

Derin Öğrenme Yöntemi Kullanılarak Geliştirilen Yapay Zekâ Yöntemi ile Panoramik Radyografilerde Dental Restorasyonların Otomatik Tespiti ve Sınıflandırılması: Metodolojik Çalışmalar

Automatic Detection and Classification of Dental Restorations in Panoramic Radiographs with Artificial Intelligence Method Developed Using Deep Learning Method: Methodological Studies

^{id} Esra AŞÇI^a, ^{id} Münevver KILIÇ^a, ^{id} Özer ÇELİK^{b,c}, ^{id} İbrahim Şevki BAYRAKDAR^{b,d}, ^{id} Elif BİLGİR^b,
^{id} Ahmet Faruk ASLAN^e, ^{id} Alper ODABAŞ^e, ^{id} Kaan ORHAN^e

^aAtatürk Üniversitesi Diş Hekimliği Fakültesi, Çocuk Diş Hekimliği ABD, Erzurum, Türkiye

^bEskişehir Osmangazi Üniversitesi, Sağlıkta Bilgisayar Destekli Tanı ve Tedavi Araştırma ve Uygulama Merkezi, Eskişehir, Türkiye

^cEskişehir Osmangazi Üniversitesi Fen Fakültesi, Matematik ve Bilgisayar Bilimleri Bölümü, Eskişehir, Türkiye

^dEskişehir Osmangazi Üniversitesi Diş Hekimliği Fakültesi, Oral ve Maksillofasiyal Radyoloji ABD, Eskişehir, Türkiye

^eAnkara Üniversitesi Diş Hekimliği Fakültesi, Oral ve Maksillofasiyal Radyoloji ABD, Ankara, Türkiye

ÖZET Amaç: Bu çalışmanın amacı, derin öğrenme yöntemi kullanılarak geliştirilen yapay zekâ yöntemi ile panoramik radyografilerde dental restorasyonları otomatik olarak tespit etmek ve sınıflandırmaktır. **Gereç ve Yöntemler:** Bu çalışmada, yapay zekâ modeli geliştirmek için 12-15 yaş aralığındaki çocuklardan alınan 789 panoramik radyografi kullanılmıştır. Radyografiler, Atatürk Üniversitesi Diş Hekimliği Fakültesi Pedodonti ABD radyoloji arşivinden elde edilmiştir. Çalışmamıza dâhil edilen panoramik radyografiler dolgu ve kanal tedavisi olmak üzere 2 gruba ayrılmıştır. PyTorch kütüphanesi ile uygulanan U-Net modeli restoratif materyallerin tespiti ve segmentasyonu için kullanılmıştır. Yapay zekâ performansı, karışıklık matrisi kullanılarak değerlendirilmiştir. **Bulgular:** Yapay zekâ sistemi dolgu grubuna ait test grubunda; 50 görüntüde bulunan 94 dolgulu diş etiket sayısından 89'unu gerçek pozitif, 1'ini yanlış pozitif ve 4'ünü yanlış negatif olarak değerlendirmiştir. Karışıklık matrisi kullanarak hesaplanan duyarlılık ve F1 skor değerleri sırasıyla 0,9569, 0,9888 ve 0,9726 olarak tespit edilmiştir. Kanal tedavisi, test grubunda 40 görüntüde bulunan 76 kanal tedavili diş etiket sayısından 60'ı gerçek pozitif, 0 yanlış pozitif ve 11'i yanlış negatif olarak değerlendirmiştir. Karışıklık matrisi kullanarak hesaplanan duyarlılık, kesinlik ve F1 değerleri sırasıyla 0,8450, 1 ve 0,9160 olarak tespit edilmiştir. **Sonuç:** Derin öğrenme tabanlı yapay zekâ modelleri, daimî dişlenme dönemine ait çocuklardan alınan panoramik radyografilerde restorasyonları otomatik olarak tespitinde çok iyi performans göstermiştir. Yapay zekâ araçları, klinisyenlere zaman kazandırabilir ve karar destek sistemi olarak yardımcı olabilir.

ABSTRACT Objective: This study aims to detect and classify it with the artificial intelligence method developed using the deep learning method. **Material and Methods:** In this study, 789 panoramic radiographs taken from children aged 12-15 were used to develop an artificial intelligence model. Radiographs were obtained from the radiology archive of Atatürk University Faculty of Dentistry, Department of Pedodontics. Panoramic radiographs included in our study were divided into two groups as filling and root canal treatment. The U-Net model implemented with the PyTorch library was used for the detection and segmentation of restorative materials. AI performance was evaluated using the confusion matrix. **Results:** Artificial intelligence system; in the test group belonging to the filler group; evaluated 89 true positives, 1 false-positive, and 4 false negatives out of 94 filled tooth tags in 50 images. Sensitivity, precision, and F1 score values calculated using the confusion matrix were found to be 0.9569, 0.9888, and 0.9726, respectively. Root canal treatment evaluated 60 as true positive, 0 false positive, and 11 false negatives out of 76 root canal-treated tooth tags in 40 images in the test group. Sensitivity, precision, and F1 values calculated using the confusion matrix were found to 0,8450, 1 ve and 0,9160, respectively. **Conclusion:** Deep learning-based artificial intelligence models have performed very well in automatically detecting restorations in panoramic radiographs of children with permanent dentition. AI tools can save clinicians time and assist as a decision support system.

Anahtar Kelimeler: Yapay zekâ; derin öğrenme; pedodonti; dental restorasyon

Keywords: Artificial intelligence; deep learning; pediatric dentistry; dental restoration

Correspondence: Esra AŞÇI

Atatürk Üniversitesi Diş Hekimliği Fakültesi, Çocuk Diş Hekimliği ABD, Erzurum, Türkiye

E-mail: esra_6221@hotmail.com



Peer review under responsibility of Türkiye Klinikleri Journal of Dental Sciences.

Received: 04 Jun 2021

Received in revised form: 18 Aug 2021

Accepted: 22 Sep 2021

Available online: 28 Sep 2021

2146-8966 / Copyright © 2022 by Türkiye Klinikleri. This is an open access article under the CC BY-NC-ND license (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

Yapay zekâ (YZ), insan zekâsını gerektiren işlevleri yerine getirebilen bilgisayar sistemlerinin geliştirilmesidir. Hızlı bir şekilde gelişmeye devam eden YZ, çoğu alanda olduğu gibi diş hekimliğinde de gelişmeye adaydır.¹ Bu gelişmeleri hızlandıran önemli nedenlerden bazıları son zamanlarda; bilgisayara olan ilginin ve bilgisayar gücünün artması, bilgiye daha kolay ulaşılması ve tıp alanında işlenmeye hazır olan önemli sayıda verinin varlığı gibi durumlardır.² Düşünme ve beynin çalışma prensiplerini modelleyerek, insan zekâsını bilgisayar vasıtasıyla taklit eden programlardan meydana gelen YZ yöntemleri, 1969 yılından beri tıp uygulamalarında farklı alanlarda kullanılmış ve bu çalışmalardan umut verici sonuçlar elde edilmiştir.

Derin öğrenme algoritmaları, maksillofasiyal radyoloji alanında hızla kendisini göstermektedir. Bu algoritmalar, verileri etiketleyen bir danışmana ihtiyaç duymadan büyük veri kümelerinden kalıpları öğrenmek için tasarlanmıştır. Derin öğrenme algoritmalarını gerçekleştirmek için çok sayıda derin öğrenme kütüphanesi ve bu kütüphanelerin kullandığı programlama dilleri bulunmaktadır.³ Derin öğrenme kütüphanelerini PyTorch, TensorFlow ve MXNet gibi grafik tabanlı ve Caffe gibi katman tabanlı çerçeveler olarak sınıflandırılabilir.⁴

Diş hekimliği klinik uygulamaları, teknolojinin getirdiği yeniliklere açıktır. Bu da YZ'nin, diş hekimliğine adaptasyonunun sağlanabileceğini gösterir.⁵ Son zamanlarda, diş hekimliğindeki YZ uygulamalarının; çürük tespiti, ortodontik tedavi öncesi planlama, implant planlaması, çenelerde izlenen patolojilerin teşhisi gibi birçok alanda uygulanabilirliği dikkat çekmektedir.⁶⁻⁸ Özellikle YZ'nin görüntü işleme ile olan uyumu, radyoloji üzerinde yapılan çalışmaları öne çıkarmıştır. Radyolojik görüntüde; çürük teşhisi, dişlerin numaralandırılması, periodontal hastalıkların tespiti, anatomik yapıların belirlenmesi, sefalometrik analiz incelenmesi, çenelerde belirti veren osteoporoz gibi bazı hastalıkların teşhisi yapılmakta olan güncel çalışmalardandır.⁹ Panoramik görüntüleme, oro-maksillofasiyal yapıların çoğunun tek bir görüntü üzerinde, minimal hasta rahatsızlığı ve düşük radyasyon etki dozu (14,2-24,3 µSv) ile geniş şekilde gösterilmesinden dolayı en yaygın kullanılan radyografik incelemelerden biridir. Maliyet

etkinliği ve nispeten düşük dozu nedeniyle dental panoramik radyografiler, ağız ve çene-yüz hastalıklarının teşhisinde yaygın bir şekilde kullanılmaktadır.

Dental restorasyonların tespiti ve sınıflandırılması için bilgisayarlı algoritmaların ve panoramik radyografilerde oral patolojik bulguların erken tespiti için yapılan çalışmaların yetersiz kaldığı görülmektedir. Bu çalışmanın amacı, maksillofasiyal anomaliliklerin otomatik olarak saptanmasına yönelik bir ilk adım olarak panoramik radyografilerde dental restorasyonları otomatik olarak tespit etmek ve sınıflandırmak için tasarlanmış, derin öğrenme algoritması geliştirmektir.

GEREÇ VE YÖNTEMLER

VERİ HAZIRLAMA

Çalışmamıza, Atatürk Üniversitesi Diş Hekimliği Fakültesi radyoloji arşivinde bulunan 12-15 yaş aralığındaki 789 çocuk hastanın panoramik radyografileri dâhil edilmiştir. Artefakt içeren görüntüler çalışma dışı bırakılmıştır. Çalışmamıza dâhil edilen panoramik radyografiler, dolgu ve kanal tedavisi içeren dental restorasyonlar olmak üzere 2 gruba ayrılmıştır.

Bu çalışmadaki tüm görüntüler, Planmeca Pro-max 2D Panoramik sistemi (Planmeca, Helsinki, Finlandiya) kullanılarak 65 kVp, 8 mA ve 16 sn'de elde edilmiştir.

Çalışma protokolü, Atatürk Üniversitesi Klinik Araştırmalar Etik Kurulu tarafından onaylanmıştır (karar tarihi ve numarası: 07.05.2020/30). Çalışma, Helsinki Deklarasyonu Prensipleri'ne göre yapılmıştır.

GÖRÜNTÜ DEĞERLENDİRMESİ

Çalışmamızda, panoramik görüntüde yer alan her bir restorasyon (dolgu veya kanal tedavisi) etiketi, deneyimli 2 hekim tarafından tarafından Colabeler yazılımı (MacGenius, Blaze Software, CA, ABD) kullanılarak manuel olarak işaretlenmiştir. Veri setinde, 2 hekimin teşhisinin eşleşmediği tüm panoramik radyografi görüntüleri çalışmadan hariç tutulmuştur. Restorasyonların yerini tanımlamak için poligon yöntemi kullanıldı. Veri setindeki 786 panoramik radyografiden toplam 3.788 etiket görüntüsü elde edildi (Resim 1, Resim 2).



RESİM 1: Dolgu restorasyonlarının etiketlenmesi.



RESİM 2: Kanal tedavili restorasyonlarının etiketlenmesi.

TABLO 1: Dolgu ve kanal tedavisi veri setinin sınıflandırması.

Grup	Dolgu	Kanal tedavisi
Eğitim	341 görüntü-683 etiket	273 görüntü-435 etiket
Doğrulama	45 görüntü-97 etiket	40 görüntü-63 etiket
Test	50 görüntü-94 etiket	40 görüntü-76 etiket

DERİN EVRİŞİMLİ SINIR AĞI

Derin öğrenme, U-Net modeli kullanılarak PyTorch kütüphanesi (sürüm 1.4.0) üzerinde gerçekleştirilmiştir. Anlamsal bölümlere görevleri için U-Net mi-

marisi kullanılmıştır. Kodlayıcı-kod çözücü tipi, 2 evrişimli katmanın dâhil olduğu 4 blok düzeyinden oluşmuştur. Bir maksimum havuz katmanı kodlama bölümünde bulunmaktadır ve kod çözme bölümünde yukarı evrişimli katmanlar vardır. Her katmanda 32, 64, 128 veya 256 evrişimli filtreler bulunur. Darboğazın yanı sıra katman 512 evrişimli filtre içerir. Kodlama katmanlarının karşılığı olan katmanlarda bağlantıları atlama ve kod çözme bölümleri mevcuttur.

MODEL VERİ HATTI

Python açık kaynak programlama dili (v.3.6.1; Python Software Foundation, Wilmington, DE, ABD) ve PyTorch kitaplığı model geliştirme için kullanılmıştır. Çalışmamızda model eğitimi, 16 GB RAM ve NVIDIA GeForce GTX 1060Ti (Nvidia Corporation Santa Clara, Kaliforniya) grafik kartı ile donatılmış bir bilgisayarda gerçekleştirilmiştir. Eğitimden önce her panoramik radyografi 2.943x1.435 pikselden 1.024x512 piksele yeniden boyutlandırılmıştır.


EĞİTİM AŞAMASI

Görüntüler aşağıdaki gibi rastgele dağıtılmıştır (Tablo 1).

Çene bölgesi, önceden eğitilmiş model ile görüntülerden kırılmıştır. Görüntülerin etiketlenmiş bölgelerinden maske görüntüleri oluşturulmuştur. Böylece en boy oranını bozmadan ideal eğitim boyutları elde edilmiştir. Veri seti bölümlere ayrılmıştır (Resim 3, Resim 4).



RESİM 3: Dolgu segmentasyon modeli.



RESİM 4: Kanal tedavisi segmentasyon modeli.

Eğitim veri kümesini genişletmek için veri artırma işlemi uygulanmıştır. Veri artırma işleminde sadece eğitim verileri kullanılmıştır. Ana teknikte eğitim verilerindeki görüntülerin dönüştürülmesiyle ek örneklerle oluşturulmuştur ve bu sayede veri seti genişletilmiştir. Eğitim ve doğrulama grubu üzerine vertikal döndürme, horizontal döndürme ve her iki döndürme yöntemleriyle öğmentasyon uygulanmıştır. Son hâliyle veri seti **Tablo 2**'de gösterilmiştir.

TABLO 2: Veri artırma işlemi sonrası dolgu ve kanal tedavisi veri seti sınıflandırması.

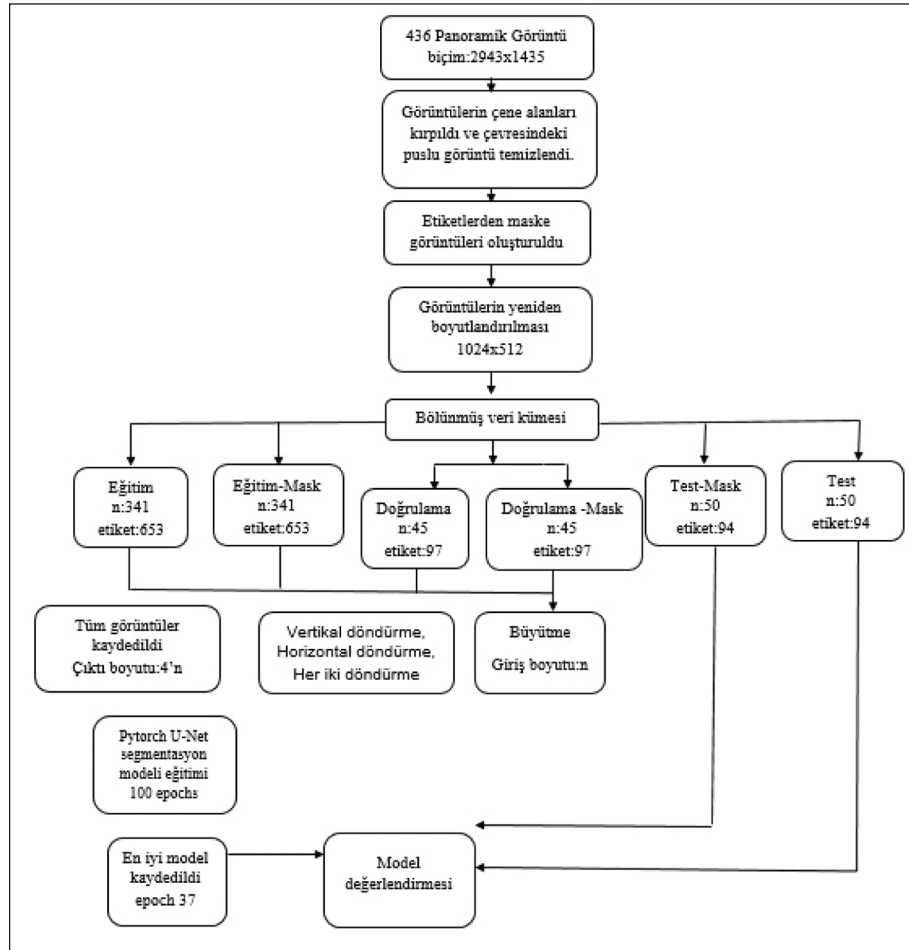
Grup	Dolgu	Kanal tedavisi
Eğitim	1.364 görüntü-2.732 etiket	1.092 görüntü-1.724 etiket
Doğrulama	180 görüntü-388 etiket	160 görüntü-254 etiket
Doğrulama	50 görüntü-94 etiket	40 görüntü-76 etiket

Dolgu için oluşturulan model Pytorch U-Net ile 100 epoch eğitilmiş, en iyi model olan 37. epoch en iyi performansı göstermiş ve bu nedenle modelde kullanılmıştır (**Şekil 1**).

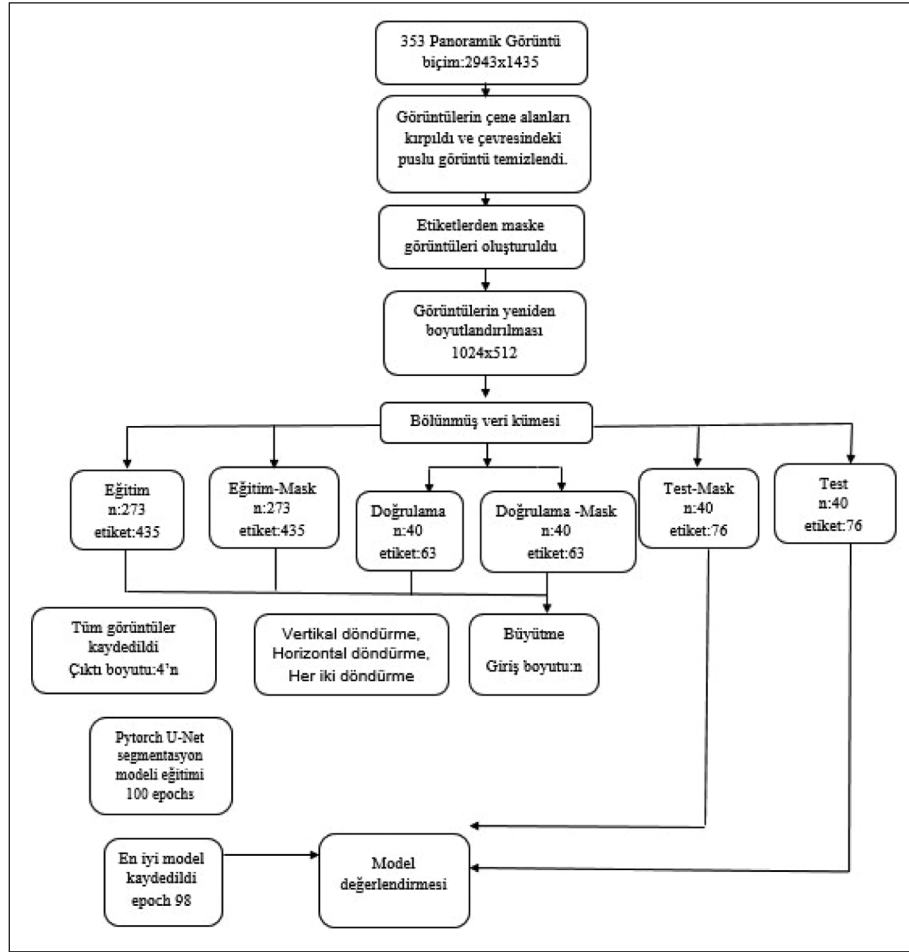
Kanal tedavisi için oluşturulan model Pytorch U-Net ile 100 epoch eğitilmiş, en iyi model olan 98. epoch en iyi performansı göstermiş ve bu nedenle modelde kullanılmıştır (**Şekil 2**).

İSTATİSTİKSEL ANALİZ

Model performansını değerlendirmek için karışıklık matrisi kullanılmıştır. Bu matris, gerçek değerlerin bilinmekte olduğu bir dizi test verisi üzerinde, bir sınıflandırma modelinin performansını tanımlamak için sıklıkla kullanılan bir tablodur. Bu matriste kullanılan metrikler: Doğru pozitif (DP), doğru şekilde tanımlanan pozitif olguların oranıdır; yanlış negatif



ŞEKİL 1: Dolgu grubuna ait yapay zeka modelinin gelişim aşamalarının şeması.



ŞEKİL 2: Kanal tedavisi grubuna ait yapay zekâ modelinin gelişim aşamalarının şeması.

(YN), yanlış şekilde pozitif olarak sınıflandırılan negatif değerlerin oranıdır; yanlış pozitif (YP), doğru şekilde sınıflandırılan negatif durumların oranıdır. Modelin başarısını değerlendirmek için kullanılan metrikler: Kesinlik; tüm sınıflardan doğru olarak ne kadar tahmin edildiğinin bir ölçüsüdür ($DP/DP+YP$), duyarlılık; modelin girdilerden pozitif sınıf etiketini tahmin etmekteki etkililiğini gösterir ($DP/DP+YN$), F1 skoru; kesinlik ve duyarlılık veri sonuçlarının harmonik ortalamasıdır.

BULGULAR

Çalışmamızda, YZ modelinin restorasyon tespitindeki başarısı her iki grupta ayrı ayrı değerlendirilmiştir.

YZ sistemi dolgu grubuna ait, test grubunda 50 görüntüde bulunan 94 dolgulu diş etiket sayısından 89'unu gerçek pozitif, 1'ini YP ve 4'ünü YN olarak

TABLO 3: Yapay zekâ modelleri tarafından doğru ve yanlış olarak tespit edilen dolgulu diş etiket sayısı ve karışıklık matrisi kullanan yapay zekâ modelinin tahmini performans ölçümleri.

Ölçüm	Değer	Ölçüm	Değer
Doğru pozitif	89	Duyarlılık	0,9569
Yanlış pozitif	1	Kesinlik	0,9888
Yanlış negatif	4	F1 skor	0,9726

değerlendirmiştir. Karışıklık matrisi kullanılarak hesaplanan duyarlılık, kesinlik ve F1 skor değerleri sırasıyla 0,9569, 0,9888 ve 0,9726 olarak tespit edilmiştir (Tablo 3).

YZ sistemi kanal tedavisi, test grubunda 40 görüntüde bulunan 76 kanal tedavili diş etiket sayısından 60'ını gerçek pozitif, 0 YP ve 11'ini YN olarak değerlendirmiştir. Karışıklık matrisi kullanılarak hesaplanan

TABLO 4: Yapay zekâ modelleri tarafından doğru ve yanlış olarak tespit edilen kanal tedavili diş etiket sayısı ve karışıklık matrisi kullanan yapay zekâ modelinin tahmini performans ölçümleri.

Ölçüm	Değer	Ölçüm	Değer
Doğru pozitif	60	Duyarlılık	0,8450
Yanlış pozitif	0	Kesinlik	1
Yanlış negatif	11	F1 skor	0,9160

duyarlılık, kesinlik ve F1 skor değerleri sırasıyla 0,8450, 1 ve 0,9160 olarak tespit edilmiştir (Tablo 4).

TARTIŞMA

Dental panoramik radyografiler nispeten düşük doz ve maliyet etkinliği sebebiyle diş hekimliğinde teşhis amacıyla yaygın olarak kullanılmaktadırlar.¹⁰ Schwendicke ve ark.nın yapmış oldukları bir derlemede anatomik yapıların tespitinde evrışimli sinir ağları kullanılarak, koni ışınli bilgisayarlı tomografi, periapikal radyografi, ısırma radyografisi ve panoramik radyografiler üzerinde sınıflandırma ve segmentasyon çalışmalarının yapılabileceğini bildirmişlerdir.¹¹ Bu derlemede, özellikle en çok panoramik radyografilerin tercih edildiği belirtilmiştir. Panoramik radyografi üzerinde yapılan çalışmalar incelendiğinde, restorasyon tespitindeki çalışmaların yeterli olmadığı görülmüştür. Bu eksikliğin giderilmesi için bu çalışma, YZ sisteminin daimî dişlenme dönemine ait panoramik radyografiler üzerinde dolgu ve kanal tedavi restorasyonlarını tespit etmedeki başarısını değerlendirmiştir.

YZ metotları; yapıları tespit etme, bölümlere ayırma ve sınıflandırma gibi görevleri gerçekleştirebilirler.¹² Bu gibi görevler için YZ modelinin, görüntü verileri ve görüntü için karşılık gelen etiketli verilerle eğitilmesi gerekir.¹¹ Eğitim süreci, modelin bir giriş görüntüsünde belirlenen bir etikete eşlemeye izin verene kadar tekrarlanır.¹³ Bu tür eğitimin ve etiket işleminin gerçekleştirilebilmesi için referans testi gerekmektedir. Altın standart ile bu referans testi oluşturulabilir.¹⁴ Örneğin altın standart, görüntüye açıklama ekleyen yani etiketleme sağlayan uzmanlar tarafından sağlanabilir. Uzmanlar, göreve bağlı olarak bir şeyin hangi yapı olduğunu, tam olarak lokali-

zasyonunu veya hangi sınırlara sahip olduğunu belirleyebilirler.¹¹ Bu prosedür, “gerçeği” görüntüye açıklama sağlayan kişilere göre tanımlanır. Bu sebeple referans testini tanımlamak için birden çok uzman tarafından aynı görüntüye açıklama sağlanır.¹⁵ Bu çalışmada verilerin etiketlenme işlemi, 3 yıllık deneyimli bir araştırma görevlisi ve 10 yıllık deneyime sahip bir pedodonti uzmanı tarafından gerçekleştirilerek doğruluk artırılmaya çalışılmıştır.

Özel bir tablo dizini olan ve hata matrisi olarak da bilinen karışıklık matrisi, tahmin edilen ve gerçekleşen durumların özetlenmesini sağlayarak algoritma performansının görselleştirilmesine olanak sağlayan bir tablo düzenidir.¹⁶ Kılıç ve ark.nın yaptıkları çalışmada, 421 panoramik radyografi üzerinde YZ yöntemi kullanılarak süt dişlerin numaralandırılması için otomatik bir algılama sistemi önerilmesini amaçlamışlar ve yöntemin performansında karışıklık matrisi kullanmışlardır.¹⁷ Çalışmalarında YP, DP, YN metriklerini kullanıp, doğru negatif metriğini dâhil etmeden model performansının değerlendirilmesini gerçekleştirmişlerdir. Bu çalışmada da restorasyon tespitinin performansını değerlendirmek için karışıklık matrisi üzerinde doğru negatif değeri kullanılmadan, DP, YP ve YN metrikleri kullanılmıştır.

Görüntülerde, manuel olarak etiketleme işleminin gerçekleştirilebilmesi için piyasada birkaç yazılım çeşidi bulunmaktadır. Bunlar; Dataturks, Colabeler, RectLabel veya LabelMe olarak örnekendirilebilir.¹⁸⁻²⁰ Bir görüntünün yüklenmesi ve açılmasıyla etiketleme süreci başlar. Daha sonra etiketlenecek nesne, dikdörtgen ya da poligon gibi bir yöntem seçilerek manuel olarak işaretlenir ve nesneye bir kimlik atanır.²¹ Ellis ve ark., göğüs radyografilerinin sınıflandırılması için YZ kullandıkları bir çalışmada Colabeler programını kullanarak veri setinde yer alan anormal vakaları, manuel olarak etiketlemişlerdir.²² Colabeler programı, sınırlayıcı kutu ya da poligon gibi seçenekleri sunarak görüntülerin etiketlenmesini sağlar. Poligon ile etiketleme sağlanması YZ yöntemiyle görüntüde segmentasyon yapılma imkânını sunmaktadır.²¹ Bu çalışma, YZ'nin daimî dişlenme dönemine ait panoramik radyografilerde restorasyon tespitinin değerlendirmesinde derin öğrenme tabanlı görüntü segmentasyon modeli kul-

lanılarak gerçekleştirilmiştir. Bu nedenle görüntülerdeki restorasyonların etiketlenmesi, açık kaynaklı ve ücretsiz etiketleme olanağı sunan Colabeler yazılımlıyla sağlanmıştır.

Son zamanlarda, evrişimli sinir ağlarına dayalı derin öğrenme modelleri bilgisayarla görme uygulamalarında başarıyla uygulanmıştır. Bu modeller, görüntü sınıflandırma, nesne algılama ve segmentasyon gibi geniş bir uygulama yelpazesini kapsayarak yüksek doğruluk elde etmişlerdir.²³⁻²⁵ Derin öğrenme modellerinin kullanımının artması, tıbbi görüntüler için benimsenmesini sağlamıştır.²⁶ U-Net, tıbbi görüntülerin hızlı ve hassas segmentasyonu için kullanılan evrişimli bir ağ mimarisidir.²⁷ O. Ronnerberger, 3 farklı tıbbi görüntüde U-Net segmentasyon yöntemini uygulamış ve çok iyi sonuçlar elde etmiştir.²⁸ Zhang ve ark. da karaciğer segmentasyonunu gerçekleştirmek için U-Net modelini kullanmışlardır.²⁹ Nishitani ve ark., panoramik görüntülerde dişlerin segmentasyonu için U-Net derin öğrenme algoritmasının kullanımının, elverişli bir yöntem olduğunu söylemişlerdir.³⁰ Bu sebeple bu çalışmada, segmentasyon için tıbbi segmentasyonlarda başarısı yüksek olan U-Net modeli tercih edilmiştir.

Makine öğrenmesine ve derin öğrenmeye destek olmak için geliştirilen Torch, açık kaynak kodlu bir kütüphanedir.³¹ Bu kütüphane, işlemin kolay hâle getirilmesini sağlar ve görüntü işlemede sıklıkla tercih edilir.³² Yoo ve ark., derin öğrenme tabanlı bir karar ağacı sınıflandırıcısı kullanarak koronavirüs hastalığı-2019'u tespit etmek için göğüs röntgeni radyografilerini değerlendirmişlerdir.³³ Çalışmalarında 2 kademeli bilgisayar destekli tanının eğitimi ve testi için PyTorch algoritmasını kullanmışlardır. Yazarlar, açık kaynak kodlu olan Torch kütüphanesinin karmaşık işlemleri basitleştirdiğini bildirmişlerdir. Bu sebeple bu çalışmada, YZ'nin geliştirilmesinde Python programlama dili ve PyTorch derin öğrenme kütüphanesi kullanılmıştır.

Dental radyografi görüntülerinin yorumlanmasında ve tedavi planlamasında YZ yöntemleri, umut vadetmektedir. Doğrudan problem çözebilme özelliğine sahip olmasından dolayı derin öğrenme, tıp alanında yaygın bir şekilde kullanılmaktadır.³⁴ Klinik uygulamalarda yaygın olarak tercih edilen panoramik

radyografi üzerinde YZ ile restorasyon tespiti, doğru teşhis ve zaman bakımından hekime kolaylık sağlayabilir.

Dental radyoloji üzerinde yapılan çoğu çalışma, lezyon tespiti, diş numaralandırılması ve çürük teşhisi üzerinde yapılmıştır.¹¹ Yapılan literatür incelemesinde, YZ'nin restorasyon tespiti üzerinde başarılı olduğunu gösteren bir çalışma mevcuttur.³⁵ Fakat hem çalışma sayısı hem de kullanılan veri seti, çalışmamıza göre yetersiz kalmaktadır. Abdalla-Aslan ve ark. 83 adet panoramik radyografi üzerinde diş restorasyonlarını otomatik olarak algılamak ve sınıflandırmak için YZ'ye dayalı algoritma geliştirmişlerdir.³⁵ Bu çalışmada, kanal tedavisi ve dolgu için hassasiyet değerleri sırasıyla %83,1 ve %83,2 bulunmuştur. Çalışmamızda ise kanal tedavisi ve dolgu için hassasiyet değerleri sırasıyla 0,95690 ve 0,8450 elde edilmiştir. Yapılan çalışmayla kıyaslandığında veri setimizin genişliği, çalışmamızdan elde edilen sonuçların güvenilirliğini artırmaktadır.

Bu çalışmanın bazı sınırlılıkları bulunmaktadır. Bu çalışmada elde edilen sonuçlar, herhangi bir farklı radyografi yöntemiyle karşılaştırılmamıştır. Bundan dolayı, gelecekte derin öğrenmeye dayalı CNN sistemlerinin daha fazla vakayla eğitilmesi ve daha gelişmiş algoritmaların kullanılması, panoramik radyografilerde restorasyon tespitinin başarısını artıracaktır. Bu da yöntemin, rutinde klinik prosedürlerde yerini almasını sağlayacaktır.

SONUÇ

Derin öğrenme tabanlı YZ modelleri, daimî dişlenme dönemine ait çocuklardan alınan panoramik radyografilerde restorasyonları tespit etmek için umut verici bir araçtır. YZ, klinisyene zaman kazandırmasının ve yardımcı olmasının yanı sıra restorasyonların otomatik olarak tespit edilmesinde önemli bir rol oynayabilir. Bu avantajların pratiğe dökülebilmesi için süt ve karışık dişlenme dönemlerine ait radyografiler üzerinde çalışmalara da ihtiyaç vardır. Mevcut tüm restorasyon türlerini dâhil ederek algoritmanın performansını iyileştirmek ve çeşitli panoramik makinelerde genelleştirilebilirliğini ve geçerliliğini değerlendirmek için daha fazla araştırmaya ihtiyaç vardır.

Finansal Kaynak

Bu çalışma sırasında, yapılan araştırma konusu ile ilgili doğrudan bağlantısı bulunan herhangi bir ilaç firmasından, tıbbi alet, gereç ve malzeme sağlayan ve/veya üreten bir firma veya herhangi bir ticari firmadan, çalışmanın değerlendirme sürecinde, çalışma ile ilgili verilecek kararı olumsuz etkileyebilecek maddi ve/veya manevi herhangi bir destek alınmamıştır.

Çıkar Çatışması

Bu çalışma ile ilgili olarak yazarların ve/veya aile bireylerinin çıkar çatışması potansiyeli olabilecek bilimsel ve tıbbi komite üyeliği veya üyeleri ile ilişkisi, danışmanlık, bilirkişilik, herhangi bir firmada çalışma durumu, hissedarlık ve benzer durumları yoktur.

Yazar Katkıları

Fikir/Kavram: İbrahim Şevki Bayrakdar; Münevver Kılıç, Elif Bilgir; Esra Aşçı; **Tasarım:** İbrahim Şevki Bayrakdar; Özer Çelik, Ahmet Faruk Aslan, Alper Odabaş; **Denetleme/Danışmanlık:** Münevver Kılıç, İbrahim Şevki Bayrakdar, Kaan Orhan; **Veri Toplama ve/veya İşleme:** Münevver Kılıç, Esra Aşçı, İbrahim Şevki Bayrakdar; **Analiz ve/veya Yorum:** Özer Çelik, Alper Odabaş, Ahmet Faruk Aslan, Kaan Orhan; **Kaynak Taraması:** Münevver Kılıç, Esra Aşçı; **Makalenin Yazımı:** Münevver Kılıç, Esra Aşçı, Elif Bilgir; **Eleştirel İnceleme:** Münevver Kılıç, İbrahim Şevki Bayrakdar, Kaan Orhan.

KAYNAKLAR

- Khanagar SB, Al-Ehaideb A, Maganur PC, Vishwanathaiah S, Patil S, Baeshen HA, et al. Developments, application, and performance of artificial intelligence in dentistry - a systematic review. *J Dent Sci*. 2021;16(1):508-22. [Crossref] [PubMed] [PMC]
- Park WJ, Park JB. History and application of artificial neural networks in dentistry. *Eur J Dent*. 2018;12(4):594-601. [Crossref] [PubMed] [PMC]
- Şeker A, Diri B, Balık HH. Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme [A review about deep learning methods and applications]. *Gazi Mühendislik Bilimleri Dergisi*. 2017;3(3):47-64. [Link]
- Gao X, Ramezanghorbani F, Isayev O, Smith JS, Roitberg AE. TorchANI: a free and open source PyTorch-based deep learning implementation of the ANI neural network potentials. *J Chem Inf Model*. 2020;60(7):3408-15. [Crossref] [PubMed]
- Khanna S. Artificial intelligence: contemporary applications and future compass. *Int Dent J*. 2010;60(4):269-72. [PubMed]
- 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. [Crossref] [PubMed]
- Poedjiastoei W, Suebnukarn S. Application of convolutional neural network in the diagnosis of jaw tumors. *Healthc Inform Res*. 2018;24(3):236-41. [Crossref] [PubMed] [PMC]
- Woo SY, Lee SJ, Yoo JY, Han JJ, Hwang SJ, Huh KH, et al. Autonomous bone reposition around anatomical landmark for robot-assisted orthognathic surgery. *J Craniomaxillofac Surg*. 2017;45(12):1980-8. [Crossref] [PubMed]
- Hwang JJ, Jung YH, Cho BH, Heo MS. An overview of deep learning in the field of dentistry. *Imaging Sci Dent*. 2019;49(1):1-7. [Crossref] [PubMed] [PMC]
- Terlemez A, Tassoker M, Kizilcakaya M, Gulec M. Comparison of cone-beam computed tomography and panoramic radiography in the evaluation of maxillary sinus pathology related to maxillary posterior teeth: do apical lesions increase the risk of maxillary sinus pathology? *Imaging Sci Dent*. 2019;49(2):115-22. [Crossref] [PubMed] [PMC]
- Schwendicke F, Golla T, Dreher M, Krois J. Convolutional neural networks for dental image diagnostics: a scoping review. *J Dent*. 2019;91:103226. [Crossref] [PubMed]
- Casalegno F, Newton T, Daher R, Abdelaziz M, Lodi-Rizzini A, Schürmann F, et al. Caries detection with near-infrared transillumination using deep learning. *J Dent Res*. 2019; 98(11): 1227-33. [Crossref] [PubMed] [PMC]
- LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015;521:436-44. [Crossref] [PubMed]
- Wenzel A, Hintze H. The choice of gold standard for evaluating tests for caries diagnosis. *Dentomaxillofac Radiol*. 1999;28(3):132-6. [Crossref] [PubMed]
- Walsh T. Fuzzy gold standards: approaches to handling an imperfect reference standard. *J Dent*. 2018;74 Suppl 1:S47-S9. [Crossref] [PubMed]
- Stehman SV. Selecting and interpreting measures of thematic classification accuracy. *Remote Sens Environ*. 1997;62(1):77-89. [Crossref]
- Kılıç MC, Bayrakdar IS, Çelik Ö, Bilgir E, Orhan K, Aydın OB, et al. Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs. *Dentomaxillofac Radiol*. 2021;50(6): 20200172. [Crossref] [PubMed] [PMC]
- Colabeler [Internet]. Best al annotation tool ever. (Erişim tarihi: 2019) Erişim linki: [Link]
- Dataturks [Internet]. Erişim linki: [Link]
- RectLabel [Internet]. Erişim linki: [Link]
- Dümmel J, Hochstein M, Glöckle J, Furmans K. Effizientes labeln von artikeln für das einlernen künstlicher neuronaler netze [Efficient labelling of articles for teaching artificial neural networks. *Logistics Journal: Proceedings*. 2019;12:1-9. [Link]
- Ellis R, Ellestad E, Elicker B, Hope MD, Tosun D. Impact of hybrid supervision approaches on the performance of artificial intelligence for the classification of chest radiographs. *Computers in Biology and Medicine*. 2020;120: 103699. [Crossref] [PubMed]
- Collet F. Xception: deep learning with depthwise separable convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017;1251-8. [Link]
- Redmon J, Farhadi A. YOLO9000: better, faster, stronger. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017;7263-71. [Crossref]
- Chen LC, Papandreou G, Kokkinos I, Murphy K, Yuille AL. Deeplab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs. *IEEE Trans Pattern Anal Mach Intell*. 2017;40:834-48. [Crossref] [PubMed]
- Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. *Med Image Anal*. 2017;42:60-88. [Crossref] [PubMed]

27. Ozturk O, Saritürk B, Seker DZ. Comparison of fully convolutional networks (FCN) and U-Net for road segmentation from high resolution imageries. IJEGEO. 2020;7(3):272-9. [[Crossref](#)]
28. Ronneberger O, Fischer P, Brox T In U-net: Convolutional networks for biomedical image segmentation, International Conference on Medical image computing and computer-assisted intervention. Springer; 2015. p.234-41. [[Crossref](#)]
29. Zhang L, Xu L. An automatic liver segmentation algorithm for CT images U-Net with separated paths of feature extraction. 2018 IEEE 3rd International Conference on Image, Vision and Computing (ICIVC). IEEE: 2018:294-8. [[Link](#)]
30. Nishitani Y, Nakayama R, Hayashi D, Hizukuri A, Murata K. Segmentation of teeth in panoramic dental X-ray images using U-Net with a loss function weighted on the tooth edge. Radiol Phys Technol. 2021;14(1):64-9. [[Crossref](#)] [[PubMed](#)]
31. Kızrak MA, Bolat B. Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma [A comprehensive survey of deep learning in crowd analysis]. Bilişim Teknolojileri Dergisi. 2018;11(3):263-86. [[Crossref](#)]
32. Collobert R, Kavukcuoglu K, Farabet C. Torch7: a matlab-like environment for machine learning. BigLearn, NIPS Workshop; 2011. [[Link](#)]
33. Yoo SH, Geng H, Chiu TL, Yu SK, Cho DC, Heo J, et al. Deep learning-based decision-tree classifier for COVID-19 diagnosis from chest X-ray imaging. Front Med (Lausanne). 2020;7:427. [[Crossref](#)] [[PubMed](#)] [[PMC](#)]
34. Khanagar SB, Al-Ehaideb A, Maganur PC, Vishwanathaiah S, Patil S, Baeshen HA, et al. Developments, application, and performance of artificial intelligence in dentistry - a systematic review. J Dent Sci. 2021;16(1): 508-22. [[Crossref](#)] [[PubMed](#)] [[PMC](#)]
35. Abdalla-Aslan R, Yeshua T, Kabla D, Leichter I, Nadler C. An artificial intelligence system using machine-learning for automatic detection and classification of dental restorations in panoramic radiography. Oral Surg Oral Med Oral Pathol Oral Radiol. 2020;130(5):593-602. [[Crossref](#)] [[PubMed](#)]