



The Journal of Turkish Dental Research Türk Diş Hekimliği Araştırma Dergisi

e-ISSN: 2822-4310 | Yıl / Year: 2026 | Cilt – Volume: 5 | Sayı – Issue: 1

Periodontolojide Yapay Zeka Kullanımı: Günümüzdeki Uygulamalar, Yenilikler ve Gelecek

Artificial Intelligence in Periodontology: Current Applications, Innovations, and Future Perspectives

Periodontoloji ve Yapay Zeka

Erkin ERDOĞAN¹, Büşra YILMAZ², Gülnur EMİNGİL³, Ali GÜRKAN⁴

¹Arş. Gör., Ege Üniversitesi, Diş Hekimliği Fakültesi, Periodontoloji Anabilim Dalı, İzmir
erkinerdogan@msn.com

ORCID: 0009-0002-8019-8098

²Arş. Gör., Ege Üniversitesi, Diş Hekimliği Fakültesi, Periodontoloji Anabilim Dalı, İzmir
busratkn92@gmail.com

ORCID: 0000-0003-3631-3933

³Prof. Dr., İstinye Üniversitesi Diş Hekimliği Fakültesi, Periodontoloji Anabilim Dalı, İstanbul/TÜRKİYE
gemingil@yahoo.com

ORCID: 0000-0002-4869-9629

⁴Prof. Dr., Tınaztepe Üniversitesi Diş Hekimliği Fakültesi, Periodontoloji Anabilim Dalı, İzmir/TÜRKİYE
ali.gurkan@tinaztepe.edu.tr

ORCID: 0000-0001-5405-5689

Yazar Katkıları : Çalışma konusunun belirlenmesi ve literatür taraması: Gülnur Emingil, Büşra Yılmaz, Erkin Erdoğan
Verilerin toplanması, değerlendirilmesi ve derlenmesi: Erkin Erdoğan

Yazının ilk taslağının hazırlanması: Büşra Yılmaz, Erkin Erdoğan. Bilimsel içerik ve yapısal düzenlemeler: Ali Gürkan

Çıkar Çatışması : Bu çalışma kapsamında yazarların ve/veya aile bireylerinin, bilimsel ya da tıbbi komite üyelikleri, danışmanlık, bilirkişilik, herhangi bir firmada görev alma, hissedarlık veya benzeri çıkar çatışması oluşturabilecek herhangi bir durumu bulunmamaktadır.

Makale Bilgisi / Article Information

Makale Türü / Article Types: Derleme / Review

Geliş Tarihi / Received: 04-05-2025

Kabul Tarihi / Accepted: 08-10-2025

Sayfa / Pages: 61-78

Sorumlu Yazar / Corresponding Author: Ali GÜRKAN

DOI: <https://doi.org/10.58711/turkishjdentres.vi.1691244>

Periodontolojide Yapay Zeka Kullanımı: Günümüzdeki Uygulamalar, Yenilikler ve Gelecek

Artificial Intelligence in Periodontology: Current Applications, Innovations, and Future Perspectives

ÖZET

Son yıllarda yapay zeka teknolojileri, sağlık hizmetlerinde tanıdan tedaviye pek çok alanda dönüşüm yaratmıştır. Diş hekimliği özelinde, özellikle görüntüleme verilerinin analizi ve klinik karar destek sistemlerinin gelişimiyle birlikte, yapay zekanın potansiyeli giderek daha fazla önem kazanmaktadır. Periodontal hastalıkların teşhis, sınıflandırma, tedavi planlaması ve hasta takibi gibi alanlarında bu teknolojinin katkılarını ele alan güncel çalışmalar dikkat çekici bulgular sunmaktadır. Bu çalışmada, periodontoloji alanında yürütülen yapay zeka temelli araştırmalar değerlendirilmiş; klinik, radyografik ve biyolojik verilerin analizinde kullanılan yapay zeka modellerinin doğruluk, özgüllük ve duyarlılık düzeyleri karşılaştırılmıştır. Derin öğrenme algoritmalarının tedavi takibi, risk tahmini ve uzaktan hasta izleminde etkili olduğu ve kişiselleştirilmiş ağız sağlığı uygulamalarında da yenilikçi bir yaklaşım sunduğu gözlemlenmiştir. Bununla birlikte, sınırlı veri çeşitliliği, tek merkezli tasarımlar ve etik-yasal belirsizlikler, mevcut modellerin genellenebilirliğini ve klinik uygulanabilirliğini kısıtlamaktadır. Gelecekte, daha büyük ve temsili veri setleriyle yapılacak çok merkezli çalışmaların, yapay zekanın periodontoloji pratiğine güvenli ve etkili entegrasyonuna olanak sağlayacağı öngörülmektedir.

Anahtar Kelimeler: Yapay zeka; periodontoloji; derin öğrenme

ABSTRACT

In recent years, artificial intelligence (AI) has transformed numerous aspects of healthcare, particularly in the analysis of medical imaging and decision support systems. In the field of dentistry, the application of AI is gaining momentum, especially for its ability to enhance diagnostic accuracy and clinical efficiency. Periodontology has emerged as a promising area where AI can contribute to disease detection, classification, prognosis, and patient monitoring.

This review examines the current literature on AI applications in periodontology, focusing on models that utilize clinical, radiographic, and biological data. The findings highlight the effectiveness of deep learning in monitoring treatment outcomes, estimating risk, and enabling remote follow-up, while also contributing to personalized care strategies. Despite these promising developments, limitations such as restricted dataset diversity, single-center study designs, and unresolved ethical or legal concerns challenge the broader clinical integration of AI. Multicenter studies with large and diverse datasets are needed to develop robust, generalizable models and ensure the safe, reliable use of AI in periodontal care.

Keywords: Artificial intelligence; periodontology; deep learning

Giriş

Periodontitis, subgingival mikrobiyotanın disbiyotik hale gelmesiyle birlikte konak yanıtının aracılık ettiği, kök yüzeyinin bakteriyel biyofilmle enfekte olarak zaman içerisinde bağlantı epitelinin apikale göç etmesi sonucu periodontal ataşmanın kaybıyla karakterize kronik enflamatuvar bir hastalıktır.¹ 2019 Küresel Hastalık Yüklü çalışmasına göre, dünya genelinde yaklaşık 1,1 milyar şiddetli periodontitis vakası bulunurken 1990–2019 yılları arasında şiddetli periodontitis prevalansının %8,44 arttığı ortaya konulmuştur.² Bu yüksek küresel yük karşısında yapay zekâ teknolojilerindeki güncel gelişmelerin periodontolojide tanı, risk değerlendirmesi ve tedavi planlamasına yenilikçi yaklaşımlar kazandırdığı; klinik ve radyolojik verilerin yüksek doğrulukla analiz edilmesini sağlayarak periodontitisin erken teşhisine destek olduğu ve hastalık yönetiminde olumlu sonuçlar ortaya koyduğu belirtilmektedir.³

Öte yandan periodontitisin diabetes mellitus, respiratuvar ve kardiyovasküler hastalıklar gibi sistemik hastalıklarla bağlantılı olması genel sağlıkla ilgili multidisipliner yönünü ortaya koymaktadır.^{4,5,6,7} Bu durum sonucunda, periodontitis ve ilişkili sistemik hastalıkların, tedavi masraflarına ek olarak iş gücü kaybı nedeniyle sağlık sistemine ve ekonomiye ciddi bir yük getirdiği bildirilmektedir.⁸ Dünya Sağlık Örgütü'nün 2019 yılında yayımladığı Küresel Ağız Sağlığı Durum Raporu'na göre ağız içi hastalıkların küresel anlamda yıllık dolaylı maliyeti yaklaşık 323 milyar Amerikan doları olup bu miktarın 167 milyar dolarını total işsizlik, 82 milyar dolarını şiddetli periodontitis, 22 milyar dolarını daimi diş çürükleri, 1,5 milyar dolarını süt dişi çürükleri ve 50 milyar dolarını ise ağız kanserleri, ağız mukozası hastalıkları, travmalar ve temporomandibuler eklemler hastalıkları gibi diğer durumlar oluşturmaktadır.⁹

Periodontal hastalıkların teşhisinin kolay ve tedavisinin etkin bir şekilde gerçekleştirilebilir olması¹⁰, toplum ağız ve diş sağlığında sağlanacak iyileştirmelerle birlikte tedavi maliyetlerinin ve iş gücünde verimlilik kaybının azalmasına olanak sağlayarak önemli ekonomik faydalar getirebilir.¹¹ Yapay zekâ modellerinin klinik ve radyografik verileri analiz ederek periodontal hastalıkların değerlendirilmesinde deneyimli klinisyenlere yakın başarı gösterdiği^{12,13} ve klinik pratiğe adaptasyonu ile birlikte

tanı ve tedavide gereksiz uygulamaların önlenmesine, dolayısıyla sağlık alanındaki ekonomik yükün azaltılmasına katkı sağlayabileceği bildirilmektedir.¹⁴ Güncel derleme çalışmamızda amacımız, literatürde periodontoloji alanında fayda sağlayabilecek yapay zeka araştırmalarının değerlendirilmesidir.


Yapay Zeka ve Tarihsel Gelişim Süreci

Yapay zeka, insanın bilişsel yetilerini, algılama, akıl yürütme, problem çözme, öğrenme ve eyleme geçme gibi süreçlerini, belirli bir bağlama özgü verilerden türetilen örüntüler aracılığıyla hesaplama temelli teknolojilerle simüle eden insan üretimi bir yapı olarak tanımlanmaktadır.¹⁵ Bilim kurgu romanlarında makinelerin bilinç kazanabileceğine dair ilk düşüncelerin ardından, II. Dünya Savaşı sırasında *Enigma* kodunun çözümünde kullanılan Bombe adlı makinenin başarısı, Alan Turing'in makinelerin akıl yürütme kapasitesine sahip olabileceği yönündeki düşüncelerine zemin hazırlamıştır.¹⁶ Yapay zekâ kavramının teorik temelleri, 20. yüzyılın başlarında Alan Turing'in makinelerin insan gibi düşünebileceğini açıkladığı Turing testi ile atılmıştır.^{17,18} 1956 yılında ise Yapay Zeka Yaz Araştırma Projesi adlı atölye çalışmasında Marvin Minsky ve John McCarthy tarafından "yapay zeka" kavramı resmen tanımlanmıştır.¹⁹ 2000'li yıllara kadar durağan seyreden yapay zeka çalışmaları, 2006 yılında Geoffrey Hinton ve ark. tarafından ortaya atılan *Artificial Neural Network*-Yapay Sinir Ağı kavramıyla²⁰ hız kazanarak modern yapay sinir ağlarının temeli atılmıştır. 2012 yılında Alex Krizhevsky tarafından oluşturulan görsel bir veri tabanı kullanılarak eğitilen, çok sayıda gizli katman aracılığıyla görüntülerdeki örüntüleri tanıyarak yeni veri tanıma yeteneği kazanan bir derin öğrenme temelli evrişimli nöral ağ yapısına sahip olan AlexNet, görsel nesne tanıma veritabanı olan ImageNet yarışmasında büyük bir başarı elde etmiştir.²¹

Yapay Zeka, Makine Öğrenmesi ve Derin Öğrenme

Yapay zeka insanın bilişsel fonksiyonlarını taklit eden ve çeşitli veriler aracılığıyla öğrenme ve problem çözme yeteneği olan, makine öğrenmesini ve derin öğrenmeyi aynı çatı altında toplayan bir kavramdır. Makine öğrenmesi ve derin öğrenme "yapay zeka" kavramının kimi zaman birbiri yerine kullanılan fakat farkı anlamlara gelen iki

ayrı alt tipidir.²² Makine öğrenmesi, sunulan veri kümesi üzerinden belirli desenleri öğrenip görülmemiş verileri herhangi bir beşeri müdahale olmadan öğrendiği desenler üzerinden sonuç tahmini yapan yapay zeka modelidir.²³ Derin öğrenme ise makine öğrenmesinin bir parçası olup, nöral ağlar aracılığıyla insan beyninin analitik yönünü modelleyerek daha karmaşık veriler için yapay zeka modelleridir. (Şekil 1).



Şekil 1. Yapay zeka kavramları arasındaki hiyerarşik ilişki

Yapay Zeka: İnsan zekasını ve davranışlarını taklit eden en kapsamlı alandır.

Makine Öğrenmesi: Veriler üzerinden örüntüleri tanıyarak yeni girdilerle istenilen çıktıları sunar.


Nöral Ağ: Karmaşık desen ve veriler arasında ilişkiler kurarak daha kompleks analizler sağlar.

Derin Öğrenme: Öğrenme işleminin makineler tarafından kendi kendilerine büyük ve çeşitli veri setleri üzerinden gerçekleştirildiği modellerdir.

Temel olarak insan beynindeki nörona benzer görev üstlenen yapay nöronlardan (*perceptron*) oluşurlar.²⁴ Bu nöronlar bir giriş katmanı, birden fazla gizli katman ve bir çıkış katmanı olarak sıralanarak yapay sinir ağını oluştururlar (Şekil 2). Giriş katmanı, veriyi (örneğin bir görüntüyü) ağına içine alarak gizli katmanlara iletir. Gizli katmanlarda veri analiz edilir ve veriye ait çeşitli örüntüler tanınarak öğrenme süreci tamamlanır. Bu öğrenilen özellikler doğrultusunda, çıkış katmanı veriyi sınıflandırır veya bir tahminde bulunur.²⁵

Derin öğrenme modelleri kendilerine sunulan veri seti üzerinden kendi başlarına yeni desenler tanıyıp ve farklı modeller öğrenebilirken makine öğrenmesi modellerine yeni bir desenin elle girilmesi gerekmektedir. Dolayısıyla makine öğrenmesi modellerinin daha yoğun emek isteyen maliyetli süreçleri beraberinde getirdikleri söylenebilmektedir.²⁶

Bir makine öğrenmesi modeli yanlış bir tahmin yaptığında hatanın profesyoneller tarafından elle düzeltilmesi gerekirken derin öğrenme modelleri, elde ettiği sonucu kendi veri seti içerisinde sınavarak hatasını düzeltebilecek ve bir sonraki yinelemede doğru sonucu elde edebilecek algoritmaya sahiptir. Bu özelliği sebebiyle derin öğrenme modelleri, makine öğrenmesine kıyasla daha yüksek doğruluk oranı göstererek gerçek hayat senaryosunu daha iyi simüle edebilmektedir.²⁷ Ayrıca derin öğrenme, veri seti arttıkça daha verimli hale gelmesiyle ve kendisini eğitmek için veri setini kendi içerisinde sınamasıyla zaman ve maliyet anlamında makine öğrenmesinden ayrılmaktadır.²⁸ Derin öğrenme teknolojisinin mevcut dünyayı değiştirme kapasitesinde olduğunu, özellikle güçlü bir hesaplama motoru olarak teknoloji odaklı otomasyon, akıllı ve zeki sistemlere




Şekil 2. Derin öğrenme mimarisinin genel yapısı

katkıda bulunarak Endüstri 4.0'ın amacını gerçekleştirdiği sonucuna varmak mümkün görünmektedir.²⁹

Medikal alanda yapay zekanın en önemli kullanım alanlarından biri görüntü işlemedir. Bunun için özel bir derin öğrenme metodu olan *Convolutional Neural Network*-Evrişimsel sinir ağları (CNN) çeşitli radyografik görüntülerin yorumlanmasında kullanılmaktadır.³⁰ CNN, özel bir konvolüsyonel katman eklenmiş özel bir yapay zeka modelidir. Konvolüsyonel katman, kenarlar, şekiller, sınırlar ve renkler gibi spesifik özellikler üzerinden görüntünün yorumlanmasını sağlamaktadır.³¹

Sağlık Alanında Görüntü İşleme ve Model Oluşturma

Geçtiğimiz yıllarda yapay zekanın sağlık alanının çeşitli disiplinlerinde radyolojik görüntü işleme amacıyla kullanımı insan gözünün ötesinde bir bakış açısıyla daha yüksek hassasiyette sonuçlar elde edilmesine, daha az personel ve süreyle daha büyük miktarda verinin işlenmesine olanak vererek yeni bir dönemin başlamasına olanak vermiştir.³² Bu gelişmelerle birlikte, özellikle görüntü işleme odaklı çalışmalarda öne çıkan yapay zeka alt dallarından biri olan CNN'in, makine öğrenmesine kıyasla sunduğu algoritmik yaklaşımlar sayesinde



Şekil 3. Veri seti hiyerarşisi ve model eğitim süreci

Eğitim seti: Modele örüntüler üzerinden belirli konuda tahmin yapmayı öğretir.

Doğrulama seti: Eğitim sırasında aşırı uyum gibi durumları kontrol eder ve modelin performansını ölçer. Doğrulama seti, eğitim setinin bir parçasından oluşturulur.

Test seti: Modelin daha önce karşılaşmadığı verilerden oluşan ve ortaya konan modelin son performansını değerlendirir.

karmaşık içsel yapılar içeren radyolojik verilerle örüntüler oluşturarak yeni veri tahmininde daha üstün performans gösterdiği bildirilmiştir.³³

Bir CNN modelinin eğitimi boyunca 3 farklı veri seti (eğitim, doğrulama ve test) kullanılmaktadır (Şekil 3).²⁶ Eğitim setiyle modelin temel öğrenimi sağlandıktan sonra, kaynağı bilinen ancak modelin daha önce karşılaşmadığı verilerden oluşan doğrulama seti ile modelin doğruluğu ve aşırı uyum gösterip göstermediği değerlendirilerek en uygun model seçimi yapılır. Modelin son başarısını değerlendirmek için ise, eğitim sürecine dahil edilmemiş örneklerden oluşan test seti kullanılarak, modelin yeni veriler karşısındaki genelleme yeteneği ölçülür.

Pratikteki Zorluklar

Diş hekimliğinde dijital görüntülemenin teşhisten tedaviye kadar uzanan yolda hekime rehberlik etmesi ve hastaların birbirine benzer sebeplerle (çürük, kemik kaybı, apikal lezyon vs.) başvurması sebebiyle model eğitimi ve testi amacıyla kullanılacak veri setinin kolay bir şekilde oluşturulabilmesi yapay zekanın diş hekimliğinde efektif bir şekilde kullanılabileceği fikrini desteklemektedir.³³ Bunun yanı sıra diş hekimliğinde yapay zeka uygulamalarının rutin kullanılmasına zorluk oluşturan birtakım durumlar söz konusudur:

A. Veri seti oluşturmak (Yetersiz veri seti)

Çeşitli sektörlerde kullanılan yapay zeka modellerine kıyasla diş hekimliği alanında yüksek tahmin oranı göstermesi amaçlanan yapay zeka modellerinin sağlık sektöründe etik kaygıların getirdiği veri koruma gereksesi ve kurum & kuruluşların verileri bir arada kullanılmasına olanak vermeyecek şekilde izole hale getirmesi sonucu kısıtlı veri setiyle oluşturulabilmektedir. Bu limitasyonların yapay zeka öğrenme faaliyetlerini kısıtlayarak yeni veri yorumlama kabiliyetini olumsuz etkilediği bildirilmektedir.³⁴ Daneshjou ve ark.³⁵ tarafından yapılan bir çalışmada, deri hastalıklarını ele alan yapay zeka modellerinin kullanıldığı 70 çalışmada kullanılan toplam 1,065,291 görüntünün yalnızca %24,2'sinin kamuya açık olduğu belirtilmiştir.

B. Aşırı Uyum (overfitting) ve Genellenebilirlik Eksikliği

Aşırı uyum, algoritmanın yüksek doğruluk oranı göstermesine sebep olacak yaygın özellik gösteren

veri grubu üzerinden eğitilerek daha önce görülmemiş, ilginç veriler karşısında belirsiz sonuç göstermesi olarak tanımlanmaktadır.³⁶ Böylelikle model, eğitim verilerine benzer girdiler için yüksek performans gösterirken, farklı veriler için düşük performans göstermektedir. Bu durumu engellemek için örneklem büyüklüğü artırılması, veri seti çeşitlendirilmesi (döndürme, ölçekleme ve gürültü ekleme vs.) ve model mimarisindeki karmaşıklığın azaltılması önerilmektedir.³⁷

Ulaşım, nüfus (yaş, cinsiyet, dental ve tıbbi durum) ve veri kaydı (görüntü kalitesi, görüntü elde etme yöntemi vb.) kaynaklı sorunlar sebebiyle çoğunlukla tek merkezli yürütülen yapay zeka çalışmaları yetersiz veri sebebiyle kısıtlı genellenebilirlik göstererek farklı bir veri grubu üzerinde düşük tahmin başarıyla sonuçlanmaktadır.³⁸ Oluşturulmak istenen algoritma için hedef kitlenin belirlenmesinin, veri seti dağılımının (eğitim ve test) buna göre hazırlanmasının, dahil edilen hasta profilinin sosyoekonomik ve sosyokültürel olarak varyasyon göstermesiyle veri setinin çeşitlendirilmesinin ve çalışmalarda çok merkezli bir şekilde veri güvenliğini koruyarak farklı merkezler arasında oluşturulan veri havuzlarının kullanılmasının tahmin başarısını artırdığı bildirilmektedir.^{39,40}

C. Yapay Zeka ve Yasal Yükümlülükler

Son yıllarda yapay zeka teknolojilerinin sağlık alanındaki hızlı gelişimi ve klinik uygulamalardaki kazanımları dikkat çekmekle birlikte, bu teknolojilerin kullanımına eşlik eden etik sorunlar ve potansiyel riskler de önem kazanmaktadır. Yapay zekanın hatalı önerilerde bulunarak hekimin karar alma sürecini zorlaştırması, elde edilen sonuçların klinisyen tarafından yanlış yorumlanması ya da yeterince anlaşılamaması, donanım kaynaklı arızalar nedeniyle hatalı çıktılar üretilmesi ve hastaların yapay zeka destekli önerilere gereken önemi göstermemesi gibi durumlar ortaya çıkan sonuçlardan kimin sorumlu olacağı konusunda belirsizlik yaratmaktadır. Bu bağlamda, hekim, hasta, sağlık kurumu, yazılım geliştirici ve üretici firma arasındaki hukuki ve etik sorumlulukların sınırlarının netleştirilmesi gerekmektedir.⁴¹ Günümüzde hekimi bütünüyle egale ederek klinik süreci tek başına yöneten otonom sağlık hizmetleri, gelişmiş ve güvenilir olmaması sebebiyle faaliyet göstermiyor olsalar da ilerleyen dönemlerde ortaya çıkabilecek potansiyel hataların veya

yan etkilerin hukuki boyutunu değerlendirilmesi, insan ve makine arasındaki hukuki sorumluluk paylaşımının belirsizliğini aydınlatılması açısından yasal regülasyonlarla birlikte yeni yönetmeliklerin ve buna uygun bilirkişilerin faaliyet göstermesi gerekeceği düşünülmektedir.⁴²

Yapay Zeka Kullanımının Sağladığı Avantajlar

Yapay zekanın tıbbi ve dental sağlık hizmetlerine entegre edilmesi birçok disiplinde tanı ve tedaviye yaklaşım açısından postoperatif komplikasyon riskini azaltarak, daha iyi karar almayı sağlayarak ve gereksiz prosedürlerin eliminasyonu sayesinde hasta başı süreyi azaltarak bir devrim yaratmasıyla geçtiğimiz son yıllarda popülerliği ciddi anlamda artmıştır.^{43,44} Yapay zeka uygulamaları, teşhis doğruluğunu artırma, tedavi planlamasını optimize etme ve sonuç değerlendirmesini kolaylaştırma gibi pratiklerle diş hekimliği alanında köklü dönüşümlere olanak sağlamaktadır.⁴⁵ Gelişmiş makine öğrenmesi algoritmaları, hastalara ait klinik, radyografik ve üç boyutlu görüntüleme verilerini içeren büyük veri kümelerini yüksek bir doğrulukla analiz ederek dental hastalıkların erken tespitine olanak tanımakta; ayrıca programlama, hasta kayıt yönetimi ve yapay konsültasyon süreçleriyle klinik verimliliğine önemli katkı sağlamaktadır.⁴⁶ Oluşturulan birçok model diş hekimliğinin farklı alanlarında yüksek doğruluk, özgüllük ve duyarlılık göstermiştir.⁴⁷

Yapay Zeka Modellerinin Değerlendirilmesinde Kullanılan Temel Ölçütler

Yapay zeka uygulamalarını anlamak ve literatürde sunulan sonuçları eleştirel bir bakış açısıyla değerlendirebilmek için, bu modellerin performansını ölçmede kullanılan temel değerlendirme metriklerinin bilinmesi büyük önem taşımaktadır. Yapay zeka çalışmalarında F1 skoru, modelin yanlış pozitif ve yanlış negatif tahminleri en aza indirirken doğru pozitif tahminleri artırma yeteneğini dengelemek için kullanılan bir metrik değeridir. F1 skorunun 1 olması ideal dengeyi temsil ederken, 0 en düşük skordur.⁴⁸ Eğri altındaki alan (AUC) ise oluşturulan tanısıl araçların karşılaştırılması için kullanılan matematiksel bir ifadedir. Sonucun 1'e yakın olması oluşturulan yeni modelin referans alınan materyale yakın sonuçlar verdiğini ifade etmektedir.⁴⁹

Dice-Sørensen katsayısı (DSC) ise iki örnek arasındaki benzerliği ölçmek amacıyla kullanılan istatistiksel bir yöntemdir. Buna göre sonuç 1'e yaklaştıkça karşılaştırılan iki görüntünün birbirine benzerliği artmaktadır.⁵⁰

Periodontolojide Yapay Zeka Uygulamaları

1. Periodontal hastalık teşhisi

Radyografiler ve intraoral görüntüler üzerinden mikrobiyal dental plağın ve hiperemi, ödem gibi enflamatuvar belirteçlerin görsel teşhisinin yapılabilceği düşüncesiyle yapay zeka modellerinin periodontal hastalıkların teşhisinde kullanılarak yüksek doğruluk ve güvenilirlikle klinisyene tanıda yardımcı olması hatta hastanın kendi kendisini muayene etmesine olanak sağlayabilmesi literatürde ileri sürülmüştür.⁵¹ Tablo I periodontal hastalıkların teşhisi üzerine yapılan yapay zeka araştırmalarını göstermektedir. 567 adet ağız içi fotoğraf kullanılarak oluşturulan derin öğrenme modelinin gingival enflamasyonu sınıflandırıldığı (sağlıklı, şüpheli ve hastalıklı) bir çalışmada⁵² ise oluşturulan model diş etini hastalıklı ve sağlıklı olarak 98,38% oranında doğruluk oranıyla sınıflandırmıştır. Chau ve ark. yürüttüğü başka bir çalışmada ise cep telefonu üzerinden kullanılan tele-diş hekimliği aracı olan derin öğrenme temelli bir program (*GumAI*), gingivitis teşhisinde uzman periodontologların değerlendirmeleriyle karşılaştırılmıştır. Sonuç olarak, uzman periodontologlarla karşılaştırıldığında %85 doğruluk ve 0,91 F1 skoru ile başarılı bir performans sergileyen derin öğrenme temelli tele-diş hekimliği uygulamasının (*GumAI*), kişiselleştirilmiş ağız hijyeni önerileri ve hastalıklı dişeti bölgelerinin görsel olarak gösterilmesi sayesinde bireylerin sorunlu alanları daha iyi algılamalarına ve öz-bakımlarını geliştirmelerine katkı sağladığı; bu nedenle katılımcıların %100'lük olumlu geri bildirim verdiği bildirilmektedir. Ayrıca, bu yüksek kabul düzeyinin, ağız ve diş sağlığı hizmetlerine erişimde zorluk yaşayan bireyler açısından tele-diş hekimliği uygulamalarının uygulanabilirliğini ve sürdürülebilirliğini göstermesi bakımından önemli olduğu bildirilmektedir.⁵³ Daha geniş bir veri seti kullanarak (683 intraoral görüntü) 4 farklı yapay zeka modeli üzerinden yapay zekanın intraoral görüntülerden gingivitis teşhisi koyma başarısını değerlendiren bir çalışmada oluşturulan modellerin %85 ila %92 doğruluk oranıyla tanı koyabildiği ortaya koyulmuştur. Oluşturulan modelin klinisyenlerin

periodontal hastalık teşhisini kolaylaştırabilmesine ek olarak hastaların mobil uygulamalar aracılığıyla kendi kendilerini muayene etmesine olanak sağlayabileceği belirtilmektedir.⁵⁴

2. Periodontal hastalığın sınıflandırılması

Periodontal hastalıkların sınıflandırılmasına yönelik yapay zeka araştırmaları Tablo II'de verilmiştir. Papantonopoulos ve ark.⁵⁵ yaptığı bir çalışmada oluşturulan yapay zeka modeli daha önce yapılmış 4 farklı çalışmaya dahil edilen şiddetli periodontitis hastalarından elde edilen klinik (radyografik kemik kaybı) ve immünolojik veriler (periferik kandaki monosit, lenfosit, bazofil, nötrofil ve eozinofil & CD3, CD4, CD19 hücrelerinin toplam sayıları ve CD4/CD8 oranı) üzerinden hastalığın kronik periodontitis (KP) veya agresif periodontitis (AgP) olarak sınıflandırılmasında 90%-98% oranında doğruluk göstermiştir. Benzer şekilde, yapay zekanın anket verileri, fırçalama sonrası sondalamada kanama indeksi ve tükürük biyomarkerları (aMMP-8) kullanılarak periodontal sağlığın, gingivitisin ve periodontitisin farklı evrelerini yüksek doğruluk oranıyla ayırt edebildiği bildirilmiştir.⁵⁶

Yapay zeka modelleri, 2017 yılında güncellenen periodontal hastalıkların evrelendirme ve derecelendirme sistemine uyumlu olarak geliştirilmiş; bu yeni sınıflama doğrultusunda teşhis ve evrelendirme sürecini destekleyecek çeşitli yaklaşımlar sunmuştur. Yapay zeka aracı kullanılarak 2000 adet panoramik görüntü üzerinden diş, mine sement hududu ve kret tepesi etiketlemesinin ve kemik kaybının belirlenerek periodontitisin evrelendirilmesinin değerlendirildiği bir çalışmada⁵⁷, geliştirilen model, diş etiketlemesi için %97, sementoenamel birleşim ve kret tepesi etiketlemesi için %98 doğruluk oranı göstermiştir. Evrelendirme için modelin %94,4 doğruluk oranı göstermesiyle beraber genel diş hekimi %86,7, periodontolog %91,1 doğruluk oranı göstermiştir. Bir başka çalışmada, klinik veriler (cinsiyet, yaş, sigara kullanımı, plak indeksi, sondalamada kanama, klinik ataşman kaybı ve cep derinliği) kullanılarak modelin periodontal hastalığı %84,2 oranında doğruluk göstererek evrelendirdiği bildirilmiştir.⁵⁸

3. Risk tahmini, prognoz tahmini ve tedavi planlaması

Objektif parametreler kullanılarak önceden

oluşturulmuş kontrol listelerinin medikal alanda rutin kullanımı hastalığın teşhisi, progresyonu ve uygulanacak tedavinin yönlendirilmesi açısından güvenli ve kaliteli bir sağlık hizmetinin verilmesine olanak sağlamaktadır.⁵⁹ İlgili parametrelere ait verilerin yapay zeka algoritmalarına sunulması, süre kazanımına ek olarak klinik deneyimi az olan hekimlerin çeşitli kontrol listelerini daha verimli bir şekilde kullanılmalarına olanak sağlayabileceği bildirilmektedir.⁶⁰ Konuyla ilgili literatür Tablo III'de özetlenmiştir.

1740 periapikal görüntü kullanılarak geliştirilen yapay zeka modelinin diş prognozu belirleme başarısı, 3 uzman periodontolog tarafından periodontal hastalığın şiddetinin hafif, orta ve şiddetli olarak sınıflandırılması referans olarak alınarak değerlendirilmiştir. Modelin premolarların prognozu için %81,0 oranında, molarlar için %76,7 oranında doğruluk gösterdiği ve kötü prognoz gösteren premolar dişler için çekim endikasyonunu %82,8 oranında, molarlar için %73,4 oranında tahmin başarısı göstermiştir.⁶¹ 94 hastaya ait 2359 adet dişin dahil edildiği bir başka çalışmada deneyimli klinisyenlerin ve farklı disiplinlerden (protetik diş tedavisi, periodontoloji, endodonti, ortodonti ve ağız, diş ve çene cerrahisi) hekimlerin oluşturduğu altın standart prognoz belirteci referans alınarak 17 farklı parametre üzerinden (tıbbi ve dental anamnez, ekstraoral ve intraoral muayene, radyografik inceleme ve periodontal, endodontik, protetik ve ortodontik durumlar) 3 farklı yapay zeka modelinin diş prognozunu (1'den 5'e kadar; 1: umutsuz diş ve 5: sağlıklı diş) en düşük %66,87, en yüksek % 84,13 oranında doğru tahmin ettiği bildirilmiştir.⁶²

Klinik ve hasta bildirimiyle elde edilen sözel verilerle periodontal hastalığa yakalanma riski veya mevcut periodontal hastalığın prognozu değerlendirilerek tedavi önerilerinde sunulabilir.⁶³ Lang ve Tonetti'nin ortaya koyduğu 6 parametreye dayanarak geliştirilen Periodontal Risk Değerlendirmesi (PRD) isimli algoritma (%BoP, %PD $\geq$ 5mm, eksik diş sayısı, alveolar kemik kaybı yüzdesi %, diabetes mellitus ve İnterlökin-1 polimorfizmi gibi periodontal hastalığın duyarlılığını etkileyecek sistemik rahatsızlıkları ve sigara tüketim alışkanlıkları) periodontal hastalığa dair risk, prognoz belirlemesi ve tedavi önerisi yapabilmekte ve günümüz periodontoloji klinik pratiğinde kullanılmaktadır.⁶³ Benzer şekilde, *International Team for*

Implantology-Uluslararası İmplantoloji ekibi tarafından geliştirilmiş olan *SAC Classification in Implant Dentistry*-İmplant Diş Hekimliğinde SAC Sınıflandırması isimli kılavuzda da hastanın tıbbi, dental ve çevresel verilerine dayanarak objektif kriterlerle dental implant tedavisinin cerrahi ve protetik açıdan basit, ileri veya kompleks olarak sınıflandırarak tedavide standardizasyonun sağlanması amaçlanmaktadır.⁶⁴ Kılavuz her hasta için standart bir değerlendirme olan genel belirteçler (estetik risk, tedavi sürecinin karmaşıklığı ve komplikasyon riski) modifiye edici faktörler (genel, estetik, cerrahi ve restoratif durumlar) tanımlanmaktadır. "SAC Değerlendirme Aracı" ise SAC Sınıflandırması referans alınarak oluşturulan bir bilgisayar algoritması olup hastaya ait parametrelerin sisteme girilmesiyle mevcut tedavinin karmaşıklığı ve risk faktörleri hakkında hekime anında bilgi sunma özelliği ile öne çıkmaktadır. Bu bağlamda, Correia ve ark.⁶⁵ 30 hastaya ait 104 dişsiz bölgenin dahil edildiği bir çalışmada implant cerrahisinin SAC Değerlendirme Aracı kullanılarak farklı tecrübeye ve yeterlilik seviyesinde olan klinisyenler arasındaki uyumu değerlendirmişlerdir. Çalışmada, SAC uygulamasının klinik deneyimi kıyasla az olan hekimlerin cerrahi işleme karar verme başarısını artırdığı ve uygulamanın tecrübesiz hekimlerin uyguladıkları tedaviyi iyileştirebileceği bildirilmiştir. Cerrahisiz periodontal tedavi sonrasında ortalama 9.5 $\pm$ 4.5 yıl destekleyici periodontal tedavi sürecinde olan 160 hastanın PRD aracıyla periodontitis prognozu ve diş kaybı arasındaki ilişkisinin değerlendirildiği bir çalışmada hastanın PRD tarafından belirlenen risk durumunun (düşük, orta ve yüksek) periodontitis ilerlemesi ve diş kaybı açısından anlamlı şekilde ilişkili olduğu sonucuna varılmıştır.⁶⁶ Başka bir çalışmada ise cerrahisiz periodontal tedaviden 5-17 yıl sonra değerlendirilmeye alınan agresif periodontitis tanısı almış 86 hastanın PRD aracına göre risk profilleri belirlenerek destekleyici periodontal tedaviye uyumları değerlendirilmiştir. İnterlökin-1 polimorfizmi kriteri dışı tutulduğunda PRD aracının diş kaybı üzerindeki etkisine dayanarak istatistiksel olarak anlam gösterdiği ve bu şekilde agresif periodontitis hastalarının farklı risk gruplarına ayrılabilceği sonucuna varılmıştır.⁶⁷

Yapay zekanın implant prognozunun değerlendirildiği bir çalışmada ise, Tablo III'te materyal kısmında belirtilen çeşitli hasta parametreleri bir araya getirilip analiz edilerek,

tek implantın sağ kalım oranı için %94,48 test doğruluğu gösteren bir yapay zeka algoritması geliştirilmiştir.⁶⁸

4. Uzaktan izleme ve Hasta Kooperasyonu

Periodontal hastalığın takibinin yapılabilmesi ve hasta uyumunun değerlendirilebilmesi için geçmişten bu yana çeşitli dijital araçlar geliştirilmektedir.^{69,70} Geçmiş çalışmalar dijital görüntülerin de bu anlamda kullanılabileceğini göstermektedir.^{71,72} Hastaya ait klinik verilerin ve görsellerin yapay zeka algoritmalarına yüklenmesiyle hastanın kendi kendini izlemesine ve klinisyenin hastayı uzaktan takip etmesine olanak sağlayabileceği dental izleme sistemlerinin belirli önerilerle, hatırlatmalarla, arşivleme ve hekime takip olanağı sunmasıyla özellikle hekime ulaşamayan bireylerde dental farkındalık düzeyinde artışa, zaman kazanımına ve erken teşhise olanak sunduğu belirtmektedir.⁷³ Günümüzde ağız içi görüntülerle beraber periodontal tedavi sonuçlarının ve etkinliğinin izlemine sağlayan yapay zeka araçlarının kullanımı literatürde göze çarpmaktadır (Tablo IV).

Snider ve ark. tarafından yürütülen çalışmada, ortodontik tedavi gören bireylerin periodontal bulgularının yapay zeka destekli *Dental Monitoring* sistemiyle uzaktan izlenmesi değerlendirilmiştir. Çalışmada, sistemin plak birikimi, gingival inflamasyon ve diş eti çekilmesi gibi parametreleri tespit etmedeki performansı incelenmiştir. Elde edilen sonuçlar, *Dental Monitoring* sisteminin mevcut periodontal bozuklukları belirlemede sınırlı duyarlılığa sahip olduğunu, ancak sağlıklı durumları doğru bir şekilde tanımlamada yüksek düzeyde güvenilirlik sunduğunu ortaya koymuştur.⁷⁴ Bu bulgular, yapay zekaya dayalı dijital takip sistemlerinin hasta kooperasyonunu artırma ve hekime ulaşmanın zor olduğu durumlarda takip sürecine katkı sağlama potansiyelini desteklemektedir.

Bir başka çalışmada periodontitis hastalarının 3 aylık süre boyunca haftada bir kez akıllı telefon aracılığıyla yapay zeka destekli diş izleme uygulaması cerrahisiz periodontal tedavi sonrası periodontal verilerdeki (sondalanan cep derinliği, klinik ataşman seviyesi ve plak indeksi) değişime etkisi araştırılmıştır. Hastalar yalnızca uygulamayı kullanan (AI n=16), uygulamaya ek olarak klinik danışmanlık alan (AIHC n=17) ve kontrol grubu (CG n=20) olarak üçe ayrılmıştır. 3 ayın sonunda elde edilen sonuca göre AI ve AIHC gruplarında kontrol grubuna kıyasla periodontal veriler açısından iyileşme

gözlenmiştir; AIHC grubunda AI grubuna kıyasla sondalamada cep derinliğinde daha büyük bir azalma ve klinik ataşman seviyesinde daha büyük bir iyileşme gözlenmiştir.⁷⁵ Bu bulgular ışığında, yapay zeka destekli dijital izleme uygulamalarının cerrahisiz periodontal tedavi sonrası klinik iyileşmeyi destekleyici etkisi olduğu görülmekle birlikte, uygulamanın motivasyon artırıcı yönüyle beraber, katılımcıların gözlemlendikleri algısıyla ortaya çıkan davranış değişikliklerini tanımlayan “*Hawthorne etkisi*”ne benzer bir durumun da sonuçlarda rol oynayabileceği öngörülmektedir.⁷⁶

Balaci ve ark. intraoral fotoğraflar kullanarak yaptıkları 2 aşamalı çalışmalarında iki farklı durumu derin öğrenme ile değerlendirmişlerdir. İlk aşamada 20 hasta üzerinden periodontal hastalığın tespit edilebilirliğini, ikinci aşamada ise 24 hasta üzerinden cerrahisiz periodontal tedavi görmüş hastaların tedavi öncesi ve sonrası durumlarının karşılaştırılarak periodontal hastalığın progresyonunun tahmin edilebilirliğini test edecek 2 adet derin öğrenme modeli geliştirilmiştir. Modeller, periodontal hastalığı %66,7 doğruluk oranı gösterirken, tedavi öncesi-sonrası fotoğraflar üzerinden periodontal tedavinin ilerlemesini ölçmede %91,6 doğruluk oranı göstermiştir.⁷⁷

5. Kişiselleştirilmiş Sağlık Uygulaması

Periodontal hastalığın tedavisinde, yalnızca disbiyotik mikrobiyal dental plakla mücadelede odaklanan geleneksel yaklaşımdan öteye geçilerek; hastanın genetik, fenotipik, biyomoleküler ve psikososyal özellikleri dikkate alınarak, risk faktörleri ile klinik ve moleküler belirteçler de değerlendirilir. Bu kapsamda, hastayı sağlık hizmetinin aktif bir parçası haline getiren, öngörülü, önleyici, kişiselleştirilmiş ve katılımcı bir yaklaşım sunan P4 kavramı geliştirilmiştir.^{78,79} Diş hekimliğinde hastaya ait tıbbi ve dental verilere ek olarak kişiselleştirilmiş mikrobiyom, metabolom ve proteom gibi omik verilerin oluşturduğu geniş veri setleri hassas hasta yönetiminin (P4) sağlanmasını kolaylaştırabilmektedir.⁴⁴

Periodontal hastalıklarla mücadelede karşılaşılan zorluklardan en önemlileri hastalığın yalnızca bir patojene bağlı değil birbiriyle etkileşim içerisinde olan birden fazla patojen mikroorganizmanın içinde bulunduğu disbiyotik ortamdan kaynaklanması ve disbiyozun ve hastalığın hastadan hastaya göre farklı şiddette olması olarak sıralanabilmektedir.⁸⁰ Bu sebepten dolayı tek bir metabolit

veya patojenden ziyade konağın sağlıklı durumundan hastalık durumuna geçiş sürecindeki metabolit ve patojen motiflerine odaklanmak önem arz etmektedir.⁸¹ Bu anlamda sağlık politikaları belirleyicilerinin diş hekimleriyle tıbbın farklı disiplinlerini (immünoloji, endokrinoloji, kardiyoloji gibi) bir araya getirerek yapay zeka destekli kişiselleştirilmiş teşhis araçlarının klinik pratiğe entegrasyonu sağlaması gerektiği fikri ortaya çıkmaktadır.⁸²

Tükürük biyobelirteçleri kullanılarak yapay zeka aracılığıyla çeşitli rahatsızlıkların tahmininin değerlendirilmesi mümkündür.⁸³ Eriksson ve ark.⁸⁴ romatoid artrit (RA) olan ve olmayan periodontitis hastaları üzerinden mikrobiyom ve proteom markerları aracılığıyla bilgisayar algoritması kullanarak RA ve periodontal tanı arasındaki ilişkiyi değerlendirmiştir. Sonuç olarak mikrobiyota ve konak medyatörlerinin kombine biçimde değerlendirilmesi, mikrobiyota ve konak medyatörlerinin tek başına değerlendirilmesine göre periodontitis ve RA arasındaki ilişkiyi daha iyi açıklayacağı ifade edilmiştir. Bu bulgular, yalnızca RA özelinde değil, sistemik hastalıklarla ilişkili tüm periodontal durumlarda klasik yaklaşımların yetersiz kalabileceğini; bireyselleştirilmiş mikrobiyom-konak etkileşimlerinin analizine dayanan ve yapay zeka destekli çok boyutlu tanı modellerinin periodontal tıpta yeni bir paradigmayı mümkün kılabilceğini ortaya koymaktadır.

6. Alveol kemik kaybı tespiti

Yapay zekanın 12,719 panoramik görüntü kullanılarak periodontal kemik kaybının teşhis başarısının değerlendirildiği bir çalışmada yapay zeka modeli için F1 skoru 0,75; çalışmaya dahil edilen 5 klinisyenin ortalama F1 skoru ise 0,69 olarak bulunmuştur.⁸⁵ Oluşturulan modelin klinisyenlere kıyasla daha üstün performans sergileyerek periodontal kemik kaybı teşhisini kolaylaştıracağı ve iş yükünü azaltarak klinik pratiğe önemli faydalar olabileceği bildirilmektedir. Radyografik kemik kaybının belirlenmesinin hedeflendiği başka bir çalışmada kemik kaybının belirlendiği önceki çalışmalara kıyasla modelde optimizasyonlar gerçekleştirilerek doğruluk oranı %76,2 olarak bulunmuştur.⁸⁶ Diğer bir çalışma ise 640 panoramik görüntü üzerinden yapay zekanın kemik kaybını belirlemesi değerlendirilerek doğruluk oranı farklı diş bölgelerinde değişmekle birlikte ortalama %77 olarak

bulunmuştur ve modelin genel diş hekimlerine kıyasla daha üstün başarı gösterdiği tespit edilmiştir.⁸⁷ 1121 panoramik görüntünün kullanıldığı bir başka çalışmada, kemik kaybını belirlemek için geliştirilen yapay zeka modeli için F1 skoru total kemik kaybı tespiti için 0,994, horizontal kemik kaybı tespiti için 0,943, vertikal kemik kaybı tespiti için 0,673 ve furkasyon bölgesindeki kemik kaybı tespiti için 0,912 olarak bulunmuştur.⁸⁸ Tablo V'de özetlenen tüm bu çalışmalar, yapay zeka tabanlı modellerin periodontal kemik kaybının teşhisinde hem doğruluk hem de hız açısından yüksek potansiyele sahip olduğunu, bu teknolojilerin klinik karar süreçlerine entegre edilmesinin periodontal tanıda yeni bir dönemi başlatabileceğini göstermektedir.

7. İmplant marka/modelinin belirlenmesi

Ticari olarak, dental implant pazarı içinde farklı markaların bulunduğu geniş bir hacme sahiptir. İmplant ve bileşenleriyle ilgili herhangi bir sorunu çözmek amacıyla ve yapılan protetik, cerrahi veya periodontal işlemlerin sağlıklı bir şekilde yapılabilmesi adına kullanılan implantın markası dahil olmak üzere uzunluğu, çapı, platformu ve abutment tipi gibi özelliklerin bilinmesi gerekmektedir. Çeşitli sebeplerden dolayı implant markasına dair herhangi bir bilgiye ulaşılmadığı durumlarda yapay zeka uygulamalarının bu konuda klinisyene yardımcı olabileceği düşünülmektedir.⁸⁹ Bu konuyla ilgili yapılan çalışmaların özeti Tablo VI'da sunulmuştur.

12 implant markasıyla 9767 panoramik görüntü üzerinden markanın ve implant tedavisinin hangi aşamada olduğunu belirleyebilen yapay zeka algoritmasının başarısının değerlendirildiği bir çalışmada algoritmanın başarılı sonuçlar gösterdiği bildirilmektedir.⁹⁰ Lee ve ark.⁹¹ 156,965 panoramik ve periapikal görüntü üzerinden 10 farklı üreticinin 27 farklı implant tipini tanıyabilen bir yapay zeka algoritmasını geliştirdiği bir çalışmada ise implant markasının 586 adet bozuk (düşük kaliteli, yabancı cisim içeren, radyasyona aşırı maruz kalmış vs.) radyografik film üzerinden tahmin başarısı değerlendirilmiştir. Sonuç olarak periodontoloji uzmanının yaptığı incelemede doğruluk oranı %37,2±29,0% iken geliştirilen modelin %95,05 oranında doğruluk gösterdiği bildirilmiştir. 116,756 panoramik ve 40,209 periapikal radyografik görüntünün kullanıldığı başka bir çalışmada ise 10 üreticiye ait 27 farklı implant sistemini tanımak

için geliştirilmiş yapay zeka modeli sadece panoramik görüntüler kullanılarak %85,20, sadece periapikal görüntüler kullanılarak %84,40 ve her iki görüntüleme tipi kullanılarak %85,70 doğruluk oranı elde edilmiştir.⁹² Hsiao ve ark.⁹³ ise 336 periapikal film kullanarak yaptığı bir çalışmada 3 farklı implant markası olmak üzere toplam 788 implant görüntüsü üzerinden 10 farklı yapay zeka mimarisi aracılığıyla implant markasının ve tipinin tahmin başarısını değerlendirmiştir. Sonuç olarak en düşük doğruluk oranı %81,89 iken en yüksek doğruluk oranı 0,2 saniyeden kısa bir süre içerisinde olmak üzere %96,85 olarak bulunmuştur.

8. Yapay Zeka Destekli İmplant Planlaması

Konik ışınli bilgisayarlı tomografi taramaları (CBCT), dental implant tedavilerinin planlanması için günümüzde kabul görmüş bir radyografik yöntemdir. Yapay zeka algoritmalarının CBCT taramalarının yorumlanması, anatomik yapıların tanınması ve implant planlamasında zorluklarla karşılaşan klinisyenler için büyük miktarda veriyi analiz edebileceği bildirilmektedir.⁹⁴ Bu amaçla geliştirilen yapay zeka modellerine yönelik çalışmalar Tablo VII’de özetlenmektedir. Yapay zeka destekli implant tedavisi planlanması ve uygulanması konusunda algoritmaların güvenilirliğini in vitro olarak belirlemek amacıyla ve Chen ve ark.⁹⁵ yaptığı bir çalışmada derin öğrenme modellerinin yaptığı analizler aracılığıyla dişsiz alveolar kret üzerinde ideal implant pozisyonunun belirlenebileceği ortaya koyulmuştur. Bir başka çalışma, implant yerleştirme protokolünün belirlenmesi için bir YZ modeli geliştirmek amacıyla CBCT taramalarının kullanılıp 14 klinisyenin el hissiyatı ve tomografik veriler referans alınarak oluşturulan YZ algoritması yeterli primer stabiliteyi elde etmek amacıyla ameliyat öncesi durumu değerlendirip uygulanması gereken implant protokolünü %93,8 doğruluk oranıyla başarılı bir şekilde aktardığı bildirilmiştir.⁹⁶ Mandibular kanalın anterior loop gibi varyasyonları da dikkate alınarak yapılan bir çalışmada mandibular kanalın belirlenmesi ve segmentasyonu amacıyla bir yapay zeka algoritması geliştirilmiştir. Oluşturulan algoritma anterior loop varyasyonundan bağımsız olarak mandibular kanalı 0,997, anterior loop varlığında mandibular kanalı 0,998 doğruluk oranıyla başarılı bir şekilde belirlemiştir.⁹⁷ Mandibulada dişsiz alveolar kretin sınırlarının belirlenmesini ve

segmentasyonunu sağlayan bir başka çalışmada yapay zeka algoritması geliştirilmiştir. Elde edilen sonuca göre manuel segmentasyonla kıyaslandığında DSC değeri 0,78 olarak hesaplanmış olup geliştirilen modelin başarılı olduğu ve ortaya koyulan otomasyon sayesinde süre ve maliyet anlamında ciddi kazanımlar elde edileceği ifade edilmektedir.⁹⁸

Bayrakdar ve ark.⁹⁹ yaptığı bir çalışmada CBCT görüntüleri kullanılarak geliştirilen yapay zeka modelinin implant tedavisi planlamasında kemik yüksekliğini, kalınlığını ve anatomik bölgeleri belirlemesi değerlendirilmiştir. Model ölçümleri ve manuel ölçümler arasında kemik yüksekliğinin belirlenmesinde önemli bir fark yokken, kemik kalınlığının belirlenmesinde istatistiksel olarak bir fark olduğu ve manuel ölçümlerin daha tutarlı olduğu bulunmuştur. Mandibular kanalın, sinüslerin ve dişsiz alveol kretinin belirlenmesinde ise doğruluk oranı sırasıyla %72,2, %66,4 ve %95,3 olarak bildirilmiştir.

Sonuç

Yapay zekâ teknolojileri, Periodontoloji alanında tanıdan tedaviye birçok klinik süreci dönüştürme potansiyeline sahiptir. Güncel literatür, özellikle görüntü işleme, hastalık sınıflandırması, tedavi planlaması ve uzaktan takip gibi alanlarda yüksek doğruluk oranlarıyla umut verici sonuçlar sunmaktadır. Bununla birlikte, sınırlı veri çeşitliliği, etik belirsizlikler ve genellenebilirlik sorunları, klinik entegrasyonda dikkatle ele alınması gereken başlıca engellerdir. Gelecekte çok merkezli, kapsayıcı ve etik temelli çalışmalarla bu teknolojilerin periodontal pratiğe güvenli ve etkili bir biçimde entegre edilmesi mümkün görünmektedir.

Tablo I. Periodontal Hastalık Teşhisi

Yazar	Yıl	Ülke	Metot	Materyal	Eğitim Seti	Kullanılan Mimari	Performans Ölçümleri ve Sonuçları
Askerian ve ark.	2019	ABD	Ağız içi görüntüler kullanarak gingivitis teşhisi	Ağız içi fotoğraflar	30	SVM	Doğruluk oranı: 94,3%
Chau ve ark.	2023	Çin	Ağız içi görüntüler kullanarak gingivitis teşhisi	Ağız içi fotoğraflar	567	DeepLabv3	Duyarlılık: 0,92 Özgüllük: 0,94
Li ve ark.	2024	Çin	Çeşitli yapay zeka modelleri kullanarak ağız içi görüntüler üzerinden gingivitis tanısı	Ağız içi fotoğraflar	683	AlexNet, VGG, GoogleNet, ResNet	F1 Skorları AlexNet: 0,95 VGGNet: 0,93 GoogLeNet: 0,92 ResNet: 0,90
Chau ve ark.	2025	Çin	Yaşlı bireylerde ağız içi görüntüler kullanarak gingivitis teşhisi	Ağız içi fotoğraflar	454	ANN	Doğruluk oranı: 85% F1 Skoru: 0,91

Tablo II. Periodontal Hastalık Sınıflandırılması

Yazar	Yıl	Ülke	Metot	Materyal	Eğitim Seti	Kullanılan Mimari	Performans Ölçümleri ve Sonuçları
Papantonopoulos ve ark.	2014	ABD	İmmünolojik belirteçler üzerinden agresif ve kronik periodontitis sınıflaması	OPG Periferik kan sayımı CD3, CD4 ve CD19	Daha önce 4 farklı çalışmaya dahil edilen 347 periodontitis hastası	U-Net	Doğruluk oranı: 90%-98%
Ossowska ve ark.	2022	Polonya	Demografik ve klinik veriler kullanılarak periodontitisin derece ve evrelendirilmesi	Cinsiyet Yaş Sigara tüketimi Plak/Kanama indeksi Klinik ataşman kaybı Sondalama derinliği	110 hasta	ANN	Doğruluk oranı: 84,2%
Deng ve ark.	2023	Çin	Periodontal sağlığın, gingivitisin ve periodontitisin farklı evrelerini ayırt edebilen tarama aracı oluşturarak doğruluğunu değerlendirmek	Anket verileri (Yaş, cinsiyet, sigara tüketimi, sistemik rahatsızlık) aMMP-8 Fırçalama sonrası kanama indeksi	408 hasta	ANN	Doğruluk oranı: Periodontal sağlık: 82,7% Gingivitis: 83,9% Periodontitis: 84,1% Evre I/II sınıflandırması: 68,6% Evre II/IV sınıflandırması: 91,9%
Jundaeng ve ark.	2025	Tayland	Radyografik görüntü üzerinden diş, sementoenamel birleşim ve kret tepesi etiketlemeyle beraber kemik kaybı tayini yapılarak periodontitisin evrelendirilmesi	Panoramik görüntü	2000	YOLOv8	Doğruluk oranı; Diş etiketleme: 97% Sementoenamel birleşke ve kret tepesi tayini: 98% Evrelendirme: 94,4%

Tablo III. Risk tahmini, prognoz tahmini ve tedavi planlaması

Yazar	Yıl	Ülke	Metot	Materyal	Eğitim Seti	Kullanılan Mimari	Performans Ölçümleri ve Sonuçları
Matulene ve ark.	2010	İsviçre	Periodontal değerlendirme amacıyla diş kaybı ve periodontitis nüksü arasındaki ilişki	Destekleyici periodontal fazında olan periodontitis hastaları	160		PRD aracı ve diş kaybı & periodontitis ilerlemesi arasındaki ilişki istatistiksel olarak anlam göstermiştir.
Meyer-Bäumer ve ark.	2012	Almanya	Periodontal değerlendirme amacıyla diş kaybı ve periodontitis nüksü arasındaki ilişki	Destekleyici periodontal fazında olan periodontitis hastaları	164		PRD aracı ve diş kaybı & periodontitis ilerlemesi arasındaki ilişki istatistiksel olarak anlam göstermiştir.
Lee ve ark.	2018	Kore	3 uzman periodontolog tarafından yürütülmüş referans bir çalışmaya dayanarak periodontal hastalığı olan dişlerin prognozunu belirlemek	Periapikal görüntü	1740		Doğruluk oranı Premolarlar için: 81% Molarlar için: 76, 7%
Correia ve ark.	2020	Portekiz	SAC Değerlendirme aracının klinik açıdan deneyimsiz diş hekimlerine implant tedavisi planlaması konusundaki desteğini değerlendirmek	SAC parametreleri	Dişsiz bölgeye sahip 30 hasta		Deneyimli klinisyenin SAC aracı kullandığı ve kullanmadığı durum arasındaki uyum: 81,7% Değerlendirme aracı kullanılarak deneyimli diş hekimleriyle deneyimsiz diş hekimleri arasındaki uyum: 67,3%-73,6% Değerlendirme aracı kullanılmadan deneyimsiz diş hekimleri arasındaki uyum: 34,6%
Lee ve ark.	2022	ABD	Deneyimli farklı disiplinlerden uzmanların belirlediği altın standart 17 klinik parametre üzerinden dişlerin prognozunun 3 farklı makine öğrenme algoritması tarafından belirlenmesi	Klinik ve radyografik parametreler	94 hasta, 2,359 adet diş		Doğruluk oranı Gradyan artırma sınıflandırıcısı: 69% Karar ağacı sınıflandırıcısı: 84,13% Rastgele orman sınıflandırıcısı: 83,12%
Lyakhov ve ark.,	2022	Rusya	Çeşitli hasta verilerini yorumlayarak implant prognozunun değerlendirilmesi	Genel faktörler (yaş, sistemik durum, sigara kullanımı vs.) Dentoalveolar durum (Beslenme, oral hijyen, çeşitli dental hastalıklar ve durumlar vs.) Implant bölgesiyle ilgili durumlar (Gin-gival biyotip, kemik özelliği, sinüs, implant bölgesi vs.)	1,648 hasta		Doğruluk oranı: 94,48%

Tablo IV. Uzaktan izleme ve Hasta Kooperasyonu

Yazar	Yıl	Ülke	Metot	Materyal	Eğitim Seti	Kullanılan Mimari	Performans Ölçümleri ve Sonuçları
Balaei ve ark.	2017	Kore	Periodontal hastalığı tespit etmek ve tedavi sürecini izlemek amacıyla iki adet yapay zeka algoritmasının kullanılması	Ağız içi fotoğraflar	Tedavi öncesi ve sonrası olmak üzere toplam 88 ağız içi fotoğraf		Sağlıklı ve hastalıklı bireyler: 66,7%, Tedavi öncesi sonrası görüntüleri: 91,6% doğruluk oranıyla sınıflamıştır.
Shen ve ark.	2022	Tayvan	Periodontitis hastalarında Dental Monitoring aracının tedavi sonuçları üzerindeki etkisinin değerlendirilmesi	Ağız içi fotoğraflar Sondalama derinliği Klinik ataşman seviyesi Plak indeksi	Yapay zeka desteği alan hasta (AI): 16 Yapay zeka desteğiyle birlikte klinik danışmanlık alan hasta (AIHC): 17 Kontrol grubu hasta: 20		AI ve AIHC gruplarında kontrol grubuna kıyasla iyileşme gözlenmiştir; AIHC grubunda AI grubuna kıyasla sondalamada cep derinliğinde daha büyük bir azalma ve klinik ataşman seviyesinde daha büyük bir iyileşme gözlenmiştir
Snider ve ark.	2024	ABD	Dental Monitoring aracının diş taşı varlığının, ağız hijyeninin ve mukogingival durumların değerlendirilmesi	Ağız içi fotoğraflar	Ortodontik tedavisi devam eden 24 hasta		Doğruluk oranı: Plak ve diş taşı için: %60 Gingivitis için: %49 Diş eti çekilmesi için: %72

Tablo V. Alveol kemik kaybı tespiti

Yazar	Yıl	Ülke	Metot	Materyal	Eğitim Seti	Kullanılan Mimari	Performans Ölçümleri ve Sonuçları
Kim ve ark.	2019	Kore	Panoramik görüntüler üzerinden yapay zeka modelinin ve klinisyenlerin alveol kemik kaybı tespiti	Panoramik görüntü	12.179	DeNTNet	F1 skoru: DeNTNet için: 0,75 Klinisyenler için 0,69
Jiang ve ark.	2022	Çin	Panoramik görüntüler üzerinde alveol kemik kaybı miktarının belirlenmesi ve periodontitis evrelenirilmesi	Panoramik görüntü	640	YOLO-v4	F1 skoru: Vertikal kemik kaybı tespiti: 0,64 Furkasyon defektlerinin tespiti: 0,83 Evrelendirme için: 0,77
Kong ve ark.	2023	Çin	Panoramik görüntüler üzerinde alveol kemik kaybı tespiti	Panoramik görüntü	1.747	YOLO-v4	Doğruluk oranı: 76,2%
Kurt Bayrakdar ve ark.	2024	Türkiye	Panoramik görüntüler üzerinde alveol kemik kaybı miktarının ve türünün belirlenmesi	Panoramik görüntü	1.121	ANN	F1 skoru: Total kemik kaybı tespiti: 0,997 Horizontal kemik kaybı tespiti: 0,943 Vertikal kemik kaybı tespiti: 0,673 Furkasyon defektlerinin tespiti: 0,912

Tablo VI. İmplant marka/modelinin belirlenmesi

Yazar	Yıl	Ülke	Metot	Materyal	Eğitim Seti	Kullanılan Mimari	Performans Ölçümleri ve Sonuçları
Suegawa ve ark.	2021	Japonya	Radyografik görüntüler üzerinden implant markasını tanıma ve implant tedavisi sürecinde hangi basamakta olduğunu belirleme	Panoramik görüntü	9767	ResNet 18 ResNet 34 ResNet 50 ResNet 101 ResNet 152	F1 skoru: İmplant modeli için Tedavi basamağı için ResNet 18: 0.974 ResNet 34: 0.982 ResNet 50: 0.983 ResNet 101: 0.987 ResNet 152: 0.989 0.994 0.995 0.995 0.996 0.996
Hsiao ve ark.	2023	ABD	Radyografik görüntüler kullanarak implant modeli tanıma	Periapikal görüntü	336	YOLO-v4	Doğruluk oranı: 81,89% -96,85%
Park ve ark.	2023	Kore	Büyük merkezli bir veri seti kullanarak implant mark ve modeli belirleme	Panoramik ve periapikal görüntü	116.756 panoramik 40.209 periapikal görüntü	AutoML	F1 skoru Sadece periapikal: 83% Sadece panoramik: 83,1% Periapikal & panoramik: 84%
Lee ve ark.	2024	Kore	Radyografik görüntüler kullanarak implant modeli tanıma	Panoramik ve periapikal görüntü	157.495	ResNet 50	F1 Skoru 94,17% Doğruluk oranı 95,05%

Tablo VII. Yapay zeka destekli implant cerrahisi planlaması

Yazar	Yıl	Ülke	Metot	Materyal	Eğitim Seti	Kullanılan Mimari	Performans Ölçümleri ve Sonuçları
Kurt Bayrakdar ve ark.	2021	Türkiye	Tomografi görüntüleri kullanılarak implant planlanan bölgelerin kemik yüksekliği, kalınlığı ve anatomik yapılar açısından değerlendirilmesi	Tomografi görüntüleri	508	U-Net	Doğruluk oranı: Sinüs ve fossalar için: 66,4% Mandibuler kanal için: 72,2% Dişsiz bölgelerin belirlenmesi için: 95,3%
Moufti ve ark.	2023	Birleşik Arap Emirlikleri	Tomografi görüntüleri kullanılarak mandibulada implant yerleşimine uygun olan bölgeleri belirlemek	Tomografi görüntüleri	43	U-Net	DSC değeri 0.78
Oliveira-Santos ve ark.	2023	Belçika	Tomografi görüntüleri kullanılarak mandibuler kanal ve anterior loop etiketlemesi	Tomografi görüntüleri	313		Doğruluk oranı: 99,7%
Sakai ve ark.	2023	Japonya	Tomografi görüntüleri kullanarak uygun implant yerleştirme protokolünü belirleme	Tomografi görüntüleri	1200	LeNet-5	Doğruluk oranı: 93,8%
Chen ve ark.	2024	Çin	YZ destekli implant planlama aracının güvenilirliğinin in vitro belirlenmesi ve kemik yoğunluğunun bilgisayar destekli implant cerrahisinin doğruluğu üzerindeki etkisinin değerlendirilmesi	Tomografi görüntüleri	10 hasta		YZ ideal implant pozisyonunu hesaplayabilir Kemik yoğunluğundaki artış açıl sapmayı da arttırmaktadır.

Kaynaklar

1. Tonetti MS, Greenwell H, Kornman KS. Staging and grading of periodontitis: Framework and proposal of a new classification and case definition. *J Periodontol*. 2018;89(Suppl 1):S159-S172
2. Chen MX, Zhong YJ, Dong QQ, Wong HM, Wen YF. Global, regional, and national burden of severe periodontitis, 1990-2019: An analysis of the Global Burden of Disease Study 2019. *J Clin Periodontol*. 2021;48(9):1165-1188.
3. Scott J, Biancardi AM, Jones O, Andrew D. Artificial Intelligence in Periodontology: A Scoping Review. *Dent J (Basel)*. 2023;11(2):43. Published 2023 Feb 8.
4. Sanz M, Kornman K; Working Group 3 of the Joint EFP/AAP Workshop. Periodontitis and adverse pregnancy outcomes: Consensus report of the Joint EFP/AAP Workshop on Periodontitis and Systemic Diseases. *J Periodontol*. 2013;84(4 Suppl):S164-S169.
5. Lalla E, Papapanou PN. Diabetes mellitus and periodontitis: A tale of two common interrelated diseases. *Nat Rev Endocrinol*. 2011;7(12):738-748.
6. Lockhart PB, Bolger AF, Papapanou PN, et al. Periodontal disease and atherosclerotic vascular disease: Does the evidence support an independent association? A scientific statement from the American Heart Association. *Circulation*. 2012;125:2520-2544.
7. Gomes-Filho IS, Passos JS, Seixas da Cruz S. Respiratory disease and the role of oral bacteria. *J Oral Microbiol*. 2010;2:10.3402/jom.v2i0.5811. Published 2010 Dec 21.
8. Peres MA, Macpherson LMD, Weyant RJ, et al. Oral diseases: A global public health challenge. *Lancet*. 2019;394(10194):249-260.
9. Jain N, Dutt U, Radenkov I, Jain S. WHO's global oral health status report 2022: Actions, discussion and implementation. *Oral Dis*. 2024;30(2):73-79.
10. Tonetti MS, Jepsen S, Jin L, Otomo-Corgel J. Impact of the global burden of periodontal diseases on health, nutrition and wellbeing of mankind: A call for global action. *J Clin Periodontol*. 2017;44(5):456-462.
11. Listl S, Galloway J, Mossey PA, Marcenes W. Global economic impact of dental diseases. *J Dent Res*. 2015;94(10):1355-1361.
12. Patil S, Joda T, Soffe BW, et al. Efficacy of artificial intelligence in the detection of periodontal bone loss and classification of periodontal diseases: A systematic review. *J Am Dent Assoc*. 2023.
13. Fidyawati D, Lelyati S, Iskandar H, Suhartanto H, Soeroso Y. Artificial intelligence for detecting periodontitis: Systematic literature review. *Open Dent J*. 2024;18.
14. Issa J, Jaber M, Rifai I, Mozdziak P, Kempisty B, Dyszkiewicz-Konwińska M. Diagnostic test accuracy of artificial intelligence in detecting periapical periodontitis on two-dimensional radiographs: A retrospective study and literature review. *Medicina (Kaunas)*. 2023;59(4):768.
15. Williams C. A brief introduction to artificial intelligence. In: *Proceedings OCEANS '83*. 1983:94-99.
16. Haenlein M, Kaplan A. A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. *Calif Manage Rev*. 2019;61:5-14.
17. Borana J. Applications of Artificial Intelligence & Associated Technologies. Presented at: *Proceedings of the International Conference on Emerging Technologies in Engineering, Biomedical, Management and Science (ETEBMS-2016)*; March 5-6, 2016; Jodhpur, India.
18. Turing A.M. Computing machinery and intelligence. *Mind*. 1950;49:433-460.
19. McCarthy J, Minsky M, Rochester N, Shannon CE. A proposal for the Dartmouth summer research project on artificial intelligence, August 31, 1955. *AI Mag*. 2006;27:12-14.
20. Hinton GE, Osindero S, Teh YW. A fast learning algorithm for deep belief nets. *Neural Comput*. 2006;18(7):1527-1554.
21. Tang W, Sun J, Wang S, Zhang Y. Review of AlexNet for medical image classification. *EAI Endorsed Trans E-Learn*. 2023;9.
22. Tiwari T, Tiwari T, Tiwari S. How artificial intelligence, machine learning and deep learning are radically different? *Int J Adv Res Comput Sci Softw Eng*. 2018;8(2):1.
23. Louridas P, Ebert C. Machine learning. *IEEE Softw*. 2016;33(5):110-115.
24. Minsky M, Papert S. *Perceptrons: An Introduction to Computational Geometry*. Cambridge, MA: MIT Press; 1969.
25. O'Shea K, Nash R. *An Introduction to Convolutional Neural Networks*. arXiv. 2015;abs/1511.08458.
26. Xu Y, Goodacre R. On splitting training and validation set: a comparative study of cross-validation, bootstrap and systematic sampling for estimating the generalization

- performance of supervised learning. *J Anal Test*. 2018;2:249-262
27. Vargas R, Mosavi A, Ruiz R. Deep learning: A review. Preprints. 2018.
28. Chahal A, Gulia P. Machine learning and deep learning. *Int J Innov Technol Explor Eng*. 2019;8(12):4910-4914.
29. Lillhore UK, Simaiya S, Kaur A, et al. Impact of deep learning and machine learning in Industry 4.0. In: *Cyber-Physical, IoT, and Autonomous Systems in Industry 4.0*. 2021:179-197.
30. Maier A, Syben C, Lasser T, Riess C. A gentle introduction to deep learning in medical image processing. *Z Med Phys*. 2019;29(2):86-101.
31. Alzubaidi L, Zhang J, Humaidi AJ, et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *J Big Data*. 2021;8(1):1-74.
32. Davenport T, Kalakota R. The potential for artificial intelligence in healthcare. *Future Healthc J*. 2019;6(2):94-98.
33. Schwendicke F, Samek W, Krois J. Artificial intelligence in dentistry: Chances and challenges. *J Dent Res*. 2020;99(7):769-774.
34. Saw SN, Ng KH. Current challenges of implementing artificial intelligence in medical imaging. *Phys Med*. 2022;100:12-17.
35. Daneshjou R, Smith MP, Sun MD, Rotemberg V, Zou J. Lack of Transparency and Potential Bias in Artificial Intelligence Data Sets and Algorithms: A Scoping Review. *JAMA Dermatol*. 2021;157(11):1362-1369.
36. Salman S, Liu X. Overfitting mechanism and avoidance in deep neural networks. *arXiv*. Published online 2019. *arXiv*:1901.06566.
37. Yamashita R, Nishio M, Do RKG, Togashi K. Convolutional neural networks: An overview and application in radiology. *Insights Imaging*. 2018;9(4):611-629.
38. Krois J, Garcia Cantu A, Chaurasia A, et al. Generalizability of deep learning models for dental image analysis. *Sci Rep*. 2021;11(1):1-7.
39. Gianfrancesco MA, Tamang S, Yazdany J, Schmajuk G. Potential Biases in Machine Learning Algorithms Using Electronic Health Record Data. *JAMA Intern Med*. 2018;178(11):1544-1547.
40. Rischke R, Schneider L, Müller K, et al. Federated learning in dentistry: Chances and challenges. *J Dent Res*. 2022;101(11):1269-1273.
41. Maliha G, Gerke S, Cohen IG, Parikh RB. Artificial intelligence and liability in medicine: Balancing safety and innovation. *Milbank Q*. 2021;99(3):629-647.
42. Terranova C, Cestonaro C, Fava L, Cinquetti A. AI and professional liability assessment in healthcare: A revolution in legal medicine? *Front Med*. 2023;10:1337335.
43. Pitchika V, Büttner M, Schwendicke F. Artificial intelligence and personalized diagnostics in periodontology: A narrative review. *Periodontol 2000*. 2024;95(1):220-231.
44. Agrawal P, Nikhade P. Artificial Intelligence in Dentistry: Past, Present, and Future. *Cureus*. 2022;14(7):e27405.
45. Rastogi I, Siddiqui SR, Khan FR. Artificial intelligence up fronting dentistry. *J Orofac Health Sci*. 2024;11(2):47-49.
46. Nazemian S, Boggs ST, Jimenez Ciriaco E, et al. What every dentist needs to know about the use of artificial intelligence in dentistry. *Gen Dent*. 2023;71(3):23-27.
47. Khanagar SB, Al-Ehaideb A, Maganur PC, et al. Developments, application, and performance of artificial intelligence in dentistry: A systematic review. *J Dent Sci*. 2021;16(1):508-522.
48. Zhang D, Wang J, Zhao X. Estimating the uncertainty of average F1 scores. In: *ICTIR 2015 - Proceedings of the 2015 ACM SIGIR International Conference on the Theory of Information Retrieval*. 2015:317-320.
49. Hanley JA, McNeil BJ. The meaning and use of the area under a receiver operating characteristic (ROC) curve. *Radiology*. 1982;143(1):29-36.
50. Dice LR. Measures of the amount of ecologic association between species. *Ecology*. 1945;26:297-302.
51. Askarian B, Tabei F, Tipton GA, Chong JW. Smartphone-based method for detecting periodontal disease. In: *2019 IEEE Healthcare Innovations and Point of Care Technologies (HI-POCT)*. IEEE; 2019:53-55.
52. Chau RCW, Li GH, Tew IM, et al. Accuracy of Artificial Intelligence-Based Photographic Detection of Gingivitis. *Int Dent J*. 2023;73(5):724-730.
53. Chau RCW, Cheng ACC, Mao K, et al. External validation of an AI mHealth tool for gingivitis detection among older adults at daycare centers: A pilot study. *Int Dent J*. Published online 2025.
54. Li W, Guo E, Zhao H, et al. Evaluation of transfer ensemble learning-based convolutional neural network models for the identification of chronic gingivitis from oral photographs.

- BMC Oral Health. 2024;24(1):1-12.
55. Papantonopoulos G, Takahashi K, Bountis T, Loos BG. Artificial neural networks for the diagnosis of aggressive periodontitis trained by immunologic parameters. *PLoS One*. 2014;9(3):e89757.
 56. Deng K, Zonta F, Yang H, Pelekos G, Tonetti MS. Development of a machine learning multiclass screening tool for periodontal health status based on non-clinical parameters and salivary biomarkers. *J Clin Periodontol*. Published online 2023.
 57. Jundaeng J, Chamchong R, Nithikathkul C. Artificial intelligence-powered innovations in periodontal diagnosis: A new era in dental healthcare. *Front Med Technol*. 2025;6:1469852.
 58. Ossowska A, Kusiak A, Świetlik D. Evaluation of the progression of periodontitis with the use of neural networks. *J Clin Med*. 2022;11(16):4667.
 59. Mayer EK, Sevdalis N, Rout S, et al. Surgical checklist implementation project: The impact of variable WHO checklist compliance on risk-adjusted clinical outcomes after national implementation: A longitudinal study. *Ann Surg*. 2016;263(1):58-63.
 60. Elhaddad M, Hamam S. AI-Driven Clinical Decision Support Systems: An Ongoing Pursuit of Potential. *Cureus*. 2024;16(4):e57728. Published 2024 Apr 6.
 61. Lee JH, Kim DH, Jeong SN, Choi SH. Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. *J Periodontal Implant Sci*. 2018;48(2):114-123.
 62. Lee SJ, Chung D, Asano A, et al. Diagnosis of tooth prognosis using artificial intelligence. *Diagnostics (Basel)*. 2022;12(6):1422.
 63. Lang NP, Tonetti MS. Periodontal risk assessment (PRA) for patients in supportive periodontal therapy (SPT). *Oral Health Prev Dent*. 2003;1(1):7-16.
 64. Dawson A, Chen S, eds. *The SAC Classification in Implant Dentistry*. 1st ed. Berlin: Quintessence; 2009.
 65. Correia A, Rebolo A, Azevedo L, Polido W, Rodrigues PP. SAC Assessment Tool in Implant Dentistry: Evaluation of the Agreement Level Between Users. *Int J Oral Maxillofac Implants*. 2020;35(5):990-994.
 66. Matuliene G, Studer R, Lang NP, et al. Significance of periodontal risk assessment in the recurrence of periodontitis and tooth loss. *J Clin Periodontol*. 2010;37(2):191-199.
 67. Meyer-Bäumer A, Pritsch M, Cosgarea R, et al. Prognostic value of the periodontal risk assessment in patients with aggressive periodontitis. *J Clin Periodontol*. 2012;39(7):651-658.
 68. Lyakhov PA, Dolgalev AA, Lyakhova UA, et al. Neural network system for analyzing statistical factors of patients for predicting the survival of dental implants. *Front Neuroinform*. 2022;16:1067040.
 69. Eley BM, Cox SW. Advances in periodontal diagnosis. 1. Traditional clinical methods of diagnosis. *Br Dent J*. 1998;184(1):12-16.
 70. Juan MC, Alcañiz M, Monserrat C, Grau V, Knoll C. Computer-aided periodontal disease diagnosis using computer vision. *Comput Med Imaging Graph*. 1999;23(4):209-217.
 71. Ramachandra SS, Mehta DS, Sandesh N, Baliga V, Amarnath J. Periodontal probing systems: A review of available equipment. *Compend Contin Educ Dent*. 2011;32(2):71-77.
 72. Youssif A, Gawish A, Moussa M. Automated periodontal diseases classification system. *Int J Adv Comput Sci Appl*. 2012;3(1):30-35.
 73. Jampani ND, Nutalapati R, Dontula BS, Boyapati R. Applications of teledentistry: A literature review and update. *J Int Soc Prev Community Dent*. 2011;1(2):37-44.
 74. Snider V, Homsy K, Kusnoto B, et al. Clinical evaluation of artificial intelligence driven remote monitoring technology for assessment of patient oral hygiene during orthodontic treatment. *Am J Orthod Dentofacial Orthop*. 2024;165(5):586-592.
 75. Shen KL, Huang CL, Lin YC, et al. Effects of artificial intelligence-assisted dental monitoring intervention in patients with periodontitis: A randomized controlled trial. *J Clin Periodontol*. 2022;49(10):988-998.
 76. Watts T. Periodontal treatment and glycemic control in diabetic patients: The problem of a possible Hawthorne effect. *J Dent Res*. 2006;85(4):294-295.
 77. Balaei AT, de Chazal P, Eberhard J, Domnisch H, Spahr A, Ruiz K. Automatic detection of periodontitis using intra-oral images. *Annu Int Conf IEEE Eng Med Biol Soc*. 2017;2017:3906-3909.
 78. Bartold PM, Ivanovski S. P4 Medicine as a model for precision periodontal care. *Clin Oral Investig*. 2022;26(9):5517.

79. Jameson JL, Longo DL. Precision medicine—personalized, problematic, and promising. *N Engl J Med*. 2015;372(23):2229-2234.
80. Jiao Y, Hasegawa M, Inohara N. The role of oral pathobionts in dysbiosis during periodontitis development. *J Dent Res*. 2014;93(6):539-546.
81. Abusleme L, Hoare A, Hong BY, Diaz PI. Microbial signatures of health, gingivitis, and periodontitis. *Periodontol 2000*. 2021;86(1):57-78.
82. Schwendicke F, Chaurasia A, Wiegand T, et al. Artificial intelligence for oral and dental healthcare: Core education curriculum. *J Dent*. 2023;128:104363.
83. Adeoye J, Su YX. Artificial intelligence in salivary biomarker discovery and validation for oral diseases. *Oral Dis*. 2024;30(1):23-37.
84. Eriksson K, Lundmark A, Delgado LF, et al. Salivary microbiota and host-inflammatory responses in periodontitis affected individuals with and without rheumatoid arthritis. *Front Cell Infect Microbiol*. 2022;12:841139.
85. Kim J, Lee H, Song I, Jung K. DeNTNet: Deep neural transfer network for the detection of periodontal bone loss using panoramic dental radiographs. *Sci Rep*. 2019;9.
86. Kong Z, Ouyang H, Cao Y, et al. Automated periodontitis bone loss diagnosis in panoramic radiographs using a bespoke two-stage detector. *Comput Biol Med*. 2023;152:106374.
87. Jiang L, Chen D, Cao Z, Wu F, Zhu H, Zhu F. A two-stage deep learning architecture for radiographic staging of periodontal bone loss. *BMC Oral Health*. 2022;22(1).
88. Kurt-Bayrakdar S, Bayrakdar İŞ, Yavuz MB, et al. Detection of periodontal bone loss patterns and furcation defects from panoramic radiographs using deep learning algorithm: A retrospective study. *BMC Oral Health*. 2024;24(1):155.
89. da Mata Santos RP, Vieira Oliveira Prado HE, Soares Aranha Neto I, et al. Automated Identification of Dental Implants Using Artificial Intelligence. *Int J Oral Maxillofac Implants*. 2021;36(5):918-923.
90. Sukegawa S, Yoshii K, Hara T, et al. Multi-task deep learning model for classification of dental implant brand and treatment stage using dental panoramic radiograph images. *Biomolecules*. 2021;11(6).
91. Lee JH, Kim YT, Lee J. Identification of dental implant systems from low-quality and distorted dental radiographs using AI trained on a large multi-center dataset. *Sci Rep*. 2024;14(1):1-8.
92. Park W, Huh JK, Lee JH. Automated deep learning for classification of dental implant radiographs using a large multi-center dataset. *Sci Rep*. 2023;13(1):4862.
93. Hsiao CY, Bai H, Ling H, Yang J. Artificial intelligence in identifying dental implant systems on radiographs. *Int J Periodontics Restorative Dent*. 2023;43(3):363-368.
94. Urban R, Haluzová S, Strunga M, et al. AI-assisted CBCT data management in modern dental practice: Benefits, limitations and innovations. *Electronics*. 2023;12(7):1710.
95. Chen Z, Liu Y, Xie X, Deng F. Influence of bone density on the accuracy of artificial intelligence-guided implant surgery: An in vitro study. *J Prosthet Dent*. 2024;131(2):254-261.
96. Sakai T, Li H, Shimada T, et al. Development of artificial intelligence model for supporting implant drilling protocol decision making. *J Prosthodont Res*. 2023;67(3):360-365.
97. Oliveira-Santos N, Jacobs R, Picoli FF, Lahoud P, Niclaes L, Groppo FC. Automated segmentation of the mandibular canal and its anterior loop by deep learning. *Sci Rep*. 2023;13(1):1-9.
98. Moufti MA, Trabulsi N, Ghousheh M, et al. Developing an artificial intelligence solution to autosegment the edentulous mandibular bone for implant planning. *Eur J Dent*. 2023;17(4):1330-1337.
99. Kurt Bayrakdar S, Orhan K, Bayrakdar IS, et al. A deep learning approach for dental implant planning in cone-beam computed tomography images. *BMC Med Imaging*. 2021;21(1):86.