

# Dentomaksillofasiyal Radyolojide Yapay Zeka Uygulamalarının Rolü: Bölüm 1

Elif Şener(0000-0003-1402-9392)<sup>a</sup>, Güniz Baksı Şen(0000-0001-5720-2947)<sup>a</sup>

*Selcuk Dent J*, 2022; 9: 713-720(Doi: 10.15311/selcukdentj.853884)

Başvuru Tarihi: 06 Ocak 2021  
Yayına Kabul Tarihi: 04 Mart 2021

### ÖZ

#### Dentomaksillofasiyal Radyolojide Yapay Zeka Uygulamalarının Rolü: Bölüm 1

Günümüzde bilgisayar destekli görüntüleme teknikleri ve görüntü analiz yöntemlerinin kullanımının hızlanması; konvansiyonel hasta tedavi yaklaşımını da değiştirmiştir. Gerek medikal gerekse dental tanı ve tedavi planlamasında yararlanılan yapay zeka uygulamaları; hayatımızın her alanında olduğu gibi dental alanda da devrim yaratmıştır. İnsan zekasını taklit eden ve topladıkları bilgilere göre yinelemeli olarak kendilerini geliştirebilen sistemler anlamına gelen yapay zeka; hız artışı, yüksek başarı, düşük maliyet, ulaşılabilirlik ve işlerde optimizasyon gibi birçok avantajı ile günümüzde sağlık alanında giderek daha sıklıkla kullanılır hale gelmektedir. Bundan en çok etkilenecek disiplinlerin başında temel tanıya destek olan ve diğer tüm disiplinlere tanısal açıdan destek veren radyolojidir. Bu derlemenin amacı; dişhekimliğinin farklı disiplinlerinde radyolojik verilerden yararlanılarak gerçekleştirilen yapay zeka uygulamalarının tanı ve tedavi aşamalarındaki avantaj, dezavantaj ve sınırlıklarını tartışmaktır.

#### ANAHTAR KELİMELELER

Dijital görüntüleme, Dentomaksillofasiyal radyoloji, Yapay zeka, Dental

### ABSTRACT

#### Role of Artificial Intelligence Applications in Dentomaxillofacial Radiology: Part 1

Nowadays, the acceleration of the use of computer-aided imaging techniques and image analysis methods has also changed the conventional patient treatment approach. Artificial intelligence applications utilized in both medical and dental diagnosis and treatment planning has revolutionized the dental field, as in all areas of our lives. Artificial intelligence, system imitating human intelligence and improving itself recursively according to the collected information, is more often used in healthcare with many advantages such as speed increase, high success, low cost, accessibility and optimization in work. One of the disciplines that will be most affected by this development is radiology, which supports basic diagnosis and provides diagnostic support to all other medical disciplines. The purpose of this review is to discuss the advantages, disadvantages and limitations of artificial intelligence applications realized using radiological data for diagnosis and treatment stages in different disciplines of dentistry.

#### KEYWORDS

Digital imaging, Dentomaxillofacial radiology, Artificial intelligence, Dental

Medikal radyoloji; teknolojik gelişmelerin en yoğun yaşandığı bilim dalıdır. Ultrason, Bilgisayarlı Tomografi (BT), Manyetik Rezonans Görüntüleme (MRG) ve Pozitron Emisyon Tomografi (PET) gibi ileri görüntüleme yöntemlerinin keşfinin yanı sıra; 3B modelleme ve görüntü analiz yöntemlerinin de kliniklerde kullanılması; hastalıkların tanı ve tedavi sürecine büyük katkı sağlamaktadır. Ancak, çok sayıda yeni görüntüleme yönteminin kullanılması ile değerlendirilmesi gereken görüntü sayısındaki artış, hem çekimleri gerçekleştiren radyoloji teknisyenlerinin hem de uzman radyologların iş yükünü arttırmakta ve çok sayıda radyoloji elemanı ihtiyacı doğmaktadır. Ortaya çıkan bu ihtiyacı gidermek ve radyasyon çalışanlarına destek olmak üzere kullanılan ve tanısal kapasiteyi hem arttıran, hem hızlandıran görüntü analiz yöntemlerine ek olarak son yıllarda geliştirilen yapay zeka (YZ) uygulamaları; sağlık sektöründe devrim yaratmıştır.<sup>1</sup>

Yapay zeka; algılama, akıl yürütme, öğrenme, muhakeme etme, karar verme gibi insan zekâsıyla ilişkilendirilen zihinsel süreçleri taklit edecek bilgisayar yazılımları üretmeyi hedefleyen bilgisayar biliminin bir alt dalı olarak tanımlanmaktadır. Fonksiyonel olarak insan zihninin yeniden tasarımı olarak nitelendirilebileceğimiz yapay zekâ ürünleri; online alışveriş sitelerinden cep telefonu ses

tanıma uygulamalarına kadar gündelik yaşamı kolaylaştıran geniş bir yelpazede hizmet sunabilmektedir.<sup>2</sup> Yapay zekâ teknolojileri, hayatımızın her alanında olduğu gibi medikal alanda da önemli uygulamalarda kullanılabilmektedir. Tıbbi yapay zeka yöntemlerinin bir veri kümesi içindeki anlamlı ilişkileri ortaya çıkarabilme kapasitesi pek çok klinik senaryoda tanı, tedavi ve takip sürecinde kullanılmaktadır. İnsan beyninin değerlendiremeyeceği büyüklükteki verilerin makineler ve yazılımlar aracılığıyla çok kısa sürede değerlendirilip yapay zekâ tarafından 'öğrenilerek' kullanılması, tanı ve tedavi planlamasına yeni ölçüt ve yaklaşımlar getirmiştir.<sup>3</sup> Dijital olarak kodlanmış görüntülerin bilgisayar diline kolaylıkla çevrilebildiği düşünüldüğünde, yapay zeka uygulamalarının günümüzde bilgisayar destekli görüntüleme yöntemlerinin sıklıkla kullanıldığı medikal radyoloji alanında önemli bir rol oynaması kaçınılmazdır. Dilimize "Makine Öğrenimi" olarak çevrilen 'Machine Learning' (ML), bilgisayarların doğrudan programlanmadan öğrenebilmesini sağlayan bilgisayar biliminin bir alt dalıdır ve görüntü temelli yapay zeka sistemlerinin en önemli bileşenidir. Günümüzde gelişim içinde olan bu

<sup>a</sup> Ege Üniversitesi Diş Hekimliği Fakültesi, Ağız Diş ve Çene Radyolojisi AD, İzmir, Türkiye

teknoloji; yapay sinir ağları olarak isimlendirilmekte ve insan beyni biyolojik sinir ağlarının yapı ve fonksiyonlarına benzer algoritma ve hesaplama modellerini içermektedir.<sup>4</sup>

Günümüzde yapay zeka sistemlerinin geliştirilmesi için yararlanılacak temel kaynakların başında gelen diyagnostik görüntüler; hastalık riski taşıyan olguların otomatik olarak belirlenmesi (örn: osteoporozla bağlı fraktür riski)<sup>5</sup>, patolojik oluşumların saptanması<sup>6</sup>, hastalıkların ayırıcı tanısı<sup>7</sup> gibi birçok farklı medikal amaçla kullanılabilir. Medikal yapay zeka sistemleri ve radyoloji bilimi arasındaki sinerji, çok sayıda hastalığın kesin tanısının yüksek doğrulukta konulabilmesinin yanısıra işlem hızının ve başarı yüzdesinin artması, maliyetin azalması, ulaşılabilirliğin kolaylaşması ve işlem optimizasyonu gibi birçok avantaj sağlamaktadır.<sup>8</sup>

Yapay zeka uygulamaları, medikal alanda olduğu kadar dental alanda da hızla gelişme göstermektedir. Dişhekimliğinde de yapay zeka teknolojisinin en çok fayda sağladığı disiplin dento-maksillo fasiyal radyolojidir (DMFR).<sup>1</sup> DMFR uygulamalarında kullanılan görüntüleme yöntemlerinin çoğunda dental ve alveoler sert dokuların görüntülenmesini sağlayan X-ışınları kullanıldığı için, tanı ve tedavi planlaması amacıyla geliştirilen YZ algoritmalarının sıklıkla diş ve çene kemiği gibi sert dokulara yönelik klinik uygulamaları kapsadığı görülmektedir. Kraniofasiyal anatomik yapıların yanı sıra patolojik değişikliklerin lokalizasyonunun otomatik olarak belirlenmesi, maksillofasiyal kist ve tümörlerin sınıflandırılması çürük, periodontal ve periapikal hastalık tanısı; bu uygulamaların başında yer almaktadır.<sup>9-12</sup> Yapılan bilimsel çalışmalar değerlendirildiğinde, DMFR alanında klinik uygulamalara yönelik YZ algoritmalarının çoğunun periapikal, panoramik ve sefalometrik radyografiler gibi iki boyutlu (2B) görüntüler kullanılarak gerçekleştirildiği görülmektedir.<sup>13</sup> Ancak, bilindiği üzere 2B görüntülerin magnifikasyon, distorsiyon, süperpozisyon gibi dezavantajlarının yanı sıra üçüncü boyuta dair bilgi içermemesi; gerek anatomik noktaların belirlenmesinde gerekse olası patolojik değişikliklerin saptanmasında YZ algoritmalarının diyagnostik doğruluğunu azaltmaktadır.<sup>14</sup> Dental volümetrik tomografi (DVT) başta olmak üzere 3B görüntüleme yöntemlerinin dişhekimliği kliniklerinde yaygın kullanımı sayesinde, 2B görüntülerin oluşturduğu dezavantajlar elimine edilmiş ve YZ algoritmalarının etkinliği ve başarısı artmıştır.<sup>15</sup>

Dentomaksillofasiyal radyoloji uygulamaları içinde 3B görüntüler kullanılarak gerçekleştirilen YZ uygulamalarının etkinliğinin araştırıldığı çalışmaların çoğunluğunu, dental ve maksillofasiyal hastalıkların tanısına yönelik olanların oluşturduğu dikkat çekmektedir.<sup>9-12</sup> Diyagnostik kapasiteyi arttırmak amacıyla geliştirilen öğrenme algoritmaları, görüntü verileri ve tanı çıktıları arasındaki ilişkiyi araştıran derin öğrenme tekniklerini içermektedir. Derin öğrenme; nesne tanıma, konuşma tanıma, doğal dil işleme gibi

alanlarda çok katmanlı yapay sinir ağlarını kullanan bir yapay zeka yöntemidir ve makine öğrenmesinin (ML) bir alt dalı olarak nitelendirilmektedir.<sup>16</sup> Geleneksel makine öğrenmesi yöntemlerindeki kodlanmış kurallar ile öğrenmeden farklı olarak; resim, video, ses ve metinlere ait verilerin görsel simgelerini kullanarak otomatik olarak öğrenebiliyor olması; diyagnostik amaçla gerçekleştirilen öğrenme algoritmalarının geliştirilmesinde en elverişli yöntem olmasını sağlamıştır.<sup>14</sup> Dentomaksillofasiyal hastalıkların tanısı amacıyla derin öğrenme tekniklerinin kullanıldığı çalışmalar; kraniyo-maksillofasiyal cerrahi, endodonti, periodontoloji, restoratif dişhekimliğinden adli dişhekimliğine kadar birçok farklı dental disipline ait konuları içermektedir.<sup>13</sup>

### Kraniomaksillofasiyal Cerrahi Alanında YZ Uygulamaları

Kraniyo-maksillofasiyal cerrahi uygulamaları içinde derin öğrenme tekniklerinin sıklıkla kullanıldığı alanların başında; kemik içi patolojik oluşumların tanısı gelmektedir.<sup>9,17-21</sup> Maksillofasiyal bölgede alveoler kemiklerde gözlenen kist ya da tümörlerin ayırıcı tanısında özellikle benzer radyolojik bulgulara sahip komplike olgularda, sadece radyolojik veriler ile doğru tanı koymak mümkün olmamakta, histopatolojik inceleme ile tanının kesinleştirilmesi gerekmektedir. YZ uygulamaları sayesinde çene yüz bölgesindeki kist/tümörlerin histopatolojik incelemelerine gerek olmadan sadece radyolojik bulgular ile tanısının konabilmesi; klinik uygulamalarda büyük öneme sahiptir.<sup>23</sup> Kist ve/veya tümör sınıflamaları için kullanılan YZ uygulamaları teknik olarak lezyonun saptanması, farklı yapıdaki dokuların ayrıştırılması (segmentasyonu), doku karakterinin saptanması (texture feature extraction) ve sınıflanması olmak üzere 4 temel basamaktan oluşmaktadır.<sup>13</sup> Ancak, günümüzde kullanılan derin öğrenme algoritmalarının çoğunda lezyonun saptanması ve segmentasyonu tamamen otomatik olarak gerçekleştirilememekte, bu aşamaların manuel olarak yapılması gerekmektedir.<sup>17,24</sup> Yılmaz ve ark.<sup>17</sup>, periapikal kist ve keratokistlerin sınıflandırılmasını amaçladıkları çalışmada kendi geliştirdikleri yarı otomatik bir algoritma ile lezyonların saptanması ve segmentasyonu için farklı düzlemlerde elde edilen DVT kesitlerinde lezyon bulunan bölgeleri manuel olarak işaretlemek gerektiğini bildirmişlerdir. Bu zaman alıcı ek işlem, mevcut algoritmanın etkinliğini ve rutin klinik uygulamalarda kullanılmasını zorlaştırmaktadır.<sup>17</sup> Bu ve buna benzer olumsuzlukları gidermek ve pratikte kullanım kolaylığı sağlamak için araştırmacılar yapay zeka uygulama basamaklarının otomatik olarak gerçekleştirildiği algoritmalar geliştirmeye yönelmiştir.<sup>9,18-22</sup> Lee ve ark.<sup>22</sup>, periapikal kist, dentigeröz kist ve keratokistin panoramik radyografi ve DVT görüntüleri üzerinde saptanmasına yönelik otomatik bir derin öğrenme algoritması geliştirmiştir. Kistik lezyonun sınırlarının otomatik olarak belirlendiği bu çalışmada, lezyon segmentasyonunun

manuel yöntemle kıyasla daha etkin bir şekilde ve daha kısa zamanda gerçekleştirildiği savunulmaktadır.<sup>22</sup> Bu çalışmada dikkat çeken en önemli bulgulardan biri, DVT görüntüleri üzerinde gerçekleştirilen algoritma uygulamalarının panoramik radyografi görüntülerine kıyasla daha doğru sonuç verdiği'dir. Buna göre, 3B görüntülerin 2B görüntülere kıyasla lezyon sınırlarının saptanmasında daha doğru sonuç verdiği bildirilmektedir. Abdoali ve ark. ise, asimetri analizi yardımıyla radiküler kist, dentigeröz kist ve keratokistlerin otomatik olarak segmente edildiği bir algoritmanın etkinliğini araştırmışlardır.<sup>9</sup> Geliştirilen algoritmanın lezyonların saptanmasında başarılı olduğu ancak, boyutu küçük kist olgularında düşük performans gösterdiği, sınırları düzensiz olan keratokist olgularında segmentasyon sürecinin sekteye uğradığı ve simetrik lezyon varlığında yetersiz sonuçlar verdiği vurgulanmaktadır.<sup>9</sup> Bu olumsuzlukları gidermek amacıyla Abdoali ve ark. radiküler kist, dentigeröz kist ve keratokist olgularının otomatik olarak sınıflandırılmasında DVT görüntülerinden yararlanarak yeni bir YZ modeli geliştirmişlerdir.<sup>18</sup> Yeni algoritma lezyon sınıflaması yönünden öncekilere kıyasla daha başarılı bulunmakla birlikte, alveoler kemiklerde gözlenen patolojik oluşumların sınıflandırılmasında kullanılacak tamamen otomatik bir algoritmanın geliştirilmesi için daha fazla sayıda çalışmaya gerek olduğu belirtilmektedir.

Maksillofasial cerrahi alanında YZ algoritmalarının test edildiği alanlardan biri de implant uygulamalarıdır. Diş implantları, kısmi veya tam dişsiz hastalar için sıklıkla tercih edilen bir tedavi alternatifine haline gelmiştir. İmplantın başarısını etkileyen parametrelerin başında implant uygulanacak kemik bölgesinin miktarı ve kalitesi gelmektedir. Kemik kalitesi ile ilgili çalışmalar incelendiğinde; mevcut bölgedeki trabeküler kemik yapısının tanımlanması için otomatik bir sınıflama algoritması geliştirildiği göze çarpmaktadır. Yirmibeş kadavra mandibuladan elde edilen DVT görüntüleri üzerinde trabeküler kemik yapı ve miktarına yönelik morfometrik parametreleri saptamak üzere bir tahmin modeli geliştiren Nicolileo ve ark.<sup>24</sup>; bu algoritmanın gözlemciler tarafından yapılan sübjektif kemik yapısı sınıflamasından daha yüksek performans gösterdiğini saptamıştır. Ancak, bu çalışmada grupların homojen bir dağılım göstermemesi ve daha da önemlisi gruplar arasında karşılaştırma yapmak üzere bir altın standart kullanılmamış olması sonuçlara temkinli yaklaşılması gerektiğini düşündürmektedir.<sup>24</sup> Nicolileo ve ark.'nın geliştirdiği model ile elde edilen bulgular kemik yapısının değerlendirilmesinde gözlemciye dayalı sübjektif olumsuzlukları ortadan kaldırmakla birlikte mevcut kemik kalitesine göre implant planlaması yapmak ve buna göre implant üstü protezleri bilgisayar destekli olarak tasarlamak için daha fazla sayıda çalışma yapılması gerektiği ortadadır.

Dental implantların mevcut kemik dokusunun miktarının ve kalitesinin yeterince incelenmeden uygulanması, implantlarda mekanik ve biyolojik

komplikasyonların da sıklıkla ortaya çıkmasına neden olmaktadır. Herhangi bir komplikasyonun ortaya çıkması durumunda ve hastanın kendi hekimi dışında hekimlere veya farklı kliniklere başvurmaları durumunda, dişhekimlerinin uygulanmış olan dental implant sistemini tanıyıp ileri tedavi yöntemlerini buna göre düzenlemeleri gerekmektedir. Bir başka hekim tarafından yerleştirilmiş implant sistemini (marka-model) tanımak üzere panoramik ve periapikal radyograflerin incelenmesi, uygulanan birincil yöntemdir. Ancak, dental implant sistemlerini radyografik olarak tanımlayabilmek ve farklı implant modellerini radyografler üzerinde ayırt etmek son derece zor ve çoğunlukla da mümkün olmayan bir işittir. Bu aşamada doğru şekilde yapılamayan sınıflamalar; daha invaziv tedavi yöntemlerinin uygulanmasına neden olabilmektedir. Bu olumsuzluğu gidermek adına; literatürde panoramik ve periapikal radyografler üzerinde implant tiplerini ve modellerini ayırt etmek amacıyla geliştirilen derin öğrenme algoritmaları ile olumlu sonuçlar alındığı bildirilmektedir.<sup>25-27</sup> Ancak bu konuyla ilgili yapılmış çalışmaların sadece 2B görüntüler üzerinde gerçekleştirildiği dikkat çekmektedir. Gelecekte 3B görüntüler ile yapılacak çalışmaların implantların sınıflandırılması açısından daha olumlu sonuçlar vereceği düşünülmektedir.

İmplant uygulamalarının başarısını etkileyen temel faktörlerden biri vital dokularla komşuluğun doğru saptanmasıdır. Özellikle alt çenede inferior alveoler kanalın (IAK) doğru lokalizasyonu, implant pozisyonunun, açısının ve boyutlarının belirlenmesinde büyük önem taşımaktadır. Ayrıca, mandibular kanalın lokalizasyonunun doğru saptanması, bölgede gerçekleştirilebilecek ileri cerrahi işlemlerin kanal içinde yer alan damar/sinir paketini travmatize etmesini önlemek amacıyla da önemlidir.<sup>28</sup>

Mandibular kanalın lokalizasyonunun önem taşıdığı bir diğer konu da gömülü 3. molar (3M) diş çekimleridir. Gömülü dişin sürme yönü ile ilgili çok sayıda çalışma bulunmakla birlikte, gömülü diş ile kanalın ilişkisini saptamaya yönelik gerçekleştirilen YZ çalışmalarının sayısının çok az olduğu görülmektedir.<sup>28-31</sup> Yapılan sınırlı sayıda çalışmada gömülü diş ile kanalın ilişkisini otomatik olarak saptamak üzere geliştirilen derin öğrenme algoritmalarının performansının radyologların performansına eşdeğer olduğu bulunmuştur.<sup>29,30</sup> Ancak, bu çalışmalarda grupların karşılaştırılması sırasında kullanılan altın standart radyologların görüş birliğidir. Araştırmalarda "uzman" hekimlerin görüş birliğinin altın standart olarak kullanılmaması gerektiği, karşılaştırma amacı ile seçilen yöntemin tamamen bağımsız ve güvenilirliği, doğruluğu kanıtlanmış bir standart ile yapılması bilimsel araştırmanın temel kuralları arasındadır.<sup>32</sup> Buna göre; gömülü diş ile mandibular kanal ilişkisinin otomatik olarak belirlenmesi amacıyla altın standart olarak kabul edilen yöntemler kullanılarak karşılaştırmalı çalışmalar yapılması gerekmektedir. Sadece 2B görüntüler ile değil 3B görüntüler kullanılarak da yapılabilecek bu

çalışmaların olumlu sonuçlar vermesi; gelecekte derin öğrenme algoritmalarının hem implant uygulamaları hem de diğer maksillofasiyal cerrahi işlemler konusunda klinisyenlere büyük destek sağlaması beklenmektedir.<sup>28,31</sup>

Bisfosfonat kullanan hastalarda diş çekimi sonrası çene kemiklerinde gözlenen osteonekrozun (BRONJ) saptanması amacıyla geliştirilen derin öğrenme algoritmaları da maksillofasiyal cerrahi uygulamaları içinde yer almaktadır. Beş farklı ML modelinin BRONJ saptanmasındaki etkinliğinin konvansiyonel yöntemlerle karşılaştırmalı olarak değerlendirildiği güncel bir çalışmada; kullanılan tüm ML yöntemlerinin konvansiyonel yöntemlerden üstünlüğünü kanıtlanmıştır.<sup>33</sup> Bu konuda gerçekleştirilecek ileri çalışmaların da benzer sonuçlar vermesi durumunda gelecekte YZ algoritmalarının klinik uygulamalarda rutin kullanımı ile kraniyo-maksillofasiyal operasyonlar ve biyopsilerin YZ veya robotik temelli otonom yöntemlerle gerçekleştirilmesinin mümkün olacağı düşünülmektedir.<sup>34,35</sup>

### Endodonti Alanında YZ Uygulamaları

Endodonti uygulamaları içinde derin öğrenme tekniklerinin sıklıkla kullanıldığı alanların başında periapikal lezyon tanısı gelmektedir. Bu alanda yapılan çalışmalar 1990'lı yıllara kadar dayanmaktadır. Mol ve ark.'nın 1992 yılında periapikal lezyonların tanısı amacıyla bilgisayar destekli görüntü analizlerinden yararlandıkları çalışma ilk örneklerdendir.<sup>36</sup> Çalışmada periapikal bölgenin belirlenmesi, periapikal lezyon varlığının değerlendirilmesi ve lezyon saptanan olgularda lezyon boyutlarının hesaplanması basamakları için geliştirilen analiz sisteminin diagnostik doğruluk değeri %80.2 olarak saptanmış ancak bu değer gözlemciler tarafından yapılan hesaplamalar ile korelasyonunun düşük olduğu bulunmuştur. Ayrıca, radyografik apeksin belirlenmesi için bir gözlemciye ihtiyaç duyulması geliştirilen sistemin handikapları arasındadır.<sup>36</sup> Makine öğreniminin periapikal lezyon tanısındaki performansını ölçmeyi hedefleyen bir başka çalışmada periapikal bölgede lezyon varlığı/yokluğunu 4 farklı kategoride sınıflandıran araştırmacılar; makine temelli bir sınıflamanın gözlemci temelli bir sınıflamaya kıyasla üstün sonuç verip vermeyeceğini araştırmıştır.<sup>37</sup> Bu çalışmanın sonuçlarına göre gözlemcilerin lezyon varlığını doğru sınıflandırma oranı %57 iken, makine öğrenimi temelli sınıflandırma oranı %84 olarak bulunmuştur.<sup>37</sup> Makine temelli öğrenmenin üstün sonuç vermiş olması periapikal lezyon tanısı için YZ uygulamalarının umut vaat ettiğini gösteren bir sonuç olsa da; her iki çalışmada dikkat çeken en önemli dezavantaj dijitalize edilmiş 2B görüntülerin kullanılmış olmasıdır.<sup>36,37</sup> 2B görüntülerin görüntü çözünürlüğünün yetersizliği ve üçüncü boyuta dair bilgi içermemesinin; YZ algoritmalarının olası patolojik değişikliklerin saptanmasında diyagnostik doğruluğunu azalttığı bildirilmektedir.<sup>14</sup> Bu olumsuzluğu gidermek için son dönemde gerçekleştirilen çalışmalarda 3B

görüntülerden yararlanılmaktadır.<sup>12,38</sup> Seltzer ve ark.<sup>12</sup> DVT görüntüleri üzerinde periapikal lezyonların otomatik olarak saptanması amacıyla geliştirdikleri derin öğrenme algoritması ile periapikal lezyon saptama doğruluğunu %93 olarak bulmuştur. Bu çalışmada periapikal lezyon saptanabilirliğini test eden algoritmanın tanısıl doğruluğunu karşılaştırmalı olarak değerlendirmek amacıyla altın standart olarak klinisyenlerin gerçekleştirdiği yarı-otomatik segmentasyon işlemleri kullanılmıştır.<sup>12</sup> Periapikal lezyonların otomatik olarak saptanabilirliğini araştıran başka bir çalışmada ise derin öğrenmedeki konvulasyonel sinir ağları (KSA) modeli kullanılmış ve çalışma daha geniş bir örnek grubu üzerinde gerçekleştirilmiştir.<sup>38</sup> Test edilen algoritmanın periapikal lezyon saptama oranının %92.8 olduğu bildirilmektedir. Aynı algoritma lezyon boyutlarının ölçüm etkinliği açısından değerlendirildiğinde; otomatik ölçüm ile klinisyenlerin manuel segmentasyon yöntemi kullanarak gerçekleştirdiği ölçümler arasında farklılık saptanmamıştır. Ancak, çalışmaya dahil edilen birkaç olguda YZ ölçümleri, manuel hacim ölçümlerinden farklılık göstermiştir.<sup>38</sup> Çalışmanın bulguları periapikal lezyonların saptanması ve hacim ölçümlerinin otomatik olarak gerçekleştirilebilmesi adına umut verici olmakla birlikte çalışmada periapikal lezyon tanımı yapılmamış ve hangi görüntülerin lezyon olarak değerlendirildiği, hangi boyut(lar)daki lezyonların çalışmaya dahil edildiği açıklanmamıştır. Yanı sıra; çalışmada klinisyenlerin manuel segmentasyon ile elde ettiği veriler, altın standart olarak kabul edilmiştir. Bir yöntemin altın standart olarak sayılabilmesi için: 1- hassas ve tekrarlanabilir bir yöntem ile belirlenmiş olması 2- lezyonun pato-anatomik görüntüsünü yansıtması 3- değerlendirilmekte olan diyagnostik yöntemden bağımsız olması gerektiği bilinmektedir.<sup>32</sup> Buna göre, yukarıda adı geçen çalışmalarda bildirilen YZ algoritmalarının performanslarına temkinli yaklaşılmalı ve algoritmaların gerçek performansı için histolojik incelemeler gibi gerçek altın standart değerlendirmelerinin kullanıldığı çalışmalar yapılması gerekmektedir.

Derin öğrenme algoritmaları içinde konvulasyonel sinir ağları (KSA) modelini kullanılarak geliştirilen YZ uygulamalarının performansının test edildiği bir diğer alan ise periapikal lezyon iyileşmesinin değerlendirilmesidir. Periapikal lezyonun erken tanısı kadar endodontik tedavinin başarısı etkileyen bir parametre olan periapikal lezyonun iyileşmesini değerlendirmek amacıyla Yang ve ark.<sup>39</sup>; kanal tedavisi öncesi ve sonrasında alınmış toplam 196 periapikal radyografi üzerinde 3 dereceli skala kullanılarak (iyileşme var, iyileşme yok, değişiklik yok) geliştirdikleri derin öğrenme algoritmasını uzman değerlendirmeleri ile karşılaştırmışlar ve iki yöntemin benzer sonuç verdiğini saptamışlardır.<sup>39</sup>

Periapikal bölgede gözlenen patolojik oluşumların



(kist/granulom) ayırıcı tanısında kullanılmak üzere geliştirilen derin öğrenme algoritmaları da endodonti alanındaki YZ uygulamaları içinde yer almaktadır. Özellikle kanal tedavisine yanıt vermeyen komplike olgularda YZ kullanımı histopatoloji gibi invaziv yöntemlere alternatif oluşturacağı için büyük önem kazanmaktadır. Okada ve ark.'nın DVT görüntülerini kullanarak geliştirdikleri makine temelli öğrenme algoritması ile; kist ve granulomun ayırıcı tanısı yönünden umut verici sonuçlar elde edilmiştir.<sup>40</sup> Periapikal kist ve granulomların doğru şekilde sınıflanması amacıyla geliştirilen bu algoritmanın dezavantajı, lezyonun segmentasyonunun otomatik olarak değil manuel olarak yapılması zorunluluğudur. 28 olgu gibi sınırlı örnek sayısı ile gerçekleştirilmiş olması da bu çalışmanın bir diğer kısıtlılığıdır.<sup>40</sup> Gelecekte yapay zeka uygulama basamaklarının otomatik olarak tamamlandığı gelişmiş algoritmaların daha geniş hasta grupları üzerinde gerçekleştirildiği çalışmalar sayesinde YZ algoritmalarının rutin klinik uygulamalarda kullanımının artması beklenmektedir.

Kist/granulom sınıflaması amacıyla YZ algoritmalarından yararlanılan bir diğer medikal alan ise biyoinformatiktir. Biyolojik bilgilerin yaratılması ve saklanması için veritabanlarının oluşturulması esasına dayanan bu alan; farklı hastalıklardan etkilenen hücrelerin derlenip sağlıklı hücreler ile kıyaslanması ve aradaki farklılıklardan hastalık tanısının konması esasına dayanmaktadır. Medikal bilimlerde çok önemli rol oynayan bu alanda, son yıllarda gen ekspresyon analizi üzerine yoğunlaştığı göze çarpmaktadır. Poswar ve ark.'nın periapikal granulom ve kist olgularının gen ekspresyonlarını karakterize etmek için geliştirdiği algoritma ile 2 farklı patolojik oluşum için elde edilen gen haritaların farklılık göstermesi; sadece enflamatuvar düzeyde değil moleküler düzeyde de YZ algoritmaları yardımıyla lezyon ayırımını yapmanın mümkün olabileceğini kanıtlamaktadır.<sup>41</sup>

Endodontik tedavinin uzun dönem başarısını etkileyen faktörler periapikal lezyonun erken tanısı ve doğru sınıflaması ile sınırlı olmayıp, kök kanal morfolojisinin belirlenmesinden kök kanal boyunun saptanması gibi kanal tedavisinin uygulama basamaklarının da yüksek doğrulukta gerçekleştirilmesini kapsamaktadır. Kanal tedavisi uygulama basamakları aşamasında YZ uygulamalarının etkinliğini araştıran çalışmaların başında Saghiri ve ark.'nın kök kanal boyu saptanmasına yönelik çalışması gelmektedir.<sup>42</sup> Elli bir tek köklü dişe yerleştirilen kanal aletleri ile elde edilen periapikal radyografiler üzerinde kanal aletinin apikal foramene göre lokalizasyonunun 3 dereceli (kısa, uzun, tam boyunda) bir skala yardımı ile değerlendirildiği çalışmada; yapay sinir ağları modeli kullanılarak geliştirilen YZ algoritması ile endodontistlerin radyografiler üzerinde yaptıkları skorlamalar karşılaştırmalı olarak değerlendirilmiştir. Stereomikroskop ile yapılan kök kanal boyu değerlendirmelerinin altın standart olarak kullanıldığı bu

çalışmada YZ algoritmasının endodontistlerin yaptıkları değerlendirmelerden daha doğru sonuç verdiği saptanmıştır. Klinisyenler tarafından gerçekleştirilen kanal boyu değerlendirmelerinin kişiye bağlı varyasyonlar içermesi nedeniyle tedavinin başarısı üzerindeki olumsuz etkilerinin göz önüne alınması; kanal boyu belirlemek için daha objektif bir yöntem olan YZ uygulamalarını öne çıkarmaktadır.<sup>42</sup>

Kök ve kanal morfolojisinin doğru belirlenmesi kanal tedavisinin başarısını etkileyen faktörler arasındadır. Hiraiwa ve ark.<sup>43</sup> geliştirdikleri derin öğrenme algoritmasını panoramik radyografilerde mandibular 1. molarların kök morfolojisinin sınıflandırılması amacıyla test etmiş ve aynı dişlerin DVT görüntüleri üzerinde gerçekleştirilen değerlendirmeleri altın standart olarak kullanmıştır. Çalışmanın bulgularında; kullanılan derin öğrenme algoritmasının mandibular 1. molar dişlerin distal köklerinde tek ya da ekstra kök varlığının ayırıcı tanısında yüksek performans gösterdiği bildirilmektedir.<sup>43</sup> Ancak, bu çalışmada da yukarıda söz edilen endodontik çalışmalarda olduğu gibi gerçek altın standart kullanılmamış, karşılaştırma için DVT görüntüleri üzerindeki değerlendirmeler altın standart kabul edilmiştir. Adı geçen tüm çalışmalar göz önünde bulundurulduğunda; YZ algoritmalarının gerçek performanslarının değerlendirilmesinde histopatolojik incelemeler gibi gerçek altın standartların kullanıldığı çalışmaların yapılması gerekliliği bir kez daha ortaya çıkmaktadır.

Kök kanalı morfolojisinin yanısıra kök kanal şekillerinin yüksek doğrulukla belirlenmiş olması; kanal tedavisinin başarısını etkileyen faktörler içinde yer almaktadır. Benyo ve ark.<sup>44</sup> kök kanal şekillerinin otomatik olarak belirlenmesi amacıyla geliştirdikleri YZ algoritmasının etkinliğini test ettikleri çalışmada hem mikro-BT hem DVT görüntülerinden yararlanmışlar, YZ algoritmasının her iki görüntüleme sistemi için de performans oranının %90'ın üzerinde olduğunu saptamışlardır.<sup>44</sup> YZ algoritmalarının gelecekte yaygın kullanımı ile aşırı eğri kanalların varlığı gibi tedavinin başarısını olumsuz etkileyebilecek verilere önceden sahip olunmasına; hem tedavi planlamasının en doğru şekilde yapılmasına hem de tedavi sırasında kullanılacak ekipmanlarının üretici firmalar tarafından daha etkin bir şekilde geliştirilmesine olanak sağlayacak bir parametredir.

Endodonti alanında YZ uygulamalarının performansının test edildiği bir alan da vertikal kök kırıklarının saptanmasıdır. Johari ve ark.<sup>45</sup> vertikal kök kırıklarının saptanması amacıyla geliştirdikleri derin öğrenme algoritmasının performansını hem periapikal hem DVT görüntüleri üzerinde test etmişler ve DVT görüntülerinin doğruluğunu periapikal filmlere kıyasla daha yüksek bulmuşlardır. Ancak; çalışmanın in vitro koşullarda çekilmiş tek köklü dişler üzerinde gerçekleştirilmiş olması en büyük sınırlılığıdır. Bu

konuda klinik koşulları taklit eden deri ya da kemik gibi dokularında simüle edildiği çalışmaların gerekli olduğu böylece algoritmanın performansının daha doğru şekilde değerlendirilebileceği vurgulanmaktadır.<sup>45</sup>

## SONUÇ

Derlemenin bu bölümünde diş hekimliği alanındaki güncel YZ uygulamaları gözden geçirilmiş, cerrahi ve endodonti alanında tanı ve tedavi aşamalarında derin öğrenme algoritmaları kullanımına yönelik öne çıkan araştırmalara değinilmiştir. Derin öğrenme mimarilerinin temelindeki matematiksel modeller ne kadar iyi anlaşılırsa gelecekte de derin öğrenme yöntemleri o kadar başarılı olacaktır. Gelecekte bu konuda yapılması planlanan çalışmaların geniş kapsamlı ve büyük gruplarla gerçekleştirilmesi; elde edilecek sonuçların doğruluğunu ve çalışmaların kalitesini arttıracaktır.

**KAYNAKLAR**

1. Hung K, Yeung AWK, Tanaka R, Bornstein MM. Current applications, opportunities, and limitations of AI for 3D imaging in dental research and practice. *Int J Environ Res Public Health* 2020;17:4424.
2. Gandomi A, Haider M. Beyond the hype: Big data concepts, methods, and analytics. *Int J Inf Manag* 2015;35:137–44.
3. Jiang, F, Jiang Y, Zhi H, Dong Y, Li H, Ma S, et al. Artificial intelligence in healthcare: past, present and future. *Stroke Vasc Neurol* 2017;2:230–43.
4. King BF Jr. Artificial intelligence and radiology: what will the future hold? *J Am Coll Radiol* 2018;15:501-3.
5. Ferizi U, Besser H, Hysi P, Jacobs J, Rajapakse CS, Chen C, et al. Artificial intelligence applied to osteoporosis: a performance comparison of machine learning algorithms in predicting fragility fractures from MRI data. *J Magn Reson Imaging* 2019;49:1029-38.
6. Schuhbaeck A, Otaki Y, Achenbach S, Schneider C, Slomka P, Berman DS, et al. Coronary calcium scoring from contrast coronary CT angiography using a semiautomated standardized method. *J Cardiovasc Comput Tomogr.* 2015;9:446-53.
7. Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature* 2017;542:115-18.
8. Hosny A, Parmar C, Quackenbush J, Schwartz LH, Aerts HJWL. Artificial intelligence in radiology. *Nat Rev Cancer* 2018;18:500-10.
9. Abdolali F, Zoroofi RA, Otake Y, Sato Y. Automatic segmentation of maxillofacial cysts in cone beam CT images. *Comput Biol Med* 2016;72:108-19.
10. 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;48:114–23.
11. Lee JH, Kim DH, Jeong SN, Choi SH. Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *J Dent* 2018;77:106–11.
12. Seltzer FC, Shi KJ, Zhang Z, Yan H, Yoon H, Mupparapu M, et al. Artificial intelligence for the computer-aided detection of periapical lesions in cone-beam computed tomographic images. *J Endod.* 2020;46:987-93.
13. Hung K, Montalvo C, Tanaka R, Kawai T, Bornstein MM. The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review. *Dentomaxillofac Radiol* 2020;49:20190107.
14. Leite AF, Vasconcelos KF, Willems H, Jacobs R. Radiomics and machine learning in oral healthcare. *Proteomics Clin Appl* 2020;14:e1900040.
15. Hwang JJ, Jung YH, Cho BH, Heo MS. An overview of deep learning in the field of dentistry. *Imaging Sci Dent* 2019; 49:1-7.
16. Kaya U, Yılmaz A, Dikmen Y. Deep learning methods used in the field of health. *European Journal of Science and Technology* 2019;16:792-808.
17. Yılmaz E, Kayıkcıoğlu T, Kayıpmaz S. Computer-aided diagnosis of periapical cyst and keratocystic odontogenic tumor on cone beam computed tomography. *Comput Methods Programs Biomed* 2017;146:91-100.
18. Abdolali F, Zoroofi RA, Otake Y, Sato Y. Automated classification of maxillofacial cysts in cone beam CT images using contourlet transformation and spherical harmonics. *Comput Methods Programs Biomed* 2017;139:197-207.
19. Mikulka J, Gescheidtova E, Kabrda M, Perina V. Classification of jaw bone cysts and necrosis via the processing of orthopantomograms. *Radioengineering* 2013;22:114–22.
20. Nurtanio I, Astuti ER, Ketut Eddy Pumama I, Hariadi M, Purnomo MH. Classifying cyst and tumor lesion using support vector machine based on dental panoramic images texture features. *IAENG Int J Comput Sci* 2013;40:29–37.
21. Rana M, Modrow D, Keuchel J, Chui C, Rana M, Wagner M, et al. Development and evaluation of an automatic tumor segmentation tool: a comparison between automatic, semi-automatic and manual segmentation of mandibular odontogenic cysts and tumors. *J Craniomaxillofac Surg* 2015;43:355-59.
22. Lee JH, Kim DH, Jeong SN. Diagnosis of cystic lesions using panoramic and cone beam computed tomographic images based on deep learning neural network. *Oral Dis.* 2020;26:152-58.
23. Poedjiastoeti W, Suebnukarn S. Application of convolutional neural network in the diagnosis of jaw tumors. *Healthc Inform Res* 2018;24:236-241.
24. Nicolielo LFP, Van Dessel J, van Lenthe GH, Lambrichts I, Jacobs R. Computer-based automatic classification of trabecular bone pattern can assist radiographic bone quality assessment at dental implant site. *Br J Radiol* 2018;91:20180437.
25. Lee JH, Kim YT, Lee JB, Jeong SN. A performance comparison between automated deep learning and dental professionals in classification of dental implant systems from dental imaging: a multi-center study. *Diagnostics (Basel)* 2020;10:910.
26. Lee JH, Jeong SN. Efficacy of deep convolutional neural network algorithm for the identification and classification of dental implant systems, using panoramic and periapical radiographs: A pilot study. *Medicine (Baltimore)* 2020;99:e20787.
27. Takahashi T, Nozaki K, Gonda T, Mameno T, Wada M, Ikebe K. Identification of dental implants using deep learning-pilot study. *Int J Implant Dent* 2020;6:53.

28. Jaskari J, Sahlsten J, Järnstedt J, Mehtonen H, Karhu K, Sundqvist O, et al. Deep learning method for mandibular canal segmentation in dental cone beam computed tomography volumes. *Sci Rep* 2020;10:5842.
29. Vinayahalingam S, Xi T, Bergé S, Maal T, de Jong G. Automated detection of third molars and mandibular nerve by deep learning. *Sci Rep* 2019;9:9007.
30. Fukuda M, Arijji Y, Kise Y, Nozawa M, Kuwada C, Funakoshi T, et al. Comparison of 3 deep learning neural networks for classifying the relationship between the mandibular third molar and the mandibular canal on panoramic radiographs. *Oral Surg Oral Med Oral Pathol Oral Radiol* 2020;130:336-43.
31. Kwak GH, Kwak EJ, Song JM, Park HR, Jung YH, Cho BH, et al. Automatic mandibular canal detection using a deep convolutional neural network. *Sci Rep* 2020;10:5711.
32. Wenzel A. Gold standard for the comparison of the diagnostic accuracy of panoramic images for approximal caries detection. *Dentomaxillofac Radiol* 2009;38:245.
33. Kim DW, Kim H, Nam W, Kim HJ, Cha IH. Machine learning to predict the occurrence of bisphosphonate-related osteonecrosis of the jaw associated with dental extraction: A preliminary report. *Bone* 2018;116:207-14.
34. O'Sullivan S, Leonard S, Holzinger A, Allen C, Battaglia F, Nevejans N, et al. Operational framework and training standard requirements for AI-empowered robotic surgery *Int J Med Robot* 2020;16:1-13.
35. Tarassoli SP. Artificial intelligence, regenerative surgery, robotics? What is realistic for the future of surgery? *Ann Med Surg (Lond)* 2019;41:53-55.
36. Mol A, van der Stelt PF. Application of computer-aided image interpretation to the diagnosis of periapical bone lesions. *Dentomaxillofac Radiol* 1992;21:190-4.
37. Carmody DP, McGrath SP, Dunn SM, van der Stelt PF, Schouten E. Machine classification of dental images with visual search. *Acad Radiol* 2001;8:1239-46.
38. Orhan K, Bayrakdar IS, Ezhov M, Kravtsov A, Özyürek T. Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans. *Int Endod J* 2020;53:680-89.
39. Yang J, Xie Y, Liu L, Xia B, Cao Z, Guo C. Automated dental image analysis by deep learning on small dataset. *IEEE 42nd Annual Computer Software and Applications Conference (COMPSAC)* 2018; 492-97.
40. Okada K, Rysavy S, Flores A, Linguraru MG. Noninvasive differential diagnosis of dental periapical lesions in cone-beam CT scans. *Med Phys*. 2015;42:1653-65.
41. Poswar Fde O, Farias LC, Fraga CA, Bambirra W Jr, Brito-Júnior M, Sousa-Neto MD, et al. Bioinformatics, interaction network analysis, and neural networks to characterize gene expression of radicular cyst and periapical granuloma. *J Endod*. 2015;41:877-83.
42. Saghiri MA, Garcia-Godoy F, Gutmann JL, Lotfi M, Asgar K. The reliability of artificial neural network in locating minor apical foramen: a cadaver study. *J Endod* 2012;38:1130-4.
43. Hiraiwa T, Arijji Y, Fukuda M, Kise Y, Nakata K, Katsumata A, et al. A deep-learning artificial intelligence system for assessment of root morphology of the mandibular first molar on panoramic radiography. *Dentomaxillofac Radiol* 2019;48:20180218.
44. Benyó B. Identification of dental root canals and their medial line from micro-CT and cone-beam CT records. *Biomed Eng Online* 2012;11:81.
45. Johari M, Esmaeili F, Andalib A, Garjani S, Saberhari H. Detection of vertical root fractures in intact and endodontically treated premolar teeth by designing a probabilistic neural network: an ex vivo study. *Dentomaxillofac Radiol* 2017;46:20160107.

## Yazışma Adresi:

Elif ŞENER  
Ege Üniversitesi  
Diş Hekimliği Fakültesi  
Ağız Diş ve Çene Radyolojisi AD,  
İzmir, Türkiye  
E-mail : esogur@yahoo.com