

Panoramik Radyografilerde Mandibular Kondil Morfolojisinin Belirlenmesinde Yapay Sinir Ağlarının Performansının Değerlendirilmesi: Metodolojik Çalışmalar

Evaluation of Performance of Artificial Neural Networks in Determination of Mandibular Condil Morphology in Panoramic Radiographies: Methodological Studies

¹Kader AZLAĞ PEKİNCE^a, ²Buse Yaren KAZANGİRLER^b, ³Adem PEKİNCE^a

^aKarabük Üniversitesi Diş Hekimliği Fakültesi, Ağız, Diş ve Çene Radyolojisi ABD, Karabük, Türkiye

^bKastamonu Üniversitesi Taşköprü Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, Kastamonu, Türkiye

ÖZET Amaç: Bu çalışmada; yapay sinir ağlarının (YSA), panoramik filmlerde mandibular kondil morfolojisini belirlemedeki performansının değerlendirilmesi amaçlanmıştır. **Gereç ve Yöntemler:** Çalışma için 18 yaş altı bireylere ait olan toplam 1.645 dijital panoramik görüntü incelendi. Bu görüntüler üzerinde sağ ve sol eklem olmak üzere toplam 3.290 mandibular kondil bölgesi kesilerek morfolojik açıdan değerlendirildi. Kesilen görüntüler normal ve anormal olarak etiketlenen kondil görüntüleri YSA modeline verilmek üzere %75 eğitim seti, %15 doğrulama seti ve %10 test seti olarak ayrıldı. Çalışmada, sinir ağı mimarisi olarak DenseNet mimarisi kullanıldı. **Bulgular:** Çalışma kapsamında, özellikle seçilen sinir ağı modeli ile eğitim aşaması için %91,76'ya ulaşırken, test aşaması için %89,00 doğruluk oranı ile yüksek performansa ulaştığı varsayılmıştır. Buna göre normal sınıfı için 197 adet normal etiketi test edilirken, 19 adet veride yanlış olarak anormal etiketi bulunmuştur. Bununla birlikte değerlendirme sırasında 96 adet anormal sınıfı doğru olarak test edilirken 17 adet veri ise normal olarak değerlendirilmiştir. **Sonuç:** Mandibular kondil morfolojisi, YSA kullanılarak yüksek oranda doğru tespit edilmiştir. İlerde yapılacak çalışmalarda veri sayısı artırılarak başarının daha da artırılması mümkündür. Temporomandibular eklem bölgesinin yapay zekâ destekli programlar tarafından yüksek doğrulukla değerlendirilebilmesi, klinikte çokça karşılaşılan bu grup hastaların doğru tanı almalarını hızlandıracak ve doğru yönlendirme ile daha çabuk tedavi imkânı bulmalarını kolaylaştıracaktır.

Anahtar Kelimeler: Panoramik radyografi; mandibular kondil; yapay zekâ; bilgisayarlı görü teknikleri

ABSTRACT Objective: In this study; it is aimed to evaluate the performance of artificial neural networks in determining the morphology of the mandibular condyle in panoramic images. **Material and Methods:** A total of 3,290 including right and left joints, mandibular condyles were cut and morphologically examined on 1,645 digital panoramic images. Condyle images that labeled as normal and abnormal were divided into 75% training set, 15% validation set and 10% test set to be given to the artificial neural network model. In this study, DenseNet architecture and GoogLeNet architectures was used as the neural network architecture. **Results:** Within the scope of the study, it was assumed that while it reached 91.76% for the training phase with the selected neural network model, it reached a high performance with an accuracy rate of 89.00% for the test phase. Accordingly, while 197 normal labels were tested for the normal class, 19 incorrectly abnormal labels were found in the data. However, during the evaluation, 96 classes of abnormal were tested correctly, while 17 data were evaluated as normal. **Conclusion:** A high rate of success has been achieved with the use of artificial neural networks in determining the morphology of the mandibular condyle. It is possible to further increase the success by increasing the number of data in future studies. Evaluating the temporomandibular joint region with high accuracy by artificial intelligence-supported programs will accelerate the correct diagnosis of this group of patients, who are frequently encountered in the clinic, and make it easier for them to get treatment more quickly with the right guidance.

Keywords: Panoramic radiography; mandibular condyle; artificial intelligence; computer vision techniques

KAYNAK GÖSTERMEK İÇİN:

Azlağ Pekince K, Kazangirler BY, Pekince A. Panoramik radyografilerde mandibular kondil morfolojisinin belirlenmesinde yapay sinir ağlarının performansının değerlendirilmesi: Metodolojik çalışmalar. Türkiye Klinikleri J Dental Sci. 2024;30(1):40-8.

Correspondence: Kader AZLAĞ PEKİNCE

Karabük Üniversitesi Diş Hekimliği Fakültesi, Ağız, Diş ve Çene Radyolojisi ABD, Karabük, Türkiye

E-mail: kaderazlag@icloud.com



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

Received: 16 Oct 2023

Received in revised form: 17 Dec 2023

Accepted: 18 Dec 2023

Available online: 04 Jan 2024

2146-8966 / Copyright © 2024 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/>).

Temporomandibular eklem (TME); temporal ve mandibular kemikler arasında oluşan, başın tek hareketli eklemi olma özelliği taşıyan bir çift eklemdir. TME, temporal kemiğin mandibular fossasına uyan mandibular kondil tarafından oluşturulur.¹

Mandibular kondil; mesio-distal yönde geniş, konveks yüzeylere sahip ve kabaca oval olarak tarif edilen bir şekle sahiptir. Bununla birlikte mandibular kondilde morfolojik değişiklikler görülebilmektedir. Bu değişiklikler; normal fonksiyona, parafonksiyonel alışkanlıklara veya dejeneratif eklem hastalıklarına yanıt olarak kondillerin yeniden şekillenmesinin bir sonucu olarak ortaya çıkabilir.

Panoramik radyografi tekniğiyle elde edilen görüntülerde; TME bölgesine, kafa kemiklerinin süperpoze olması nedeniyle bu bölgenin yorumlanması oldukça güçleşmektedir. Bununla birlikte panoramik görüntü; TME'nin ve çevresindeki anatomik yapıların genel görünümünü sağlamak, her iki eklem için karşılıklı değerlendirmesini yapmak için kullanılan faydalı bir görüntüleme yöntemidir. Konik ışımlı bilgisayarlı tomografiden (KIBT) daha ucuz, daha ulaşılabilir ve radyasyon dozunun daha düşük olması gibi avantajları nedeniyle eklem kemik bileşenlerinde meydana gelen değişikliklerin görüntülenmesinde sıklıkla ilk aşamada tercih edilmektedir. Ayrıca kondillerin morfolojisini değerlendirmek için farklı tekniklerin çeşitli karşılaştırmalı çalışmaları yapılmıştır. Hegde ve ark. konvansiyonel radyografi tekniklerinin, TME anormalliklerini ve kemik değişikliklerini belirlemek için kullanılacak yararlı ve değerli bir görüntüleme yöntemi olduğunu bildirmişlerdir.²

Yapay zekâ (YZ) günümüzde her alanda oldukça fazla kullanılmakta ve uygulandığı her alana kolaylık ve pratiklik sağlamaktadır. İş yükünün ve zamana olan ihtiyacın artması ile YZ oldukça kullanışlı hâle gelmiştir. Günümüzde medikal alanda, YZ ve özellikle bilgisayarlı görü tekniklerinin uygulanması önemli ölçüde yaygınlaşmaktadır.³ Bu sebeple, insan gücüne dayalı bir tespit yerine YZ'den destek alacak bir karar destek mekanizması sıklıkla tercih edilen bir çözüm olmaktadır.

Yapay sinir ağları (YSA) olarak sınıflandırılan sinir ağları, verileri işlemek için kullanılır. Sinir ağ-

ları, derin öğrenme yöntemlerinde yaygın olarak kullanıldığından, "Derin Sinir Ağları" terimi geçerlilik kazanmıştır. YSA, YZ merkezinde yer alan oldukça geniş bir mimari üzerine kurulu modellerdir.⁴ YSA modelleri, kapsamlı miktarda veri içeren bir derin öğrenme süreci yoluyla, bir bilgisayarın kendi başına düşünmeyi öğrenme, karar verme ve sorunları çözme kapasitesiyle sunulmasını sağlayan bir tür YZ algoritmasıdır.⁵

Görüntü segmentasyonu; düz radyografi, bilgisayarlı tomografi, manyetik rezonans ve ultrason görüntüleri dâhil olmak üzere çeşitli yöntemler kullanılarak elde edilen görüntülerdeki çeşitli anatomik yapıları veya lezyonları tanımlamak için kullanılmıştır. Diş hekimliğinde; diş segmentasyonu, yaş tahmini, üçüncü molar dişler ve mandibular alveolar sinir arasındaki ilişkinin tespiti, kistler ve maksiller sinüs gibi klinik durumlar için YZ algoritmalarının uygulandığı çeşitli çalışmalar bildirilmiştir.⁶⁻⁹

Bu çalışmada; YSA'ların panoramik radyografilerde mandibular kondil morfolojisini belirlemedeki performansı değerlendirilmiştir.

GEREÇ VE YÖNTEMLER

GÖRÜNTÜLERİN SEÇİLMESİ, HAZIRLANMASI VE DEĞERLENDİRİLMESİ

Mandibular kondil morfolojisinin değerlendirilmesi için Karabük Ağız ve Diş Sağlığı Eğitim ve Araştırma Hastanesi röntgen arşivine ait Aralık 2020 ile Şubat 2022 tarihleri arasında çekilmiş olan ve rastgele seçilen DICOM formatındaki 2.000 panoramik radyografik görüntü incelendi. Bu görüntüler, üreticinin talimatları doğrultusunda (80 kV tüp voltajı, 9 mA ve 14,4 sn) ve aynı panoramik radyografi cihazı (I-Maxtouch, OwandyRadiology, Fransa) kullanılarak elde edilen görüntülerdir.

Çalışmamızın etik kurul onayı, Karabük Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulundan alınmıştır (13 Ocak 2021 tarih ve 2021/451 nolu karar) ve çalışma Helsinki Deklarasyonu prensiplerine uygun olarak yapılmıştır.

İncelenen panoramik radyografik görüntülerden; kondil sınırlarının izlenmesini bozacak kadar süperpozisyon olan 173, artefakt olan 38 ve 18 yaş altı bi-

reylere ait olan 144 olmak üzere toplam 355 görüntü çalışmaya dâhil edilmedi. Mandibular kondillerin net olarak izlenebildiği, artefakt olmayan ve 18 yaş üzerinde olan bireylere ait toplamda 1.645 panoramik görüntü üzerinde 3.290 kondil incelendi.

Seçilen görüntüler, kondil başını incelemeye olanak verecek şekilde ve TIFF formatında ayrı ayrı kırılarak çıkarıldı. Kesilen görüntüler üzerinde sağ-sol ayrımı yapılmadan, mandibular kondil sınırları çizilerek işaretleme yapıldı.

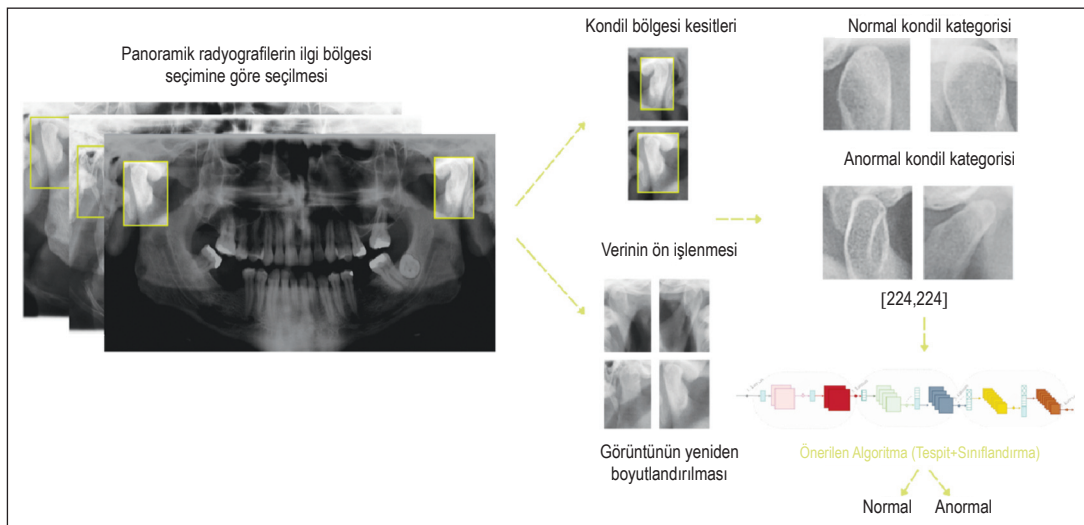
Modele girdi olarak verilecek görüntüler, algoritmanın uygun görüntü boyutlarına yönelik ilgili ön işleme tekniklerinden geçirildi. Bu aşamada, kullanılacak ESA modeller için görüntüler yeniden boyutlandırma aşamasından geçirilerek ilgili modelin türüne bağlı olarak 224x224 piksel boyutlarına indirgenerek yeniden düzenlendi (Şekil 1).

Mandibular kondilin sınırları normalde düzgün, kesintisiz ve dışbükeydir.¹ Bu nedenle normal kondillerin dış hatlarının baştan sona dışbükey bir konfigürasyona sahip olması ve aynı bireyde her iki kondil arasında simetrisinin bulunması gerektiği varsayılır. Ancak kondil başının üst yüzeyinde hafif düzleşme veya belirgin dışbükeylik gibi anatomik varyasyonlar gözlemlenmektedir. Bu durumda, sağ ve sol kondil başlarının boyutu ve şekli karşılaştırılmalı ve mandibuların simetrisi değerlendirilmelidir.¹

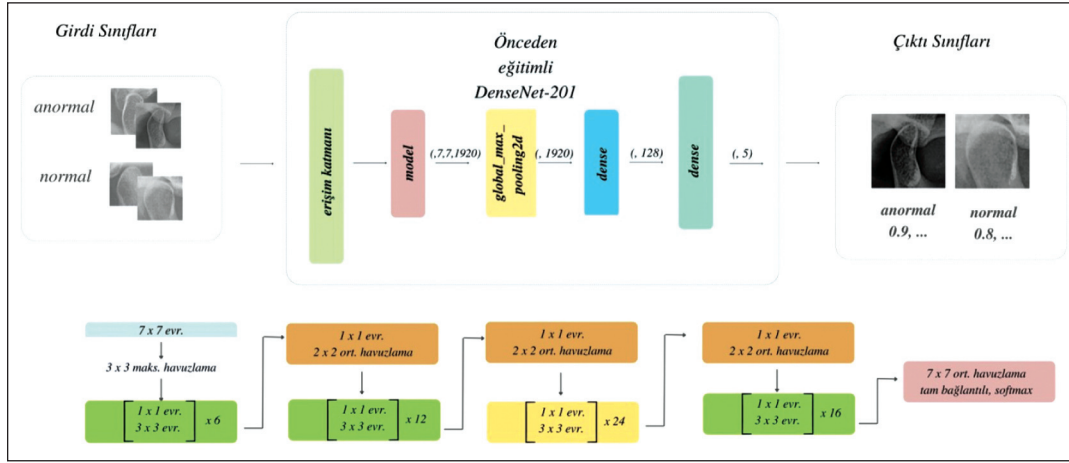
Çalışmamızda; sınırları düzgün konveks ve kesintisiz olan kondiller, simetrikleri ile birlikte değerlendirilerek, normal olarak etiketlenmiştir. Bu kriterlere uymayan; sınırları kesintili, düz olup simetrik olmayan veya içbükey sınırlara sahip kondiller anormal sınıfına dâhil edilmiştir. Hafif düzleşme veya belirgin dışbükeylik olan kondiller simetrik olduğunda normal sınıfına dâhil edilirken, tek taraflı olduğunda anormal sınıfına dâhil edildi. Erozyon, osteofit formasyonu veya belirgin düzleşme gibi osteoartritik değişiklikler izlenen kondiller ve kuş gagası-deltoid-çarpık parmak-açılı-düz şeklinde morfolojik olarak sınıflandırılan tüm kondiller anormal olarak etiketlendi. Etiketlenen görüntülerin rastgele seçilen %20'lik kısmı; gözlemci içi uyum değerlendirilmesi amacıyla aynı hekim tarafından farklı bir zamanda tekrar incelendi. Sonuçların uyumu Cohen kappa analizi ile değerlendirildi. İstatistiksel analizler SPSS® yazılımı (Windows için SPSS v. 20.0; SPSS Inc., Chicago, IL) aracılığıyla gerçekleştirildi. Elde edilen κ değeri ($\kappa=0,8$); Landis ve Koch'a göre yorumlandı ve yeterli düzeyde uyum olduğu tespit edildi.

Hazırlanmış ve etiketlenmiş olan kondil görüntüleri, ESA modeline verilmek üzere %75 eğitim seti ve %15 doğrulama seti ve %10 test seti olarak ayrıldı.

Şekil 2'de geliştirilen yöntemin detaylarına yer verilmektedir. Buna göre girdi verisi olarak ham görüntüler kullanılırken, ilgili DenseNet algoritmasının



ŞEKİL 1: Veri kümesinin elde edilmesi ve sinir ağına girdi olarak verilme mimarisi/şematği.



ŞEKİL 2: Kondil sınıflandırması için özel olarak hazırlanmış DenseNet-201 mimarisi.

dan geçirilerek bir sınıflandırma görev çıkışı elde edilmektedir. Çalışmada önerilen mimari, 4 adet yoğun bloktan geçirilerek her bir yoğun blok arasında bir konvolüsyon işlemi gerçekleştirilerek ortalama havuzlama katmanına iletilmiştir. Daha sonra, sinir ağında yer alan nöronların birbirine tam bağlantılı bağ kurması ile mimarinin son aktivasyon fonksiyonu konfigüre edilmiştir. Alınan net girdiyi ilgili modelden geçirerek net çıktı olarak hesaplamayı sağlamaktadır. Bu sebeple, sinir ağlarında ve özellikle çok kategorili sınıflarda yaygın olarak kullanılmakta olan Softmax fonksiyonu seçilmiştir. Softmax, genellikle son katman olarak görüldüğü derin öğrenme sınıflandırma görevlerinde popüler bir seçim olarak kullanılmaktadır.¹⁰⁻¹²

DenseNet mimarisinin yoğun bağlantıları ile yüksek performanslı bir topluluk modeli oluşturulmuştur. Derin öğrenme modellerinde katman ve süreç sayısı arttıkça katmanlardaki bilgi kaybıyla karşılaşabilmektedir. Buna ilaveten DenseNet mimarisi, özellik haritalarını her katmanda ileri beslemeli ve yinelemeli bir modelde birleştirilerek diğer mimarilerden daha yüksek bir bilgi akışı sağlamaktadır.¹³ Güçlü öznitelik yayılımına sahip olan bu mimari, yok olan gradyan problemini çözerken parametre sayısını azaltır.

Sınıflandırma modellerinin değerlendirilmesinde genellikle literatürde sıkça yer alan doğruluk, hassasiyet, duyarlılık ve f1-puanı metrikleri kullanılmaktadır.¹⁴ Yalnızca tek bir metrik ile model perfor-

mansını başarılı bulmak neredeyse imkânsızdır. Denklem 1, 2, 3 ve 4'te yer alan metrikler modelin başarı ölçütlerinden sayılmaktadır. Model performansı değerlendirilirken yalnızca doğruluk puanı yeterli görülmemektedir. Hassasiyet değeri, pozitif olarak tahmin edilen sınıflarının kaç adedinin pozitif bulunduğunu hesaplarken duyarlılık değeri ise pozitif olarak kesin tahmin edilmesi gereken sınıflar için ne kadarının doğru tahmin edildiğini hesaplamaktadır [doğru pozitif (DP), doğru negatif (DN), yanlış pozitif (YP), yanlış negatif (YN)].

$$\text{Denklem 1: Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN}$$

$$\text{Denklem 2: Hassasiyet} = \frac{DP}{DP+YP}$$

$$\text{Denklem 3: Duyarlılık} = \frac{DP}{DP+YN}$$

Doğruluk değerinin hesaplanmasında tüm pozitif ve negatif değerler kullanılarak, ölçülürken hassasiyet değerlerinin hesaplanması için Denklem 2'de yalnızca pozitif olan veriler kullanılmıştır. Diğer hesaplama ölçütlerinden olan duyarlılık değerlerinin hesaplanması Denklem 3'te verilmiştir. Ayrıca hassasiyet ve duyarlılık değerleri genellikle birbiriyle ters orantılıdır. F1 puanı, potansiyel optimizasyon yöntemlerini değerlendirmek için bir ölçümdür. Geri çağırma ve kesinlik değerlerinin harmonik ortalaması alınarak elde edilir ve aşağıdaki formül kullanılarak hesaplanır.⁶

$$\text{Denklem 4: } F1\text{-puanı} = 2 * \frac{\text{Hassasiyet} * \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}}$$

Modelin deneysel bulgular bölümü için en çarpıcı olan metriklerden bir tanesi ise kayıp değerlerini temsil eden grafikleridir. Eğitim sırasında, oluşturulan her ilgili bölgedeki çoklu görev kaybı L ile belirtilir. Denklem 5'te kayıp değerinin (L) hesaplanmasına yer verilmiştir. Buna göre kayıp değeri doğruluk değerinin 1'e tamamlanması ile bulunmaktadır.

$$\text{Denklem 5: } L=1\text{-Doğruluk}$$

BULGULAR

Bu çalışmada, panoramik radyografiler üzerinden mandibular kondil bölgeleri kırılarak, kondillerin morfolojilerinin yüksek performanslı tespiti ve normal/anormal şeklinde sınıflandırılmasına yönelik derin öğrenme tabanlı bir algoritma yaklaşımı uygulanmıştır. Önerilen mimaride bir ESA türünden olan DenseNet mimarisi ile ortaya konulan tahmin skorları ve sonuçları, uzun ve tekrarlayan tespit görevlerinin otomatikleştirilmesini ve minimum maliyet-zaman yapısında gerçekleştirilmesini sağlamaktadır. Çalışma kapsamında, özellikle seçilen sinir ağı modeli ile eğitim aşaması için %91,76'ya ulaşırken test aşaması için %89,00 doğruluk skoru ile yüksek performansa ulaştığı varsayılmıştır. Algoritma performansının yüksek olduğu ve test verilerinin eğitim verilerinden ayrı hazırlandığı göz önünde bulundurulmalıdır. Dolayısıyla mandibular kondil morfolojilerinin tespit edilmesi ile bir kondil

bölgesinin belirlenmesi ve bu duruma göre anormal morfolojilerin sınıflandırılması için bir algoritma geliştirme olasılığı doğrulanmıştır. Önerilen sinir ağı algoritması sayesinde YZ'nin medikal alanda görüntüleri evrimsel filtreleme ve sınıflandırma konusunda tercih edilmesinin sebebini kanıtlamıştır.

Tablo 1'de yer alan GoogLeNet ağı sonuçları istatistiksel açıdan yuvarlanarak yazıldığı için tabloda büyük farklar yok gibi görülebilmektedir. Fakat bu durumun aksine GoogLeNet için her sınıf adına doğruluk değeri %83,52668213'ü bulurken, harmonik performans sonucunu veren f1-puanı değeri ise %83,30195731'i bulmuştur.

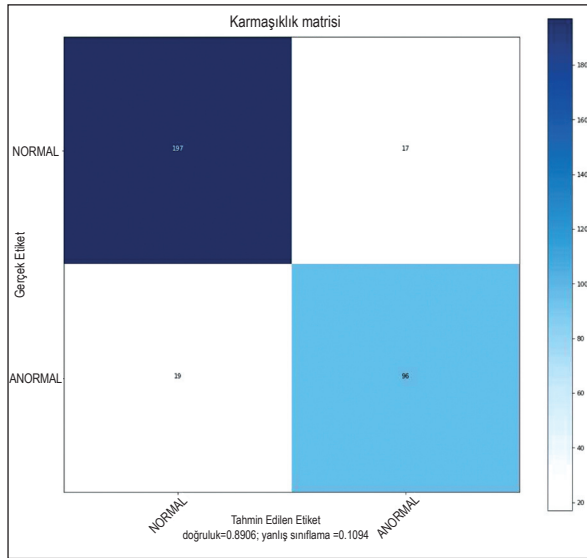
Tablo 1'de yer alan başarı değerleri dikkatle incelendiğinde, DenseNet modelinin geliştirilmiş olduğu 201 katmanlı versiyon mimarisi %6'lık bir artış farkı ile test aşaması için tabloda verilen doğruluk ve hassasiyet sonuçlarına ulaşmıştır. Bunun yanı sıra aynı eğitim verisi ve aynı ön işlem şartlarında doğru bir eğitim sağlandığında DenseNet-201 modeli için eğitim doğruluğu ise %91,76'ya ulaşmıştır. Bu durumda, eğitim esnasında modelin gerçekleştirdiği kayıp değeri 0,2173'e ulaşırken test doğruluğu %89'a ulaşmıştır. **Tablo 2**'de ise normal ve anormal sınıfları için tek sınıf başına doğruluk metrik sonuçlarına yer verilmiştir. Anormal sınıfının, sınıflandırma başarısının normal kondil sınıfına nazaran daha düşük olması beklenen bir sonuç olmuştur. Duyarlılık puanının hassasiyete göre daha yüksek oluşu model performansının değerlendirilmesinde kritik ölçüt olan **Şekil 3**'te yer alan karmaşıklık matrisi sonuçlarına

TABLO 1: Yapay sinir ağlarının mandibular kondil morfolojisi tespitindeki karşılaştırmalı performans sonuç tablosu.

Algoritma	Doğruluk	Hassasiyet	Duyarlılık	F1-puanı
GoogLeNet	%83	%84	%83	%83
DenseNet-201	%89	%89	%88	%89

TABLO 2: DenseNet-201 modelinin mandibular kondil morfolojisi tespitindeki performans sonuç tablosu.

Sınıf	Hassasiyet	Duyarlılık	F1-puanı
Normal	%88	%93	%91
Anormal	%90	%84	%87
Makro ortalama doğruluk	%89	%88	%89
Ağırlıklandırılmış ortalama doğruluk	%89	%89	%89



ŞEKİL 3: Karmaşıklık matrisi.

dayanmaktadır. Matris detaylıca incelendiğinde, diyagonal olarak yer alan değerler DP değerlerini ifade etmektedir. Bu durumda, denklemlerde yer alan performans metrikleri için ilgili DP, DN, YP, YN değerleri bu matristen elde edilerek hesaplanmıştır.

Sinir ağı mimarisinin performansı bazı durumlarda ve görevlerde oldukça yüksek olur iken, modelin ezber yaptığı durumlarla karşılaşmaktadır. Bu durumun önüne geçilmesi YSA'nın kayıp ve doğruluk grafikleri incelenirken, erken durdurma kriterlerinin de göz önünde bulundurulduğu varsayılmalıdır. Ek olarak, sinir ağının öğrenme aşamasında optimizasyon algoritması olan Adamax algoritmasında, 0,001 öğrenme oranı kullanılmıştır.¹⁵ Adam algoritmasının iyileştirilmiş versiyonu olan Adamax, sinir ağı katmanlarındaki ağırlıkları hızlı bir şekilde ayarlaması ve ampirik sonuçlar üzerinde pratikte daha iyi performans göstermektedir.⁶ Şekil 2'de yer alan 2. grafik yani kayıp grafiğine bakıldığında ise kayıp değeri yani modelin hata oranı diye ifade edersek oldukça azaldığı görülmektedir. Bu durumda, kayıp değeri ne kadar düşük olursa model o kadar iyi öğrenmiş demektir.

Şekil 3'te yer alan matris en iyi algoritma sonucunu veren modele yani DenseNet-201 mimarisine aittir. Karmaşıklık matrisi için yatay eksen tahmin edilen etiketleri gösterirken dikey eksen gerçek etiketleri yani uzman bilgisini barındırmaktadır. Buna

göre normal sınıfı için 197 adet normal etiketi test edilirken, 19 adet veride yanlış olarak anormal etiketi bulunmuştur. Bununla birlikte değerlendirme sırasında 96 adet anormal sınıfı doğru olarak test edilirken, 17 adet veri ise normal olarak değerlendirilmiştir. Tablo 2'de yer alan ölçüm sonuçları göz önünde bulundurulduğunda matristeki hata değerleri uygun görülebilmektedir.

TARTIŞMA

Bu çalışma, panoramik radyografilerde mandibular kondil morfolojisinin tespiti ve sınıflandırılmasında YSA modellerinin performansının değerlendirilmesi üzerine odaklanmıştır. Çalışmadaki gerekli araştırmalar ve yöntemlerin uygulanması sonucunda, YSA tabanlı yöntemlerin mandibular kondil morfolojisini belirlemede oldukça başarılı olduğunu göstermiştir. YSA modellerinden olan ESA'lar büyük veri kümelerinden öznelik çıkarılmasını sağlayarak, öğrenme yetisi ile radyografik görüntülerdeki mandibular kondil yapısını doğru bir şekilde tanımlayabilmeyi sağlamıştır.

Panoramik görüntüleme klinikte ilk tercih edilen teknik olsa da eklem görüntülemesinde kısıtlılıkları bulunmaktadır. Panoramik film, çekim esnasında ağzın hafif açık ve mandibulanın hafif önde konumlandırılması nedeniyle kondilin; glenoid fossa içindeki normal pozisyonunu verememektedir. Ayrıca bu teknikte kafa kemiklerinin, TME'nin kemik bileşenleri üzerine süperpoze olması bu yapılarda meydana gelen küçük değişikliklerin belirlenebilmesini zorlaştırmaktadır. Panoramik radyografiler eksik yönleri nedeniyle kondil ve TME bölgesi değerlendirmesinde yetersiz kalabilmektedir. Panoramik filmlere ait bu eksiklerin giderildiği bir görüntüleme yöntemi olan KIBT kullanıldığında çalışmanın başarısının artabileceği öngörülmektedir.

KIBT; TME görüntülemesinde her düzlemde kesitsel görüntü vermesi, süperpozisyonun ortadan kalkmasına ve bu bölgenin engelsiz değerlendirilmesine olanak sağlar. KIBT; kondil erozyonlarının değerlendirilmesinde geleneksel yöntemlerden daha güvenilirdir.¹⁶ Bu nedenlerle KIBT'nin TME osteoartritinin tanımlanmasında etkili bir araç olarak kullanılması önerilir.¹⁶

Çalışmamızda mandibular kondil bölgesi panoramik görüntülerden kırılarak kullanıldı. Bu çalışmanın bir sonraki adımında kondilin segmentasyonu ve osteoartritik değişikliklerin öğretilmesi ve morfolojik sınıflamasının yapılması da düşünülebilir.

Mandibular kondillerin panoramik filmlerdeki görüntülerini sınıflandıran birçok çalışma bulunmaktadır ve bu çalışmalarda çeşitli gruplandırmalar yapılmıştır.

Oliveira-Santos ve ark. mandibular kondilin morfolojik sınıflamasını; oval, kuş gagası, deltoid ve çarpık parmak şeklinde sınıflandırmıştır.¹⁷ Çamlıdağ ve ark. düz, yuvarlak ve açılı olarak gruplandırmıştır.¹⁸ Yale ve ark. konveks, yuvarlak, açılı ve düz olarak sınıflama yapmışlardır.¹⁹ Khanal ve ark. ise oval, kuş gagası, deltoid ve çarpık parmak olarak sınıflandırmışlardır.²⁰

Çalışmamızda; kondiller, morfolojilerine göre detaylı gruplandırılmamıştır. YSA'ya mandibular kondiller; normal ve anormal olarak 2 grup olarak tanımlanmış ve başarısı test edilmiştir. Elde edilen sonuçlar tatmin edici olup çalışmamızın ileriki aşamasında detaylı morfolojik sınıflamalardan herhangi biri kullanılarak YSA'nın eğitilmesi de düşünülebilir.

Çalışmada kondiller, uzman hekim tarafından değerlendirilirken sağ-sol birlikte değerlendirilmiştir. Ancak kondiller YSA'ya verilirken, panoramik görüntü üzerinden kırılarak çıkarılmış ve sağ-sol olarak etiketlenmemiştir. Bu ise simetriği ile beraber değerlendirilerek, normal veya anormal olarak etiketlenen verilerin YSA tarafından tek taraflı değerlendirilmesi ile sonuçlanmıştır.

Tek bir görüntü üzerinde YSA tarafından segmente edilerek, sağ-sol şeklinde de eğitim verildiğinde başarı oranının daha da artacağını tahmin etmekteyiz. Zira hafif düzleşme veya belirgin konveksiteye sahip olan kondiller uzman hekim tarafından simetriği dikkate alınarak sınıflandırılmasına rağmen YZ ağı kondilleri bağımsız olarak değerlendirilmiştir.


Çalışmada kaynaklanan hata payının büyük bir bölümünün veri kümesinde eş zamanlı olarak yer alan sol ve sağ mandibular eklem verilerinin olması sayılmaktadır. Bu sebeple, gelecek çalışmalarda TME sınıfının sol ve sağ mandibular eklem olarak

sinir ağına verilmesi hedeflenen performansın artmasına sebep olabileceği öngörülmüştür.

YSA eğitilirken kullanılan omurga ağı için önceden eğitilmiş modeller kullanılır ve bu yapı transfer öğrenme olarak adlandırılır.²¹ Verimlilik açısından transfer öğrenme kullanılarak yeniden eğitilen model değerlendirilir ve sonuçlar bazı son teknoloji yaklaşımlarla karşılaştırılır. ESA'ların görüntü sınıflandırmasına dayalı transfer öğrenme işlevi literatürde daha önce de bildirilmiştir.^{22,23} Böylelikle YSA modelleri için eğitilen ağırlıklar ile herhangi bir veri kaynağı için kullanıma sunulurken, performans metrikleri sonucunun artırılması sağlanır.²⁴

DenseNet-201 ve GoogLeNet modeli ile eğitimi sağlanmış olan sinir ağları, literatürde görüntülerin sınıflandırılması görevlerinde sıkça yer alan performans metrikleri ile ölçülmek üzere test aşamasına getirilmiştir. Modelin test edilmesi adımında, mandibular kondil morfolojisi tespiti için eğitim kümesindeki verilerin öğrenilme kapasitesi ölçülmektedir. YSA modellerinin yalnızca eğitilmesi değil aynı zamanda farklı test verileri üzerinde tespit aşamasında yüksek başarı göstermesi gerekmektedir. Bu durum, eğitim verilerinin homojen bir şekilde dağıtılması ve modelin doğru öğrenmesine bağlıdır. GoogLeNet sınıflandırıcısı görüntülerin sınıflandırılması görevinde son derece iyi çalışabilen bir algoritmadır. Ancak **Tablo 1**'deki sonuçlar incelendiğinde, DenseNet-201 modelinin bu görev için daha performanslı sonuç verdiği kanısına ulaşılmaktadır. Çünkü YSA modellerinin başarısı; veri kümesinin büyüklüğü, görevin karmaşıklığı ve ön işleme görevlerine bağlıdır. Bunun en büyük sebeplerinden birisi, DenseNet-201 modelinin konfigüre edilerek ön işlem adımlarından geçirilmesi sayılabilir. Katman sayısının 201 adet olması ise öznelikleri mimari içerisinde bir sonraki katmana iletilerek öğrenme adımının daha iyi sağlanmasına sebep olmaktadır.

Ağın öğrenmesi esnasında kayıp değerleri hesaplanırken **Şekil 4**'te görüldüğü üzere 2 ayrı grafik elde edilmektedir. Veri kümesinin %75'i eğitim için ayrılırken eğitim kümesinin %15'lik bölümü ise modelin doğrulamasında kullanıldığı için şekilde yer alan sonuçlar eğitim ve doğrulama adımlarına aittir. Dolayısıyla doğrulama verisi, modelin eğitim kümesinde daha önce tanışmış olduğu veriler olmuştur.



ŞEKİL 4: Eğitim ve test kümesi için doğruluk ve kayıp değerleri grafiği.

Ancak %10'luk bölüm ise modelin daha önce hiç karşılaşmadığı test aşaması verileri olmuştur. Bu sebeple hata payının olması muhtemeldir. Buna göre solda yer alan ilk grafik eğitim ve doğrulama doğruluğunu temsil ederken sağda yer alan 2. grafik ise eğitim ve doğrulama kayıp değerlerini ifade etmektedir. Mavi ile şekillendirilen çizgiler eğitim esnasında elde edilen doğruluk ve kayıp değerlerini temsil ederken turuncu çizgiler ise doğrulama esnasında elde edilen değerlere aittir.

Çalışmamız, Kim ve ark. yaptığı bir çalışma ile karşılaştırıldığında, YSA tabanlı mandibular kondil morfolojisi belirleme yöntemlerinin diğer ilgili çalışmalarla uyumlu olduğunu görülmekte ve bu alanda YSA'ların uygulanabilirliğini ve etkinliğini daha da vurgulamaktadır.²⁵ Ancak konuyla ilgili daha fazla araştırma yapılması ve farklı veri kümeleri ile deneyimlerin yapılması, YSA tabanlı yöntemlerin potansiyelini tam olarak anlaşılmasına yardımcı olacaktır.

Dolayısıyla çalışma sonuçlarının doğruluğunu artırmak için uzmanlar tarafından etiketlenmiş çok fazla veri gerekmektedir. Veri sayısının artırılması ile hata payının düşeceği öngörülmektedir.

SONUÇ

Sonuç olarak bu çalışmada, mandibular kondil morfolojisinin belirlenmesinde YSA'ların kullanılması ile yüksek oranda başarı elde edilmiştir. Panoramik

görüntüler üzerinde değerlendirilmesi zor olan bu bölgede oluşan değişikliklerin ESA ile tanımlanabilmesinin, hastaların bu konuda uzman olan hekimlere yönlendirilmesi konusunda klinisyenlere kolaylık sağlayacağını düşünmekteyiz.

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: Kader Azlağ Pekince, Adem Pekince, Buse Yaren Kazangirler; **Tasarım:** Kader Azlağ Pekince, Adem Pekince, Buse Yaren Kazangirler; **Denetleme/Danışmanlık:** Kader Azlağ Pekince, Adem Pekince, Buse Yaren Kazangirler; **Veri Toplama ve/veya İşleme:** Kader Azlağ Pekince, Adem Pekince, Buse Yaren Kazangirler; **Analiz ve/veya Yorum:** Kader Azlağ Pekince, Adem Pekince, Buse Yaren Kazangirler; **Kaynak Taraması:** Kader Azlağ Pekince, Adem Pekince, Buse Yaren Kazangirler; **Makalenin Yazımı:** Kader Azlağ Pekince, Buse Yaren Kazangirler; **Eleştirel İnceleme:** Adem Pekince.

KAYNAKLAR

- Mallya SM, Lam EWN. Radiographic anatomy. White and Pharaoh's Oral Radiology. 8th ed. St. Louis, Missouri: Elsevier; 2019. p.504.
- Hegde S, Praveen B, Shetty SR. Morphological and radiological variations of mandibular condyles in health and diseases: a systematic review. Dentistry. 2013;3(1):154-8.
- 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]
- Géron A. Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow. 3rd ed. Sebastapol, CA: O'Reilly Media, Inc.; 2022.
- Ba-Hattab R, Barhom N, Osman SAA, Naceur I, Odeh A, Arisha Asad A, et al. Detection of periapical lesions on panoramic radiographs using deep learning. Applied Sciences. 2023;13(3):1516. [Crossref]
- Yaren Tekin B, Ozcan C, Pekince A, Yasa Y. An enhanced tooth segmentation and numbering according to FDI notation in bitewing radiographs. Comput Biol Med. 2022;146:105547. [Crossref] [PubMed]
- De Tobel J, Radesh P, Vandermeulen D, Thevissen PW. An automated technique to stage lower third molar development on panoramic radiographs for age estimation: a pilot study. J Forensic Odontostomatol. 2017;35(2):42-54. [PubMed] [PMC]
- 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(1):152-8. [Crossref] [PubMed]
- 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 Radiol. 2019;35(3):301-7. [Crossref] [PubMed]
- De Brébisson A, Vincent P. An exploration of softmax alternatives belonging to the spherical loss family. arXiv. 2015;151105042. [Link]
- Vincent P, De Brébisson A, Bouthillier X. Efficient exact gradient update for training deep networks with very large sparse targets. arXiv. 2015;1412.7091. [Link]
- Yaohua X, Xudong M. A sar oil spill image recognition method based on densenet convolutional neural network. IEEE. 2019;78-81. [Crossref]
- Huang G, Liu Z, Van Der Maaten L, Weinberger KQ. Densely connected convolutional networks. IEEE. 2017;4700-8. [Crossref]
- Goutte C, Gaussier E. A probabilistic interpretation of precision, recall and F-score, with implication for evaluation. In: Losada DE, Fernández-Luna JM, eds. Advances in Information Retrieval. 1st ed. Berlin, Heidelberg: Springer; 2005. p.345-59. [Crossref]
- Kingma DP, Ba J. Adam: A Method for Stochastic Optimization. arXiv. 2014;1412.6980v9 2014. [Link]
- Honey OB, Scarfe WC, Hilgers MJ, Klueber K, Silveira AM, Haskell BS, et al. Accuracy of cone-beam computed tomography imaging of the temporomandibular joint: comparisons with panoramic radiology and linear tomography. Am J Orthod Dentofacial Orthop. 2007;132(4):429-38. [Crossref] [PubMed]
- Oliveira-Santos C, Bernardo RT, Capelozza ALÁ. Mandibular condyle morphology on panoramic radiographs of asymptomatic temporomandibular joints. IJD International Journal of Dentistry. 2009;8(3). [Link]
- Çamlıdağ I, Sayıt AT, Elmali M. Is condyle morphology a factor for anterior temporomandibular disc displacement? Turk J Med Sci. 2022;52(5):1609-15. [Crossref] [PubMed] [PMC]
- Yale SH, Ceballos M, Kresnoff CS, Hauptfuehrer JD. Some observations on the classification of mandibular condyle types. Oral Surg Oral Med Oral Pathol. 1963;16:572-7. [Crossref] [PubMed]
- Khanal P, Pranaya K. Study of mandibular condyle morphology using orthopantomogram. Journal of Nepal Dental Association. 2020;20(1):3-7. [Link]
- Hussain M, Bird JJ, Faria DR. A study on CNN transfer learning for image classification. In: Lotfi A, Bouchachia H, Gegov A, Langensiepen C, McGinnity M, eds. Advances in Computational Intelligence Systems. 1st ed. Switzerland AG: Springer International Publishing; 2019. p.191-202.
- Gupta J, Pathak S, Kumar G. Deep Learning (CNN) and Transfer Learning: A Review. Journal of Physics: Conference Series. 2022;2273(1):012029. [Crossref]
- Han D, Liu Q, Fan W. A new image classification method using CNN transfer learning and web data augmentation. Expert Systems with Applications. 2018;95:43-56. [Crossref]
- Kazangirler CB, Özcan C, Tekin BY. Ön Eğitimli Evrişimli Sinir Ağları ile UI Öğelerinin Tespiti ve Sınıflandırılması. 5th International Conference on Data Science and Applications (ICONDATA'22); 7-11 Ekim 2022; Muğla: Icondata; 2022. p.100-7. [Link]
- Kim D, Choi E, Jeong HG, Chang J, Youm S. Expert system for mandibular condyle detection and osteoarthritis classification in panoramic imaging using r-cnn and cnn. Applied Sciences. 2020;10(21):7463-4. [Crossref]