

**Bölüm 26**

**Diş Hekimliğinde Yapay Zeka:  
Fırsatlar ve Zorluklar**

**NESLİHAN YILMAZ ÇIRAKOĞLU<sup>1</sup>**

<sup>1</sup> Doç. Dr.; Karabük Üniversitesi Diş Hekimliği Fakültesi Endodonti Anabilim Dalı  
neslihan.yilmazcirakoglu@karabuk.edu.tr ORCID No: 0000-0002-8316-3133



## **ZET**

“Yapay zekâ” terimi ilk kez 1950’lerde ortaya çıkmıřtır ve normalde insanlar tarafından gerekleřtirilen grevleri yerine getirebilen makineler retme fikri anlamına gelmektedir. Yapay zekanın alt alanı olan “makine ęrenimi” ise grnmeyen verilerin tahmin edilmesini saęlayan verilerde isel istatistiksel kalıpları ve yapıları ęrenmek iin kullanılan algoritmalar dır. Makine ęrenimini modelinin populer bir alt tipi olan “nral aęlar”; grnt veya dil gibi karmařık veri yapılarında klasik makine ęrenimi algoritmalarından daha bařarılı performans gstermektedir. Yapay zeka teknolojisi genel zellikleri ele alındıęında diř hekimlięi iin olduka uygundur. Geliřtirilen ve hala zerinde alıřılan yapay zekâ modelleri sayesinde diř hekimleri daha hızlı ve daha gvenilir teřhisler yaparak daha etkin tedaviler gerekleřtirebilecektir. Bu alanda yapılan tm alıřmalar genel olarak yapay zekâ algoritmalarına katkı saęlamaktadır.

**Anahtar Kelimeler:** Derin ęrenme, Nral Sinir Aęı, Yapay zekâ

## **GİRİŞ**

“Yapay zekâ” terimi ilk kez 1950’lerde ortaya çıkmıştır ve normalde insanlar tarafından gerçekleştirilen görevleri yerine getirebilen makineler üretme fikri anlamına gelmektedir. Yapay zekanın alt alanı olan “makine öğrenimi” ise görünmeyen verilerin tahmin edilmesini sağlayan verilerde içsel istatistiksel kalıpları ve yapıları öğrenmek için kullanılan algoritmalarlardır. Makine öğrenimini modelinin popüler bir alt tipi olan “nöral ağlar”; görüntü veya dil gibi karmaşık veri yapılarında klasik makine öğrenimi algoritmalarından daha başarılı performans göstermektedir (Schwendicke vd., 2020). Herhangi bir nöral ağın ana bileşeni insan nöronlarından ilham alınarak oluşturulan ve matematiksel olarak doğrusal olmayan yapay nöronlardır. Yapay nöronların matematiksel işlemler kullanılarak istifleme yöntemi ile birbirine bağlanması ile görüntü sınıflandırması gibi belirli bir sorunu çözmeyi amaçlayan (örneğin çürük bir dişi gösteren radyografik görüntü: evet ya da hayır) ağlar tasarlanmıştır (Schwendicke vd., 2020). “Derin öğrenme” terimi derin (çok katmanlı) yapay sinir ağları mimarlığının bir örneğidir. Bu teknik özellikle görüntüleme gibi karmaşık veri yapılarında oldukça faydalıdır. Çünkü bir görüntüyü; onun kenarlar, köşeler, şekiller ve makroskobik desenler gibi hiyerarşik özellikleriyle birlikte gösterebilme yeteneğine sahiptir.

Derin yapay sinir ağları temel yaklaşım makineleri gibi düşünülebilir (Hornik, 1991). Bir dizi matematiksel koşul verildiğinde yapay sinir ağları şunları yapabilir:

Herhangi bir bilgi verisini (örneğin çürük bir dişin radyografik görüntüsü) eşleştirerek belirli bir çıktı (örneğin; çürük bir diş) olarak tahmin edebilme yeteneğine sahiptir.

Yapay sinir ağları yeterince fazla miktarda veri ve hesaplama kaynağı mevcut olduğunda sağlanan verilerin içsel istatistiksel kalıplarını sunmak için eğitilebilir. Eğitim sürecinde veri noktaları ve ilgili etiketler (sınıflandırma görevleri) veya sayısal görevler sinir ağları tarafından tekrar tekrar gözden geçirilir. Bu sayede nöronlar arası bağlantılar (model yüklemeleri olarak da isimlendirilir) tahmin hatalarının (gerçek ve tahmin edilen veri arasındaki farklılık) minimize edilmesi amacıyla yinelemeli olarak optimize edilir. Böylece eğitilmiş bir sinir ağı yeni bir veriyi ağ üzerinden geçirerek görünmeyen sonuçları tahmin edebilecek seviyeye gelir.

Son 70 yılda yapay zeka uygulamaları hem birtakım fırsatlar hem de bazı zorluklar doğurmuştur. Bu süre zarfında çok sayıda aksilik de yaşandı. “Yapay zeka kışları” adı verilen ve bu teknolojideki beklentilerin gerçek sonuçları karşılaşmadığı dönemler oldu. Günümüzde ise önceki yıllara göre iyimser bakış daha fazla, çünkü son on yılda makine öğrenimi ve daha geniş kapsamlı alanlarda

olağanüstü başarılar imza atıldı. Örneğin; doğal dil modellerinin metinsel çıktıkları insan yazarlar ve yapay olarak oluşturulmuş metinler arasında fark ayırt edilmeyecek kadar inandırıcıdır. Sonuç olarak öyle görünüyor ki; ekonomi, sağlık ve politika gibi farklı toplumsal alan ve disiplinlerde yer alması nedeniyle yapay zeka teknolojisi bir ütopya olmaktan çıkıp ciddi bir gerçekliğe doğru yer değiştiriyor. Son yıllarda dış hekimliği alanı da yapay zekanın öne çıktığı alanlardan biri olmuştur.

### ***Yapay Zekanın Tıp Ve Dış Hekimliği Alanında Avantajları***

Yapay zeka teknolojisinde tıp alanında özellikle de bilgisayarla görme alanında önemli atılımlar olmuştur. Bu gelişmeler için çok sayıda sürücü tanımlanmıştır (Naylor, 2018).

Teşhis amaçlı görüntüleme birçok sağlık hizmetinin merkezinde yer alır. Subjektif ve değişken incelemedeki farklılıkların önüne geçmek ve rutin görevleri ortadan kaldırarak maliyeti düşürürken tedavinin etkinliğini artırmak gibi avantajları nedeniyle yapay zeka görüntüleme alanında öne çıkmaktadır.

Dış hekimliğinde görüntüleme hastanın tedavi planlaması ve yürütülmesi boyunca olan süreçte önemli bir rol oynar. Dış hekimleri genellikle hastanın aynı anatomik bölgesinden farklı görüntüler elde eder. Ayrıca bu görüntülere klinik kayıtlar, hastanın genel durumu ve ilaç kullanımını da içeren sistemik ve dental anamnez verileri gibi görsel olmayan veriler de eşlik eder. Bu veriler genellikle hastalardan farklı zamanlarda toplanır. Yapay zeka bunları entegre ederek teşhis ve tedaviye karar vermede etkin bir şekilde kullanabilmektedir.

Birçok dental durum (çürük, apikal lezyonlar, periodontal kemik kaybı vb.) toplumda nispeten oldukça yaygın görülür. Çok sayıda vaka içeren veri kümeleri bazı kısıtlamalar olsa da oluşturulabilir.

Dijital sağlık verileri yapay zeka teknolojisinde her zaman ulaşılabilir şekilde saklanır; şu ana kadar bu veriler oldukça heterojen olsa da sistemler; düzenlenmiş ve yapılandırılmış veri sağlamak için gün geçtikçe daha fazla çaba harcıyorlar.

Yapay zeka teknolojisi; tıbbi/dental öykü, sosyodemografik ve klinik veriler, görüntü verileri, biyomoleküler veriler, sosyal ağ verileri gibi farklı ve heterojen veri alanları arası entegrasyona imkan sağlar. Bu çok aşamalı verilerin en iyi şekilde kullanılmasına ve etkileşimlerine olanak sağlar.

Yapay zeka teknolojisi; geleneksel araştırma hiyerarşilerine bilgisayar simülasyonları deneyimi ekleyerek araştırma ve keşif yapmayı kolaylaştırır. Diğer araştırma yöntemleri ve mevcut modelleme stratejileriyle birlikte tamamlayıcı bir deneyim sunar.

Yapay zeka teknolojisi; rutin işleri kolaylaştırarak doktor/diş hekimi ve hasta arasında gerçekleşen yüz-yüze görüşme vaktinin ve insani bakımın artmasını sağlar. Bu yalnızca yardımcı teşhis yöntemleriyle sınırlı değildir; ses, konuşma, metin tanıma ve çeviri hizmetleri doktorların/diş hekimlerinin kayıt tutma zamanlarını azaltmaya yardımcı olur (Israni ve Vergheese., 2019).

Yapay zeka ayrıca sağlık hizmetlerini hastalar açısından daha katılımcı hale getirmeyi hedeflemektedir. Hastaların kendi kendilerini izleme ve öz denetim yoluyla tedavi sürecinde daha aktif bir konuma getirilmesi amaçlanmaktadır.

Sürekli olarak depolanan verilerin kullanılması kronik hastalıklardaki devamlı ilaç tedavisinin dezavantajlarının üstesinden gelebilir (Topol, 2019). Genelde yıllar içinde ve çoğu zaman artan semptomlarla ortaya çıkan; fakat hastanın klinisyen tarafından sadece birkaç dakika görüldüğü hastalık durumları (periodontal hastalık gibi) buna en iyi örnektir. Sağlık durumunun sürekli olarak non-invaziv olarak takip edilmesi hastalığın altında yatan daha derin (kişisel veya gizli) nedenlerin anlaşılabilmesine olanak sağlayabilir.

Teşhis ve tedavi masraflarını azaltarak oldukça fazla kompleks ve kronik hastaya sahip ve gittikçe yaşlanan bir toplumun yükünü taşıyan sağlık sistemlerinin işini kolaylaştırabilir. Yapay zeka ayrıca dünyanın birçok yerine ulaşarak Dünya Sağlık Örgütü'nün Sürdürülebilir Kalkınma Hedeflerine ulaşmayı destekleyecek şekilde iş gücündeki eksikliklerin giderilmesine yardımcı olur. (<https://www.who.int/sdg/en/>).

### ***Yapay Zekanın Zorlukları Ve Gelecekteki Gelişmeler***

Yapay zeka teknolojisi genel özellikleri ele alındığında diş hekimliği için oldukça uygundur. Ancak birçok avantajına rağmen henüz büyük ölçüde klinik uygulama rutinine girememiştir. Örneğin diş hekimliğinde konvansiyonel yapay sinir ağları, 2015 yılından itibaren ağırlıklı olarak diş röntgenlerinde olmak üzere yalnızca araştırma amacıyla kullanılmıştır (Schwendicke vd., 2019). Yapay zeka teknolojisinin diş hekimliğinde rutin olarak kullanılamamasının 3 ana nedenini görüyoruz. Bu nedenlerle mücadele etmek dental yapay zeka teknolojisinin ilerlemesi ve klinik olarak daha kullanılabilir olmasına yardımcı olacaktır;

- Öncelikle medikal ve dental veriler kişisel bilgilerin gizliliği ve bazı kurumsal engeller nedeniyle diğer veriler gibi sürekli ulaşılabilir değildir. Veriler genellikle ayrılmış, kişiselleştirilmiş ve sınırlı olarak çalışabilen sistemler yardımıyla saklanmaktadır. Veri kümeleri yapay zeka alanındaki diğer veri kümeleriyle karşılaştırıldığında nispeten daha küçüktür. Her hastaya ait veriler üçgenleme veya doğrulama için sınırlı seçeneğe sahip, karmaşık, çok yönlü ve hassastır. Medikal ve dental veriler (örn; elektronik tıbbi kayıtlar) genellikle sistematik olarak eksik olduğu ve rasgele olmadığı

için düşük değişken bütünlülük gösterirler. Örnekleme genellikle seçim yanlılığına yol açar. Bu nedenlerle bu tür veriler üzerinden geliştirilen yapay zeka uygulamaları doğuştan ön yargılı olmaya eğilimlidir (Gianfrancesco vd., 2018).

- İkinci olarak dental yapay zeka araştırmalarında; verileri işlemek, ölçmek ve sonuçlarını doğrulamak çoğunlukla tekrarlanamaz ve sabittir (Schwendicke vd., 2019). Ayrıca veri kümelerinin nasıl seçildiği, derlendiği ve nasıl bir ön işlenmeden geçtiği belirsizdir. Veriler çoğu zaman hem eğitim hem de test için kullanılır; bu durum “veri gözetleme önyargısı” adı verilen duruma yol açar (Gianfrancesco vd., 2018; England ve Cheng., 2019). Bir veriyi etiketlemek veya farklı etiketleri birleştirmek için kaç tane uzman gerektiği konusunda tam bir fikir birliğine varmak mümkün değildir (Walsh, 2018).
- Üçüncü olarak; yapay zekanın diş hekimliğindeki sonuçları genellikle kolayca elde edilemez. Günümüzün dental yapay zeka uygulamaları tarafından elde edilebilecek data; klinik tedavi için gereken kompleks karar verme kısmında yalnızca kısmen bilgilendirmedir (Maddox vd., 2019). Ayrıca sorumluluklara ve şeffaflığa yönelik sorular da belirsizliğini sürdürür.

### ***Ağız, Diş ve Çene Cerrahisinde Yapay Zeka Uygulamaları***

Yapay zeka, ağız ve çene cerrahisi alanındaki en büyük ivmesini robotik uygulamalar sayesinde kazanmıştır. Yapay zeka programları ile cerrahi işlem öncesinde; oluşabilecek komplikasyonları önlemek için anatomik yer işaretleri oluşturulabilmektedir. Bu sayede önemli anatomik yapıların korunması ve operasyonların daha kısa sürede tamamlanması mümkün olmaktadır (Widmann, 2007). Ayrıca yapay zeka teknolojisi ile, diş çekimi sonrası oluşabilecek postoperatif ödem tahmin edilmeye çalışılmıştır. Yapılan bir çalışmada; gömülü mandibular üçüncü molar operasyonu sonrası görülen yüz ödemi değerlendirilmek için yapay zeka modeli geliştirilmiş ve bu model, %98 doğruluk göstermiştir (Zhang vd., 2018). Orhan ve arkadaşları CBCT (konik ışınli bilgisayarlı tomografi) görüntüleri üzerinde yapay zeka programı kullanarak gömülü üçüncü molarların konum teşhisindeki doğruluğu değerlendirmiş ve sonucunda dişlerin anatomik yapılarla olan ilişkisini tespit etmede %86,2 doğruluk başarısı tespit etmişlerdir (Orhan vd., 2021). Başka bir çalışmada, panoramik radyograflarda derin evrişimsel sinir ağı kullanılarak üçüncü molar çekimlerinin zorluğu değerlendirilmiştir. Çekim zorluğu Pedersen zorluk skoru (PDS) kullanılarak üç gözlemcinin ortak fikirlerine göre belirlenmiştir. Hem ramus ile ilişkisinin belirlenmesinde hem de mandibular ikinci molara referansla

belirlenen derinlik bilgisinde sırasıyla %82,03, %90,2 ve %78,9 başarı oranları elde edilmiştir (Yoo vd., 2021).

Oral mukozadaki şüpheli alanların tespit edilerek benign ve malign lezyonların taraması ve sınıflandırılması da yapay zeka algoritmaları ile yapılabilmektedir (Lim vd., 2003). Ağız bölgesinde saptanan malign tümörlerin prognozunu etkileyen en önemli faktör, erken tanıdır. Buna rağmen çoğu olgu ileri evrede teşhis edilmektedir. Ariji ve arkadaşlarının yaptıkları bir çalışmada derin öğrenme yöntemi kullanılarak oral kanserli hastalarda lenf nodu metastazının bilgisayarlı tomografi yöntemi aracılığı ile tespiti yapılmıştır. Çalışma sonucunda yapay sinir ağı modeli % 78,2 oranında doğru tahminde bulunmuştur. Çalışma sonucunda yapay zeka modellerinin malign lezyonlarının teşhisinde klinisyenlere yardımcı olabileceği belirtilmiştir (Ariji, vd., 2019). Rosma ve arkadaşları yapay zeka sistemi ile klinisyenlerin ön teşhislerini karşılaştırarak kişilerin ağız kanseri geliştirme risklerini değerlendirmişler ve yapay zeka modelinin %59,9'luk bir doğruluk gösterdiğini bulmuşlardır (Rosma vd., 2010). Bu sonuç toplumdaki ağız kanseri prevalansını tahmin etmede; geniş çaplı oral taramaların işe yarayabileceğini akla getirmektedir. Sağlık hizmetlerinin kısıtlı olduğu birçok bölgede yapay zeka algoritmalarıyla taramalar yapılarak morbidite ve mortalite oranlarının düşeceği tahmin edilmektedir (Ilhan vd., 2020). Vinayahalingam ve arkadaşları derin öğrenme sayesinde oluşturdukları bir sistem aracılığıyla mandibular üçüncü molar dişler ile inferior alveolar kanalın tespit ve segmentasyonunu gerçekleştirmişlerdir. Üçüncü molar diş ile inferior alveolar kanal arasındaki ilişkinin hızlı bir şekilde yapay zeka tarafından tespitinin cerraha ameliyat öncesi erken bilgilendirme sağlayarak oluşabilecek komplikasyonların engellenebileceğini belirtmişlerdir. Ancak kurdukları sistemin bu haliyle klinik rutinde kullanılabilirliğinin sınırlı olduğunu ve oluşturulan modelin doğruluk oranlarının ve algoritmasının geliştirilmesi gerektiğini önermişlerdir (Vinayahalingam vd., 2019).

### ***Periodontolojide Yapay Zeka Uygulamaları***

Periodontal hastalıklar, periodonsiyumun iltihaplanması ile karakterize; geniş popülasyonları etkileyebilen yaygın bir hastalıktır ve tedavi edilmediğinde diş kaybına sebep olabilir. Periodontolojide yapay zeka ve derin nöral sinir ağı teknolojileri ile ilgili birçok uygulama yapılmıştır. Alveolar kemik kaybının tespiti ve kemik yoğunluğundaki erken değişiklikler yapay zeka modelleri ile tespit edilebilmektedir. Ayrıca implant ve çevre dokularla ilgili enfeksiyonların (peri-implantitis vb.) derin öğrenme yöntemleri ile erken teşhisinde erken müdahalelerin yapılabileceği düşünülmektedir. Lee ve arkadaşları periodontal hastalık nedeniyle kötü prognoza sahip dişleri tespit etmek için bir yapay zeka



modeli geliştirmiş ve %78,9 doğruluk oranı elde etmiştir. (Lee vd., 2018). Alalharith ve arkadaşları ortodontik tedavi gören hastalarda periodontal hastalığın yapay zeka algoritması ile tespitinde başarı oranının %77,1 olduğunu bildirmiştir (Alalharith vd., 2020). Krois ve arkadaşları yaptıkları çalışmada; derin nöral sinir ağları yardımıyla panoramik radyografiler üzerinde periodontal kemik kaybı tespiti yapmaya çalışmışlar ve sonucunda yapay zeka modelinin kararlarının uzman bir diş hekimiyle % 81 oranında uyumlu olduğunu tespit etmişlerdir (Krois vd., 2019).

Cha ve arkadaşları geliştirdikleri yapay zeka modeli ile periapikal radyografilerde implant tespiti yaparak alveolar kemik kaybını değerlendirmişler ve model ile diş hekimleri arasında önemli bir fark olmadığını bildirmişlerdir. Bu nedenle, modelin peri-implantitisin saptanmasında kullanılabileceğini belirtmişlerdir (Cha vd., 2021). Yapay zeka, implant planlaması alanında da kullanılmıştır. Kurt Bayrakdar ve arkadaşları 75 CBCT görüntüsünde kanal, sinüs/fossa ve eksik diş bölgelerinin tespitini gerçekleştirmişler ve en yüksek başarı oranını %95,3 ile eksik diş alanı tespiti olarak belirtmişlerdir. Çalışma sonucunda yapay zeka teknolojisinin pratisyenlere klinik uygulamalarda yardımcı olabileceği belirtilmiştir (Kurt Bayrakdar vd., 2021).

### ***Ağız, Diş ve Çene Radyolojisinde Yapay Zeka Uygulamaları***

Yapay zeka teknolojisi, ağız, diş ve çene radyolojisinde diş tespiti ve segmentasyonu, ekstra kök ve süpernümerer diş tespiti, dikey kök kırığı tespiti, apikal lezyon tespiti, osteoporoz teşhisi, Sjögren sendromu tespiti ve ultrasonografide kullanılmaktadır. Panoramik radyograflarda, periapikal radyograflarda ve bitewing radyograflarında diş tespiti ve segmentasyonu için derin öğrenme destekli yapay zeka modelleri üzerinde en az uzmanlar kadar başarılı olan çok sayıda çalışma yayınlanmıştır. Ekert ve arkadaşları derin öğrenme destekli yapay sinir ağları kullanarak panoramik radyograflarda apikal lezyonları tespit etmişler ve sistemin %65 hassasiyet gösterdiğini belirtmişlerdir (Ekert vd., 2019). Periapikal radyografiler üzerine bir başka çalışmada ise, Pauwels ve arkadaşları yapay zeka sisteminin %80'in üzerinde bir başarı oranı geliştirdiğini belirtmişlerdir (Pauwels vd., 2021). Orhan ve arkadaşları CBCT'de periapikal patolojileri saptayan bir yapay zeka modeli geliştirmiş ve bu modelin toplamda 153 periapikal lezyondan 142'sini başarılı bir şekilde saptadığını bildirmiştir (Orhan vd., 2020). Hiraiwa ve arkadaşları ise Sjögren sendromunun tespiti için CBCT görüntülerini değerlendirmiş ve geliştirilen modelin %96 doğruluk gösterdiğini belirtmiştir (Hiraiwa vd., 2019).

Lee ve arkadaşları osteoporozun tespiti için panoramik radyografilerde derin sinir ağları kullanan bir model geliştirmiş ve %98,5 doğruluk oranı bildirmiştir

(Lee vd., 2019). Bunun yanı sıra, Orhan ve arkadaşları yapay zeka tabanlı bir yöntemle ultrason görüntülerinde masseter kasının segmentasyonunu gerçekleştirmişler ve üç farklı yapay zeka modeli için başarı oranlarını sırasıyla %96, %94 ve %98 olarak belirtmişlerdir (Orhan vd., 2021). 3D görüntülerin daha karmaşık ve geniş eğitim veri setine sahip olması ve etiketleme sürecinin hatasız yapılması zor olduğundan, CBCT’de yapay zeka tabanlı tanıya odaklanan çalışmaların sayısı henüz yeterli değildir. Johari ve arkadaşları

hem ağız içi hem de CBCT görüntülerini yapay zeka modeli ile değerlendirerek dikey ve yatay kök kırıkları için yüksek duyarlılık ve özgüllük sağlamışlardır (Johari vd., 2016).

### ***Restoratif Diş Hekimliğinde Yapay Zeka Uygulamaları***

Diş çürükleri geçmişten günümüze toplumda en yaygın görülen hastalık olarak kabul görmesine rağmen; florür ve diğer çürük önleyici ajanların kullanımının yaygınlaşmasıyla birlikte diş çürüğü prevalansı da gittikçe azalmaktadır. Özellikle teşhisi zor olan arayüz çürüklerinin belirlenmesinde bite-wing radyografiler önemli bir role sahiptir (Heaven vd., 1994). Ancak bite-wing radyografilere rağmen bazı klinik durumlarda örneğin gözle kavitezyon izlenmeyen ve minenin 1/3 dış kısmının mineralizasyon kaybına uğradığı arayüz çürüklerinde radyografik olarak herhangi bir bulguya rastlanmadığı için çürük teşhisi oldukça zor olabilmektedir (Akpata vd., 2001). Bu nedenlerle son yıllarda bilgisayar destekli programlarla erken tanı çalışmaları hızlandırılmıştır (Wenzel, 2001). Karine ve arkadaşları sinir ağlarını kullanarak arayüz çürüklerini teşhis ettikleri bir çalışmada oluşturdukları yapay zeka modellemeleri ile teşhis etme başarısının %39,4 oranında arttığını tespit etmişlerdir (Devito vd., 2008). Schwendike ve arkadaşları ise evrişimli sinir ağlarını kullanarak arayüz çürüklerini teşhis için yaptıkları çalışmada % 80 oranında başarılı tahminler yapabildiğini bulmuşlardır (Schwendike vd., 2020). Cantu ve arkadaşları yaptıkları çalışmada, bite-wing radyografilerde çürük teşhisinde geliştirdikleri yapay zeka modeliyle deneyimli diş hekimlerinin performansını karşılaştırmışlardır. Çalışmada algoritma, diş hekimlerinden (%71) önemli ölçüde daha yüksek doğruluk oranına (%80) sahip olarak bulunmuştur (Cantu vd., 2020).

Askar ve arkadaşları derin öğrenme yöntemi ile ağız içi fotoğraflarda beyaz nokta lezyonlarının tespitini gerçekleştirmişler ve sistem %80’in üzerinde doğruluk göstermiştir (Askar vd., 2021). Öte yandan, Casalegno ve arkadaşları translüminasyon görüntülerinde çürüklerin otomatik tespiti ve lokalizasyonu için bir yapay zeka modeli geliştirmiş ve %72,7’lik bir başarı oranı elde etmiştir (Casalegno vd., 2019). Lee ve arkadaşları ise derin sinir ağı kullanılarak

periapikal radyografilerde çürük tespiti üzerine premolar ve molar dişler üzerinde bir çalışma yapmışlar ve en yüksek başarıyı %89 ile premolar dişlerde elde etmişlerdir. Araştırmacılar, derin öğrenme destekli yapay zeka modellerinin önemündeki yıllarda etkili bir çürük teşhis yöntemi olacağını belirtmişlerdir (Lee vd., 2018). Yapay zekanın restoratif diş hekimliğinde diğer bir kullanım alanı ise taşkın restorasyon tespitidir. Taşkın restorasyonlar periodontal hastalık, diş eti iltihabı ve diş etlerinde kanama gibi birçok probleme yol açmaktadır. Bu nedenle tespitleri önem arz etmektedir (Lang vd., 1990). Fadel ve arkadaşlarının yaptıkları bir çalışmada yapay sinir ağları kullanılarak taşkın restorasyon tespiti yapılmaya çalışılmış ve model % 85,6 oranında başarılı olmuştur (Fadel vd., 2020).

### ***Protetik Diş Hekimliği Alanında Yapay Zekâ***

Protetik diş hekimliği alanı hastaların estetik beklentilerle başvurduğu bir bölümdür. Yapay zekâ uygulamaları ile yüz bölgesinde yapılan ölçümler ve antropolojik hesaplamalar yapılarak hastaların estetik beklentilerinin en yüksek düzeyde karşılanması amaçlanmaktadır (Vera vd., 2013). Geliştirilen CAD/CAM yazılımları ile geleneksel döküm yönteminin zaman alıcı ve zahmetli süreci bırakılarak insan hataları minimuma indirilmiştir. Bu bağlamda yapay zekâyı CAD/CAM sistemlerine entegre etmenin klinik uygulamalar için oldukça verimli olabileceği düşünülmektedir (Raith vd., 2017). Diğer yandan protetik tedavi sonrası yüz profillerini stimüle etmek için sanal gerçeklik simülasyonu (Virtual Reality Simulation, VRS) teknolojisi kullanılabilir. Bu yöntemle hem diş hekimi hasta estetiğini maksimum verimle sağlar; hem de hastanın daha fazla motive olmasını sağlar (Vecsei vd., 2017; Kikuchi vd., 2013). Toshihito ve arkadaşları derin öğrenme yöntemini kullanarak yaptıkları bir çalışmada; diş restorasyonlarını ve dişler üzerinde protezleri otomatik olarak tespit etmeye çalışmışlardır. Çalışma sonucunda metal restorasyonlar % 80'lik bir başarıyla tespit edilirken, diş rengindeki estetik restorasyonlar ise %60 oranında başarıyla tespit edilmiştir (Takahashi vd., 2021).

### ***Adli Diş Hekimliği Alanında Yapay Zekâ***

Adli diş hekimliğinde yapay zeka uygulamalarının geçmişi her ne kadar eski olmasa da özellikle kimlik tespit çalışmaları için oldukça büyük bir öneme sahiptir (Khanagar vd., 2021). Do Tobel ve arkadaşları panoramik radyografiler üzerinde mandibular üçüncü molar dişlerin evrelendirmesinde evrişimli sinir ağlarını kullanarak evrelendirme metodu ile yaş tahmini yapmışlardır. Çalışma sonunda kullandıkları yapay zeka modelinin doğruluk derecesi % 51 olarak bulunmuştur (De Tobel vd., 2017). Patil ve arkadaşlarının geliştirdikleri bir yapay

zekâ modeli ise panoramik radyografiler üzerinden cinsiyet tahmini yapmaya çalışmışlar ve sistemin sonucunda başarı oranı oldukça yüksek (%75 doğruluk) olarak bulunmuştur (Patil vd., 2020). Sonuç olarak bu yapay zekâ modellerinin cinsiyet ve yaş belirlemede oldukça elverişli oldukları kanaatine ulaşılmıştır. Bir başka çalışmada ise yapay sinir ağları yardımıyla mandibular morfoloji tahmin edilmeye çalışılmış ve başarılı sonuçlar (%95 doğruluk) elde edilmiştir. Tüm bu yapılan çalışmalar yapay zekâ uygulamalarının adli diş hekimliğinde de etkin bir şekilde kullanılabileceğini göstermektedir (Niño-Sandoval vd., 2017).

## **SONUÇ**

Geliştirilen ve hala üzerinde çalışılan yapay zekâ modelleri sayesinde diş hekimleri daha hızlı ve daha güvenilir teşhisler yaparak daha etkin tedaviler gerçekleştirebilecektir. Bu alanda yapılan tüm çalışmalar genel olarak yapay zekâ algoritmalarına katkı sağlamaktadır. Ayrıca elde edilen hasta konforu ve hızlı teşhis-tedavi hasta memnuniyetini de artırarak klinisyen-hasta ilişkilerini olumlu yönde geliştirerek hekimlerin performansını artırmaktadır.

## KAYNAKÇA

- Akpata E, Farid M, Al-Saif K, Roberts E. (2001). Cavitation at radiolucent areas on proximal surfaces of posterior teeth. *Caries research*, 35, 2-5.
- Alalharith DM, Alharthi HM, Alghamdi WM, et al. (2020). A Deep Learning-Based Approach for the Detection of Early Signs of Gingivitis in Orthodontic Patients Using Faster Region-Based Convolutional Neural Networks. *Int J Environ Res Public Health*, 17, 8447.
- Ariji, Y., Fukuda, M., Kise, Y., Nozawa, M., Yanashita, Y., et al. (2019). Contrast-enhanced computed tomography image assessment of cervical lymph node metastasis in patients with oral cancer by using a deep learning system of artificial intelligence. *Oral surgery, oral medicine, oral pathology and oral radiology*, 127, 458-463.
- Askar H, Krois J, Rohrer C, et al. (2021). Detecting white spot lesions on dental photography using deep learning: A pilot study. *J Dent*, 107, 103615.
- Cantu AG, Gehrung S, Krois J, et al. (2020). Detecting caries lesions of different radiographic extension on bitewings using deep learning. *J Dent*, 100, 103425.
- Casalegno F, Newton T, Daher R, et al. (2019). Caries Detection with Near-Infrared Transillumination Using Deep Learning. *J Dent Res*, 98, 1227-1233.
- Cha JY, Yoon HI, Yeo IS, et al. (2021). Peri-Implant Bone Loss Measurement Using a Region-Based Convolutional Neural Network on Dental Periapical Radiographs. *J Clin Med*, 10, 1009.
- De Tobel, J., Radesh, P., Vandermeulen, D., Thevissen, P. W. (2017). An automated technique to stage lower third molar development on panoramic radiographs for age estimation: a pilot study. *The Journal of forensic odonto-stomatology*, 35, 42.
- Devito, K. L., de Souza Barbosa, F., & Felipe Filho, W. N. (2008). An artificial multilayer perceptron neural network for diagnosis of proximal dental caries. *Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology*, 106, 879-884.
- Ekert T, Krois J, Meinhold L, et al. (2019). Deep Learning for the Radiographic Detection of Apical Lesions. *J Endod*, 45, 917-922.
- England JR, Cheng PM. (2019). Artificial intelligence for medical image analysis: a guide for authors and reviewers. *AJR Am J Roentgenol*. 212, 513-519.
- Fadel, H. T., Abu-Hammad, O., Ghulam, O. A., Dar-Odeh, N. (2020). Are artificial neural networks useful for predicting overhanging dental

- restorations a cross-sectional study. *World Journal of Dentistry*, 11, 99-104.
- Gianfrancesco MA, Tamang S, Yazdany J, Schmajuk G. (2018). Potential biases in machine learning algorithms using electronic health record data. *JAMA Intern Med*, 178,1544–1547.
- Heaven TJ, Weems RA, Firestone AR. (1994). The use of a computer-based image analysis program for the diagnosis of approximal caries from bitewing radiographs. *Caries Res*, 28, 55-58.
- Hiraiwa T, Arijji Y, Fukuda M, et al. (2019). A deep-learning artificial intelligence system for assessment of root morphology of the mandibular first molar on panoramic radiography. *Dentomaxillofac Radiol*, 48, 20180218.
- Hornik K. (1991). Approximation capabilities of multilayer feedforward networks. *Neural Netw*, 4, 251–257.
- Ilhan B, Lin K, Guneri P, et al. (2020). Improving Oral Cancer Outcomes with Imaging and Artificial Intelligence. *J Dent Res*, 99, 241-248.
- Israni ST, Verghese A. (2019). Humanizing artificial intelligence. *JAMA*, 321, 29–30.
- Johari M, Esmaceli F, Andalib A, et al. (2016). A Novel Thresholding Based Algorithm for Detection of Vertical Root Fracture in Nonendodontically Treated Premolar Teeth. *J Med Signals Sens*, 6, 81-90.
- Khanagar, S. B., Al-Ehaideb, A., Maganur, P. C., et al. (2021). Developments, application, and performance of artificial intelligence in dentistry—A systematic review. *Journal of dental sciences*, 16, 508-522.
- Kikuchi, H., Ikeda, M., Araki, K. (2013). Evaluation of a virtual reality simulation system for porcelain fused to metal crown preparation at Tokyo Medical and Dental University. *Journal of dental education*, 77, 782-792.
- Krois, J., Ekert, T., Meinhold, L., et al. (2019). Deep learning for the radiographic detection of periodontal bone loss. *Scientific reports*, 9, 1-6.
- Kurt Bayrakdar S, Orhan K, Bayrakdar IS., et al. (2021). A deep learning approach for dental implant planning in cone-beam computed tomography images. *BMC Med Imaging*, 21, 86.
- Lang, N. P., Adler, R., Joss, A., Nyman, S. (1990). Absence of bleeding on probing an indicator of periodontal stability. *Journal of clinical periodontology*, 17, 714-721.
- Lee JH, Kim DH, Jeong SN, et al. (2018). Diagnosis and prediction of periodontally compromised teeth using a deep learning-based convolutional neural network algorithm. *J Periodontal Implant Sci*, 48, 114-123.

- Lee JH, Kim DH, Jeong SN, et al. (2018). Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *J Dent*, 77, 106-111.
- Lee JS, Adhikari S, Liu L, et al. (2019). Osteoporosis detection in panoramic radiographs using a deep convolutional neural network-based computer-assisted diagnosis system: a preliminary study. *Dentomaxillofac Radiol*, 48, 20170344.
- Lim K, Moles DR, Downer MC, et al. (2003). Opportunistic screening for oral cancer and precancer in general dental practice: results of a demonstration study. *Br Dent J*, 194, 497-502.
- Maddox TM, Rumsfeld JS, Payne PRO. (2019). Questions for artificial intelligence in health care. *JAMA*, 321, 31–32.
- Naylor CD. (2018). On the prospects for a (deep) learning health care system. *JAMA*, 320, 1099–1100.
- Niño-Sandoval, T. C., Pérez, S. V. G., González, F. A., et al. (2017). Use of automated learning techniques for predicting mandibular morphology in skeletal class I, II and III. *Forensic science international*, 281, 187-e1.
- Orhan K, Bayrakdar IS, Ezhov M, et al. (2020). Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans. *Int Endod J*, 53, 680-689.
- Orhan K, Bilgir E, Bayrakdar IS, et al. (2021). Evaluation of artificial intelligence for detecting impacted third molars on cone-beam computed tomography scans. *J Stomatol Oral Maxillofac Surg*, 122, 333-337.
- Orhan K, Yazıcı G, Kolsuz ME, et al. (2021). An Artificial Intelligence Hypothetical Approach for Masseter Muscle Segmentation on Ultrasonography in Patients with Bruxism. *Journal of Advanced Oral Research*. 12, 206-213.
- Patil, V., Vineetha, R., Vatsa, S., et al. (2020). Artificial neural network for gender determination using mandibular morphometric parameters: A comparative retrospective study. *Cogent Engineering*, 7, 1723783.
- Pauwels R, Brasil DM, Yamasaki MC, et al. (2021). Artificial intelligence for detection of periapical lesions on intraoral radiographs: Comparison between convolutional neural networks and human observers. *Oral Surg Oral Med Oral Pathol Oral Radiol*, 131, 610-616.
- Raith, S., Vogel, E. P., Anees, N., et al. (2017). Artificial Neural Networks as a powerful numerical tool to classify specific features of a tooth based on 3D scan data. *Computers in biology and medicine*, 80, 65-76.
- Rosma MD, Sameem AK, Basir A, et al. (2010). The use of artificial intelligence to identify people at risk of oral cancer: empirical evidence in Malaysian

- university. *International Journal of Scientific Research in Education*, 3, 10-20.
- Schwendicke F, Golla T, Dreher M, Krois J. (2019). Convolutional neural networks for dental image diagnostics: a scoping review. *J Dent*, 91, 103226.
- Schwendicke F, Rossi J, Göstemeyer G., et al. (2020). Cost-effectiveness of artificial intelligence for proximal caries detection. *Journal of Dental Research*, 0022034520972335.
- Schwendicke, F. A., Samek, W., Krois, J. (2020). Artificial intelligence in dentistry: chances and challenges. *Journal of dental research*, 99, 769-774.
- Takahashi, T., Nozaki, K., Gonda, T., Mameno, T., Ikebe, K. (2021). Deep learning-based detection of dental prostheses and restorations. *Scientific Reports*, 11, 1960.
- Topol E. (2019). Deep medicine: how artificial intelligence can make healthcare human again. *New York: Basic Books*.
- Vecsei, B., Joós-Kovács, G., Borbély, J., & Hermann, P. (2017). Comparison of the accuracy of direct and indirect three-dimensional digitizing processes for CAD/CAM systems—an in vitro study. *Journal of prosthodontic research*, 61, 177-184.
- Vera, V., Corchado, E., Redondo, R., Sedano, J., & Garcia, A. E. (2013). Applying soft computing techniques to optimise a dental milling process. *Neurocomputing*, 109, 94-104.
- Vinayahalingam, S., Xi, T., Bergé, S., Maal, T., & De Jong, G. (2019). Automated detection of third molars and mandibular nerve by deep learning. *Scientific reports*, 9, 1-7.
- Walsh T. (2018). Fuzzy gold standards: approaches to handling an imperfect reference standard. *J Dent*, 74, 47-49.
- Wenzel A. (2001). Computer-automated caries detection in digital bitewings: consistency of a program and its influence on observer agreement. *Caries Res*, 35, 12-20.
- Widmann G. (2007). Image-guided surgery and medical robotics in the cranial area. *Biomed Imaging Interv J*, 3, 11.
- Yoo JH, Yeom HG, Shin W, et al. (2021). Deep learning-based prediction of extraction difficulty for mandibular third molars. *Sci Rep*, 11, 1954.
- Zhang W, Li J, Li ZB, et al. (2018). Predicting postoperative facial swelling following impacted mandibular third molars extraction by using artificial neural networks evaluation. *Sci Rep*, 8, 12281.