

Panoramik Radyograflarda Apikal Patoloji Tanısında Yapay Zeka Güvenilirlik Değerlendirmesi: Farklı Eşik Değerlerinde Karşılaştırmalı Bir Çalışma

Gediz Geduk(0000-0002-9650-2149)^α, Hatice Biltekin(0000-0001-9668-0888)^α, Çiğdem Şeker(0000-0001-8984-1241)^α

Selcuk Dent J, 2022; 9: 126-132 (Doi: 10.15311/selcukdentj.835913)

Başvuru Tarihi: 4 Aralık 2020
Yayına Kabul Tarihi: 13 Şubat 2021

ÖZ

Panoramik Radyograflarda Apikal Patoloji Tanısında Yapay Zeka Güvenilirlik Değerlendirmesi: Farklı Eşik Değerlerinde Karşılaştırmalı Bir Çalışma

Amaç: Panoramik radyograflar üzerinden tespit edilen apikal patolojilerin yapay zekâ temelli ticari bir yazılım ile doğruluğunun tespit edilmesidir.

Gereç ve Yöntemler: Çalışmada en az bir tane apikal patolojinin olduğu 100 panoramik radyografi seçilmiş ve Denti.AI ticari yazılımına yüklenmiştir. Sistemin %30, %60, %90 eşik değerlerinde apikal patolojiyi tespit etmesi sağlanmıştır. Panoramik radyograflar Ağız, Diş ve Çene Radyolojisi alanında uzmanlık eğitimi tamamlamış iki diş hekimi ve Ağız, Diş ve Çene Radyolojisi uzmanlık eğitimi sürdüren iki araştırma görevlisi tarafından seçilmiştir. Verilerin analizi SPSS 22.0 Paket Veri Programı ile yapılmıştır.

Bulgular: Çalışmanın sonunda %30, %60, %90 eşik değerleri için sensitivite değerleri sırasıyla %62.6, %38.1 ve %6.8, spesifite değerleri %0, %100 ve %100, tanısal doğruluk değerleri 61.3, 39.3 ve 8.6 olarak bulunmuştur. Pozitif prediktif değerleri (PPV) %96.8, 100 ve 100, negatif prediktif değerleri (NPV) 0, 3.2 ve 2.1, eğri altında kalan alan (AUC) ise 0.313, 0.69 ve 0.534 olarak hesaplanmıştır. İstatistiksel testlerde p<0.05 değeri anlamlı olarak kabul edilmiştir.

Sonuç: Yapay zekâ programı, özellikle eşik değer düşürüldüğü zaman uzman diş hekimlerine yakın sonuçlar vermektedir. Bu şekilde hazırlanan yapay zekâ tabanlı ticari yazılımlarda örnek sayılarının artışı ve bunların geriye dönük tespit edilmesinin doğruluğu artıracaklarını, bu tip yazılımların klinik tanılarda daha çok yer alacağını ve yoğun kliniklerde başvurulabilecek bir destek sistemi olabileceği düşünülmektedir.

ANAHTAR KELİMELELER

Apikal Patoloji; Yapay Zeka; Derin Öğrenme; Panoramik Radyografi.

ABSTRACT

Artificial Intelligence Reliability Assessment In The Diagnosis Of Apical Pathology In Panoramic Radiographs: A Comparative Study On Different Threshold Values

Background: To determine the accuracy of apical pathologies detected on panoramic radiographs with an artificial intelligence-based commercial software.

Methods: In the study, 100 panoramic radiographs with at least one apical pathology were selected and uploaded to Denti.AI commercial software. The system was enabled to detect apical pathology at 30%, 60%, and 90% threshold values. Panoramic radiographs were selected by graduated Oral and Maxillofacial Radiologist resident and two research assistants who are continuing their residency training in Oral and Maxillofacial Radiology. Data analysis was performed with SPSS 22.0 Packet Data Program.

Results: At the end of the study, sensitivity values were 62.6%, 38.1% and 6.8%, specificity values were 0%, 100% and 100%, and diagnostic accuracy values were 61.3, 39.3 and 8.6 for the threshold values of 30%, 60%, 90%, respectively. PPV values were calculated as 96.8, 100 and 100%, NPV values as 0, 3.2 and 2.1, AUC values as 0.313, 0.69 and 0.534. In statistical tests, p <0.05 value was accepted as significant.

Conclusion: The artificial intelligence program gives results close to specialist dentists, especially when the threshold value is lowered. It is thought that the increase in the number of samples and retrospective detection of artificial intelligence-based commercial software prepared in this way, will increase the accuracy, this type of software will be more involved in clinical diagnoses and should be a support system that should be used in intensive clinics.

KEYWORDS

Apical Pathology; Artificial Intelligence; Deep Learning; Panoramic Radiography.

Apikal patolojiler, %90'dan fazlası apikal apse, apikal granülom ve apikal kist olarak sınıflandırılan enflamatuvar lezyonlar olup enflamatuvar bir süreç olarak apikal periodontitis ile başlarlar.^{1,2}

Apikal periodontitis, esas olarak endodontik sistemin bakteriyel enfeksiyonu ve periapikal kemik dokusunun buna bağlı verdiği yanıtı içeren enflamatuvar bir süreçtir.^{3,4,5} Apikal periodontitiste oluşan kemik yıkımı hem mikrobiyal enfeksiyon hem de savunma mekanizmasının bir sonucudur.^{3,4,5} ve çenelerde dişlere bağlı en sık görülen enflamatuvar lezyondur.⁶ Kemik yıkımı radyograflarda rarefiye

osteit olarak adlandırılan radyolüsent bir görüntü oluşturur.¹ Apikal lezyonların tespitinde en sık periapikal ve panoramik radyograflar kullanılırken⁷ asemptomatik lezyonlar genelde radyograflarda tesadüfi olarak tespit edilir.⁸ Panoramik radyograflar, apikal lezyonların tespitinde sınırlı hassasiyet ve NPV göstermesine rağmen, spesifikliği, PPV'si ve genel olarak iyi bir tanısal ayırt etme kabiliyeti ile sıklıkla tercih edilmektedir. Bu nedenle, apikal patolojileri panoramik radyograflarda tespit etmek diş hekimleri için rutin bir hale gelmiştir.⁹ Radyoloji pratiğinde, tıbbi görüntüler radyologlar tarafından kısa sürede kapsamlı bir şekilde analiz edilip, değerlendirilmektedir.

^α Zonguldak Bülent Ecevit Üniversitesi, Diş Hekimliği Fakültesi Ağız Diş ve Çene Radyolojisi Bölümü, Zonguldak, Türkiye

Ancak modern tıbbi teknolojilerdeki ilerlemelerle birlikte görüntüleme verisi miktarı hızla artmakta ve buna bağlı olarak da radyologların iş yükü de artmaktadır.¹⁰

Derin öğrenme, çeşitli klinik uygulamalarda otomatik karar verme için kullanılan bir yapay zekâ yöntemidir. Yapay sinir ağlarının geliştirilmesi ile oluşturulan tekniklerle, veri setleri otomatik olarak kategorize edilmekte ve çok katmanlı Evrişimsel Sinir Ağları (Convolutional Neural Network-CNN) aracılığıyla verilerle ilgili öğrenme özellikleri desteklenmektedir.⁸

Son zamanlarda, yapay zekâ ve derin öğrenme nesne, yüz ve aktivite tanıma, izleme ve üç boyutlu haritalama\planlama ve lokalizasyon belirleme dâhil olmak üzere bilgisayarla görsel işlevler konusunda iyi performans göstermektedir.¹¹ Radyografik görüntülerin, bilgisayar diline kolay çevrilebilen Dijital olarak kodlanmış görüntülerden oluşması nedeniyle, yapay zekanın tıp alanında kullanımını kolaylaştırmaktadır.¹² Tıbbi segmentasyon ve tanı¹³, lezyon tespiti¹⁴, sınıflandırma¹⁵, görüntü rekonstrüksiyonu^{16,17} gibi birçok alanda derin öğrenme sistemleri başarı ile kullanılmaktadır.^{18,19} Özellikle, derin öğrenme temelli CNN modelleri kullanılarak diyabetik retinopati, cilt kanseri ve akciğer tüberkülozu tespiti ve sınıflandırılması gibi birçok başarılı çalışma yapılmıştır.^{20,21,22} Ancak, diş hekimliğinde yapay zekâ temelli daha az sayıda çalışma bulunmaktadır. Yapılan çalışmalar arasında evrişimli sinir ağının ve derin öğrenmenin kullanıldığı intraoral dental radyografilerden çürük tespiti¹⁸, apikal patoloji tespiti^{8,9,23}, kök kırıklarının saptanması²⁴, periodontal kemik kaybı²⁵, diş tanınması ve numaralandırılması²⁶, otomatik sefalometrik analiz²⁷, maksiller sinüzit tespiti¹⁹ vb. bulunmaktadır.

Planlanan çalışmada panoramik radyografilerde geleneksel yöntemler ile tespit edilen apikal patolojilerin, güncel ve hekim kullanımına sunulmuş derin öğrenme yöntemi-CNN mimarisi kullanan ticari yazılım Denti.AI (www.denti.ai) ile tespitinin güvenilirliği incelenmiştir.

GEREÇ VE YÖNTEM


Çalışmanın etik kurul onayı Zonguldak Bülent Ecevit Üniversitesi Etik Kurul Komitesi'nden alınmıştır (2020/05) ve Helsinki Bildirgesi'nin etik standartlarına uygundur. Çalışma retrospektif veri tarama çalışması olarak planlanmıştır.

Çalışmada 2019 yılında Zonguldak Bülent Ecevit Üniversitesi Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi Anabilim Dalı kliniğine başvuran, rutin muayene veya diğer sebeplerle arşivde panoramik radyografisi bulunan ve dişlerinden en az birinde apikal patoloji tespit edilen 100 hastanın panoramik radyografi görüntüleri Veraview IC5 HD (J Morita Mfg. Corp., Kyoto, Japan) panoramik cihazı ile 60-70 kVp ve 1-7.5mA aralığında erişkin dozunda elde edilmiştir.

Denti.AI (www.denti.ai, Toronto, CA) adlı ticari yapay zekâ programına yüklenerek, programın apikal patolojileri tespit etme düzeyinin incelenmesi retrospektif olarak yapılmıştır. Panoramik radyografiler Ağız, Diş ve Çene Radyolojisi alanında uzmanlığını almış ve üç yıldan fazla çalışma tecrübesi bulunan iki hekim ve Ağız, Diş ve Çene Radyolojisi uzmanlık eğitimini sürdüren iki araştırma görevlisi tarafından oluşturulan ortak bir konseyde dişlerde "apikal patoloji var/yok" şeklinde seçilmiştir. Tüm hekimlerin ortak fikri ile panoramik radyografide en az bir tane apikal patoloji var denilen hastalar çalışmaya dahil edilmiş olup en az bir hekimin fikir ayrılığı yaşadığı hasta radyografileri çalışmaya dahil edilmemiştir.

Dâhil etme kriterleri arasında hastaların 13-100 yaş aralığında bulunması (13 yaştan önce karışık dişlenme devam etmektedir), tüm çenede radyografide görülen en az bir adet diş görülmesi ve hekimler tarafından ortak kararla apikal patolojinin mevcut olduğu dişlerin bulunduğu radyografiler yer almaktadır. Çalışmadan çıkarma kriterleri ise panoramik radyografide optimum değerlendirmeye mâni olacak kadar artefakt bulunması, süt dişlerinin ağız ortamında bulunması ve ciddi boyutlara ulaşmış maksillofasiyal patolojilerin yer almasıdır. Bu koşullara uyan 100 adet hasta panoramik radyografisi seçildikten sonra bu radyografiler Denti.AI yazılımında diagnostik teste tabi tutulmuştur. Bu çalışmada kullanılan sistem hazır ticari bir sistem olduğu için, farklı yapay zekâ çalışmalarında olduğu gibi öğrenme verisi ve test verisi ayrı ayrı yazılıma verilmemiştir.^{11,13,17,19}

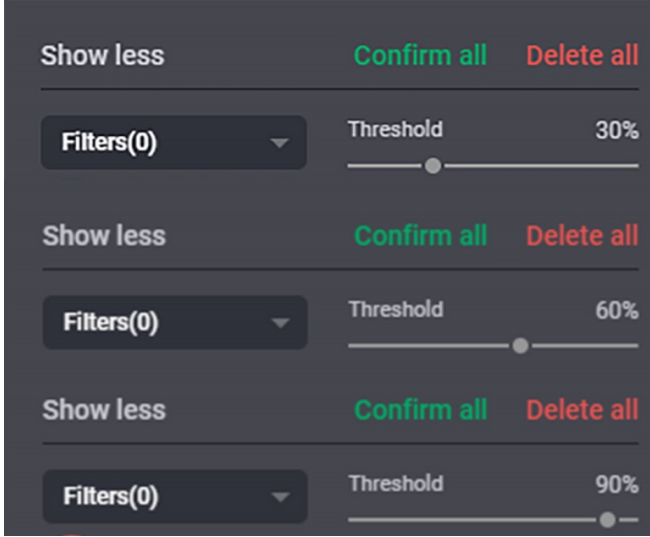
Yazılımın kendi doğası sonucu apikal patolojiler ve diğer tespit edilen patolojiler, lezyonlar, eksiklikler yazılım tarafından %0-%99 eşik aralığında belirtilerek sistemde görülmektedir. (Şekil 1)



Şekil 1

Kullanılan yazılımın ara yüzü ve sistem dahilinde gösterilen dolgular, lezyonlar.

Sistemin etkinliğini ve doğruluğunu değerlendirebilmek için sistemin eşik aralıkları manuel olarak ayrı ayrı %30, %60 ve %90 olarak ayarlandıktan sonra örnek grubu teker teker sisteme yüklenerek sistemin "apikal patoloji var/apikal patoloji yok" demesi sağlandı. (Şekil 2)



Şekil 2

Sistemde manuel olarak ayarlanan threshold (eşik) değerleri

Eşik aralıkları olarak yüksek değerler içerisinde üç aralık seçildi, bu üç aralıktan sonuncusu %100 ayarlanmak istendi ancak mevcut teknolojide yapay zeka bir yorumu, değerlendirmeyi asla %100 kesinlik ile yapmamaktadır.

Bu şekilde her eşik değer için üç farklı değerlendirme veri seti oluşturuldu. Yazılım sisteme yüklenen radyografiyi kendinde bulunan patolojiler üzerinden total bir değerlendirmeye alıp tüm sonuçları ekrana vermektedir. Verilen sonuçlar içerisinde apikal patoloji bulunan dişler not edilmiştir.

Çalışma planı doğrultusunda panoramik radyografide en az bir bölgede apikal patoloji görülen 100 hastanın yazılım sonuçları çıktısı alınıp istatistiksel olarak karşılaştırmaya tabi tutulmuştur.

İSTATİSTİKSEL ANALİZ

Tüm verilerin değerlendirilmesi için SPSS 22.0 Paket Veri Programı (SPSS 21.0 Software Package Program, Inc., Chicago, IL, ABD) kullanıldı. Geleneksel diagnostik yöntem ve yapay zekâ (Denti.AI) ile tespit edilen apikal patolojilerin karşılaştırmalı değerleri için tanımlayıcı istatistikler uygulandı. $P < 0.05$ değeri istatistiksel olarak anlamlı kabul edildi.

CNN algoritmasının (Denti.AI) tespit ve tanısal performansı için tanısal doğruluk, duyarlılık (sensitivite), özgüllük (spesifite), PPV, NPV, ROC (receiver operator characteristics curve) ve AUC hesaplandı.

BULGULAR

Çalışmaya dahil edilen 100 panoramik radyografide apikal patoloji varlığı için kurulan konseyde toplam 147 adet apikal patoloji tespit edildi. Manuel olarak belirlenen üç farklı eşik değer sonuçları Tablo 1'de ayrıntılı olarak verildi.

Tablo 1.

Değiştirilen eşik değer ile yazılımdan alınan sonuçların konsey kararı (altın standart) ile karşılaştırılması

Eşik Değer (Threshold)	Altın Standart	
	Patoloji Var	Patoloji Yok
%30	Patoloji Var	92
	Patoloji Yok	55
%60	Patoloji Var	56
	Patoloji Yok	91
%90	Patoloji Var	10
	Patoloji Yok	137

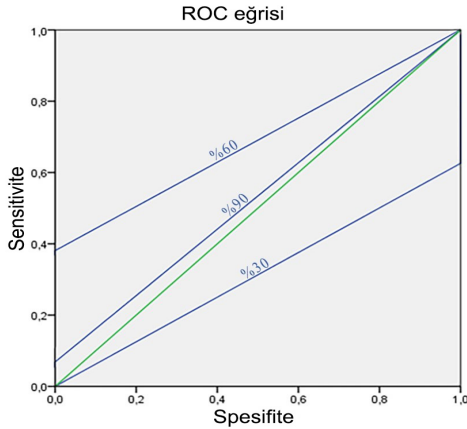
Bu sonuçlara göre genel olarak eşik değer küçültüldükçe yapay zekâ yazılımının diagnostik performansı yükselmektedir. Ancak %30 gibi fazla düşük bir eşik değere çekildiği zaman yazılım apikal patoloji olmayan dişlerde de patoloji varmış gibi algılayabilmektedir. Eşik değer %30 seviyesine çekildiği zaman üç dişte apikal patoloji olmamasına rağmen yazılım o üç dişte apikal patoloji varmış gibi sonuç göstermiştir. Bu sebeple hekim değerlendirmesinde 147 dişte apikal patoloji var, 3 dişte apikal patoloji yok sonucu üzerinden hesaplamalar yapılmıştır.

Oluşturulan konsey tarafından tespit edilen 147 apikal patolojinin %30 eşik değerinde 92'si, %60 eşik değerinde 56'sı apikal patoloji lehine tespit edilir iken %90 eşik değerinde sadece 10'u apikal patoloji var şeklinde yazılım tarafından belirtilmiştir. Bu değerler %30 eşik değerinde %61.3 tanısal doğruluk gösterirken; %60 eşik değerinde %39.3, %90 eşik değerinde %8.6 olarak tespit edildi.

Her eşik değer için ayrı ayrı ölçülen sensitivite değerleri %30, %60, %90 sırası ile olacak şekilde %62.6, %38.1 ve %6.8 olarak hesaplandı. Spesifite değerleri ise yine ayrı sıra ile %0, %100 ve %100 olarak bulundu. Sensitivite, spesifite, pozitif prediktif değer, negatif prediktif değer, ROC eğrisi ve eğri altındaki alan Tablo 2 de ayrıntılı olarak belirtildi. (Şekil 3)

Tablo 2.**Üç farklı eşik değerde hesaplanan istatistik veriler**

Eşik Değer (Threshold)	AUC(%)	Sensivite(%)	Spesifite(%)	PPV(%)	NPV(%)	Tanısıl Doğruluk (Diagnostic Accuracy)(%)
%30	0.313	62.6	0	96.8	0	61.3
%60	0.690	38.1	100	100	3.2	39.3
%90	0.534	6.8	100	100	2.1	8.6

**Şekil 3**

Belirlenen eşik değerler için ROC eğrileri

TARTIŞMA

Apikal patolojilerin (periodontitisin) tespit edilmesi enfeksiyonun kontrolü için tedavi protokolünün belirlenmesini sağlamaktadır²⁸ ve tanı, tedavi ve takibinde periapikal ve panoramik radyografiler sıklıkla kullanılmaktadır.⁷ Ancak periapikal radyolüensilerin radyografilerde tespit edilebilmesi için kemikteki mineral kaybının %30-50 arasına ulaşması gerekmektedir.²⁸ Panoramik radyografiler mandibular ve maksiller arkları ve diş destekleyici yapıları tek görüntüde içeren bir görüntüleme yöntemi. Periapikal radyografiler interdental alveolar kemik ve periapikal çevre dokular hakkında daha detaylı bilgi veren bir görüntüleme yöntemidir.⁷ Bu görüntüleme yöntemlerinde radyografik yorumlama X-ışını açılanması, kök morfolojik varyasyonları, apikali çevreleyen kemik yoğunluğu, radyografik kontrast gibi koşullara bağlı olarak etkilenmektedir.²⁸ Ayrıca bu görüntüleme yöntemleri üç boyutlu yapının iki boyutlu temsili olduğu için lezyonun gerçek boyutu, diş ve çevre dokularla arasındaki ilişki hakkında yeterli bilgiyi vermemektedir. Bu sebeplerden dolayı konik ışınli bilgisayarlı tomografi (KIBT) daha yüksek kalite sunabilmektedir.⁷ KIBT'nin klinik rutinde kullanılması ise maliyet etkinliği ve radyasyon dozu göz önüne alındığına tartışmalıdır.^{9,28}

Estrela ve arkadaşlarının²⁸ apikal periodontitisin saptanmasında KIBT, panoramik ve periapikal radyografinin doğruluğu ile ilgili yapmış olduğu

çalışmada KIBT referans görüntüleme yöntemi olarak alınmıştır. Çalışmanın sonucunda periapikal radyografiler için doğruluk değeri %54,5 (duyarlılık 0,55), panoramik radyografiler için doğruluk değeri %27,8 (duyarlılık 0,28) bulunmuştur.²⁸ Bu da periapikal bir lezyonun varlığını doğru bir şekilde tanımlamak için periapikal radyografilerin panoramik radyografilerden daha doğru sonuç verdiğini göstermektedir.

Derin öğrenme ve sinir yöntemlerinin geliştirilmesiyle birlikte yapay zekanın tıp alanında kullanımı hızlanmıştır ve klinikte birçok alanda sorunların çözülmesi için kullanılmıştır. Tıp alanında yapay zekâ uygulamalarının artmasıyla beraber diş hekimliğinde de kullanım artmaya başlamıştır.⁸ Literatür taramasında yapay zekâ temelli yazılımların kullanılarak apikal patolojinin tespitinin yapıldığı az sayıda çalışmaya ulaşılmıştır.^{8,9,23}

Ekert ve arkadaşları⁹ panoramik radyografi üstünde apikal patoloji tespit etmek için 7 katmanlı ileri beslemeli CNN kullanmıştır. Temel durumda (muayene eden eden 6 hekimden en az ikisinin ortak karar verdiği görüntüler) CNN'nin AUC'si 0,85 (0,04), duyarlılık ve özgüllük sırasıyla 0,65 (0,12) ve 0,87 (0,04) idi. Elde edilen PPV 0,49 (0,10) ve NPV ise 0,93 (0,03) bulunmuştur. Yalnızca tüm denetçilerin üzerinde anlaşmaya vardığı apikal patolojinin olduğu görüntüler dahil edilerek değerlendirildiğinde ise AUC'ye 0.95'e (0.02), duyarlılık 0.74'e (0.19), özgüllük 0.94'e, PPV 0.67'ye, NPV 0.95'e yükselmiştir.⁹

Bu çalışmanın sonucunda orta dereceli eğitilmiş bir CNN'nin panoramik radyografilerde apikal patolojileri saptamada tatmin edici bir ayırım yapabildiği gösterilmiştir. Ancak duyarlılığın iyileştirilmesi gerektiği sonucuna varılmıştır.⁹

Orhan ve arkadaşlarının⁸ apikal patolojiyi tespit etmek için KIBT görüntülerini kullandığı manuel segmentasyon yöntemi ve yapay zekâ sistemi tarafından oluşturulan ölçümler arasında önemli bir fark olmadığı tespit edilmiştir. Yapay zeka sistemi, incelenen 153 (% 92,8) periapikal lezyondan 142'sini tespit etmiştir. Derin öğrenmeye dayalı yapay zekâ sistemlerinin KIBT görüntülerinde apikal patolojiyi tespit etmede faydalı olduğu anlaşılmıştır.⁸

Endres ve arkadaşları²³ panoramik radyografideki radyolüsent lezyonları tespit etmede oral ve maksillofasiyal cerrahlar ve derin öğrenme sistemini karşılaştırmıştır. Referans standart verileri, hastanın tümünü tedavi eden 7 yıllık deneyime sahip tek bir oral ve maksillofasiyal cerrah tarafından toplanmıştır. 24 oral ve maksillofasiyal cerrahın panoramik radyografik görüntüleri değerlendirmelerine dayanan ortalama tanısıl PPV 0,69 (\pm 0,13) iken derin öğrenme algoritması ortalama 0.60 (\pm 0.04) hassasiyet ve 0.67 (\pm 0.05) PPV değerlerinde bulunmuştur.²³

Ayrıca panoramik ve periapikal radyografik görüntülerin kullanıldığı yapay zekâ temelli diş hekimiği alanında birçok çalışma mevcuttur.^{18,19,24,25,26}

Lee ve arkadaşları¹⁸ yapmış oldukları çalışmada, derin CNN algoritmalarının dental çürüklerin periapikal radyografilerde teşhisinin etkinliğini değerlendirmiştir. Toplam 3000 periapikal radyografik görüntünün kullanıldığı çalışmada hem premolar hem de molar dişler için duyarlılık %81, özgüllük %83, PPV %80.7, NPV %81.4 ve AUC değeri 0.845 olarak bulunmuştur. Çalışmanın sonucunda derin CNN algoritmasının, periapikal radyografilerde diş çürüğü tespitinde oldukça iyi sonuç verdiği görülmüştür.¹⁸

Murato ve arkadaşlarının¹⁹ panoramik radyografide maksiller sinüzit tanısı için derin öğrenme sistemini uyguladıkları çalışmada bilgisayarlı tomografi (BT) veya KIBT ile birlikte panoramik radyografisi çekilen ve maksiller sinüste enflamasyonlu lezyonları olan ve olmayan hastalar seçilmiştir. Lezyonların varlığı, BT veya KIBT ile doğrulanmıştır. Derin öğrenme sistemi %87.5 doğruluk, % 86.7 duyarlılık, % 88.3 özgüllük ve 0.875 AUC değerlerine sahipken, radyologlar %89.6 doğruluk, %90.0 duyarlılık, %89.2 özgüllük, 0.896 AUC değerlerine sahiptir. Sonuç olarak derin öğrenme sisteminin tanısız performansını yüksek bulunmuş ve radyologlarla arasında anlamlı bir fark görülmemiştir.¹⁹

Bizim çalışmamızda %30, %60, %90 eşik değerleri için sensitivite değerleri sırasıyla %62.6, %38.1, %6.8; spesifite değerleri %0, %100, %100; tanısız doğruluk değerleri %61.3, %39.3, %8.6 olarak hesaplanmıştır. Eşik değerin %90 gibi yüksek bir seviyeye getirildiğinde yazılım sınırları net olmayan çoğu patolojiyi 'apikal patoloji var' şeklinde kabul etmemektedir ve bunun sebebinin yüksek eşik değerlerde yazılımın çok daha kesin sonuçlar vermek istemesi olduğunu düşünmekteyiz.

Yapay zekâ temelli yazılımın bazı durumlarda radyologlar kadar iyi tespit yapamamasının altında birçok sebep bulunmaktadır. Öncelikle yazılımın kendini geliştirmesi için çok örnek (veri) olması gerekmektedir. Ayrıca yapay zekâ panoramik radyografideki artefaktlardan anatomik varyasyonlardan ve apikal patoloji dışındaki diğer lezyonlardan etkilenebilir.

Ekert ve arkadaşlarının⁹ yaptığı çalışmada duyarlılık %65, özgüllük %87'dir. Bu çalışmada, sistem özel olarak planlanmış olup, çalışma planına uygun farklı yapay zekâ mimarileri değerlendirilmiştir. Bizim çalışmamızda çıkan %62.6, %38.1, %6.8 olan sensitivite değerleri threshold arttıkça azalma göstermiştir ve benzer çalışmaya göre nispeten daha düşüktür. Buna sebep olarak yazılımın (Denti.AI) genel kullanıma açık olması (özelleşmemiş olması, apikal patoloji dışındaki durumları da analiz etmesi); panoramik radyografide apikal patoloji tanısının zaten kolay olmaması ve eşik aralığının artışıyla birlikte sistemin kritik hatalardan kaçınmaya çalışması olabilir.

Sistemin özgüllük değerlerine baktığımızda ise uygun çalışmalardan daha yüksek değer verdiği görülmüştür

(%100).^{8,9} Ancak eşik değeri çok düşük tutulursa testin sağlıklı örnekleri de fazladan pozitif gösterdiği tespit edilmiştir.

Çalışmamızda yapay zekâ temelli yazılımın birtakım eksiklikleri tespit edilmiştir. Diş kökünün neredeyse tamamını içeren büyük apikal lezyonları tespit edememiştir. Lateral fossa ile burun yumuşak dokusu arasında kalan çevre kemik dokuya göre daha radyolüsent görüntü veren bölgeyi lateral dişte apikal patoloji olarak göstermiştir. Diş apikallerinin mandibular kanala süperpoze olması ile oluşan radyolüsensileri de apikal patoloji olarak göstermiştir.

Yapay zekâ analizleri yapılırken doğru sonuçlar alınabilmesi için alt alveolar kanal, maksiller insiziv kanal, mental foramen, maksiller sinüs ve nazal fossa gibi komşu normal anatomik yapılar bölümlere ayrılabilir. Birden fazla dişle ilişkili büyük lezyonlar, tamamlanmamış apeks gelişimi, açık apeks veya normalden daha büyük kök kanalı, dens in dente gibi diş anomalileri de yapay zekâ sisteminin analizlerini değiştirebilir. Dolayısıyla daha doğru analizlerin yapılabilmesi için daha fazla anatomik varyasyon içeren görüntülerle programlamaya ihtiyaç vardır.⁸

SONUÇ

Bu şekilde hazırlanan yapay zekâ tabanlı ticari yazılımlarda doğruluğun artırılması ve klinik tanılarda daha çok yer alması için;

- Örnek sayılarının artırılması,
- Bu örneklerin geriye dönük doğrulanması,
- Yazılımın çeşitli testlere tabi tutulması,
- Yapay zeka çalışmalarında bu çalışmada olduğu gibi eşik değeri aralığı var ise bu değerin ortalama sayılarda tutulması önerilmektedir.

KAYNAKLAR

1. White SC, Pharoah MJ. Oral Radyoloji: İlkeler Ve Yorumlama. Çevirenler: Nursel Akkaya, Zuhale Çökertaş Yandımata. 7. Baskı Ankara: Palme Yayınevi; 2018. s. 315.
2. Koivisto T, Bowles WR, Rohrer M. Frequency and distribution of radiolucent jaw lesions: a retrospective analysis of 9,723 cases. *Journal of Endodontics* 2012;38(6), 729-32.
3. Kakehashi S, Stanley HR, Fitzgerald RJ. The effects of surgical exposures of dental pulps in germ-free and conventional laboratory rats. *Oral Surg Oral Med Oral Pathol* 1965;20:340-9.
4. Möller ÅJ, Fabricius L, Dahlen G, Öhman AE, Heyden GUY. Influence on periapical tissues of indigenous oral bacteria and necrotic pulp tissue in monkeys. *European Journal of Oral Sciences* 1981;89(6), 475-84.
5. Azuma MM, Samuel RO, Gomes-Filho JE, Dezan-Junior E, Cintra LTA. The role of IL-6 on apical periodontitis: a systematic review. *International endodontic journal* 2014;47(7), 615-21.
6. Braz-Silva PH, Bergamini ML, Mardegan AP, De Rosa CS, Haseus B, Jonasson P. Inflammatory profile of chronic apical periodontitis: a literature review. *Acta Odontologica Scandinavica* 2019;77(3), 173-80.
7. Arslan ZB, Demir H, Berker Yıldız D, Yaşar F. (2020). Diagnostic accuracy of panoramic radiography and ultrasonography in detecting periapical lesions using periapical radiography as a gold standard. *Dentomaxillofacial Radiology* 2020;49, 20190290.
8. Orhan K, Bayrakdar IS, Ezhov M, Kravtsov A, Özyürek T. Evaluation of artificial intelligence for detecting periapical pathosis on cone-beam computed tomography scans. *International Endodontic Journal* 2020;53(5), 680-89.
9. Ekert T, Krois J, Meinhold L, Elhennawy K, Emara R, Golla T, et al. Deep learning for the radiographic detection of apical lesions. *Journal of endodontics* 2019;45(7), 917-22.
10. Wang S, Summers RM. Machine learning and radiology. *Medical image analysis* 2012;16(5), 933-51.
11. Sklan JE, Plassard AJ, Fabbri D, Landman BA. Toward content-based image retrieval with deep convolutional neural networks. In *Medical Imaging 2015: Biomedical Applications in Molecular, Structural, and Functional Imaging* (Vol. 9417, p. 94172C). International Society for Optics and Photonics 2015.
12. Hung K, Montalvao C, Tanaka R, Kawai T, Bornstein MM. The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review. *Dentomaxillofacial Radiology* 2020;49(1), 20190107.
13. Christ PF, Elshaer MEA, Ettliger F, Tatavarty S, Bickel M, Bilic P, et al. Automatic liver and lesion segmentation in CT using cascaded fully convolutional neural networks and 3D conditional random fields. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer: Cham; 2016. p. 415-23.
14. Lakhani P, Sundaram B. Deep learning at chest radiography: automated classification of pulmonary tuberculosis by using convolutional neural networks. *Radiology* 2017;284:574-82.
15. Yasaka K, Akai H, Abe O, Kiryu S. Deep learning with convolutional neural network for differentiation of liver masses at dynamic contrast-enhanced CT: a preliminary study. *Radiology* 2018;286:887-96.
16. Kim KH, Choi SH, Park SH. Improving arterial spin labeling by using deep learning. *Radiology* 2018;287:658-66.
17. Liu F, Jang H, Kijowski R, Bradshaw T, McMillan AB. Deep learning MR imaging-based attenuation correction for PET/MR imaging. *Radiology* 2018;286:676-84.
18. Lee JH, Kim DH, Jeon SN, Choi SH. Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *Journal of dentistry* 2018;77, 106-11.
19. Murata M, Arijji Y, Ohashi Y, Kawai T, Fukuda M, Funakoshi T, et al. Deep-learning classification using convolutional neural network for evaluation of maxillary sinusitis on panoramic radiography. *Oral radiology* 2019;35(3), 301-7.
20. Gulshan V, Peng L, Coram M, Stumpe, MC, Wu D, Narayanaswamy A, et al. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *Jama* 2016;316(22), 2402-10.
21. 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(7639), 115-8.
22. Lopez-Garnier S, Sheen P, Zimic M. Automatic diagnostics of tuberculosis using convolutional neural networks analysis of MODS digital images. *PLoS one* 2019;14(2), e0212094.
23. Endres MG, Hillen F, Salloumis M, Sedaghat AR, Niehues SM, Quatela O, et al. Development of a deep learning algorithm for periapical disease detection in dental radiographs. *Diagnostics* 2020;10(6), 430.
24. Johari M, Esmaeili F, Andalib A, Garjani S, Saberkeri H. Detection of vertical root fractures in intact and endodontically treated premolar teeth by designing a probabilistic neural network: an ex vivo study. *Dentomaxillofacial Radiology* 2017;46(2), 20160107.

- 25.Krois J, Ekert T, Meinhold L, Golla T, Kharbot B, Wittemeier A, et al. Deep learning for the radiographic detection of periodontal bone loss. Scientific reports 2019;9(1), 1-6.
- 26.Tuzoff DV, Tuzova LN, Bornstein MM, Krasnov AS, Kharchenko MA, Nikolenko SI, et al. Tooth detection and numbering in panoramic radiographs using convolutional neural networks. Dentomaxillofacial Radiology 2019;48(4), 20180051.
- 27.Amasya H, Yildirim D, Aydogan T, Kemalolu N, Orhan K. Cervical vertebral maturation assessment on lateral cephalometric radiographs using artificial intelligence: comparison of machine learning classifier models. Dentomaxillofacial Radiology 2020;49, 20190441.
- 28.Estrela C, Bueno MR, Leles CR, Azevedo B, Azevedo JR. Accuracy of cone beam computed tomography and panoramic and periapical radiography for detection of apical periodontitis. Journal of endodontics 2008;34(3), 273-79.

Yazışma Adresi:

Hatice Biltekin
Zonguldak Bülent Ecevit Üniversitesi, Diş Hekimliği
Fakültesi
Ağız Diş ve Çene Radyolojisi Bölümü
67100 Kozlu, Zonguldak, Türkiye
Telefon: +90 (372) 261 35 82
Cep telefonu: 0 545 792 35 32
E-mail: dthaticebiltekin@gmail.com