segmentasyonu ve gerçeğe dayalı segmentasyon).
- $(|A \cap B|)$, iki kümenin kesişimindeki eleman sayısını belirtir.
- $(|A|)$ ve $(|B|)$, sırasıyla (A) ve (B) kümesindeki toplam eleman sayısını temsil eder.

DSC değeri 0 ile 1 arasında değişir. 1, iki görüntünün tam olarak örtüştüğünü ifade ederken, 0, görüntülerin birbirinden farklı olduğunu gösterir. DSC, genellikle segmentasyon performansını değerlendirmek için kullanılır çünkü gerçek pozitifleri ve yanlış pozitifleri dikkate alarak daha anlamlı bir karşılaştırma sağlar. DSC'nin en belirgin avantajlarından biri, fvdli boyutlarda olan görüntülerde de doğru sonuçlar elde edilmesini sağlamasıdır. Bu nedenle, DSC, bölümlendirme, görüntü

segmentasyonu, eşleme ve benzerlik ölçümü gibi çeşitli uygulamalarda yaygın bir şekilde kullanılmaktadır.

BÖLÜM IV


Bulgular ve Yorumlar

Test doğruluğu, DSC ve Intersection over Union (IoU), segmentasyon modelinin performansını değerlendirmek için kullanılan ölçütlerin bazılarıdır(Tablo 4). Elde edilen sonuçlar implantların segmentasyonundaki yüksek hassasiyeti göstermektedir:


- Test Doğruluğu: 0.999
- Dice Benzerlik Katsayısı (DSC): 0.986
- Intersection over Union (IoU): 0.974

Tablo 4: OPG'ler üzerindeki peri-implantitis tespitinde derin öğrenme modelinin segmentasyon ve sınıflandırma görevleri için performans metrikleri.

Görev	Metrik	Skor
Segmentasyon	Test doğruluğu	0.999
	Dice Similarity Coefficient (DSC)	0.986
	Intersection over Union (IoU)	0.974
	Doğru pozitifler (TP)	576
	Yanlış pozitifler (FP)	165
Sınıflandırma	Doğru negatifler (TN)	2890
	Yanlış negatifler(FN)	62
	Doğruluk	0.777
	Hassasiyet	0.903
	F1 Skor	0.835



Şekil 20. OPG üzerindeki implantların manuel segmentasyonu, implant sınırlarını belirleme sürecinin detaylı gösterilmesi. (b) OPG üzerindeki implantların model yardımı ile otomatik segmentasyonu.



Şekil 21 . a)OPG üzerindeki implantların manuel segmentasyonu. (b) Modelin OPG üzerindeki implantların otomatik segmentasyonu. Manuel ve otomatik segmentasyonlar arasında minimal fvdlılıklar gözlemlenmiştir; bu durum, protetik restorasyonlar ve implantlardan kaynaklanan üst üste binmeler nedeniyle meydana gelmiş ve DSC değerini düşürmüştür.

Sınıflandırma Performansı

Sınıflandırma modeli, peri-implantitis görülen implantlar ile sağlıklı implantları ayırt etmeyi amaçlamaktadır. Toplam 3693 implant arasından 638'i peri-implantitisli olarak tanımlanmış, 3055'i ise klinik muayenelerde sağlıklı olarak sınıflandırmıştır. Model, peri-implantitis olan 638 implantın 576'sını doğru bir şekilde tanımlamıştır. Ancak, 165 sağlıklı implantı da peri-implantitis olarak yanlış şekilde sınıflandırmıştır.

Sınıflandırma görevindeki performans metrikleri şunlardır:

Doğru Pozitif (TP): 576 (Şekil 22)


Yanlış Pozitif (FP): 165 (Şekil 23)

Doğru Negatif (TN): 2890 (Şekil 24)


Yanlış Negatif (FN): 62

Bu değerlerden, anahtar performans ölçütleri hesaplanmıştır:


- Kesinlik: $TP / (TP + FP) \approx 0.77$
 - Hatırlama (Duyarlılık): $TP / (TP + FN) \approx 0.90$
 - F1 Skoru: $2 \times (Kesinlik \times Hatırlama) / (Kesinlik + Hatırlama) \approx 0.83$



Şekil 22. Modelin, periimplantitis bulunan implantların sınıflandırmasına örnekler.



Şekil 23. A) Sınıf II maloklüzyonlu bir hastanın mandibulası, fokal alandan uzak bir şekilde konumlanmış olup, OPG de hem implantın hem de mandibular dişlerin yatay büyütülmesi gösterilmiştir. (B-C-D) Maksiller alveolar kemik üzerindeki hava yolu üst üste binmesi, hastanın dilinin maksiller dişlerin palatinal yüzeyine karşı konumlandırılmaması sonucunda oluşmuş ve implantların etrafında radyolüsent bir alan meydana getirmiştir. Model, bu implantlarda peri-implantitis için yanlış pozitif bir tahmin üretmiştir. (E) Bir çekim soketinde hemen implant yerleştirilmesi, peri-implantitise benzer bir kemik kaybı modeli oluşturmuş ve bu durum, peri-implantitis için yanlış pozitif tahminine yol açmıştır. (F) Alveolar kemik bölgesindeki zayıflama, kemiğin beklenenden daha radyolüsent görünmesine neden olmuş ve bu durum, peri-implantitis olarak yanlış yorumlanma olasılığını artırmıştır.



Şekil 24. Model, peri-implantitis olmayan kemik kaybı bulunmayan durumları tespitine örnekler.

Ayrıca modelin etkinliğinin çeneler arası dağılımına bakılacak olunursa, modelin maksillada daha çok FP (False Positive), sağlıklı olduğu halde periimplantitis tanısı almıştır. Gerçekte peri-implantitis olup modelin kaçırdığı FN (False Negative) olgulara ise mandibulada daha fazla rastlanmıştır. Tablo 5’de segmente edilmiş implantların çeneye göre performans dağılımı gösterilmektedir.

Tablo 5. Çenelere Göre Performans Dağılımı. TP (True Positive): Modelin gerçek peri-implantitisli vakaları doğru sınıflandırması, FP (False Positive): Sağlıklı olduğu hâlde modelin peri-implantitis diye sınıflandırdığı vakalar, TN (True Negative): Sağlıklı olup, modelin de sağlıklı dediği vakalar, FN (False Negative): Gerçekte peri-implantitisli olup, modelin kaçırdığı (sağlıklı dediği) vakalar

Çene	Toplam İmplant	Klinik Olarak Peri- Implantitisli	TP (True Positive)	FP (False Positive)	TN (True Negative)	FN (False Negative)
Mandibula	2105	390	354	70	1645	36
Maksilla	1588	248	222	95	1245	26
Toplam	3693	638	576	165	2890	62

En Çok Hata (False Positive) Görülen Durumlar

1.Maksilla Anterior ve Hava Yolu Süperpozisyonu

Dili, sert damağa doğru konumlandırmayan hastalarda, maksilla anterior bölgede hava yolu (airway) süperpozisyonu nedeniyle radyolüsent görüntü artışı oluşmuştur. Bu durum bazı sağlıklı implantların peri-implantitisli gibi görünmesine (FP) yol açmıştır.

2.Class II İskeletsel Kapanış

Kapanış sorunu olan hastalarda mandibulanın focal trough’tan uzaklaşması nedeniyle implant ve mandibular dişlerde horizontal büyütme görülmüştür. 12

implantta, bu radyografik distorsiyon modelin peri-implantitis varmış gibi (FP) sınıflandırma yapmasına sebep olmuştur.

3.Immediate Implant Uygulaması

Çekim yapılan sokete immediate implant yerleştirilen vakalarda, erken dönemdeki kemik kaybı veya iyileşme süreci, radyografide peri-implantitis benzeri bir görüntü oluşturabilmektedir. Çalışmamızda toplam 6 implant, yanlış pozitif (FP) olarak değerlendirilmiştir.

BÖLÜM V

Tartışma

Yapay zekâ, sağlık alanında hastalıkların teşhisinde önemli bir araç olarak giderek daha fazla kullanılmaktadır. Gelişmiş makine öğrenimi (MÖ) ve derin öğrenme (DÖ) teknikleri sayesinde yapay zeka, büyük miktarda tıbbi veriyi analiz ederek hastalıkların erken teşhisini, prognozunu ve kişiselleştirilmiş tedavi planlarını desteklemektedir. Özellikle radyoloji, patoloji ve dermatoloji gibi görüntüleme odaklı tıbbi alanlarda, yapay zeka sistemleri doktorların teşhis sürecini hızlandırarak hata oranlarını azaltabilmektedir (Esteva ve vd., 2017; Topol, 2019). Yapay zeka destekli teşhis sistemleri, radyolojik görüntülerde akciğer kanseri nodüllerini tespit edebilmekte ve dermatolojik lezyonların malign olup olmadığını değerlendirebilmektedir (Ardila ve vd., 2019). Yapay zekanın sağlık alanında hastalık teşhisi amacıyla kullanımına dair yapılan araştırmalar, bu teknolojinin hekimlere destek sağladığını ve klinik karar verme süreçlerini iyileştirdiğini göstermektedir. Ancak, etik, güvenilirlik ve veri gizliliği gibi konular hâlâ tartışmalı olup, geniş çaplı klinik entegrasyon için daha fazla çalışma gerekmektedir (He ve vd., 2019).

Yapay zekâ, özellikle derin öğrenme ve makine öğrenimi algoritmaları sayesinde tıbbi görüntüleme alanında büyük bir gelişim göstermiştir. Radyografilerin analiz edilmesi ve hastalıklarla ilişkili bulguların otomatik olarak tespit edilmesi, yapay zekanın en başarılı olduğu alanlardan biridir. Günümüzde yapay zeka, dış hekimliği, ortopedi, onkoloji, kardiyoloji ve pulmonoloji gibi fvdli tıp dallarında kullanılan radyografik görüntüleri analiz ederek teşhis sürecini desteklemektedir (McKinney ve vd., 2020). Yapay zeka tabanlı sistemler, radyografik görüntüleri analiz ederek normal dışı yapıları ayırt edebilir, lezyonları tespit edebilir ve hatta hastalıkların şiddetini belirleyebilir. Bunun için genellikle derin öğrenme tabanlı konvolüsyonel sinir ağları (CNN) kullanılır. Bu modeller, büyük miktarda etiketlenmiş radyografik görüntüyle eğitildikten sonra yeni görüntülerde hastalıkları yüksek doğrulukla tespit edebilir (Litjens ve vd., 2017). Dış hekimliğinde yapay zeka, panoramik ve periapikal radyografileri analiz etmek için yaygın olarak

kullanılmaktadır. Yapay zeka sistemleri, diş çürükleri, periodontal hastalıklar, kemik kaybı ve peri-implantitis gibi durumları tespit edebilir.

Ortopantomografi (OPG), alt ve üst çene yapısını tek bir görüntüde gösteren panoramik bir radyografi türüdür ve diş hekimliğinde yaygın olarak kullanılmaktadır. OPG'nin değerlendirilmesi, periodontal hastalıklar, gömülü dişler, çene tümörleri ve dental implantların takibi gibi birçok klinik uygulamada önemli bir rol oynar (Lee ve vd., 2020). Derin öğrenme ve makine öğrenme algoritmaları sayesinde OPG görüntüleri otomatik olarak analiz edilebilmekte, diş ve implantların tespitini yapabilmekte ve hastalık teşhislerini koyabilmektedir. Yapay zekâ, OPG görüntülerinde implantları doğal dişlerden ayırt etmektedir. Derin öğrenme tabanlı Convolutional Neural Network modeller ile implantlar yüksek doğrulukla tespit edebilmektedir (Litjens ve vd., 2017).

Çalışmamızda oluşturduğumuz yapay zeka modelinin OPG'ler üzerindeki çoklu görevlerdeki etkinliği, çeşitli sınırlamalarla birlikte incelenmiştir. Dentomaksillofasiyal radyoloji alanında yapay zeka uygulamaları için önerilen bazı önemli noktalar şunlardır: Hem iki boyutlu (2B) hem de üç boyutlu (3B) görüntüleme tekniklerinin entegre edilmesi, veri kümesinin büyüklüğünün artırılması (örneğin, 1000'den fazla görüntüyle çalışılması), fvdli kurumlara ait kamuya açık veri setlerinin kullanılması, yüksek işlem gücüne sahip bilgisayarların tercih edilmesi, denetimsiz veya yarı denetimli öğrenme yöntemlerine yönelmek ve retrospektif çalışmalardan ziyade prospektif yöntemlerin benimsenerek yüksek düzeyde bir standardizasyon sağlaması gerektiği vurgulanmıştır.

Verimli ve etkili bir yapay zeka destekli diş hekimliği uygulaması için geniş ve nitelikli veri setlerine gereksinim vardır. Ancak bu veriler çoğunlukla çeşitli kaynaklar aracılığıyla, özellikle fvdli klinik enstitülerin veri havuzlarında bulunur. Gizlilik kısıtlamaları, bu veri havuzları arasında doğrudan veri paylaşımını kısıtladığı için işbirliği olanakları sınırlı kalmaktadır. “Federated Learning” yani birleştirilmiş öğrenme yaklaşımı, veri paylaşımı olmadan yapay zeka modellerinin ortaklaşa eğitilmesine olanak tanıyan, ölçeklenebilir ve gizliliği koruyucu bir yöntemdir; bu sistemde bilgi, verilerden elde edilen deneyimler üzerinden değiş tokuş edilmektedir. Rischke ve ekibi, 2022 yılında diş hekimliği araştırmaları alanında yapay zeka

tabanlı uygulamalar açısından iş birliği fırsatlarını ve bu alandaki zorlukları inceleyerek “federated learning” kavramını tanıtmıştır. Dijital teknolojilerin kabulü, gelecekte diş hekimliğini dönüşümlü hale getirirken, hem personelin hem de hastaların bu yeni dijital ortamda güvenli bir şekilde ilerlemelerine imkan tanıyacaktır (Dickenson ve diğerleri, 2022).

Peri-implantitis radyografik tanı kriterleri olarak çeşitli araştırmacıların fvdli görüşleri olup, Daubert ve vd, remodelasyondan sonra kemik değişiminin 2mm den fazla olması durumunu radyografik olarak peri-implantitisin tanı kriterleri arasında değerlendirirken, Frisch ve vdadaşları, Konstantinidis ve vdadaşları, Rokn ve vdadaşları, Dalago ve vdadaşları radyografik olarak aynı görüşde olup; Turullenque ve vdadaşı, Papantonopoulos ve vdadaşı ise remodelasyondan sonra 3 mm ve üzeri kemik kaybını radyografik kriterler arasında saymıştır. Bizim çalışmamızda ise 3mm ve üzeri kemik kaybı radyografik olarak tanı kriteri olarak belirlenmiştir. (Renvert vd., 2018).

Jang ve vdadaşlarının yaptığı çalışma, periapikal radyografiler üzerinde derin öğrenme yöntemini kullanarak dental implantlar ve peri-implant dokularını tespit etmeyi amaçlamıştır. 300 periapikal radyografik görüntü, %80 eğitim ve %20 test olmak üzere %80:20 oranında bölünmüştür (yani verilerin %80'i modelin eğitimi için, %20'si ise modelin testi için kullanıldı). Bu görüntüler, hem sınıflandırma hem de konumlandırma işlevlerini aynı anda gerçekleştiren Faster R-CNN olarak bilinen bir nesne tespit modeli kullanılarak değerlendirilmiştir. Bu model, sınıflandırma performansını değerlendirmek için doğruluk, hassasiyet ve F1 skoru gibi metrikler kullanılarak değerlendirilmiştir. Ayrıca, konumlandırma performansını değerlendirmek amacıyla kesişim/union oranı (IoU) kullanılmış ve ortalama kesinlik (AP) hem sınıflandırma hem de konumlandırma performansını değerlendirmek için kullanılmıştır. Sınıflandırma performansı değerlendirildiğinde, doğruluk = 0.977, hassasiyet = 0.992 ve F1 skoru = 0.984 olarak elde edilmiştir. Konumlandırma göstergesi olarak ise ortalama IoU = 0.907 olarak hesaplanmıştır. Öte yandan, hem sınıflandırma hem de konumlandırma performansına ilişkin göstergeler dikkate alındığında, ortalama kesinlik, nesne tespit düzeyini $AP@0.5 = 0.996$ ve $AP@0.75 = 0.967$ olarak hesaplanmıştır. Çalışmamızda ise doğruluk oranı 0.99

olarak hesaplanarak bu modelden daha başarılı olduğu gösterilmiştir. (Jang vd., 2022)

Revilla-Leon ve vdadaşları tarafından yapılan sistematik bir derlemeye göre, literatürde dental implantların yapay zeka modelleri ile otomatik olarak tanınma oranı %93,8 ile %98 arasında değişmektedir. Benzer şekilde, modelimizin de 0.986 DSC değerleri ile yüksek başarı elde ettiği gözlemlenmiştir. Dental implantlar, hem yivli dış yapılar hem de metalik opasiteler sebebiyle, diğer anatomik yapılar veya restorasyonlar olarak hatalı bir şekilde segmentasyona uğratılmamıştır. Bu yapıların otomatik segmentasyonunun neredeyse kusursuz bir doğrulukla belirlenebildiği tespit edilmiştir. (Revilla vd.,2022)

Lee ve vdadaşları, Wu ve vdadaşları, Chen ve vdadaşları ve çalışmamızda gösterildiği gibi, peri-implantitis tespiti için yapay zeka tabanlı teşhis araçlarının karşılaştırmalı analizi, teşhis alanındaki mevcut metodolojilerin ilerlemeleri ve kısıtlamaları hakkında birkaç kritik görüş sağlamaktadır. Yapılan her çalışmada, peri-implantitisin belirlenmesiyle ilgili karmaşanın aşılması için derin öğrenme modelleri kullanılmış, fvdli görüntüleme yöntemlerine ve yapay zeka mimarilerine odaklanılmış ve doğruluk, netlik ve klinik uygulanabilirlik açısından çeşitli sonuçlar elde edilmiştir (Lee vd., 2024; Wu vd., 2024; Chen vd., 2023).

Wu ve vd., çeşitli yapay zeka modellerine ilişkin bir kapsamlı derleme gerçekleştirmiş ve çalışmaların çoğunda doğruluğun %70 ile %96,13 arasında değiştiği derin öğrenme modellerinin kullanıldığını vurgulamıştır. Çalışmada, model performansını artırmak için fvdli radyografik verilerin dahil edilmesinin gerekliliği üzerinde durulmuştur. Çalışmamız, Wu ve vd.'nın önerileriyle uyumlu olup, birden fazla cihazdan elde edilen geniş ve çeşitli bir OPG veri seti, modelimizin genellenebilirliğini artırmıştır. Ayrıca, segmentasyon doğruluğumuzun (%99,9) ve başarılı sınıflandırma metriklerimizin, Wu ve vd.'nın belirttiği doğruluk aralığının üst sınırında yer alması, yöntemimizin klinik uygulamalar için taşıdığı potansiyeli göstermektedir.

Ying ve vdadaşları, çalışmalarında yalnızca bir OPG cihazını kullanmışlardır. Ancak, yapay zeka modelleri genellikle her görüntüleme ünitesine özgü kalıpları öğrenme eğiliminde olduğu için bu durum, sonuçları etkileyen bir yanlılık

yaratabilir. Bu yanlılığı ortadan kaldırmak amacıyla, araştırmamız fvdli görüntüleme parametrelerine sahip üç ayrı OPG ünitesi kullanılarak gerçekleştirilmiştir. (Ying vd.,2022)

Vera ve vdadaşlarının yaptığı çalışmada Toplamda 2.920 radyografi kullanılmıştır ve bu görüntüler eğitim (yüzde 50) ve test (yüzde 50) aşamaları olmak üzere ayrılmıştır. Bu çalışma, peri-implant alanındaki marginal kemik yeniden şekillenmesini otomatik olarak tespit etmek için yapay zeka tekniklerinin kullanımını araştırmaktadır. Peri-implantitis ile ilişkili kemik kaybının erken tespiti, diş hekimliği uygulamaları açısından kritik öneme sahiptir. Araştırmada, intraoral (periapikal ve bitewing) radyograflarda, kemik rezorpsiyonunu belirlemek amacıyla iki ana YZ tekniği uygulanmıştır. İlk olarak, YOLOv3 derin öğrenme tabanlı nesne tespit yöntemi, implant ve protezleri tanımak için kullanılmıştır. İkinci aşamada ise, görüntü anlama işlemleriyle implant sınırlarının belirlenmesi ve kemik yoğunluğundaki değişikliklerin analizi gerçekleştirilmiştir. Çalışmada, görüntü setinin %50'si eğitim, %50'si ise test amacıyla kullanılmıştır. Geliştirilen derin öğrenme modelinin ve görüntü anlama (IU) tekniklerinin, peri-implant alanındaki marginal kemik yeniden şekillenmesini otomatik olarak tespit etmede etkili olduğu göstermiştir. mAP@0.5 metriği kullanılarak yapılan değerlendirmelerde, derin öğrenme modelinin başarısı %53.7 ile %89.8 arasında değişen skorlarla kabul edilebilir seviyede bulunmuştur. (Vera vd., 2023)

Mameno ve vdadaşlarının yaptığı retrospektif kohort çalışmasında, makine öğrenmesi yöntemlerini kullanarak peri-implantitis başlangıcını tahmin eden bir model geliştirmek ve risk faktörlerinin etkilerini açığa çıkartmak adına en az 4 yıldır işlev gören 1408 implant arasından, peri-implantitis gelişen 127 implant ve gelişmeyen 127 implant olmak üzere toplam 254 implantı değerlendirmiştir. Peri-implantitis gelişimi için risk faktörleri olarak bilinen demografik veriler ve parametreler, lojistik regresyon, destek vektör makineleri ve rastgele ormanlar (RF) olmak üzere üç model ile analiz edilmiştir. Sonuçlar, RF modelinin peri-implantitis başlangıcını tahmin etmede en yüksek performansı gösterdiğini ortaya koydu (AUC: 0.71, doğruluk: 0.70, kesinlik: 0.72, geri çağırma: 0.66 ve f1-skoru: 0.69). Çalışmanın sonuçları, karmaşık etkileşimlerle doğrusal olmayan ilişki verilerini

dikkate alan RF modeli sayesinde peri-implantitis başlangıcının vakaların %70'inde tahmin edilebildiğini göstermektedir. (Mameno vd., 2021)

Lee ve vdadaşları periapikal radyograflardan peri-implantitisi tespit etmek için YOLOv7 derin öğrenme modelini kullanmış, yüksek spesifiklik (%100) ve kesinlik (%100) elde etmiş, ancak daha düşük hassasiyet (%94,44) ve %97,10 F1 puanı elde etmiştir. Bu, modelin negatif vakaları doğru bir şekilde tanımlamada çok etkili olmasına rağmen, tüm pozitif vakaları yakalamada biraz daha düşük performans gösterdiğini göstermektedir. Segmentasyon ve ardından sınıflandırma için bir U-Net mimarisi kullanan çalışmamız, daha fvdli metrik değerleri elde etmiştir: %77,7'lik bir kesinlik, %90,3'lük bir hassasiyet ve %83,5'lik bir F1 puanı. Bu, yaklaşımımızın gerçek peri-implantitis vakalarını belirlemede periapikal radyografi üzerinde yapılan bu çalışmaya göre kesinlik ve hassasiyet skorları yönünden daha düşük olmasının nedeninin radyografi türündeki fvdllikten kaynaklandığı düşünülmektedir. Literatürde yapay zekanın OPG üzerinde periimplantitis teşhisi amacıyla kullanımını gösteren bir çalışma bulunmaması nedeniyle sonuçlarımız karşılaştırılamamıştır.

Li ve vd., yaptığı çalışmada diş çürükleri ve periapikal periodontitisin otomatik tespiti için yüksek kaliteli anotasyonlara sahip 4129 periapikal görüntü kullanılarak modifiye edilmiş bir derin öğrenme modeli geliştirmiştir. Modelin performansı, diş hekimlerinin sınıflandırma performansı ile karşılaştırılmıştır. Derin öğrenme modeli, diş çürüklerini 0.829 F1-skora ve periapikal periodontitisi 0.828 F1-skora sahip olacak şekilde otomatik olarak ayırt etmiştir. Modelin, uzmanların yapmış olduğu tespit performanslarıyla karşılaştırılması, tam otomatik yöntemin doğruluğunun genç diş hekimlerinden anlamlı derecede yüksek olduğunu göstermiştir. Derin öğrenme desteği ile uzmanlar, yalnızca uzmanların teşhis yaptığı senaryolara kıyasla daha yüksek teşhis doğruluğuna ulaşmıştır; diş çürükleri için F1-skoru ortalama 0.7844 ve periapikal periodontitis için 0.8208 olarak bulunmuştur(Li ve vd., 2022).

Bayrakdar ve vd.'larının yaptığı çalışma, derin evrişimli sinir ağı modeli temelinde oluşturulan bir yapay zeka algoritmasının, dental panoramik radyograflarda apikal lezyonların segmentasyonundaki başarısını değerlendirmeyi

amaçlamıştır. Çalışmada toplam 470 anonim panoramik radyografi, U-Net algoritması (CranioCatch, Eskişehir, Türkiye) tabanlı D-CNN yapay zeka modeli geliştirmek için kullanmıştır. Radyograflar, Eskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı Radyoloji Arşivi'nden temin edilmiştir. Apikal lezyonların segmentasyonu için PyTorch (sürüm 1.4.0) ile uygulanmış U-Net modeli kullanılmıştır. Test veri setinde, yapay zeka modeli 47 panoramik radyografide toplam 63 periapikal lezyonu segmentlemiştir. %70 IoU değerinde, periapikal lezyonların segmentasyonu için duyarlılık (sensitivity) 0.92, kesinlik (precision) 0.84 ve F1-skoru 0.88 olarak hesaplanmıştır. Yapay zekanın, panoramik radyograflara dayalı periapikal patolojilerin değerlendirilmesini kolaylaştırdığı gösterilmiştir (Bayrakdar ve vd., 2022).

Song ve vdadaşlarının yaptığı çalışmada derin CNN algoritması kullanılarak panoramik radyograflardan apikal lezyon segmentasyonu performansını değerlendirmiştir. Toplamda apikal lezyon içeren 1000 panoramik görüntü, eğitim (n=800, %80), doğrulama (n=100, %10) ve test (n=100, %10) veri kümelerine ayrılmıştır. Apikal lezyonları belirleme performansı, kesinlik (precision), duyarlılık (recall) ve F1-skoru hesaplanarak değerlendirilmiştir. Test grubunda bulunan 180 apikal lezyonun 147'si, %30'luk (IoU = 0.3) örtüşme eşiği ile panoramik radyograflardan segmentlenmiştir. %30'luk IoU eşiği ile önceden eğitilmiş CNN modeli, test grubundaki 180 apikal lezyondan 147'sini doğru şekilde segmentlemiş (doğru pozitif). 31 lezyon yanlış negatif, ayrıca 30 lezyon ise yanlış pozitif olarak bulunmuştur. %40'lık IoU eşiğinde, önceden eğitilmiş CNN modeli 143 lezyonu doğru şekilde segmentlenmiştir (doğru pozitif). 34 lezyon da yanlış negatif, 31 lezyon ise yanlış pozitif olarak bulunmuştur. %50'lik IoU eşiğinde, önceden eğitilmiş CNN modeli 125 lezyonu doğru şekilde segmentlemiştir (doğru pozitif). 44 lezyon yanlış negatif, 43 lezyon yanlış pozitif olarak bulunmuştur (Song ve vd., 2022).

Yu ve vdadaşlarının yaptığı çalışma derin öğrenmeye dayalı mevcut yöntemlerin açıklanabilirlik açısından yetersiz olması ve büyük ölçekli lezyon örneklerini toplamanın ve etiketlemenin zaman alıcı olması nedeniyle, çene kistleri ve tümörlerini tespit etmek için açıklanabilir ve güvenilir bir yöntem geliştirmeyi amaçlamıştır. Bu amaç doğrultusunda, 872 lezyon örneği ve 10.000 sağlıklı örnek

içeren geniş çaplı panoramik radyograflardan yararlanılarak, çene kistleri ve tümörlerini sınıflandırmak için iki dallı (two-branch) bir ağ modeli oluşturmuştur. İki dallı ağ modeli, öncelikle sağlıklı bireylere ait büyük ölçekli panoramik radyograflar üzerinde ön eğitimden (pretraining) geçirilmiştir, ardından örnek kategorilerini sınıflandırmak ve lezyon bölgesini segmentlemek için eğitilmiştir. Test aşamasında toplamda 200 sağlıklı ve 87 lezyon örneği değerlendirilmiştir. Sınıflandırma performans ölçütleri şunlardır: Ortalama doğruluk: %88,72, Kesinlik (precision): %65,81, Duyarlılık (sensitivity): %66,56, Özgüllük (specificity): %92,66, F1 skoru: %66,14 elde etmiştir. Önerilen yöntem, çene kistleri ve tümörlerinin teşhisinde umut verici bir performans sergilemiştir. Sınıflandırılan kategoriler ve segmentlenen lezyon bölgeleri, daha ileri teşhis için bir tanısal temel sağlamakta olup, çene tümörleri ve kistlerinin teşhisi için güvenilir bir araç sunmaktadır (Yu ve vd., 2022).

Ünsal ve vd.alarının yaptıkları çalışmada Diş Hekimliği Fakültesi 5. sınıf öğrencileri, histopatolojik incelemeleri Dentigeröz Kist olarak belirlenen 36 ortopantomografi tespit etmiş ve etkilenen dişler ile kistik boşluklar, CranioCatch'in yapay zeka destekli klinik karar destek sistemi yazılımı kullanılarak segmentlenmiştir. Veri setindeki görüntülerin boyutları birbirinden fvdli olduğu için tüm görüntüler 1024x514 piksel boyutuna yeniden ölçeklendirmiş ve veri artırma (data augmentation) işlemi uygulanarak dikey çevirme (vertical flip), yatay çevirme (horizontal flip) ve her iki çevirme yöntemi birlikte (both flips) eğitim-doğrulama sürecinde kullanmıştır. Elde edilen veri seti ile 200 epoch boyunca, 0.001 öğrenme oranı (learning rate) ile PyTorch U-Net modeli eğitilmiştir. Eğitim kümesi 112 görüntü, Doğrulama kümesi 16 görüntüden oluşmuştur. Segmentasyon işlemi tamamlandıktan sonra oluşturulan model, yeni Dentigeröz Kist ortopantomografileri üzerinde test edilmiş ve modelin başarısı değerlendirilmiştir. F1 skoru 0.67, kesinlik 0.5 ve duyarlılık 1 sonuçları elde etmiştir. Dentigeröz kist görüntülerinin analizi için Konvolüsyonel Sinir Ağı yaklaşımı kullanılarak, küçük bir veri tabanında bile kesinlik (precision) değeri 0.5 olarak bulunmuştur (Ünsal ve vd., 2022).

Vera ve vd., Chen ve vd., Cha ve vd. yapmış olduğu çalışmada peri-implant kemik kaybının belirlenmesinde iki veya daha fazla yapay zeka modeli kullanmıştır. Çalışmamızda benzer şekilde, ilk model implantı ve implant destekli protezi tespit etmek amacıyla kullanılırken, ikinci model ise implant çevresindeki belirli noktaları

tanımlayarak kemik kaybını hesaplamaktadır. Öte yandan, Lee ve vd. Yapmış olduğu çalışmada kemik kaybı tespiti için yalnızca tek bir yapay zeka modeli kullanılmıştır. Vera ve vd. (2023), implant lokalizasyonu için YOLOv3 modelini kullanmıştır. Bu model, implant ve protetik kısmı belirlemek amacıyla kullanılmıştır. Ardından, görüntü analizi tabanlı (IU) yapay zeka modeli kullanılarak implant kenarlarındaki çizgiler, kemikteki yoğunluk değişimleri ve abutment ile kron arasındaki bağlantı noktası tespit edilmiştir. Bu model, implantın toplam uzunluğunun kemik kaybına oranını yüzde olarak hesaplamaktadır. YOLOv3 modeli 0.537 ile 0.898 arasında doğruluk göstermiş, IU modeli ise 2.63 piksel hata payı skoru elde etmiştir. Chen ve vd. (2023), implant lokalizasyonu için YOLOv3 modelini, kemik kaybının tespiti için ise CNN AlexNet modelini kullanmıştır. YOLOv3 modeli %89.31 doğruluk oranı elde ederken, AlexNet modeli %90.45 doğruluk göstermiştir. Özellikle implantın ilk yiv seviyesine kadar olan kemik kaybının tespiti, implant stabilitesi açısından kritik bir gösterge olarak değerlendirmiştir.

Cha ve vdadaşları, implant çevresindeki kemiklerin sınırlarının belirsiz olması, bukkal ve lingual kemik seviyelerinin fvdli olması nedeniyle, periapikal radyografiler kullanılarak marjinal kemik seviyesi, implantın tepe noktası ve apeksini tespit etmek için derin evrişimli sinir ağı kullanmıştır. Kemik kaybı yüzdesini hesaplamak ve kemik rezorpsiyonunun şiddetini sınıflandırmak için Microsoft Common Objects in Context veri kümesine dayalı transfer öğrenme kullanılarak, modifiye edilmiş bölge tabanlı CNN (R-CNN) modeli eğitilmiştir. Toplam 708 periapikal radyografik görüntü, eğitim ($n = 508$), doğrulama ($n = 100$) ve test ($n = 100$) olarak ayrılmıştır. Eğitim veri seti, veri artırma (data augmentation) teknikleriyle rastgele zenginleştirilmiştir. Değerlendirme için, ortalama hassasiyet (average precision), ortalama duyarlılık (average recall) ve ortalama nesne anahtar noktası benzerliği (mean object keypoint similarity - OKS) hesaplanmıştır. Model ve rastgele seçilmiş bir diş hekiminin ortalama OKS değerleri karşılaştırılmıştır. Tespit edilen anahtar noktalar kullanılarak radyografik kemik kaybı ölçülmüş ve sınıflandırılmıştır. İmplantların çevresindeki sınırları tespit etme konusunda modifiye edilmiş R-CNN modeli ile diş hekimi arasında istatistiksel olarak anlamlı bir fvd bulunmamıştır. Bu modelin, peri-implantitis şiddetini değerlendirmek için radyografik peri-implant kemik kaybı oranını ölçmede kullanımı gösterilmiştir.

Kemik kaybı miktarını ölçmek için, sağlıklı kemik seviyesi için bir eşik olarak kabul edilebilecek bir referans noktası bulunmalıdır. 7. ve 8. Avrupa Periodontoloji Çalıştayı'na göre, fizyolojik yeniden şekillenme tamamlandıktan sonra, yani genellikle protez yerleştirilme zamanında (eğer hemen yükleme yapılmamışsa), başlangıç radyografisinin kullanılması önerilmektedir. Bu sayede krestal kemik seviyesindeki değişiklikler değerlendirilebilir. Ancak, birçok klinik durumda başlangıç radyografisi mevcut değildir. Bu gibi durumlar önceki çalışmalarda tartışılmıştır. 8. Avrupa Periodontoloji Çalıştayı, önceki radyografi bulunmadığında, beklenen marjinal kemik seviyesinden 2 mm'lik dikey mesafenin bir eşik olarak kullanılmasını önermiştir. Buna ek olarak, 2017 Dünya Periodontal ve Peri-İmplant Hastalıkları ve Durumları Sınıflandırma Çalıştayı'nda, önceki radyografi bulunmadığında, implantın kemik içindeki en koronal kısmından 3 mm apikale olan mesafenin eşik olarak belirlenmesi gerektiği belirtilmiştir. Veri seti, fvdli şekillere ve implant-abutment bağlantılarına sahip çeşitli implantları içermektedir. Eğer implant kemik seviyesi implantıysa ve platform switching kullanılmışsa, implantın en koronal kısmı açıkça gözlemlenir. Ancak doku seviyesi implantları gibi bazı implant türlerinde, periapikal radyografilerde pürüzlü yüzeyin en koronal noktasını belirlemek zordur. Veri setindeki tüm implant türlerini ve klinik uygulamalarda yaygın olarak kullanılan implantları kapsayabilmek için, implantın en koronal uç noktası referans konum olarak kabul edilmiştir. Başka bir deyişle, eğer fizyolojik yeniden şekillenme sonrası yıllık 0.2 mm'den fazla kemik rezorpsiyonu olmamışsa, en koronal nokta sağlıklı kemik seviyesi olduğu varsayılmıştır. Periapikal radyografilerde pürüzlü yüzeyin bitiş noktasını veya cilalı kısmın apikal ucunu belirlemek, hekimler için bile zordur. Bu sorunun üstesinden gelmek için daha fazla araştırmaya ihtiyaç olduğunu çalışmalarında belirtmişlerdir. Cha ve vd., Residual Learning Neural Network (ResNet) modelini üst ve alt çeneyi belirlemek için, Mask R-CNN modelini ise kemik kaybı ve implant lokalizasyonu için kullanmıştır. Maksiller implant tespiti için ortalama kesinlik ve geri çağırma (recall) değerleri sırasıyla 0.627 ve 0.684 olarak, mandibular implant tespiti için ise 0.657 ve 0.728 olarak rapor edilmiştir. Peri-implant kemik kaybı teşhisinde nesne anahtar noktası benzerliği (OKS) değerleri, CNN için maksiller ve mandibular vdt'a sırasıyla 0.8748 ve 0.9029 olarak belirlenmiş, toplam veri seti için ise 0.8885 olarak hesaplanmıştır.

Diş hekimlerinin OKS değeri ise 0.9012 olup, CNN ile istatistiksel olarak anlamlı bir fvd bulunmamıştır. (Cha ve vd., 2021)

Lee ve vd., implant lokalizasyonu ve peri-implant kemik kaybının ölçümü için tek bir YZ modeli olan YOLOv7 kullanmıştır. Model, peri-implant kemik kaybını tespit etmede %94.74 doğruluk oranına ulaşmıştır (Lee vd., 2024).

Liu ve vd. (2023), implant lokalizasyonu ve kemik kaybı tespiti için region-based convolutional neural network (Inception ResNet v2) modelini kullanmıştır. İki çalışma, yapay zeka modellerinin peri-implantitis teşhisindeki doğruluğunu diş hekimleriyle karşılaştırmıştır. Liu ve vd., R-CNN modelinin teşhis doğruluğunu bir uzman diş hekimi ve bir uzman diş hekimi ile kıyaslamıştır. Sonuç olarak, yapay zeka modeli şu istatistikleri elde etmiştir: Duyarlılık (Sensitivite): %67, Özgüllük (Spesifite): %87, Pozitif Öngörü Değeri (PPV): %81, Hatalı Tanı Oranı: %13 iken diş hekimlerinin değerleri ise şu şekilde rapor edilmiştir: Duyarlılık: %93 ve %62, Özgüllük: %64 ve %77, PPV: %69 ve %70, Hatalı Tanı Oranı: %36 ve %23 olarak saptanmıştır. Cha ve vd., CNN modelinin OKS değerini 0.8885 olarak belirlerken, diş hekimleri için bu değeri 0.9012 olarak hesaplamıştır. Sonuçlar, yapay zeka modeli ile diş hekimleri arasında anlamlı bir fvd olmadığını göstermektedir.

Mameno ve vd., lojistik regresyon (LR), destek vektör makineleri (SVM) ve rastgele ormanlar (RF) gibi üç fvdli CNN modelinin peri-implant kemik kaybını tahmin etme performansını karşılaştırmıştır. RF modeli, %70 doğruluk ve %72 hassasiyet ile en yüksek performansı göstermiştir (Mameno ve vd., 2021).

Zhang ve vd., dört fvdli CNN modelini (SVM, yapay sinir ağı (ANN), LR ve RF) kullanarak peri-implant kemik kaybının teşhisini karşılaştırmıştır. SVM modeli, %91.67 duyarlılık ve %100 özgüllük ile en iyi sonucu vermiştir (Zhang vd., 2020).

Yapay zekâ modellerinin eğitimi için Chan ve vd., Liu ve vd., Lee ve vd., Cha ve vd., Mameno ve vd. daşları periapikal radyografi kullanmış olup, Vera ve vd., hem periapikal hem de bitewing radyografileri kullanmış olup, Zhang ve vd. CBCT radyografilerini yapay zeka modellerine tanıtmışlardır.

Çalışmamızda gösterildiği gibi, derin öğrenme algoritmalarının dental implantları segmente etme ve OPG'ler üzerinden peri-implantitis tespitindeki yüksek

etkinliđi, klinik tanı ve tedavi planlamasını geliřtirmede yapay zeka odaklı araçların potansiyelini vurgulamaktadır. Segmentasyon modelinin mükemmele yakın dođruluđu ve yüksek DSC deđerleri, daha ileri teřhis süreçleri için implantları tanımlama konusundaki hassasiyeti vurgulamaktadır. Önerilen cihaz, NVIDIA RTX serisi gibi derin öğrenme modellerini çalıştırabilen bir GPU'ya sahip standart bir cihaz gerektirmektedir. Başlıca dental görüntüleme yazılımlarıyla uyumlu olan uzantılar aracılığıyla mevcut klinik iş akışlarına entegrasyon sağlanabilir, ancak uygulayıcılar için eğitim ve kalibrasyon gerekli olacaktır.

Derin öğrenme modelimizin genellenebilirliđi, eğitim ve dođrulama için kullanılan veri setinin çeřitliliđine bađlıdır. Veri seti, fvdı yaş grupları ve cinsiyet dağılımını içeren bir dizi hasta demografisini temsil eden 7696 adet OPG'yi içermektedir. Ayrıca, fvdı implant sistemleri, malzemeleri ve tasarımları temsil edilmiřtir, daha az kullanımda olan implant türleri ise yeterince temsil edilmemiřtir. Veri setindeki klinik koşullar, deđiřen peri-implantitis seviyeleri ve kemik yoğunluklarını kapsayacak řekilde çeřitlilik göstermektedir. Bu çeřitlilik modelin uygulanabilirliđini artırırken, daha çeřitli implant türleri ve hasta koşullarını içerecek řekilde veri setinin genişletilmesi, fvdı popölasyonlar ve klinik ortamlarda genellenebilirliđini artıracaktır. Gelecek çalışmalar, modelin performansını daha fazla dođrulamak ve geliřtirmek için çeřitli cođrafi bölgelerden ve klinik ortamlardan ek veriler içermeye odaklanmalıdır.

Çalışmamız, yapay zekanın peri-implant hastalıklarının teřhis ve yönetiminde oynayabileceđi önemli rolü vurgulamaktadır. Lee ve vdadařları ile Chen ve vdadařları, derin öğrenme modellerinin belirli görüntüleme bağlamlarındaki yeteneklerini gösterirken; çalışmamızın OPG'leri kullanarak kapsayıcı yaklařımı ve yüksek segmentasyon dođruluđuna odaklanması, bu araçların klinik uygulamaya entegrasyonu için bir yol sunmaktadır. Modelimizin yüksek hassasiyet oranı, klinik uygulamada deđerli olup, peri-implantitis vakalarının göz ardı edilme olasılıđını azaltarak zamanında müdahaleler yapılmasına olanak tanımaktadır. Ancak, kesinlik (precision) ve hatırlama (recall) dengesini sağlamak, gelecekteki arařtırmalar için önemli bir konu olmaya devam etmektedir. Wu ve vd.'ün de vurguladıđı gibi, ek radyografik ve klinik verilerle veri setlerinin genişletilmesi, bizim modelimiz de dahil olmak üzere yapay zeka modellerinin dođruluđunu artırabilir. Toplu öğrenme

(ensemble learning) tekniklerinin veya ek görüntü ön işleme adımlarının entegrasyonu, yanlış pozitifleri azaltarak modelin özgüllüğünü artırabilir ve gereksiz klinik müdahalelerin riskini minimize edebilir. Ayrıca, CBCT görüntüleme verilerinin entegrasyonunun araştırılması, implant çevresindeki kemik seviyelerindeki küçük değişiklikleri tespit etme yeteneğini artırarak modele daha bütünsel bir bakış açısı kazandırabilir.

Çalışmamızda tespit edilen önemli bir sorun, sağlıklı implantların, peri-implantitis olduğu şeklinde, yanlış sınıflandırılmasıyla sonuçlanan, yanlış pozitiflerin (165) meydana gelmesiydi. Bu durum, Chen ve vdadaşlarının bulgularıyla da örtüşmektedir; burada, görüntü distorsiyonları ve üst üste binen anatomik özellikler, modelin performansını etkileyerek yanlış sınıflamalara yol açmıştır. Sınıflandırma modeli, peri-implantitis olan implantları tespit etmedeki etkinliğini gösteren yüksek bir hatırlama değeri sergilemiştir, ancak yanlış pozitifleri azaltmak için kesinlikte iyileştirme yapılması gerekmektedir. Yüksek yanlış pozitif sayısı (165), gereksiz klinik müdahalelere yol açabilir. Olası bir çözüm olarak modelin başarısını artırmak için ek görüntüleme yöntemleri veya yapay zeka tabanlı toplu öğrenme yöntemleri kullanılmalıdır. Her iki çalışmada da OPG'lerde süperpozisyon zorlukları vurgulanmış olup, 2D görüntüleme yöntemlerinin doğru teşhis için gerekli olan karmaşık detayları yakalamadaki sınırlamaları ortaya konmuştur. Gelecekteki çalışmalar, önceki çalışmaların da önerdiği gibi, üst üste binen yapıların etkilerini azaltmak ve teşhis doğruluğunu artırmak amacıyla eğitim için CBCT gibi 3D görüntüleme yöntemlerinin kullanılmasına odaklanabilir.

Üst çenedeki hava yollarının süperpozisyonu, diş hekimliğinde panoramik radyografların önemli bir sınırlamasıdır. Bu süperpozisyon, kritik bölgelerin gizlenmesini ve implant alanının doğru bir şekilde değerlendirilmesini zorlaştırabilir. Hava yollarının maksiller yapılarla çakışması, daha az belirgin bir görüntüye yol açarak peri-implantitis gibi peri-implant durumlarının tanısını engelleyebilir. Osteoporozlu hastalarda ise azalmış kemik yoğunluğu başka bir sınırlamaya neden olmaktadır. Panoramik radyograflar, bu hastalarda düşük radyografik kontrast nedeniyle kemik kalitesindeki küçük değişiklikleri yeterince yakalayamayabilir. Bu sınırlama, zamanında müdahale için kritik olan peri-implantitisin erken belirtilerini tanımlamada zorluklara yol açabilir. Azalmış kemik yoğunluğu ayrıca, kemik

implant arayüzünün daha az belirgin görüntülenmesine neden olabilir ve bu da tanı çabalarını daha karmaşık hale getirebilir (Song vd., 2021).

Hareket artefaktları, panoramik radyografide yaygın bir başka sorundur. Görüntüleme süreci sırasında hastanın en küçük hareketi bile tanısallık detayları gizleyebilir ve görüntü kalitesini düşürebilir. Bu artefaktlar, peri-implantitisin varlığını maskeleyerek durumu yanlış teşhis etmeye veya ciddiyetinin hafife alınmasına yol açabilir. Panoramik radyografide kullanılan görüntüleme parametreleri, radyopak ve radyolüsent alanlar arasında ayrım yapmada genellikle zorluklar oluşturur. Görüntü ayarları optimize edilmediğinde, özellikle radyolüsent bölgelerde önemli bir detay kaybı yaşanabilir. Bu yetersizlik, peri-implantitisin doğru tespitini engeller, çünkü küçük radyografik değişiklikler etkili bir şekilde yakalanamayabilir. Ayrıca, pozlama ayarlarındaki değişiklikler ve hasta pozisyonlaması, tutarsız görüntü kalitesine katkıda bulunabilir. Bu sınırlamaların yanı sıra, panoramik radyograflar, CBCT gibi diğer görüntüleme yöntemlerine kıyasla daha düşük bir mekansal çözünürlüğe sahiptir. Azalmış çözünürlük, peri-implantitisin teşhisi için gerekli detayları ayırt etme yeteneğini etkileyebilir. Ayrıca, panoramik radyografilerin iki boyutlu doğası, üç boyutlu yapıların kapsamlı bir değerlendirmesini kısıtlar; bu, doğru tanı ve tedavi planlaması için sıklıkla gereklidir (Song vd., 2021).

Ümit verici sonuçlara rağmen, tüm çalışmalarda birkaç zorluk devam etmektedir. Lee ve vdadaşları, modelin klinik uygulanabilirliğini artırmak için daha çeşitli implant sistemlerine ihtiyaç duyulduğunu belirtmişlerdir; bu sınırlama çalışmamızda da mevcuttur. Verisetimiz 7696 OPG ve çeşitli implant sistemlerini içermesine rağmen, dışlama kriterleri (örneğin, artefaktlar, protetik restorasyonlar) daha karmaşık klinik senaryolarda uygulama alanını sınırlayabilmektedir. Bu sınırlamanın üstesinden gelmek, bu değişkenleri içeren artırılmış verilerle, modelin daha fazla eğitilmesini gerektirebilir, böylelikle modelin yaygın kullanımını artırabilir.

Teşhis süreçlerine yapay zekanın dahil edilmesi, etik konulara dikkatli bir yaklaşımı gerektirmektedir. Otomasyon yanlılığı, yani klinisyenlerin yapay zeka tarafından üretilen tahminlere aşırı güvenme eğilimi, önemli bir risk oluşturmaktadır.

Modelimiz klinik doğruluğu artırmayı hedeflese de klinisyen uzmanlığını tamamlamak için tasarlanmıştır; klinisyenlerin yerine geçmek amacı taşımamaktadır. Bu nedenle, yapay zeka çıktılarının eleştirel bir şekilde değerlendirilmesini teşvik etmek amacıyla uygun eğitim programlarının oluşturulması gereklidir. Ayrıca, özellikle hassas tıbbi görüntülerle çalışırken, hasta verilerinin gizliliği çok önemlidir. Çalışmada kullanılan veri seti GDPR ve kurumsal etik yönergelerine uygun olarak anonimleştirilmiş olsa da, gelecekteki uygulamalarda hasta mahremiyetini korumak için güçlü veri güvenliği uygulamalarının sürdürülmesi şarttır. Bu tür araçların daha geniş çapta kullanıma sunulabilmesi, modelin fvdli hasta gruplarına genellenebilirliğini sağlamak ve yapay zeka tahminlerindeki yanlılığı en aza indirmek için de önemlidir. Çalışmamızda, tüm DICOM görüntüleri analiz öncesinde anonimleştirilmiş ve Near East University Etik Kurulu tarafından belirlenen etik yönergelere, uluslararası veri koruma standartları olan GDPR ile uyumlu bir şekilde yürütülmüştür. Gelecekte yapay zeka araçlarının uygulanması ve klinik uzmanlar ile hastalar arasında güven ve kabulü artırmak için bu etik boyutlar dikkate alınmalıdır.

BÖLÜM VI

Sonuç ve Öneriler

Bu çalışma, OPG'lerde dental implantların segmentasyonu ve peri-implantitis tespiti için derin öğrenme modellerinin yüksek doğruluk ve güvenilirlik sağladığını vurgulamaktadır. Elde edilen sonuçlar, yapay zeka tabanlı yaklaşımların klinikte erken tanıyı destekleme ve peri-implant hastalıkların yönetimini iyileştirme potansiyeline sahip olduğunu göstermektedir. Ancak, modelin genel performansı umut verici olsa da, yanlış pozitif sonuçların gereksiz müdahaleleri önlemek için daha fazla iyileştirme yapılması gerektiğini ortaya koymaktadır. İleride yapılacak araştırmalar, modelin kesinliğini ve özgüllüğünü yükseltmek için ek verilerin entegrasyonuna odaklanmalıdır. Ayrıca, bu araçların günlük diş hekimliği uygulamalarında daha faydalı ve erişilebilir hale gelmesi için, klinik iş akışlarına sorunsuz bir entegrasyon stratejisi geliştirilmesi önemlidir. Gelecek çalışmalarda, modelin hesaplama verimliliğinin artırılmasına ve etik entegrasyonun sağlanmasına, özellikle gizlilik, klinisyen gözetimi ve otomasyon yanlılığının en aza indirilmesine odaklanmalıdır.

Kaynakça

- Adell, R. (1985). Tissue integrated prostheses in clinical dentistry. *Int Dent J*, 35(4), 259-265. <https://www.ncbi.nlm.nih.gov/pubmed/3912327>
- Agrawal, P., & Nikhade, P. (2022). Artificial Intelligence in Dentistry: Past, Present, and Future. *Cureus*, 14(7), e27405. <https://doi.org/10.7759/cureus.27405>
- Ainamo, J., & Talari, A. (1976). The increase with age of the width of attached gingiva. *Journal of periodontal research*, 11(4), 182–188. <https://doi.org/10.1111/j.1600-0765.1976.tb00069.x>
- Albawi, S., Mohammed, T.A. ve Al-Zawi, S. (2017). Understanding of a convolutional neural network. *ICET2017*, Antalya, Türkiye. doi: [10.1109/ICEngTechnol.2017.8308186](https://doi.org/10.1109/ICEngTechnol.2017.8308186)
- Albrektsson T IF. (1994). Consensus report of session IV. Quintessence, London.
- Albrektsson T. Consensus report of session IV. Paper presented at: Proceeding of the 1st European Workshop on Periodontology, 1985.
- Albrektsson, T., Zarb, G., Worthington, P., & Eriksson, A. R. (1986). The long-term efficacy of currently used dental implants: a review and proposed criteria of success. *Int J Oral Maxillofac Implants*, 1(1), 11-25. <https://www.ncbi.nlm.nih.gov/pubmed/3527955>
- Ali, S.H., Ayad, H. Ve 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/ijbme.v3i3.694>
- Angelucci, E., Brittenham, G. M., McLaren, C. E., Ripalti, M., Baronciani, D., Giardini, C., Galimberti, M., Polchi, P., & Lucarelli, G. (2000). Hepatic iron concentration and total body iron stores in thalassemia major. *N Engl J Med*, 343(5), 327-331. <https://doi.org/10.1056/NEJM200008033430503>
- Ardila, D., Kiraly, A. P., Bharadwaj, S., Choi, B., Reicher, J. J., Peng, L., ... & Corrado, G. C. (2019). End-to-end lung cancer screening with three-dimensional deep learning on low-dose chest computed tomography. *Nature Medicine*, 25(6), 954-961. <https://doi.org/10.1038/s41591-019-0447-x>
- Atieh, M. A., Alsabeeha, N. H., Faggion, C. M., Jr, & Duncan, W. J. (2013). The frequency of peri-implant diseases: a systematic review and meta-analysis. *Journal of periodontology*, 84(11), 1586–1598. <https://doi.org/10.1902/jop.2012.120592>
- Avrupa Komisyonu (2021). Proposal for regulation of the European Parliament and of The Council Laying Dawn harmonised rules on artificial intelligence (Artificial Intelligence Act) and amending certain union legislative acts.
- Ayodele, T. (2010). Types of machine learning algorithms, *New Advances in Machine Learning*. <https://www.researchgate.net/publication/221907660>. <https://doi.org/10.5772/9385>

- Babu, A., Onesimu, A. ve Sagayam, M. (2021). Artificial intelligence in dentistry: concepts, applications and research challenges, *E3S Web of Conferences* 297, https://www.e3sconferences.org/articles/e3sconf/pdf/2021/73/e3sconf_iccsre21_01074.pdf. <https://doi.org/10.1051/e3sconf/202129701074>
- Başaran, E. (2020). Timpanik membran görüntü analizi ve yapay zekâ kullanılarak sanal otitis media tanı sisteminin geliştirilmesi. Karabük Üniversitesi. Doktora Tezi.
- 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>
- Belibasakis G. N. (2014). Microbiological and immuno-pathological aspects of peri-implant diseases. *Archives of oral biology*, 59(1), 66–72. <https://doi.org/10.1016/j.archoralbio.2013.09.013> Berglundh T, Lindhe J, Ericsson I, Marinello CP, Liljenberg B, Thomsen P. The soft tissue barrier at implants and teeth. *Clin Oral Implants Res*. 1991;2(2):81-90.
- Berglundh, T., Lindhe, J., Jonsson, K., & Ericsson, I. (1994). The topography of the vascular systems in the periodontal and peri-implant tissues in the dog. *Journal of clinical periodontology*, 21(3), 189–193. <https://doi.org/10.1111/j.1600-051x.1994.tb00302.x>
- Bouri, A., Jr, Bissada, N., Al-Zahrani, M. S., Faddoul, F., & Nouneh, I. (2008). Width of keratinized gingiva and the health status of the supporting tissues around dental implants. *The International journal of oral & maxillofacial implants*, 23(2), 323–326.
- Brånemvd, P. I., Breine, U., Adell, R., Hansson, B. O., Lindström, J., & Ohlsson, Å. (1969). Intra-osseous anchorage of dental prostheses: I. Experimental studies. *Scandinavian journal of plastic and reconstructive surgery*, 3(2), 81-100.
- Buduma, N. (2017). *Fundamentals of deep learning*. O'reilly: ABD Buscema, M. (1998). Back Propagation Neural Networks. *Substance Use & Misuse*, 33(2):233–270. <https://doi.org/10.3109/10826089809115863>
- Buser, D., Sennerby, L., & De Bruyn, H. (2017). Modern implant dentistry based on osseointegration: 50 years of progress, current trends and open questions. *Periodontol 2000*, 73(1), 7-21. <https://doi.org/10.1111/prd.12185>
- Bush, J. (2018). How AI is taking the scut work out of health care. *Harvard Business Review*, 5.
- Carranza FA, Takei HH, Klokkevold PR, Newman MG. Classification of Diseases and Conditions affecting the Periodontium (2012). Carranza's Clinical Periodontology, 11th Edition. Missouri: Elsevier Saunders Inc:43-44.
- Carter, L., Farman, A. G., Geist, J., Scarfe, W. C., Angelopoulos, C., Nair, M. K., ... & Shrout, M. (2008). American Academy of Oral and Maxillofacial Radiology executive opinion

statement on performing and interpreting diagnostic cone beam computed tomography.

- Cha, J. Y., Yoon, H. I., Yeo, I. S., Huh, K. H., & Han, J. S. (2021). Peri-Implant Bone Loss Measurement Using a Region-Based Convolutional Neural Network on Dental Periapical Radiographs. *Journal of clinical medicine*, 10(5), 1009. <https://doi.org/10.3390/jcm10051009>
- Chang, M., Wennström, J. L., Odman, P., & Andersson, B. (1999). Implant supported single-tooth replacements compared to contralateral natural teeth. Crown and soft tissue dimensions. *Clinical oral implants research*, 10(3), 185–194. <https://doi.org/10.1034/j.1600-0501.1999.100301.x>
- Chen, Y. C., Chen, M. Y., Chen, T. Y., Chan, M. L., Huang, Y. Y., Liu, Y. L., Lee, P. T., Lin, G. J., Li, T. F., Chen, C. A., Chen, S. L., Li, K. C., & Abu, P. A. R. (2023). Improving Dental Implant Outcomes: CNN-Based System Accurately Measures Degree of Peri-Implantitis Damage on Periapical Film. *Bioengineering (Basel, Switzerland)*, 10(6), 640. <https://doi.org/10.3390/bioengineering10060640>
- Chen, Y.-C., Hsiao, C.-K., Ciou, J.-S., Tsai, Y.-J., & Tu, Y.-K. (2016). Effects of implant drilling parameters for pilot and twist drills on temperature rise in bone analog and alveolar bones. *Medical Engineering & Physics*, 38(11), 1314-1321. <https://doi.org/10.1016/j.medengphy.2016.08.009>
- Chrcanovic, B. R., Albrektsson, T., & Wennerberg, A. (2014). Reasons for failures of oral implants. *J Oral Rehabil*, 41(6), 443-476. <https://doi.org/10.1111/joor.12157>
- Chung, D. M., Oh, T. J., Shotwell, J. L., Misch, C. E., & Wang, H. L. (2006). Significance of keratinized mucosa in maintenance of dental implants with different surfaces. *Journal of periodontology*, 77(8), 1410–1420. <https://doi.org/10.1902/jop.2006.050393>
- Çiçek, Ö., Abdulkadir, A., & Albarqouni, S. (2016). "Label-free prediction of cardiac function using U-Net based neural networks." *M. C. C. A. M. I. (IEEE)*.
- Çiçek, Özgün & Abdulkadir, Ahmed & Lienkamp, Soeren & Brox, Thomas & Ronneberger, Olaf. (2016). 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation. 10.48550/arXiv.1606.06650.
- Dasters, R. ve Soori, M. (2021). Artificial neural network systems, *International Journal of Imaging*, 21(2): 13-25. ISSN 2231–525X
- Daubert, D. M., Weinstein, B. F., Bordin, S., Leroux, B. G., & Flemming, T. F. (2015). Prevalence and predictive factors for peri-implant disease and implant failure: a cross-sectional analysis. *Journal of periodontology*, 86(3), 337–347. <https://doi.org/10.1902/jop.2014.140438>
- Delipetrev, B., Tsinarakli, C. ve 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. Doi: 10.2760/801580

- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., & Fei-Fei, L. (2009). Imagenet: A large- scale hierarchical image database. 2009 IEEE conference on computer vision and pattern recognition, pp. 248-255.
- Depprich, R., Zipprich, H., Ommerborn, M., Naujoks, C., Wiesmann, H. P., Kiattavorncharoen, S., ... & Handschel, J. (2008). Osseointegration of zirconia implants compared with titanium: an in vivo study. *Head & face medicine*, 4(1), 30.
- Derks, J., Schaller, D., Håkansson, J., Wennström, J. L., Tomasi, C., & Berglundh, T. (2016). Peri-implantitis - onset and pattern of progression. *Journal of clinical periodontology*, 43(4), 383–388. <https://doi.org/10.1111/jcpe.12535>
- Dierens, M., Vandeweghe, S., Kisch, J., Nilner, K., & De Bruyn, H. (2012). Long-term follow-up of turned single implants placed in periodontally healthy patients after 16-22 years: radiographic and peri-implant outcome. *Clinical oral implants research*, 23(2), 197–204. <https://doi.org/10.1111/j.1600-0501.2011.02212.x>
- Dursun, E., Keceli, H. G., Dolgun, A., Velasco-Torres, M., Olculer, M., Ghoreishi, R., Sinjab, K., Sinicola, R. A., Kubilius, M., Tözüm, M. D., Galindo-Moreno, P., Yilmaz, H. G., Wang, H. L., Juodzbals, G., & Tözüm, T. F. (2019). Maxillary Sinus and Surrounding Bone Anatomy With Cone Beam Computed Tomography After Multiple Teeth Loss: A Retrospective Multicenter Clinical Study. *Implant dentistry*, 28(3), 226–236. <https://doi.org/10.1097/ID.0000000000000862>
- Duymuş, Z. Y., & Güngör, H. (2013). Dental İmplant Materyalleri. *Atatürk Üniversitesi Diş Hekimliği Fakültesi Dergisi*, 23(1), 145-152.
- Ekströmer, K., & Hjalmarsson, L. (2014). Positioning errors in panoramic images in general dentistry in Sörmland County, Sweden. *Swedish dental journal*, 38(1), 31–38.
- Elemek E. Peri-implant Dokuların Klinik ve Radyografik İncelenmesi [Doktora Tezi]: Marmara Üniversitesi; (2016).
- Esposito, M., Hirsch, J. M., Lekholm, U., & Thomsen, P. (1998). Biological factors contributing to failures of osseointegrated oral implants. (I). Success criteria and epidemiology. *Eur J Oral Sci*, 106(1), 527-551. <https://doi.org/10.1046/j.0909-8836.t01-2-.x>
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118. <https://doi.org/10.1038/nature21056>
- Ferreira, S. D., Silva, G. L., Cortelli, J. R., Costa, J. E., & Costa, F. O. (2006). Prevalence and risk variables for peri-implant disease in Brazilian subjects. *Journal of clinical periodontology*, 33(12), 929–935. <https://doi.org/10.1111/j.1600-051X.2006.01001.x>
- Fişekçioğlu, E., & El-Zuki, M. (2015). Manyetik Rezonans Görüntüleme Paranasal Sinüs Patolojileri. *Türkiye Klinikleri Journal of Oral and Maxillofacial Radiology-Special Topics*, 1(1), 83-88.

- Fransson, C., Lekholm, U., Jemt, T., & Berglundh, T. (2005). Prevalence of subjects with progressive bone loss at implants. *Clinical oral implants research*, 16(4), 440–446. <https://doi.org/10.1111/j.1600-0501.2005.01137.x>
- Frederiksen, N. L. (2009). Advanced imaging. *White SC, Pharoah MJ. Oral radiology: principles and interpretation. 6th ed. St. Louis: Mosby Elsevier*, 207-24.
- Friberg, B., & Jemt, T. (2010). Clinical experience of TiUnite implants: a 5-year cross-sectional, retrospective follow-up study. *Clin Implant Dent Relat Res*, 12 Suppl 1, e95-103. <https://doi.org/10.1111/j.1708-8208.2009.00222.x>
- Friberg, B., Jemt, T., & Lekholm, U. (1991). Early failures in 4,641 consecutively placed Branemvd dental implants: a study from stage 1 surgery to the connection of completed prostheses. *Int J Oral Maxillofac Implants*, 6(2), 142-146. <https://www.ncbi.nlm.nih.gov/pubmed/1809668>
- Gardiyanoglu E, Ünsal G, Akkaya N, Aksoy S, Orhan K. Automatic Segmentation of Teeth, Crown-Bridge Restorations, Dental Implants, Restorative Fillings, Dental Caries, Residual Roots, and Root Canal Fillings on Orthopantomographs: Convenience and Pitfalls. *Diagnostics* (Basel). 2023 Apr 20;13(8):1487. doi: 10.3390/diagnostics13081487. PMID: 37189586; PMCID: PMC10137458.
- Garg, A. K. (2010). *The Historical Development of Dental Implants*. Gaziev, J., & Lucarelli, G. (2003). Stem cell transplantation for hemoglobinopathies. *Curr Opin Pediatr*, 15(1), 24-31. <https://doi.org/10.1097/00008480-200302000-00005>
genetic programming approach to oral cancer prognosis. *PeerJ*, 4, e2482
- Gher, M. E., & Richardson, A. C. (1995). The accuracy of dental radiographic techniques used for evaluation of implant fixture placement. *International Journal of Periodontics & Restorative Dentistry*, 15(3).
- Ghosh, A. vd. (2020). Fundamental concepts of convolutional neural network, Recent Trends and Advances in Artificial Intelligence and Internet of Things, DOI: 10.1007/978-3-030-32644-9_36
- Gittelsohn GL. Vertical dimension of occlusion in implant dentistry: significance and approach. *Implant Dent*. 2002;11(1):33-40.
- Gotfredsen K, Berglundh T, Lindhe J. Bone reactions at implants subjected to experimental peri-implantitis and static load. A study in the dog. *J Clin Periodontol*. 2002;29(2):144-51.
- Gottlieb B. Biology of the cementum. *The Journal of Periodontology*. 1942;13(1):13-17.
- Greenfield, E. J. (1991). Implantation of artificial crown and bridge abutments. 1913. *The International journal of oral implantology: implantologist*, 7(2), 63.
- Guglielmotti, M. B., Olmedo, D. G., & Cabrini, R. L. (2019). Research on implants and osseointegration. *Periodontol 2000*, 79(1), 178-189. <https://doi.org/10.1111/prd.12254>

- Gupta, A. vd. (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>
- Gurney, K. (1997). *An introduction to neural networks*,; UCL Press: Londra Haenlein, M. ve Kaplan, A. (2019). A brief history of artificial intelligence: on the past, present, and future of artificial intelligence. *California Management Review*. 1-10. doi: 10.1177/0008125619864925
- Haenlein, M. ve Kaplan, A. (2019). A brief history of artificial intelligence: on the past, present, and future of artificial intelligence. *California Management Review*. 1-10. doi: 10.1177/0008125619864925
- Haffajee, A. D., & Socransky, S. S. (1994). Microbial etiological agents of destructive periodontal diseases. *Periodontology 2000*, 5, 78–111. <https://doi.org/10.1111/j.1600-0757.1994.tb00020.x>
- Han, D., Liu, Q., & Fan, W. (2018). A new image classification method using CNN transfer learning and web data augmentation. *Expert Systems with Applications*, 95, 43-56.
- Haykin, S. (2008) *Neural Networks and Learning Machines*. 3rd Edition, Prentice Hall, Upper Saddle River.
- He, J., Baxter, S. L., Xu, J., Xu, J., Zhou, X., & Zhang, K. (2019). The practical implementation of artificial intelligence technologies in medicine. *Nature Medicine*, 25(1), 30-36. <https://doi.org/10.1038/s41591-018-0307-0>
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. *Proceedings of the IEEE international conference on computer vision*, (pp. 1026-1034).
- Heitz-Mayfield, L. J., Salvi, G. E., Botticelli, D., Mombelli, A., Faddy, M., Lang, N. P., & Implant Complication Research Group (2011). Anti-infective treatment of peri-implant mucositis: a randomised controlled clinical trial. *Clinical oral implants research*, 22(3), 237–241. <https://doi.org/10.1111/j.1600-0501.2010.02078.x>
- Heitz-Mayfield, L. J. A., & Salvi, G. E. (2018). Peri-implant mucositis. *Journal of clinical periodontology*, 45 Suppl 20, S237–S245. <https://doi.org/10.1111/jcpe.12953>
- Heitz-Mayfield L. J. (2008). Peri-implant diseases: diagnosis and risk indicators. *Journal of clinical periodontology*, 35(8 Suppl), 292–304. <https://doi.org/10.1111/j.1600-051X.2008.01275.x>
- Hodez, C., Griffaton-Taillandier, C., & Bensimon, I. (2011). Cone-beam imaging: applications in ENT. *European annals of otorhinolaryngology, head and neck diseases*, 128(2), 65-78.
- Howerton, W. B., & Mora, M. A. (2008). Advancements in digital imaging: what is new and on the horizon. *The Journal of the American Dental Association*, 139, S20-S24.

- Hung, K. vd. (2020). The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review, *Dentomaxillofacial Radiology*, 49: 1-20. <https://doi.org/10.1259/dmfr.20190107>
- Itoiz M, Carranza Jr F, Cabrini R. Histotopographic distribution of alkaline and acid phosphatase in periodontal tissues of laboratory animals(1964). *The Journal of Periodontology*. 35(6):470-75.
- Jacobs, R., Fontenele, R. C., Lahoud, P., Shujaat, S., & Bornstein, M. M. (2024). Radiographic diagnosis of periodontal diseases - Current evidence versus innovations. *Periodontology 2000*, 95(1), 51–69. <https://doi.org/10.1111/prd.12580>
- Jang, W. S., Kim, S., Yun, P. S., Jang, H. S., Seong, Y. W., Yang, H. S., & Chang, J. S. (2022). Accurate detection for dental implant and peri-implant tissue by transfer learning of faster R-CNN: a diagnostic accuracy study. *BMC oral health*, 22(1), 591. <https://doi.org/10.1186/s12903-022-02539-x>
- Jankovic, S., Aleksic, Z., Dimitrijevic, B., Lekovic, V., Camargo, P., & Kenney, B. (2011). Prevalence of human cytomegalovirus and Epstein-Barr virus in subgingival plaque at peri-implantitis, mucositis and healthy sites. A pilot study. *International journal of oral and maxillofacial surgery*, 40(3), 271–276. <https://doi.org/10.1016/j.ijom.2010.11.004>
- Karahalil, B., Kadioglu, E., Tuzuner-Oncul, A. M., Cimen, E., Emerce, E., & Kishnisci, R. S. (2014). Micronucleus assay assessment of possible genotoxic effects in patients treated with titanium alloy endosseous implants or miniplates. *Mutation Research/Genetic Toxicology and Environmental Mutagenesis*, 760, 70-72.
- Karbach, J., Callaway, A., Kwon, Y. D., d'Hoedt, B., & Al-Nawas, B. (2009). Comparison of five parameters as risk factors for peri-mucositis. *The International journal of oral & maxillofacial implants*, 24(3), 491–496.
- Karoussis, I. K., Salvi, G. E., Heitz-Mayfield, L. J., Brägger, U., Hämmerle, C. H., & Lang, N. P. (2003). Long-term implant prognosis in patients with and without a history of chronic periodontitis: a 10-year prospective cohort study of the ITI Dental Implant System. *Clinical oral implants research*, 14(3), 329–339. <https://doi.org/10.1034/j.1600-0501.000.00934.x>
- Khanna, S. S., & Dhaimade, P. A. (2017). Artificial intelligence: transforming dentistry today. *Indian J Basic Appl Med Res*, 6(3), 161-167.
- Koçak, N. (2018). Maksiller Sinüsün Radyolojik Tanı Yöntemlerinin ve Limitasyonlarının Tedavi Planlamasında Rolü.
- Konstantinidis, I. K., Kotsakis, G. A., Gerdes, S., & Walter, M. H. (2015). Cross-sectional study on the prevalence and risk indicators of peri-implant diseases. *European journal of oral implantology*, 8(1), 75–88.

- Krekeler, G., Kappert, H. F., & Schilli, W. (1985). Scanning electron microscopic study of the reaction of human bone to a titanium implant. *International journal of oral surgery*, 14(5), 447–450. [https://doi.org/10.1016/s0300-9785\(85\)80078-8](https://doi.org/10.1016/s0300-9785(85)80078-8)
- Kriesel, D. (2009). A brief introduction to neural networks.. https://www.dkriesel.com/_media/science/neuronalenetze-en-zeta2-1col-dkrieselcom.pdf
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- Lachmann, S., Kimmerle-Müller, E., Axmann, D., Scheideler, L., Weber, H., & Haas, R. (2007). Associations between peri-implant crevicular fluid volume, concentrations of crevicular inflammatory mediators, and composite IL-1A -889 and IL-1B +3954 genotype. A cross-sectional study on implant recall patients with and without clinical signs of peri-implantitis. *Clinical oral implants research*, 18(2), 212–223. <https://doi.org/10.1111/j.1600-0501.2006.01322.x>
- Lambert, P. M., Morris, H. F., & Ochi, S. (2000). The influence of smoking on 3-year clinical success of osseointegrated dental implants. *Annals of periodontology*, 5(1), 79–89. <https://doi.org/10.1902/annals.2000.5.1.79>
- Lang, N. P., Berglundh, T., & Working Group 4 of Seventh European Workshop on Periodontology (2011). Periimplant diseases: where are we now?--Consensus of the Seventh European Workshop on Periodontology. *Journal of clinical periodontology*, 38 Suppl 11, 178–181. <https://doi.org/10.1111/j.1600-051X.2010.01674.x>
- Lawrynowicz, A. ve Tresp, V. (2014). Introducing machine learning, 35-50. doi: 10.1007/s10462-007-9052-3
- Lee, E. vd. (2021). Artificial intelligence in dentistry and dental education, *Dental Research: An International Journal*, 4(3), 1-6. doi: 10.3390/ijerph19063449
- Lee, J. H., Kim, D. H., Jeong, S. N., & Choi, S. H. (2020). Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *Journal of Dentistry*, 98, 103352. <https://doi.org/10.1016/j.jdent.2020.103352>
- Lee, W. F., Day, M. Y., Fang, C. Y., Nataraj, V., Wen, S. C., Chang, W. J., & Teng, N. C. (2024). Establishing a novel deep learning model for detecting peri-implantitis. *Journal of dental sciences*, 19(2), 1165–1173. <https://doi.org/10.1016/j.jds.2023.11.017>
- Li, H., Wu, X.-j., & Durrani, T. S. (2019). Infrared and visible image fusion with ResNet and zero-phase component analysis. *Infrared Physics & Technology*, 102, 103039.
- Li, S., Liu, J., Zhou, Z., Zhou, Z., Wu, X., Li, Y., Wang, S., Liao, W., Ying, S., & Zhao, Z. (2022). Artificial intelligence for caries and periapical periodontitis detection. *Journal of dentistry*, 122, 104107. <https://doi.org/10.1016/j.jdent.2022.104107>

- Lindhe, J., Berglundh, T., Ericsson, I., Liljenberg, B., & Marinello, C. (1992). Experimental breakdown of peri-implant and periodontal tissues. A study in the beagle dog. *Clinical oral implants research*, 3(1), 9–16. <https://doi.org/10.1034/j.1600-0501.1992.030102.x>
- Lindhe, J., Meyle, J., & Group D of European Workshop on Periodontology (2008). Peri-implant diseases: Consensus Report of the Sixth European Workshop on Periodontology. *Journal of clinical periodontology*, 35(8 Suppl), 282–285. <https://doi.org/10.1111/j.1600-051X.2008.01283.x>
- Lindquist, L. W., Carlsson, G. E., & Jemt, T. (1997). Association between marginal bone loss around osseointegrated mandibular implants and smoking habits: a 10-year follow-up study. *Journal of dental research*, 76(10), 1667–1674. <https://doi.org/10.1177/00220345970760100801>
- Linkevicius, T., Puisys, A., Vindasiute, E., Linkeviciene, L., & Apse, P. (2013). Does residual cement around implant-supported restorations cause peri-implant disease? A retrospective case analysis. *Clinical oral implants research*, 24(11), 1179–1184. <https://doi.org/10.1111/j.1600-0501.2012.02570.x>
- Linkow, L. I., & Cherchève, R. (1970). *Theories and techniques of oral implantology*. Mosby.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A., Ciompi, F., Ghafoorian, M., & van der Laak, J. A. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60–88. <https://doi.org/10.1016/j.media.2017.07.005>
- Lucas, L. C., Buchanan, R. A., Lemons, J. E., & Griffin, C. D. (1982). Susceptibility of surgical cobalt-base alloy to pitting corrosion. *Journal of biomedical materials research*, 16(6), 799–810.
- Ma., J., Scheider, L., Lopuschkin, S., & Achtibat, R. (2022). Towards trustworthy AI in dentistry. *Journal of Dental Research*, 101(11): 1263–1268. [http://doi: 10.1177/00220345221106086](http://doi:10.1177/00220345221106086)
- Mah, J. K., Danforth, R. A., Bumann, A., & Hatcher, D. (2003). Radiation absorbed in maxillofacial imaging with a new dental computed tomography device. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, 96(4), 508–513.
- Mahesh, B. (2019). Machine learning algorithms - a review. *International Journal of Science and Research (IJSR)*. 9(1): 381–385. doi: 10.21275/ART20203995
- Mameno, T., Wada, M., Nozaki, K., Takahashi, T., Tsujioka, Y., Akema, S., Hasegawa, D., & Ikebe, K. (2021). Predictive modeling for peri-implantitis by using machine learning techniques. *Scientific reports*, 11(1), 11090. <https://doi.org/10.1038/s41598-021-90642-4>
- Mameno, T., Wada, M., Nozaki, K., Takahashi, T., Tsujioka, Y., Akema, S., Hasegawa, D., & Ikebe, K. (2021). Predictive modeling for peri-implantitis by using machine learning techniques. *Scientific reports*, 11(1), 11090. <https://doi.org/10.1038/s41598-021-90642-4>

- Masaki C, Kondo Y, Tomoeda K, Nodai T, Munemasa T, Mukaibo T, Hosokawa R. Treatment strategies for dental implant removal: A literature review. *Jpn Dent Sci Rev*. 2024 Dec;60:120-127. doi: 10.1016/j.jdsr.2024.01.002. Epub 2024 Feb 23. PMID: 39444488; PMCID: PMC11497076.
- Mathew, A., Amudha, P. ve Sivakumari, S. (2021). Deep Learning Techniques: An Overview. in: *Advanced Machine Learning Technologies and Applications*. 599-608 DOI:10.1007/978-981-15-3383-9_54
- Máximo, M. B., de Mendonça, A. C., Alves, J. F., Cortelli, S. C., Peruzzo, D. C., & Duarte, P. M. (2008). Peri-implant diseases may be associated with increased time loading and generalized periodontal bone loss: preliminary results. *The Journal of oral implantology*, 34(5), 268–273. [https://doi.org/10.1563/1548-1336\(2008\)34\[269:PDMBAW\]2.0.CO;2](https://doi.org/10.1563/1548-1336(2008)34[269:PDMBAW]2.0.CO;2)
- Máximo, M. B., de Mendonça, A. C., Renata Santos, V., Figueiredo, L. C., Feres, M., & Duarte, P. M. (2009). Short-term clinical and microbiological evaluations of peri-implant diseases before and after mechanical anti-infective therapies. *Clinical oral implants research*, 20(1), 99–108. <https://doi.org/10.1111/j.1600-0501.2008.01618.x>.
- McKinney, S. M., Sieniek, M., Godbole, V., Godwin, J., Antropova, N., Ashrafian, H., & Suleiman, S. (2020). International evaluation of an AI system for breast cancer screening. *Nature*, 577(7788), 89-94. <https://doi.org/10.1038/s41586-019-1799-6>
- Mijwil, Maad. (2015). History of Artificial Intelligence. 3. 1-8.10.13140/RG.2.2.16418.15046.
- Miles, D. A., & Van, M. D. (1993). Implant radiology. *Dental Clinics of North America*, 37(4), 645-668.
- Misch, C. E. (2007). *Contemporary Implant Dentistry* (3rd ed.). Mosby Inc.
- Misch, C. E., & Degidi, M. (2003). Five-year prospective study of immediate/early loading of fixed prostheses in completely edentulous jaws with a bone quality-based implant system. *Clin Implant Dent Relat Res*, 5(1), 17-28. <https://doi.org/10.1111/j.1708-8208.2003.tb00178.x>
- Misch, C. E., Dietsh-Misch, F., Hoar, J., Beck, G., Hazen, R., & Misch, C. M. (1999). A bone quality-based implant system: first year of prosthetic loading. *J Oral Implantol*, 25(3), 185-197. [https://doi.org/10.1563/1548-1336\(1999\)025<0185:ABQISF>2.3.CO;2](https://doi.org/10.1563/1548-1336(1999)025<0185:ABQISF>2.3.CO;2)
- Misch, C. M., Jolly, R. L., Williams, D. R., & Chorazy, C. J. (1998). Maxillary implant surgery on a patient with thalassemia. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology*, 86(4), 401-405. [https://doi.org/10.1016/s1079-2104\(98\)90363-8](https://doi.org/10.1016/s1079-2104(98)90363-8)
- Misch, C. M., Jolly, R. L., Williams, D. R., & Chorazy, C. J. (1998). Maxillary implant surgery on a patient with thalassemia. *Oral Surgery, Oral Medicine, Oral Pathology, Oral*

Radiology, and Endodontology, 86(4), 401-405. [https://doi.org/10.1016/s1079-2104\(98\)90363-8](https://doi.org/10.1016/s1079-2104(98)90363-8)

- Mombelli, A., van Oosten, M. A., Schurch, E., Jr, & Land, N. P. (1987). The microbiota associated with successful or failing osseointegrated titanium implants. *Oral microbiology and immunology*, 2(4), 145–151. <https://doi.org/10.1111/j.1399-302x.1987.tb00298.x>
- Newman, M. G., Takeji, H., Klokkevold, P. R., & Carranza, F. A. (2011). *Carranza's clinical periodontology*. Elsevier health sciences
- Olmedo, D. G., Nalli, G., Verdú, S., Paparella, M. L., & Cabrini, R. L. (2013). Exfoliative cytology and titanium dental implants: a pilot study. *Journal of periodontology*, 84(1), 78–83. <https://doi.org/10.1902/jop.2012.110757>
- O'Mahony, A., Bowles, Q., Woolsey, G., Robinson, S. J., & Spencer, P. (2000). Stress distribution in the single-unit osseointegrated dental implant: finite element analyses of axial and off-axial loading. *Implant dentistry*, 9(3), 207–218. <https://doi.org/10.1097/00008505-200009030-00006>
- Ölçüler, Mehmet (2020). Maksiller posterior çoklu diş eksikliklerinde sinüs anatomisi ve implant ilişkisini konik ışınli bilgisayarlı tomografi ile incelenmesi. Near East University NEU Grand Library, WU600.7.O43.
- Padial-Molina, M., López-Martínez, J., O'Valle, F., & Galindo-Moreno, P. (2016). Microbial Profiles and Detection Techniques in Peri-Implant Diseases: a Systematic Review. *Journal of oral & maxillofacial research*, 7(3), e10. <https://doi.org/10.5037/jomr.2016.7310>
- Pvd, C. W., Seo, S. W., Kang, N., Ko, B., Choi, B. W., Pvd, C. M., ... & Yoon, H. J. (2020). Artificial intelligence in health care: Current applications and issues. *Journal of Korean Medical Science*, 35(42). <https://doi.org/10.3346/jkms.2020.35.e379>
- Persson, G. R., & Renvert, S. (2014). Cluster of bacteria associated with peri-implantitis. *Clinical implant dentistry and related research*, 16(6), 783–793. <https://doi.org/10.1111/cid.12052>
- Pesun, I. J. (1997). Intrusion of teeth in the combination implant-to-natural-tooth fixed partial denture: a review of the theories. *Journal of Prosthodontics*, 6(4), 268-277.
- Piattelli, A., Scarano, A., Balleri, P., & Favero, G. A. (1998). Clinical and histologic evaluation of an active "implant periapical lesion": a case report. *The International journal of oral & maxillofacial implants*, 13(5), 713–716.
- Pirim, A. G. H. (2006). YAPAY ZEKA . Yaşar Üniversitesi E-Dergisi , 1 (1) , 81-93. <https://dergipvd.org.tr/tr/pub/jyasar/issue/19113/202842>
- Rajaraman, Vaishnavi & Venugopalan, Suresh & Dhanraj, M. & Jain, Ashish. (2018). Arriving at a definitive bone quality. *Drug Invention Today*. 10. 834-838.

- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., ... & Ng, A. Y. (2018). Deep learning for chest radiograph diagnosis: A retrospective comparison of the CheXNeXt algorithm to practicing radiologists. *PLoS Medicine*, 15(11), e1002686. <https://doi.org/10.1371/journal.pmed.1002686>
- Reddy, M. S., & Wang, I. C. (1999). Radiographic determinants of implant performance. *Advances in dental research*, 13(1), 136-145.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*, (pp. 779-788).
- Renvert, S., Aghazadeh, A., Hallström, H., & Persson, G. R. (2014). Factors related to peri-implantitis - a retrospective study. *Clinical oral implants research*, 25(4), 522–529. <https://doi.org/10.1111/clr.12208>
- Renvert, S., & Polyzois, I. (2015). Risk indicators for peri-implant mucositis: a systematic literature review. *Journal of clinical periodontology*, 42 Suppl 16, S172–S186. <https://doi.org/10.1111/jcpe.12346>
- Renvert, S., Persson, G. R., Pirih, F. Q., & Camargo, P. M. (2018). Peri-implant health, peri-implant mucositis, and peri-implantitis: Case definitions and diagnostic considerations. *Journal of periodontology*, 89 Suppl 1, S304–S312. <https://doi.org/10.1002/JPER.17-0588>
- 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>
- Rinke, S., Ohl, S., Ziebolz, D., Lange, K., & Eickholz, P. (2011). Prevalence of periimplant disease in partially edentulous patients: a practice-based cross-sectional study. *Clinical oral implants research*, 22(8), 826–833. <https://doi.org/10.1111/j.1600-0501.2010.02061.x>
- Roccuzzo, M., Grasso, G., & Dalmaso, P. (2016). Keratinized mucosa around implants in partially edentulous posterior mandible: 10-year results of a prospective comparative study. *Clinical oral implants research*, 27(4), 491–496. <https://doi.org/10.1111/clr.12563>
- Rodríguez-Mercado, J. J., Roldán-Reyes, E., & Altamirano-Lozano, M. (2003). Genotoxic effects of vanadium (IV) in human peripheral blood cells. *Toxicology Letters*, 144(3), 359-369.
- Rodriguez-Argueta, O. F., Figueiredo, R., Valmaseda-Castellon, E., & Gay-Escoda, C. (2011). Postoperative complications in smoking patients treated with implants: a retrospective study. *Journal of oral and maxillofacial surgery : official journal of the American Association of Oral and Maxillofacial Surgeons*, 69(8), 2152–2157. <https://doi.org/10.1016/j.joms.2011.02.082>

- Ronchi, F., Armanet, C., & Demattè, L. (2019). "U-Net architecture for multi-class semantic segmentation in skin lesions." *Image Analysis and Stereology (IASC)*.
- Ronneberger, O., Fischer, P., & Becker, K. (2015). "U-Net: Convolutional Networks for Biomedical Image Segmentation." *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*.
- Ronneberger, Olaf & Fischer, Philipp & Brox, Thomas. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. LNCS. 9351. 234-241. 10.1007/978-3-319-24574-4_28.
- Roos-Jansåker, A. M., Lindahl, C., Renvert, H., & Renvert, S. (2006). Nine- to fourteen-year follow-up of implant treatment. Part II: presence of peri-implant lesions. *Journal of clinical periodontology*, 33(4), 290–295. <https://doi.org/10.1111/j.1600-051X.2006.00906.x>
- Roos-Jansåker, A. M., Lindahl, C., Renvert, H., & Renvert, S. (2006). Nine- to fourteen-year follow-up of implant treatment. Part II: presence of peri-implant lesions. *Journal of clinical periodontology*, 33(4), 290–295. <https://doi.org/10.1111/j.1600-051X.2006.00906.x>
- 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)
- Saini, M., Singh, Y., Arora, P., Arora, V., & Jain, K. (2015). Implant biomaterials: A comprehensive review. *World Journal of Clinical Cases: WJCC*, 3(1), 52.
- Salimi, H., Savabi, O., & Nejatidanesh, F. (2011). Current results and trends in platform switching. *Dental research journal*, 8(Suppl 1), S30–S36.
- Sarfraz Z, Sarfraz A, Iftikar HM, Akhund R. (2021). Is COVID-19 pushing us to the Fifth Industrial Revolution (Society 5.0)? *Pak J Med Sci*.37(2):591-594. doi: <https://doi.org/10.12669/pjms.37.2.3387>
- Scarfe, W. C., & Farman, A. G. (2008). What is cone-beam CT and how does it work. *Dental Clinics*, 52(4), 707-730.
- Scarfe, W. C., Farman, A. G., & Sukovic, P. (2006). Clinical applications of cone-beam computed tomography in dental practice. *Journal-Canadian Dental Association*, 72(1), 75.
- Schenk, R. K., & Buser, D. (1998). Osseointegration: a reality. *Periodontology 2000*, 17, 22–35. <https://doi.org/10.1111/j.1600-0757.1998.tb00120.x>
- Schnitman, P. A., & Shulman, L. B. (1979). Recommendations of the consensus development conference on dental implants. *J Am Dent Assoc*, 98(3), 373-377. <https://doi.org/10.14219/jada.archive.1979.0052>

- Schou, S., Holmstrup, P., Worthington, H. V., & Esposito, M. (2006). Outcome of implant therapy in patients with previous tooth loss due to periodontitis. *Clinical oral implants research*, 17 Suppl 2, 104–123. <https://doi.org/10.1111/j.1600-0501.2006.01347.x>.
- Schroeder HE (2012). *The periodontium*: Springer Science & Business Media.
- Schrott, A. R., Jimenez, M., Hwang, J. W., Fiorellini, J., & Weber, H. P. (2009). Five-year evaluation of the influence of keratinized mucosa on peri-implant soft-tissue health and stability around implants supporting full-arch mandibular fixed prostheses. *Clinical oral implants research*, 20(10), 1170–1177. <https://doi.org/10.1111/j.1600-0501.2009.01795.x>
- Schwarz, F., Becker, K., Rahn, S., Hegewald, A., Pfeffer, K., & Henrich, B. (2015). Real-time PCR analysis of fungal organisms and bacterial species at peri-implantitis sites. *International journal of implant dentistry*, 1(1), 9. <https://doi.org/10.1186/s40729-015-0010-6>
- 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>
- Serino, G., & Ström, C. (2009). Peri-implantitis in partially edentulous patients: association with inadequate plaque control. *Clinical oral implants research*, 20(2), 169–174. <https://doi.org/10.1111/j.1600-0501.2008.01627.x>
- Sharma, Aneesh. (2021). Artificial Intelligence In Health Care. *International Journal of Humanities, Arts, Medicine and Science*. 5. 106-109.
- Shiruru, Kuldeep. (2016). An Introduction To Artificial Neural Network. *International Journal of Advance Research and Innovative Ideas in Education*. 1. 27-30.
- Simonyan, Karen & Zisserman, Andrew. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv 1409.1556.
- Smola, A. and Vishwanathan, S. (2008) *Introduction to Machine Learning*. Cambridge University Press, Cambridge, UK.
- Sodek, J., & McKee, M. D. (2000). Molecular and cellular biology of alveolar bone. *Periodontology* 2000, 24, 99–126. <https://doi.org/10.1034/j.1600-0757.2000.2240106.x>.
- Song, D., Shujaat, S., de Faria Vasconcelos, K., Huang, Y., Politis, C., Lambrichts, I., & Jacobs, R. (2021). Diagnostic accuracy of CBCT versus intraoral imaging for assessment of peri-implant bone defects. *BMC medical imaging*, 21(1), 23. <https://doi.org/10.1186/s12880-021-00557-9>

- Song, I. S., Shin, H. K., Kang, J. H., Kim, J. E., Huh, K. H., Yi, W. J., Lee, S. S., & Heo, M. S. (2022). Deep learning-based apical lesion segmentation from panoramic radiographs. *Imaging science in dentistry*, 52(4), 351–357. <https://doi.org/10.5624/isd.20220078>
- Steinemann, S. G. (1998). Titanium—the material of choice? *Periodontology 2000*, 17(1), 7–21.
- Sykaras, N., Iacopino, A. M., Mvder, V. A., Triplett, R. G., & Woody, R. D. (2000). Implant materials, designs, and surface topographies: their effect on osseointegration. A literature review. *The International journal of oral & maxillofacial implants*, 15(5), 675–690.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. *Proceedings of the IEEE conference on computer vision and pattern recognition, Boston, USA*, 1(9).
- Tan, M. S., Tan, J. W., Chang, S.-W., Yap, H. J., Kareem, S. A., & Zain, R. B. (2016). A
- Tandon, D. ve Rajawat, J. (2020). Present and future of artificial intelligence in dentistry, *Journal of Oral Biology and Craniofacial Research*, doi: <https://doi.org/10.1016/j.jobcr.2020.07.015>.
- Tonetti, M. S., Gerber, L., & Lang, N. P. (1994). Vascular adhesion molecules and initial development of inflammation in clinically healthy human keratinized mucosa around teeth and osseointegrated implants. *Journal of periodontal research*, 29(6), 386–392. <https://doi.org/10.1111/j.1600-0765.1994.tb01239.x>
- Topol, E. J. (2019). High-performance medicine: The convergence of human and artificial intelligence. *Nature Medicine*, 25(1), 44–56. <https://doi.org/10.1038/s41591-018-0300-7>
- Uzialko, A. (2019). Artificial Intelligence Will Change Healthcare as We Know it. *Business News Daily*, 9.
- Vargas, R., Mosavi, A. ve Ruiz, L. (2017). Deep learning: a review. *Advances in Intelligent Systems and Computing*, 5(2): 1–15. doi: 10.20944/preprints201810.0218.v1
- Velarde, Gissel. (2019). Artificial Intelligence and its Impact on the Fourth Industrial Revolution: A Review. *International Journal of Artificial Intelligence & Applications*. 10. 10.5121/ijai.2019.10604
- Vera, M., Gómez-Silva, M. J., Vera, V., López-González, C. I., Aliaga, I., Gascó, E., Vera-González, V., Pedrera-Canal, M., Besada-Portas, E., & Pajares, G. (2023). Artificial Intelligence Techniques for Automatic Detection of Peri-implant Marginal Bone Remodeling in Intraoral Radiographs. *Journal of digital imaging*, 36(5), 2259–2277. <https://doi.org/10.1007/s10278-023-00880-3>
- Walczak, Steven & Cerpa, Narciso. (2003). Artificial Neural Networks. doi: 10.1016/B0-12-227410-5/00837-1.

- Wang, R. R., & Fenton, A. (1996). Titanium for prosthodontic applications: a review of the literature. *Quintessence international (Berlin, Germany : 1985)*, 27(6), 401–408.
- Weinberg L. A. (1998). Reduction of implant loading using a modified centric occlusal anatomy. *The International journal of prosthodontics*, 11(1), 55–69.
- Wennström, J. L., & Derks, J. (2012). Is there a need for keratinized mucosa around implants to maintain health and tissue stability?. *Clinical oral implants research*, 23 Suppl 6, 136–146. <https://doi.org/10.1111/j.1600-0501.2012.02540.x>
- Wennström, J. L., Ekestubbe, A., Gröndahl, K., Karlsson, S., & Lindhe, J. (2004). Oral rehabilitation with implant-supported fixed partial dentures in periodontitis-susceptible subjects. A 5-year prospective study. *Journal of clinical periodontology*, 31(9), 713–724. <https://doi.org/10.1111/j.1600-051X.2004.00568.x>
- White, S. C., & Pharoah, M. J. (2008). The evolution and application of dental maxillofacial imaging modalities. *Dental clinics of North America*, 52(4), 689–v. <https://doi.org/10.1016/j.cden.2008.05.006>
- White, S. C., & Pharoah, M. J. (2014). *Oral radiology-E-Book: Principles and interpretation*. Elsevier Health Sciences.
- Wilson, T. G., Jr, & Nunn, M. (1999). The relationship between the interleukin-1 periodontal genotype and implant loss. Initial data. *Journal of periodontology*, 70(7), 724–729. <https://doi.org/10.1902/jop.1999.70.7.724>
- Wilson T. G., Jr (2009). The positive relationship between excess cement and peri-implant disease: a prospective clinical endoscopic study. *Journal of periodontology*, 80(9), 1388–1392. <https://doi.org/10.1902/jop.2009.090115>
- Wu, Z., Yu, X., Wang, F., & Xu, C. (2024). Application of artificial intelligence in dental implant prognosis: A scoping review. *Journal of dentistry*, 144, 104924. <https://doi.org/10.1016/j.ident.2024.104924>
- Wu, S., Zhong, S., & Liu, Y. (2018). Deep residual learning for image steganalysis.
- Yalçın, B., & Varol, R. (2007). Investigation for the basis properties of the titanium alloy implants produced with powder metallurgy method. Süleyman Demirel Üniversitesi. Tez No: 200076
- 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.ident.2022.104076>.
- Yu, D., Hu, J., Feng, Z., Song, M., & Zhu, H. (2022). Deep learning based diagnosis for cysts and tumors of jaw with massive healthy samples. *Scientific reports*, 12(1), 1855. <https://doi.org/10.1038/s41598-022-05913-5>
- Zhang, A. Z., Lipton, M.L. ve Smola, A. (2019). *Dive into deep learning*, SAGE Publications. <https://doi.org/10.48550/arXiv.2106.11342>

- Zigdon, H., & Machtei, E. E. (2008). The dimensions of keratinized mucosa around implants affect clinical and immunological parameters. *Clinical oral implants research*, 19(4), 387–392. <https://doi.org/10.1111/j.1600-0501.2007.01492.x>
- Zitzmann, N. U., Berglundh, T., Marinello, C. P., & Lindhe, J. (2001). Experimental peri-implant mucositis in man. *Journal of clinical periodontology*, 28(6), 517–523. <https://doi.org/10.1034/j.1600-051x.2001.028006517.x>
- Zitzmann, N. U., Abrahamsson, I., Berglundh, T., & Lindhe, J. (2002). Soft tissue reactions to plaque formation at implant abutments with different surface topography. An experimental study in dogs. *Journal of clinical periodontology*, 29(5), 456–461. <https://doi.org/10.1034/j.1600-051x.2002.290511.x>
- Zitzmann, N. U., & Berglundh, T. (2008). Definition and prevalence of peri-implant diseases. *Journal of clinical periodontology*, 35(8 Suppl), 286–291. <https://doi.org/10.1111/j.1600-051X.2008.01274.x>

EKLER

EK 1

Etik Kurul Raporu




YAKIN DOĞU ÜNİVERSİTESİ
BİLİMSEL ARAŞTIRMALAR ETİK KURULU

ARAŞTIRMA PROJESİ DEĞERLENDİRME RAPORU

Toplantı Tarihi :21.12.2023
Toplantı No :2023/119
Proje No :1793

Yakın Doğu Üniversitesi Diş Hekimliği Fakültesi öğretim üyelerinden Doç. Dr. Oğuz Buhara'nın sorumlu araştırmacısı olduğu, YDU/2023/119-1793 proje numaralı ve "Ortopantomograflar Üzerinde Dental İmplantların Otomatik Segmentasyonu ve Periimplantitis Tespiti için Sınıflandırılması" başlıklı proje önerisi kurulumuzca değerlendirilmiş olup, etik olarak uygun bulunmuştur.



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. İlker Etikan	✓	✓
Doç. Dr. Mehtap Tınazlı	✓	✓
Prof. Dr. Nilüfer Galip Çelik	X	X
Doç. Dr. Dilek Sarpkaya Güder	✓	✓
Doç. Dr. Gulifeiya Abuduxike	✓	✓
Prof. Dr. Burçin Şanlıdağ	✓	✓

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

Ek 2

İntihal Raporu

Erdoğan Kibçak Tez

By: Erdoğan Kibçak

As of: May 6, 2025 6:26:08 PM
21,005 words - 94 matches - 43 sources

Similarity Index

7%

Mode: Summary Report ▼

sources:

363 words / 2% - Crossref

[Erdoğan Kibçak, Oğuz Buhara, Ali Temelci, Nurullah Akkaya, Gürkan Ünsal, Giuseppe Minervini, "Deep Learning-Driven Segmentation of Dental Implants and Peri-Implantitis Detection in Orthopantomographs: A Novel Diagnostic Tool", Journal of Evidence-Based Dental Practice, 2024](#)

281 words / 1% - Internet from 04-Oct-2022 12:00AM

[docs.neu.edu.tr](#)

145 words / 1% - Internet from 02-Dec-2024 12:00AM

[acikbilim.yok.gov.tr](#)

68 words / < 1% match - Internet from 07-Jun-2024 12:00AM

[docs.neu.edu.tr](#)

12 words / < 1% match - Internet from 27-Jul-2024 12:00AM

[docs.neu.edu.tr](#)

8 words / < 1% match - Internet from 09-Oct-2022 12:00AM

[docs.neu.edu.tr](#)

57 words / < 1% match - Internet from 23-Sep-2022 12:00AM

[acikbilim.yok.gov.tr](#)

53 words / < 1% match - Internet from 12-Oct-2022 12:00AM

[acikbilim.yok.gov.tr](#)

19 words / < 1% match - Internet from 03-Oct-2022 12:00AM

[acikbilim.yok.gov.tr](#)

8 words / < 1% match - Internet from 01-Oct-2022 12:00AM

[acikbilim.yok.gov.tr](#)

32 words / < 1% match - Internet from 24-Aug-2022 12:00AM

[9lib.net](#)

Özgeçmiş

Adı	Erdoğan	Soyadı	Kıbcak
Doğum Yeri	Güzelyurt	Doğum Tarihi	20.06.1997
Uyruğu	KKTC	Tel	05338732201
E-mail	erdogan.kibcak@neu.edu.tr		

EĞİTİM DÜZEYİ	MEZUN OLDUĞU KURUMUN ADI	MEZUNİYET YILI
DOKTORA\UZMANLIK	YDÜ DİŞ HEKİMLİĞİ FAKÜLTESİ AĞIZ, DİŞ VE ÇENE CERRAHİSİ	DEVAM EDİYOR
YÜKSEK LİSANS	-	-
LİSANS	BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ	2020
LİSE	GÜZELYURT TMK	2015

İş Deneyimi

Görevi	Kurum	Süre
Araştırma Görevlisi	Yakın Doğu Üniversitesi Diş Hekimliği Fakültesi	2020 Halen

Yabancı Dilleri	Okuduğunu Anlama*	Konuşma*	Yazma*
İngilizce	Çok iyi	Çok iyi	Çok iyi

Bilgisayar Bilgisi

PROGRAM	KULLANMA BECERİSİ
Microsoft Word, Powerpoint, Excel	İYİ

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

1. Uluslararası Hakemli Dergilerdeki (SCI, SCI-Expanded) Yayınlar

Kıbcak, E., Buhara, O., Temelci, A., Akkaya, N., Ünsal, G., & Minervini, G. (2025). DEEP LEARNING-DRIVEN SEGMENTATION OF DENTAL IMPLANTS AND PERI-IMPLANTITIS DETECTION IN ORTHOPANTOMOGRAPHS: A NOVEL DIAGNOSTIC TOOL. *The journal of evidence-based dental practice*, 25(1), 102058. <https://doi.org/10.1016/j.jebdp.2024.102058>

2. Uluslararası Konferanslarda Sunulan Ve Bildiri Kitaplarında Yayımlanan Bildiriler

Kıbcak E, Buhara O, Temelci A (2021) Radicular Cyst Enucleation Associated with Nasal Mucosa.(POSTER) Turkish Association of Oral and Maxillofacial Surgery

Kıbcak E, Temelci A, Buhara O, Uyanık LO (2021) Conservative Treatment of Pediatric Mandible Fracture.(POSTER) Turkish Association of Oral and Maxillofacial Surgeons

Temelci A, Kıbcak E, Buhara O, Uyanık LO (2021) Using Bichat Fat Tissue In The Treatment Of Oroantral Fistula.(POSTER) Turkish Association of Oral and Maxillofacial Surgery