



AĞIZ İÇİ GÖRÜNTÜLERİN DERİN ÖĞRENME İLE ANALİZİ: CNN MODELLERİNİN SINIFLANDIRMA PERFORMANSI

Sena ÇELİK^{1*}

¹Burdur Mehmet Akif Ersoy University, Faculty of Bucak Computer and Information, Department of Information Systems Engineering, 15300, Bucak, Burdur, Türkiye

Özet: Ağız içi görüntülerin sınıflandırılması, özellikle gelişmiş görüntüleme teknolojileri ve yapay zekanın (AI) ortaya çıkmasıyla birlikte, modern diş teşhisinin kritik bir yönüdür. Transfer öğrenme ve topluluk tekniklerinin entegrasyonu, bu amaçla tasarlanan modellerin performansını artırmada ümit verici sonuçlar göstermiştir. Bu çalışmada, ResNet152V2, DenseNet201, InceptionResNetV2, ConvNeXtBase ve Xception gibi derin öğrenme modelleri tek tek ve topluluk modeli olarak test edilmiştir. Kullanılan veri seti, farklı yaş gruplarından bireylerin ağız içi görüntülerini içermektedir. Modellerin eğitimi ve değerlendirilmesi aşamalarında veri ön işleme, normalizasyon ve ince ayar (fine-tuning) gibi teknikler uygulanmıştır. Doğruluk, kesinlik, duyarlılık, F1 skoru ve ROC-AUC gibi metrikler kullanılarak performans analizleri gerçekleştirilmiştir. Sonuçlar, ResNet152V2 + DenseNet201 topluluk modelinin en yüksek doğruluk oranına (%89,9) ve 0,9934 ROC-AUC değerine ulaştığını göstermektedir. Bu bulgular, derin öğrenme tabanlı yaklaşımların diş hekimliği uygulamalarında otomatik teşhis, tedavi planlaması ve uzaktan hasta değerlendirme gibi alanlarda büyük potansiyele sahip olduğunu ortaya koymaktadır. Ayrıca, diş morfolojisi ve çene yapılarının analizi için yapay zeka tabanlı sistemlerin geliştirilmesi, klinik süreçleri hızlandırarak diş hekimlerine karar destek mekanizmaları sağlayabilir. Gelecekteki çalışmalar, daha büyük ve çeşitli veri setleri kullanarak modelin genelleme yeteneğini artırmaya odaklanmalıdır.

Anahtar kelimeler: Derin öğrenme, Ağız içi görüntü analizi, CNN modelleri, Diş sınıflandırma

Analysis of Intraoral Images Using Deep Learning: Classification Performance of CNN Models

Abstract: The classification of intraoral images has become a critical aspect of modern dental diagnosis, particularly with the emergence of advanced imaging technologies and artificial intelligence (AI). The integration of transfer learning and ensemble techniques has shown promising results in enhancing the performance of models designed for this purpose. In this study, deep learning models such as ResNet152V2, DenseNet201, InceptionResNetV2, ConvNeXtBase, and Xception were tested individually and as an ensemble. The dataset includes intraoral images from individuals of various age groups. Data preprocessing, normalization, and fine-tuning techniques were applied during model training and evaluation. Performance analysis was conducted using accuracy, precision, recall, F1-score, and ROC-AUC metrics. The results indicate that the ResNet152V2 + DenseNet201 ensemble model achieved the highest accuracy (89.9%) and ROC-AUC score (0.9934). These findings highlight the great potential of deep learning-based approaches in dental applications, such as automatic diagnosis, treatment planning, and remote patient assessment. Furthermore, the development of AI-based systems for analyzing dental morphology and jaw structures can accelerate clinical workflows by providing decision-support mechanisms for dentists. Future studies should focus on expanding dataset diversity to improve model generalization.

Keywords: Deep learning, Intraoral image analysis, CNN models, Dental classification

*Corresponding author: Burdur Mehmet Akif Ersoy University, Faculty of Bucak Computer and Information, Department of Information Systems Engineering, 15300, Bucak, Burdur, Türkiye

E mail: scelik@mehmetakif.edu.tr (S. ÇELİK)

Sena ÇELİK  <https://orcid.org/0000-0001-9277-7623>

Gönderi: 3 Şubat 2025

Kabul: 21 Mart 2025

Yayınlanma: 15 Mayıs 2025

Received: February 3, 2025

Accepted: March 21, 2025

Published: May 15, 2025

Cite as: Çelik S. 2025. Analysis of intraoral images using deep learning: classification performance of CNN models. BSJ Eng Sci, 8(3): 704-714.

1. Giriş

Tıbbi bilgilerin kullanımı sağlık bilincini artırmada ve sağlık hizmetlerini en iyi standartlara yükseltmede hayati öneme sahiptir. Ağız içi görüntülerin kullanımı diş hekimlerine, ortodontistlere ve patoloğlara hastaların diş problemlerini anlamaları ve teşhis etmeleri konusunda yardımcı olmaktadır. Ancak bu görüntülerin analizi ve yorumlanması zaman alıcı ve zorlu olabilmektedir. Bu çalışma, ağız içi görüntüleri kullanılarak otomatik diş bölgesinin sınıflandırılması ve bu alandaki problemlerin çözümünde uzmanlara yardımcı olması amaçlanmıştır. Ağız içi görüntülerinin kullanıldığı alanlar geniş bir

yelpazeye sahiptir. Diş hekimliği uygulamalarında, ağız içi görüntüleri; diş eti hastalıkları, diş çürükleri, diş minesindeki hasarlar, diş yapısı ve dişler arasındaki ilişkilerin incelenmesinde kullanılmaktadır. Bununla birlikte dişlerin düzeltilmesi, yüz gelişiminin izlenmesi ve çene hareketlerinin analizinde değerli bilgiler sağlamaktadır. Ayrıca tümörlerin sınıflandırılması ve tedavi planlaması gibi pek çok aşamada ağız içi görüntüleri kullanılmaktadır.

Son yıllarda derin öğrenme teknikleri, özellikle Evrimsel Sinir Ağları (CNN'ler), ağız içi görüntülerin analizi için önemli bir araştırma alanı haline gelmiştir. CNN'ler, görüntülerden özellikleri otomatik olarak çıkarabilme



yetenekleri sayesinde, diş çürükleri, periodontal hastalıklar ve diğer ağız sağlığı sorunlarının tespitinde klinisyenlere büyük ölçüde yardımcı olmaktadır. Bu yöntemler, geleneksel teşhis yöntemleriyle karşılaştırıldığında yüksek doğruluk oranları sunarak diş hekimliği alanında devrim yaratmaktadır. Örneğin, Kühnisch vd. (2021) tarafından yapılan bir çalışmada, 3.293 bitewing radyografisi analiz edilerek CNN modellerinin diş çürüklerini tespit etme başarısı değerlendirildi. Sonuçlar, Alan Altı Eğrisi (AUC) değerlerinin 0,845 ile 0,917 arasında değiştiğini ve %80'in üzerinde tanısal doğruluk sağlandığını göstermiştir. Benzer şekilde, Tan vd. (2024), yapay zekanın farklı görüntüleme yöntemlerinde diş hekimlerine eşdeğer performans sergileyerek diş hastalıkları teşhisinde yüksek doğruluk sunduğunu ortaya koymuştur.

Görüntü işleme teknikleri, ağız içi görüntülerinin iyileştirilmesi, analizi ve teşhisi için kullanılan yöntemleri içerir. Bu teknikler arasında görüntü iyileştirme, segmentasyon, özellik çıkarma ve sınıflandırma gibi adımlar bulunmaktadır. Görüntü işleme teknikleri, ağız içi sağlık sorunlarının teşhisi ve takibi için önemli bir araç olarak kabul edilmektedir. Bununla birlikte derin öğrenme ve yapay zeka uygulamaları, ağız içi görüntülerinin otomatik analizi ve tanımlanması için kullanılan ileri düzey teknolojilerdir. Bu uygulamalar büyük veri kümeleri üzerinde eğitilmiş derin sinir ağları ve öğrenme modelleri kullanılarak ağız içi görüntülerinin patolojik bölgelerini tanımlayabilmektedir. Derin öğrenme ve yapay zeka uygulamalarının ağız içi görüntü analizindeki potansiyeli oldukça fazladır. CNN modelleri, yalnızca çürük tespiti ile sınırlı kalmayıp periodontal hastalıkların belirlenmesi, fissür örtücülerin analizi, endodontik tedavilerin değerlendirilmesi ve ortodontik planlamalar gibi birçok farklı alanda uygulanmaktadır. Khanagar vd. (2021), yapay zekanın periodontal olarak tehlikeye girmiş dişleri tahmin edebilme potansiyelini vurgularken, Alalharith vd. (2020) ise diş eti iltihabının erken teşhisinde derin öğrenme modellerinin etkinliğini ortaya koymuştur.

Maksiller ve Mandibular özellikler; dişlerin temel özelliklerinden biri cinsiyetler ve etnik gruplar arasında önemli ölçüde değişebilen boyutları ve şekilleridir. Soundarya vd. (2021), maksiller kesici diş genişliği ve köpek dişi genişliği gibi çeşitli endekslerin, diş morfolojisindeki cinsel dimorfizmi belirlemedeki önemini vurgulamıştır. Bulguları, maksiller ve mandibular dişlerin adli ve antropolojik bağlamlarda kullanılabilecek önemli boyut farklılıkları sergilediğini göstermektedir. Benzer şekilde, Al-Khannaq vd. (2022) özellikle karışık dişlenme döneminde diş sıklığını önlemek için kesici dişlerin boyutlarına göre köpek dişlerinin ve küçük azı dişlerinin genişliklerinin tahmin edilmesinin önemini vurgulamıştır. Bu tahmin yeteneği ortodontik planlama için önemlidir ve optimum diş arkı hizalaması elde etmeye yardımcı olabilmektedir.

Maksiller ve mandibular dişlerin işlevsel yönleri oklüzyon ve genel ağız sağlığında kritik bir rol oynar. Yotsuya vd.

(2020), maksiller ve mandibular arklar arasındaki uyumsuzluğun anormal oklüzyona yol açabileceğini ve bunun da çene üzerinde artan strese ve temporomandibular bozukluklar gibi olası komplikasyonlara neden olabileceğini tartışmıştır. Bu, temporomandibular gelişiminde oklüzyonun önemini vurgulayan ve uygunsuz hizalamanın önemli rahatsızlığa ve işlevsel bozukluğa yol açabileceğini belirten Kanter vd. (2018)'nin çalışmasıyla daha da desteklenmektedir. Palkit vd. (2020) tarafından vurgulandığı gibi, oklüzyon ve diş estetiği arasındaki ilişki de önemli bir husustur. Çalışmada Sınıf II maloklüzyonlu hastalarda maksiller ve mandibular taban uzunluklarındaki farklılıkların diş sıklığıyla nasıl ilişkili olduğunu araştırmıştır.

İşlevsel hususlara ek olarak, maksiller ve mandibular dişler arasındaki anatomik farklılıklar diş çürüğü ve diğer patolojilerin yaygınlığını etkileyebilir. Rithanya (2023) yaptığı çalışmada, özellikle azı dişleri olmak üzere posterior dişlerin, bakteri barındırabilen çoklu oluklar ve çukurlar içeren karmaşık morfolojileri nedeniyle çürüğe karşı daha yüksek bir duyarlılığa sahip olduğunu belirlemiştir. Bu duyarlılık, Wang vd. (2020) tarafından bildirilen değişken süngerimsi kemik yoğunluklarının kanıtladığı gibi, maksilla ve mandibuladaki anatomik farklılıklarla daha da karmaşılaşmış ve bu da çevredeki dişlerin stabilitesini ve sağlığını etkileyebileceği bildirilmiştir. Ayrıca, García-Gil vd. (2023) tarafından yapılan çalışma, arka dişlerin sürme dizisinin diş sıklığı ve ark boyutlarıyla ilişkili olduğunu ve diş morfolojisi ile ağız sağlığı sonuçları arasındaki ilişkiyi daha da karmaşık hale getirdiğini göstermiştir. Üst ve alt çene dişlerinin gelişimsel yönleri de, özellikle diş sürmesi ve ortodontik müdahalelerin zamanlaması ile ilgili olarak dikkate değerdir. Corns vd. (2021), çoğu çalışmanın alt çene dişlerinin kök gelişimine odaklandığını ve bunun genellikle ektopik pozisyona daha yatkın olan üst çene dişleri ile ilgili bilgi eksikliğine işaret ettiğini belirtmiştir. Bu, diş sürmesinin dinamiklerini ve ortodontik tedavi için etkilerini daha iyi anlamak için her iki kemeri de kapsayan kapsamlı çalışmalara olan ihtiyacı vurgulamaktadır. Ek olarak, Ueno vd. (2019) tarafından yapılan diş kemeri formu üzerine yapılan araştırma, kesici dişler arası mesafe ve meziodistal kron genişliği gibi çeşitli faktörlerin, etkili ortodontik planlama için kritik olan diş kemerinin genel şeklini ve boyutunu önemli ölçüde etkilediğini ortaya koymuştur.

Ayrıca, diş morfolojisini etkileyen genetik ve çevresel faktörler oldukça önemli bir faktör olarak ön plana çıkmaktadır. Khalaf vd. (2022), genetik yatkınlıkların diş sayısı, boyutu ve şekli bakımından farklılıklara nasıl yol açabileceğini, özellikle de fazladan dişler ve bunların alt çene kesici dişlerinin morfolojisi üzerindeki etkilerini tartışmışlardır. Bu genetik değişkenlik, farklı popülasyonların kişiye özel tedavi stratejileri gerektiren farklı diş özellikleri gösterebilmesi nedeniyle, ortodonti ve restoratif diş hekimliğinde kişiselleştirilmiş yaklaşımların önemini vurgulamaktadır.

Üst çene ve alt çene dişleri arasındaki etkileşim, dental

implantlar ağız içi görüntülerin değerlendirilmesi açısından önem arz etmektedir. Wimalarathna vd. (2021) tarafından yapılan çalışma, implant yerleştirme için hayati yapıların ve mevcut kemiğin yerini anlamının önemini vurgulayarak, her iki kemeri de etkili bir şekilde değerlendirmek için hassas görüntüleme tekniklerine olan ihtiyacı vurgulamıştır. Bu durum, implant prosedürlerinin başarısını etkileyebilecek olan üst çene ve alt çene arasındaki kemik yoğunluğu ve morfolojideki anatomik farklılıklar göz önüne alındığında özellikle önemlidir. Sonuç olarak, dişlerin maksiller ve mandibular yönlerine ilişkin farklı görüşler anatomik, işlevsel, gelişimsel ve genetik etkiler de dahil olmak üzere geniş bir yelpazedeki faktörleri kapsar. Bu iki ark arasındaki farklar diş sağlığını, tedavi planlamasını ve diş anomalilerinin önlenmesini anlamak için kritik öneme sahiptir. Araştırmalar gelişmeye devam ettikçe, diş hekimlerinin hasta sonuçlarını iyileştirmek ve ağız sağlığını optimize etmek için bu bulguları uygulamalarına entegre etmeleri önemlidir.

Belirtilen çalışmalar ve daha birçok çalışmada ışığında ağız içi görüntülerin önemi anlaşılmaktadır. Bu çalışmada, derin öğrenme tekniklerinin kullanılan veri setindeki ağız içi bölgesel segmentasyonuna katkıda bulunması planlanmaktadır. Kullanılan veri kümesinde, farklı görünümlere sahip dişlerin tanımlanması çeşitli algoritmalar ve yöntemlerle gerçekleştirilmiştir. Çalışmada birçok model test edilerek uygun olduğu düşünülen beş farklı model için çalışmalar yapılmıştır. Bu modeller; ResNet152V2, DenseNet201, InceptionResNetV2, ConvNeXtBase ve Xception' dır. Kullanılan modellerin tek başına performansları ile birlikte topluluk modeli geliştirilerek çalışmanın boyutu üst seviyeye çıkarılmış ve deneysel çalışmaların performansı artırılmıştır. Bu yaklaşımın diş hekimleri için tanı ve tedavi süreçlerini kolaylaştırmanın yanı sıra uzaktan tedavi fırsatları sağlamada da faydalı olacağına inanılmaktadır.

2. Materyal ve Yöntem

2.1. Veri Seti

Çalışmada ağız içi görüntülerini içeren bir veri seti kullanılmıştır. Veri seti, Bharati Vidyapeeth Deemed Üniversitesi Diş Hekimliği Fakültesi ve Hastanesi tarafından Hindistan'da toplanmıştır. Paylaşılan veri setinde 9562 görüntü bulunmaktadır. Yaşları 1 - 14 arasında değişen çocuklara ait sağlıklı diş görüntüleri toplanmıştır. Maksiller(üst çene) ve mandibular(alt çene) görünümlerin ön, sağ, sol ve oklüzal(çigneme yüzeyi) olmak üzere sekiz alt klasör halinde Mendeley veri deposunda saklanmaktadır (Chaudhary vd., 2024). Veri setindeki görüntüler anonimleştirilmiş olup kişisel veri içermemektedir. Dolayısıyla etik kuru onayı gerekmemektedir.

Bu veri seti, diş tıbbi teşhisinde yapay zeka uygulamalarını geliştirmek, aynı zamanda teşhis sürecini hızlandırmak ve makine öğrenmesi modellerini eğitmek amacıyla kullanılmasını amaçlamaktadır. Özellikle, diş

çürüklerinin, periodontal hastalıkların ve gelişimsel anomalilerin tespiti için oldukça önemli bir kaynak olacağı düşünülmektedir. Verilerin toplanması, kontrollü ortamda ve sabit şartlarda gerçekleştirilmiştir. Görüntülerin çekimi akıllı telefon ile yapılmıştır. Bazı yüzeylerin daha iyi görüntülenmesi için intraoral aynalar kullanılmıştır. Ağız içi dişlerin net bir şekilde görünmesini sağlamak amacıyla yanak reaktörleri kullanılmıştır. Tüm işlemler sterilizasyon ekipmanları ile dezenfekte edilmiştir (Chaudhary vd., 2024). Veri setinin içeriği Tablo 1' de gösterilmiştir.

Tablo 1. Veri seti dağılımı

Kategori	Görüntü Sayısı	Tanım
Maksiller Ön Görünüm (Upper Front)	1075	Üst çene ön dişlerin tamamını içerir.
Maksiller Sağ Görünüm (Upper Right)	1143	Üst çenenin sağ yarısındaki dişleri içerir.
Maksiller Sol Görünüm (Upper Left)	1289	Üst çenenin sol yarısındaki dişleri içerir.
Maksiller Oklüzal Görünüm (Upper Occlusal)	1140	Üst çenedeki tüm dişlerin çigneme yüzeylerini içerir.
Mandibular Ön Görünüm (Lower Front)	926	Alt çene ön dişlerin tamamını içerir.
Mandibular Sağ Görünüm (Lower Right)	1401	Alt çenenin sağ yarısındaki dişleri içerir.
Mandibular Sol Görünüm (Lower Left)	1566	Alt çenenin sol yarısındaki dişleri içerir.
Mandibular Oklüzal Görünüm (Lower Occlusal)	1022	Alt çenedeki tüm dişlerin çigneme yüzeylerini içerir.


Veri seti oluşturulurken dişlerin belli koşullardan etkilenmemesi amacıyla dişler temizlenmiş ve kurutulmuştur. Ağız içi görüntüleri 5-7 cm mesafe ile doğrudan ve yanal açılardan çekilmiştir. Çekilen görüntülerin tutarlı oluşturulması için kırpma ve boyut standizasyon işlemleri yapılmıştır. Hazırlanmış 8 farklı klasör içindeki görüntülerin ön, sağ ve sol görünümlerinde 1280x550 piksel, oklüzal görünümlerinde 1024x768 piksel olarak ayarlanmıştır.

2.1. Veri Ön İşleme

Modellerin veri setini daha iyi öğrenmesi ve daha iyi genelleme yapması için ön işleme teknikleri uygulanmıştır. Veri setindeki görüntü sayıları aynı kalacak şekilde ön işleme adımları yapılmıştır. Veri setini modellere uygun hale getirmek için bazı işlemler gerçekleştirilmiştir. Öncelikle görüntüler üzerinde normalizasyon yapılmıştır. Tüm görüntüler [0, 1] arasına ölçeklendirilmiştir. Bu işlem, modelin daha stabil öğrenmesini ve gradyan kaybolmalarının önlenmesi amacıyla yapılmıştır. Bu adım neticesinde piksel değerleri küçültülerek modelin daha iyi öğrenmesi sağlanmıştır.

Ayrıca veri setinin aşırı büyük değerlerle modelin kararsız çalışmasının engellenmesi amaçlanmıştır. Normalizasyon adımından sonra görüntülerin boyutlandırma işlemi yapılmıştır. Veri setinde bulunan görüntülerin boyutlarının farklı olması sebebiyle modellerin standart giriş boyutu gereksinimlerine uyması için tüm görseller tek bir boyuta çekilmiştir. Kullanılan modellerin gereksinimlerine dayanarak giriş formatına uygun olacak şekilde 224x224 olarak tüm görüntüler

boyutlandırılmıştır. Bu işlemler yapıldıktan sonra mevcut sekiz klasörden orantılı olacak şekilde %70 eğitim seti, %20 doğrulama seti ve %10 test seti olacak şekilde görüntüler sırasıyla 6705, 1915 ve 962 görüntü şeklinde ayrılmıştır. Kullanılan veri setine ait görüntülerin Şekil 1'de eğitim setine, doğrulama setine ve test setine ait dağılım gösterilmiştir. Şekilden anlaşılabileceği üzere veri setindeki mevcut sekiz klasörün orantılı bir şekilde üç set içerisinde dağıtıldığı görülmektedir.



Şekil 1. Veri setinin eğitim, doğrulama ve test setindeki dağılımı.

2.2. Temel Model Eğitimi, Doğrulaması ve Seçimi

Ön işleme ve normalizasyon uygulanmış ağız içi diş röntgeni görüntüleri, daha sonra her bir Evrişimli Sınır Ağları (CNN) modeline giriş verisi olarak kullanılmıştır. Çalışmada kullanılan CNN modelleri ResNet152V2, DenseNet201, InceptionResNetV2, ConvNeXt ve Xception olarak belirlenmiştir. EfficientNetV2S ve EfficientNetB4 düşük performans gösterdiği için değerlendirme dışı bırakılmıştır. Seçilen modellerin daha önceki çalışmalarda başarılı sonuçlar vermesi ve transfer öğrenme yetenekleri ve eğitilebilirlik düzeyleri etkili olmuştur. ResNet152V2; derin katman yapısı ve residual bağlantılar ile daha iyi öğrenme sağlamaktadır. DenseNet201; her katmanın önceki katmanlardan doğrudan bağlantı almasını sağlayarak bilgi akışını iyileştirmektedir. InceptionResNetV2; çoklu ölçekli özellikleri öğrenerek detaylı analiz yapar. ConvNeXtBase; modern CNN mimarileri ile optimizasyon sağlamaktadır. Xception; derin ayrık evrişimler kullanarak hesaplama verimliliğini artırmaktadır. Her bir model için farklı amaçlar değerlendirilmek üzere seçilmiştir.

Tüm modeller, Adam optimizatörü ve ağırlık azalması (weight decay) ile optimize edilmiş, 0.0001 öğrenme oranı ile eğitilmiştir. Her bir model 30 epoch boyunca eğitim ve doğrulama süreçlerine tabi tutulmuş, aşırı uyumu (overfitting) önlemek amacıyla erken durdurma (early stopping) stratejisi uygulanmıştır. Modelin daha stabil ve güvenilir sonuçlar vermesi için veri artırma (data augmentation) teknikleri kullanılmamış, ancak veri seti eğitim sürecinden önce orantılı ve dengeli bir şekilde eğitim, doğrulama ve test alt kümelerine ayrılmıştır. Veri setindeki sekiz farklı sınıf, tüm alt kümelerde dengeli bir şekilde temsil edilecek şekilde bölünmüştür.

Tekil model performans değerlendirmesine ek olarak, topluluk modelleri de çalışmaya dahil edilmiştir. İkili topluluk modeli için ResNet152V2+DenseNet201,

ResNet152V2+Xception, ResNet152V2+ConvNeXtBase ve ResNet152V2+InceptionResNetV2 kombinasyonları test edilmiştir. Çoklu (multi) topluluk modeli için ise üç veya daha fazla modelin birlikte kullanıldığı birleştirme teknikleri uygulanmıştır.

Modellerin eğitilmesi aşamasında ince ayar (fine-tuning) süreci oluşturulmuştur. İnce ayar önceden eğitilmiş bir modelin bazı katmanlarını açarak tekrar eğitmek olarak tanımlanmaktadır. Bu bağlamda ImageNet veri kümesi ile eğitilmiş modellerin ağırlıkları kullanılmıştır. Modelin ilk katmanları dondurularak önceden öğrendiği özellikler korunmuştur. Modelin son katmanları tekrar açık olarak eğitime başlanmıştır. İlk olarak modelin önceden öğrendiği özellikleri kullanarak sadece yeni sınıflandırma katmanları eğitilmiştir. İlk eğitimin ardından, modelin üst katmanları açılarak ince ayar yapılmıştır. Temel modelin üst katmanları bu aşamada serbest bırakılmıştır. Önceden eğitilmiş katmanlar daha düşük bir öğrenme oranı ile tekrar eğitilmiştir. Böylece model, önceki bilgilerini kaybetmeden yeni verilere adaptasyon sağlamıştır. İnce ayar işlemi transfer öğrenme ile başlarken, önce özellikleri çıkarılmış ve daha sonra ince ayar gerçekleştirilmiştir. Bu durum temel model eğitimini daha verimli hale getirerek doğruluğu artırmıştır. Yapılan işlemlere ait kodlama işleminde bir görüntü Şekil 2'de gösterilmiştir.

```

from tensorflow.keras.applications import
ResNet152V2
from tensorflow.keras.layers import
GlobalAveragePooling2D, Dense
from tensorflow.keras.models import Model

base_model = ResNet152V2(weights="imagenet",
include_top=False, input_shape=(224, 224, 3))

for layer in base_model.layers[:100]:
layer.trainable = False

x =
GlobalAveragePooling2D()(base_model.output)
x = Dense(256, activation="relu")(x)
output_layer = Dense(8, activation="softmax")(x)

model = Model(inputs=base_model.input,
outputs=output_layer)
model.compile(optimizer="adam",
loss="categorical_crossentropy",
metrics=["accuracy"])

model.summary()

```

Şekil 2. İnce ayar işlemi için bir bölüm.

Bu çalışmada derin öğrenme modellerinin eğitimi ve doğrulaması için Keras kütüphanesi kullanılmıştır. Keras, TensorFlow çerçevesi içinde yüksek seviyeli bir API olarak çalışarak kullanıcı dostu ve esnek bir model oluşturma süreci sunmaktadır.

Modelin eğitim sürecinde kayıp fonksiyonu (loss function) olarak *categorical cross-entropy* tercih edilmiştir. Categorical cross-entropy, çok sınıflı sınıflandırma problemlerinde yaygın olarak kullanılan bir kayıp fonksiyonudur ve modelin tahmin ettiği olasılıklar ile gerçek etiketler arasındaki farkı ölçerek modelin optimizasyonunu sağlar. Deneyisel çalışmanın etkinliğini artırmak amacıyla kayıp fonksiyonu olarak "*categorical cross-entropy*" seçilmiştir. Keras' a ait olan dökümantasyonda etiketler ve tahminler arasındaki çapraz entropi kaybını hesaplayan kayıp fonksiyonudur. Eğitim aşaması tamamlandıktan sonra modeller doğrulama setleri üzerinde test edilmiştir. Performans ölçümleri için beş metrik kullanılmıştır: Doğruluk, kesinlik, duyarlılık F1- Skoru, ROC-AUC Skoru. Bu metrikler, modellerin test verisi üzerindeki başarılarını ölçmek için kullanılmıştır.

Derin öğrenme modellerinin performansını değerlendirmek için yaygın olarak kullanılan metrikler arasında doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall) ve F1 skoru gibi önemli ölçütler bulunmaktadır (Abunasser ve Al-Hiealy, 2022; Elshennawy ve Ibrahim, 2020). Bu metrikler, modelin sınıflandırma performansını farklı açılardan detaylı bir şekilde ölçmektedir (Vakili vd., 2020). Doğruluk (accuracy), modelin yapmış olduğu sınıflandırmalar içerisinde doğru olanların oranını belirtirken; hassasiyet (precision), modelin pozitif olarak sınıflandırdığı veri noktalarının içerisinde gerçekten pozitif olanların

oranını göstermektedir (Chicco ve Jurman, 2020). Duyarlılık (recall) ise, gerçekten pozitif olan veri noktalarının ne kadarının doğru bir şekilde pozitif olarak sınıflandırıldığını ifade eder ve bu, modelin yeteneği hakkında önemli bilgiler sunmaktadır (Wang vd., 2018). F1 skoru ise hassasiyet ve duyarlılık değerlerini bir bütün olarak birleştirerek modelin performansını daha kapsamlı ve dengeli bir şekilde değerlendirmekte, bu nedenle bu metrik, geliştiricilere modelin genel başarı durumu hakkında daha iyi bir anlayış sunmaktadır (Chicco ve Jurman, 2020; Sitaula ve Shahi, 2022). ROC-AUC, bir modelin doğru pozitif oranı (TPR - True Positive Rate) ve yanlış pozitif oranı (FPR - False Positive Rate) arasındaki ilişkiyi görselleştiren bir grafikdir (Gupta vd., 2021). Bu eğri, sınıflandırıcının karar eşiği değiştirildikçe nasıl performans gösterdiğini anlamak için kullanılır. Özellikle dengesiz veri kümelerinde, ROC-AUC metriği, Accuracy (Doğruluk) gibi yanıltıcı metriklerden daha iyi bir performans göstergesi olarak kullanılır (Wang vd., 2018). Eşitlik 1-5' de hesaplama ile ilgili gerekli ölçüm işlemleri verilmiştir. Burada belirtilen TP(True Positive); doğru şekilde pozitif tahmin edilen örnekler olarak, TN(True Negative); doğru şekilde negatif tahmin edilen örnekler olarak, FP(False Positive); yanlış şekilde pozitif tahmin edilen örnekler olarak, FN(False Negative); yanlış şekilde negatif tahmin edilen örnekler tanımlamak mümkündür.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (2)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (3)$$

$$F1 = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (4)$$

$$X \text{ eksen} (FPR) = \frac{FP}{FP + TN} \quad Y \text{ eksen} (TPR) = \frac{TP}{TP + FN} \quad (5)$$

Tek başına en iyi performansı veren modeller belirlendikten sonra birleştirme teknikleri uygulanmıştır. Bu aşamada topluluk modelleri için yaygın olarak kullanılan yaklaşımlardan ağırlıklı ortalamalı karar (soft voting), çoğunluk kararı (hard voting) ve yeni bir model ile son kararın verilmesi (meta model) teknikleri uygulanmıştır. Bu yöntemler topluluk yöntemleri test edilmiştir. Tüm modellerin birleşimi ile oluşturulan model için lojistik regresyon meta model olarak kullanılmıştır. Bunun sebebi farklı derin öğrenme modellerinden elde edilen tahminleri birleştirerek nihai bir karar verebilmektir. Lojistik regresyonun seçilmesinin sebebi oldukça hafif ve hızlı bir sınıflandırma algoritması olmasıdır. Lojistik regresyon ile birlikte birden fazla modelin çıktıları alınarak, bu çıktıların üzerinden yeni bir tahmin yapılmaktadır. Bu durum modelin ağırlıklarını optimize ederek en iyi kararın verilmesini sağlamaktadır. Lojistik regresyon ile tüm modellerin tahminleri giriş olarak verilmiştir. Lojistik regresyon bu tahminleri kullanarak nihai bir tahminde bulunarak sonuç elde etmiştir. Tüm bunlar neticesinde lojistik regresyon, hangi

modelin hangi durumda daha iyi olduğunu öğrenerek, bu duruma göre de ağırlıklarını optimize etmiştir.

Ortalama tahmin yönteminde, tüm modellerin sınıf olasılıklarının ortalaması alınmakta ve en yüksek değere sahip olan sınıf seçilmektedir. Çoğunluk oylaması yönteminde her modelin tahmin ettiği sınıf alınarak en çok tahmin edilen sınıf seçilmektedir. Meta model ile temel modellerin çıktılarının bir ikinci model ile analiz edilmesini sağlamaktadır.

Seçilecek modeller belirlenirken CNN tabanlı mimariler tercih edilmiştir. ResNet152V2, DenseNet201, InceptionResNetV2, ConvNeXtBase ve Xception seçilen modellerdir. ResNet, He vd. (2016) tarafından önerilen ve derin sinir ağlarının eğitiminde karşılaşılan gradyan kaybolması problemini çözmeyi amaçlayan bir CNN mimarisidir. ResNet152V2, 152 katmana kadar çıkabilen derin bir modeldir. Derin ağlarda öğrenme sürecini kolaylaştıran residual bağlantılar içermektedir. Bu bağlantılar, önceki katmanların çıktısını doğrudan daha sonraki katmanlara ileterek geri yayılımı iyileştirmektedir. DenseNet, Huang vd. (2017) tarafından geliştirilen bir CNN mimarisidir. Bu modelin en önemli özelliği, her katmanın önceki tüm katmanlardan bilgi almasıdır. Böylece, geleneksel CNN'lerde olduğu gibi her katman sadece önceki katmandan değil, tüm önceki katmanlardan girdiyi alarak bilgi akışını güçlendirmekte ve parametre verimliliğini artırmaktadır. InceptionResNetV2, Szegedy vd. (2017) tarafından geliştirilen ve Inception mimarisi ile residual bağlantıları birleştiren bir CNN modelidir. Inception ağları, farklı boyutlarda filtreleri aynı anda çalıştırarak çoklu ölçekli özellikleri yakalarken, residual bağlantılar da derinlik arttıkça öğrenmeyi kolaylaştırmaktadır. Bu model, Google tarafından geliştirilen Inception ve ResNet mimarilerinin en iyi yönlerini birleştirerek daha yüksek doğruluk oranlarına ulaşmayı başarmıştır. ConvNeXtBase, Liu vd. (2022) tarafından geliştirilen ve standart CNN mimarilerini Transformer tabanlı modellerle rekabet edecek şekilde optimize eden bir modeldir. ConvNeXtBase, Vision Transformer (ViT) gibi yeni nesil mimarilerin getirdiği yenilikleri geleneksel CNN'lere uygulayarak daha verimli ve ölçeklenebilir bir yapı sunmaktadır. Bu model, daha büyük kernel boyutları, normalizasyon iyileştirmeleri ve optimize edilmiş

aktivasyon fonksiyonları ile geliştirilmiştir. Xception, Chollet (2017) tarafından geliştirilen ve Inception mimarisinin daha ileri bir versiyonu olan bir CNN modelidir. Xception'un temel özelliği, derin ayrık evrişimler kullanarak hesaplama maliyetini azaltırken modelin öğrenme kapasitesini artırmasıdır. Bu modelde, geleneksel konvolüsyon katmanları yerine, kanallar arasında bağımsız öğrenmeyi destekleyen ayrık evrişimler kullanılmaktadır. Böylece, daha az parametreyle daha iyi performans elde edilebilmektedir. Seçilen modeller, görüntü işleme, nesne algılama, tıbbi görüntü analizi ve diğer derin öğrenme uygulamaları için yaygın olarak kullanılmaktadır. Seçilen modeller kullanılan veri setine ve uygulama amacına bağlı olarak belirlenmiştir.


3. Bulgular ve Tartışma

Bu kısma kadar anlatılan çalışmanın detaylarının deneysel sonuçları bu bölümde anlatılmaktadır. Deneysel sonuçlar öncesinde veri setinin eğitim, doğrulama ve test setleri hazırlanmıştır. Modellerin eğitilmesi aşamasında yeterli olacağı ve tutarlı bir eğitim elde edilebilmesi amacıyla veri sayıları sabit kalmıştır. Bununla birlikte model seçimleri yapılmış ve hazırlanmış setler dengeli bir şekilde kaydedilmiştir. Çalışmada, öncelikle modellerin bireysel performansı analiz edilmiştir. ResNet152V2, DenseNet201, InceptionResNetV2, ConvNeXtBase ve Xception haricinde çalışma dahilinde birçok model test edilmiştir. Ancak değerlendirilen modeller içerisinde çalışma kapsamına uygun olarak sonuç üreten modeller dahil edilmiştir. Topluluk modeli içerisinde de uygun çalışması modellerin


Seçiminde belirleyici bir faktör olmuştur. Modellerin metrik sonuçları Tablo 2' de gösterilmiştir. Modellerin çıktıları incelendiğinde doğruluk değeri en yüksek olan modelin ResNet152V2 olduğu görülmektedir. Performans ölçümlerinde önemli bir metrik olan ROC-AUC değeri en yüksek sonuç veren modelin DenseNet201 modeli olduğu görülmektedir. Bu aşamada sistemde kullanılan modeller için eğitim ve doğruluk setleri için kayıp (loss) grafikleri ve doğruluk grafikleri hazırlanmıştır. ResNet152V2 modeli için kayıp grafiği Şekil 3' de, doğruluk grafiği Şekil 4 ' de gösterilmiştir.

Tablo2. Modellerin metrik değerlerinin karşılaştırılması

Model	Doğruluk	Kesinlik	Duyarlılık	F1	ROC-AUC
ResNet152V2	0,8557	0,8693	0,8716	0,8687	0,9870
InceptionResNetV2	0,8100	0,8339	0,8304	0,8289	0,9802
DenseNet201	0,8525	0,8826	0,8747	0,8664	0,9884
Xception	0,7934	0,8096	0,8094	0,8030	0,9787
ConvNeXtBase	0,7113	0,7460	0,7205	0,7280	0,9603




Şekil 3. ResNet152V2 eğitim ve doğrulama seti için kayıp grafiği.




Şekil 4. ResNet152V2 eğitim ve doğrulama seti için doğruluk grafiği.

ResNet152V2 gibi önceden eğitilmiş bir modelin bazı katmanları dondurularak eğitime başlanmıştır. İlk olarak modelin sadece son sınıflandırma katmanları eğitilmiş, daha sonra derin katmanlar açılarak modelin öğrenme kapasitesi artırılmıştır. Transfer öğrenme sayesinde model, ImageNet gibi bir veri setinde öğrendiği bilgileri koruyarak daha hızlı ve başarılı bir şekilde eğitilmiştir. İlk katmanların dondurulması, modelin ağız içi görüntülerine daha iyi adapte olmasını sağlamıştır. Eğitim sürecinin ilk aşamalarında kayıp değeri yüksekken, epoch ilerledikçe kayıp azalmış ve doğruluk artmıştır. Erken durdurma (early stopping) uygulanarak modelin aşırı öğrenmesi (overfitting) önlenmiştir.

DenseNet201 modeli için kayıp grafiği Şekil 5' de, doğruluk grafiği Şekil 6 ' da gösterilmiştir.




Şekil 5. DenseNet201 eğitim ve doğrulama seti için kayıp grafiği.




Şekil 6. DenseNet201 eğitim ve doğrulama seti için doğruluk grafiği.

DenseNet201 modeli, yoğun bağlantı yapısı nedeniyle daha hızlı öğrenme sağlamıştır. ResNet152V2 modeline kıyasla daha düşük başlangıç kaybı ile başlamıştır. Yoğun bağlantılar sayesinde erken öğrenme daha hızlı gerçekleşmiştir.

Xception modeli için kayıp grafiği Şekil 7' de, doğruluk grafiği Şekil 8 ' de gösterilmiştir.




Şekil 7. Xception eğitim ve doğrulama seti için kayıp grafiği.




Şekil 8. Xception eğitim ve doğrulama seti için doğruluk grafiği.

Xception modeli, ayrılcı derin evrimler (depthwise separable convolutions) kullanarak daha az parametre ile daha yüksek verimlilik sağlamaktadır. Eğitim sürecinde doğruluk değerleri diğer modellere göre daha düşük kalmıştır. Xception modeli veri setindeki detayları yakalamakta diğer modellere kıyasla daha zayıf performans göstermiştir. Xception modeli, daha hafif bir yapı sunduğu için hızlı çalışsa da, detaylı tıbbi görüntülerde bazı kayıplar yaşanmıştır. ConvNeXtBase modeli için kayıp grafiği Şekil 9' da, doğruluk grafiği Şekil 10' da gösterilmiştir.



Şekil 9. ConvNeXtBase eğitim ve doğrulama seti için kayıp grafiği.




Şekil 10. ConvNeXtBase eğitim ve doğrulama seti için doğruluk grafiği.


ConvNeXtBase modeli, Vision Transformer (ViT) tabanlı optimizasyonlar içeren modern bir CNN mimarisidir. Ancak, bu modelin doğruluk oranı beklenenden düşük çıkmıştır. Doğruluk eğrisi diğer modellere kıyasla daha dalgalı bir seyir izlemiştir. Veri setindeki kompleks morfolojik detayları yakalamakta zorlanmıştır.

InceptionResnetV2 modeli için kayıp grafiği Şekil 11' de, doğruluk grafiği Şekil 12' de gösterilmiştir. InceptionResNetV2 modelinin doğruluk eğrisi oldukça stabil ilerlemiştir. Diş morfolojisi gibi çok ölçekli (multi-scale) görüntülerde Inception mimarisi daha avantajlı bir sonuç verebilmesi mümkün olabilmektedir.


Tüm modellerin deneysel sonuçlarından bazı çıktıları için grafikleri belirtilmiştir. Bununla birlikte ROC-AUC değerleri de ölçülmüştür. En yüksek sonuç veren model olan DenseNet201 modelidir. Veri setinde belirtilen sekiz klasör için bu modelin ROC-AUC değerlerine ait grafik Şekil 13' de gösterilmiştir.



Şekil 11. InceptionResnetV2 eğitim ve doğrulama seti için kayıp grafiği.



Şekil 12. InceptionResnetV2 eğitim ve doğrulama seti için doğruluk grafiği.




Şekil 13. DenseNet201 ROC eğrisi.

DenseNet201 modelinin ROC eğrisinin eğimi oldukça yüksektir, bu da modelin pozitif sınıfları ayırt etmede başarılı olduğunu gösterir. DenseNet201'in yüksek ROC-AUC değerine sahip olması, modelin duyarlılığının (recall) iyi olduğunu kanıtlamaktadır. Tıbbi uygulamalarda yanlış negatiflerin (false negatives) azaltılması büyük önem taşımaktadır. ROC-AUC değeri yüksek bir model, gerçek pozitifleri (true positives) yüksek doğrulukla tespit edebilmektedir.

Modellerin bireysel performans değerlendirmesinden sonra ikili modellerin eğitimine başlanmıştır. ROC -AUC değerlerinin en yüksek olduğu iki modelin ve ilk ve üçüncü modelin ikili olarak model eğitim sonuçlarının metrik değerlerine ait çıktılar Tablo 3' de verilmiştir. İkili oluşturulan modellerde ROC-AUC değerinin arttığı büyük farklılıklar görülmemektedir. Bunun sebebi modellerin bireysel olarak gösterdikleri performanslarının da oldukça iyi sonuçlar olabileceği düşünülmektedir. Çalışmada kullanılmak üzere seçilen beş modelin hepsinin topluluk modeli oluşturması ve veri seti üzerinde deneysel sonuçları gerçekleştirilmiştir. Lojistik regresyonun meta model olarak kullanılması neticesinde doğru ağırlıkların seçilmesi ile model en iyi sonuçlara ulaşmıştır. Seçilen tüm modellerin birlikte eğitilmesi sonucunda oluşan çıktılar için oluşturulan tüm veri sonuçları Tablo 3' de gösterilmiştir.

Tablo3. Modellerin metrik değerlerinin karşılaştırılması

Model	Doğruluk	Keskinlik	Duyarlılık	F1	ROC-AUC
ResNet152V2+DenseNet201	0,8879	0,8988	0,9004	0,8995	0,9905
ResNet152V2+InceptionResNetV2	0,8619	0,8747	0,8749	0,8746	0,9879
Tüm Modeller	0,8990	0,9002	0,9107	0,8998	0,9934



Şekil 5. Topluluk modellerin karşılaştırılması.

Elde edilen sonuçlar, ağız içi görüntülerin sınıflandırılmasında derin öğrenme yöntemlerinin önemini ve etkinliğini ortaya koymaktadır. Tek başına en iyi performansı veren modellerin ResNet152V2 ve DenseNet201 olduğu gözlemlenmiştir. Bununla birlikte, topluluk modeli yaklaşımı ile bu modellerin birleştirilmesi, daha iyi genelleme sağlanarak sınıflandırma başarısını artırmıştır. Bu durum, ağız içi görüntü analizinde tek bir model yerine çoklu model yaklaşımlarının kullanılmasının avantajlarını göstermektedir.

Sonuçlar değerlendirildiğinde, bazı modellerin belirli sınıflarda daha yüksek doğruluk sergilediği ancak diğer sınıflarda daha düşük performans gösterdiği görülmüştür. Özellikle ConvNeXtBase modeli, diğer modellere kıyasla daha düşük doğruluk oranlarına sahip olmuştur. Bu durum, modelin mimarisinin diş görüntülerindeki karmaşık morfolojik farklılıkları tanımlamakta yetersiz kalabileceğini göstermektedir. Öte yandan, ResNet152V2 ve DenseNet201 gibi daha derin yapıya ağlar, karmaşık desenleri ve ince detayları daha iyi yakalayabilmiştir.

Topluluk modelinin başarısının en önemli nedenlerinden biri meta öğrenme (meta model) ile ağırlıkların optimize edilmesi ve farklı modellerin güçlü yönlerinden faydalanılmasıdır. Lojistik regresyon meta model olarak kullanılarak, her modelin belirli sınıflarda gösterdiği başarı oranları değerlendirilmiş ve en iyi sonucu veren modelin daha fazla ağırlıklandırılması sağlanmıştır. Bu yaklaşım sayesinde, tekil modellerde görülen genelleme eksiklikleri giderilmiş ve hata oranları minimize edilmiştir.

4. Sonuç

Bu çalışma, ağız içi görüntülerini kullanarak diş bölgesinin sınıflandırılmasına yönelik derin öğrenme tabanlı yaklaşımları incelemiş ve çeşitli model kombinasyonlarının performanslarını değerlendirmiştir.

Yapılan deneylerde ResNet152V2, DenseNet201, InceptionResNetV2, ConvNeXtBase ve Xception modelleri tek tek ve topluluk modeli şeklinde test edilmiştir. Sonuçlar, topluluk modellerinin bireysel modellere kıyasla daha yüksek doğruluk ve genelleme kabiliyetine sahip olduğunu göstermektedir. Özellikle, ResNet152V2 + DenseNet201 modeli ile elde edilen %89,9 doğruluk oranı ve 0,9934 ROC-AUC değeri, ağız içi görüntülerinin sınıflandırılmasında oldukça başarılı bir performans sergilemiştir.

Çalışmanın önemli bulgularından biri, derin öğrenme tabanlı yaklaşımların diş hekimliği alanındaki tanı süreçlerini hızlandırmada ve doğruluk oranını artırmada büyük potansiyel taşıdığıdır. Bu yöntemler, klinik ortamda daha hızlı ve güvenilir teşhisler sunarak diş hekimlerine destek olma kapasitesine sahiptir. Ayrıca, geliştirilmiş sınıflandırma modelleri, uzaktan hasta değerlendirme süreçlerinde de kullanılabilir ve dijital diş hekimliği uygulamalarına entegre edilebilir.

Pratik Kullanım Alanları:

-Otomatik Teşhis ve Tedavi Planlama: Derin öğrenme tabanlı modeller, diş hekimleri tarafından ön teşhis amacıyla kullanılabilir. Örneğin, çürüklerin veya diş eti hastalıklarının erken tespiti sağlanabilir.

-Uzaktan Hasta Takibi: Dijital platformlar aracılığıyla hastaların ağız içi görüntüleri analiz edilebilir ve ön değerlendirme yapılabilir.

-Ortodontik ve Adli Bilimler Uygulamaları: Diş morfolojisine dayalı sınıflandırma, kimlik tespiti, yüz tanıma ve ortodontik planlamada kullanılabilir.

Çalışmanın Kısıtlılıkları ve Gelecek Çalışmalar:

-Veri seti yalnızca belirli bir yaş grubuna (1-14 yaş) ait olup, yetişkin bireyleri içermemektedir. Gelecekteki çalışmalar, farklı yaş gruplarını ve daha geniş popülasyonları içeren veri setleriyle genişletilmelidir.

-Kullanılan derin öğrenme modelleri daha fazla veri artırma (data augmentation) teknikleri ile desteklenebilir, böylece modelin genelleme yeteneği artırılabilir.

-Gerçek klinik ortamlarda test edilerek modellerin pratik kullanım açısından değerlendirilmesi gerekmektedir.

Sonuç olarak, bu çalışma, ağız içi görüntülerinin analizinde derin öğrenme tekniklerinin etkinliğini göstermekte ve diş hekimliği alanında dijital teşhis ve tedavi yöntemlerine katkı sağlayabilecek önemli bir adım olarak değerlendirilmektedir. Devam eden araştırmalar, bu sistemlerin gerçek klinik ortamlarda daha geniş ölçekte uygulanabilirliğini test etmeyi amaçlamaktadır. Gelecekte, ağız sağlığı teşhislerinin otomatikleştirilmesi ve yapay zekâ destekli sistemlerin yaygınlaşmasıyla birlikte, hem klinik hem de uzaktan sağlık hizmetleri önemli ölçüde iyileşebileceği öngörülmektedir. Yapay zekâ tabanlı modellerin daha fazla geliştirilmesiyle, diş

hekimliği alanında teşhis ve tedavi süreçlerinin daha da ileriye taşınması beklenmektedir.

Katkı Oranı Beyanı

Yazarın katkı yüzdeleri aşağıda verilmiştir. Yazar makaleyi incelemiş ve onaylamıştır.

	S.Ç.
K	100
T	100
Y	100
VTI	100
VAY	100
KT	100
YZ	100
KI	100
GR	100
PY	100
FA	100

K= kavram, T= tasarım, Y= yönetim, VTI= veri toplama ve/veya işleme, VAY= veri analizi ve/veya yorumlama, KT= kaynak tarama, YZ= Yazım, KI= kritik inceleme, GR= gönderim ve revizyon, PY= proje yönetimi, FA= fon alımı.

Çalışma Beyanı

Yazar bu çalışmada hiçbir çıkar ilişkisi olmadığını beyan etmektedirler.

Etik Onay Beyanı

Bu çalışmada hayvanlar ve insanlar üzerinde herhangi bir çalışma yapılmadığı için etik kurul onayı alınmamıştır.

Kaynaklar

- Abunasser BS, Al-Hiealy MRJ. 2022. Prediction of instructor performance using machine and deep learning techniques. *Semant Scholar*, 21(2): 1-12.
- Alalharith D, Alharthi H, Alghamdi W, Alsenbel Y, Aslam N, Khan I, Barouch K. 2020. A deep learning-based approach for the detection of early signs of gingivitis in orthodontic patients using faster region-based convolutional neural networks. *Int J Environ Res Public Health*, 17(22): 8447.
- Al-Khannaq M, Nahidh M, Al-Dulaimy D. 2022. The importance of the maxillary and mandibular incisors in predicting the canines and premolars crown widths. *Int J Dent*, 2022: 1-6.
- Chaudhary S, Shah P, Paygude P, Chiwhane S, Mahajan P, Chavan P, Kasar M. 2024. Varying views of maxillary and mandibular aspects of teeth: A dataset. *Data Brief*, 56: 110772.
- Chicco D, Jurman G. 2020. The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genomics*, 21(1): 1-13.
- Chollet F. 2017. Xception: Deep learning with depthwise separable convolutions. *Proc IEEE Conf Comput Vis Pattern Recognit (CVPR)*, Honolulu, HI, USA, pp: 1251-1258.
- Corns S, Liversidge H, Fleming P. 2021. An assessment of root stage of canine and premolar teeth at alveolar eruption. *J Orthod*, 49(2): 122-128.
- Elshennawy NM, Ibrahim DM. 2020. Deep-pneumonia framework using deep learning models based on chest X-ray images. *Diagnostics (Basel)*, 10(9): 649.

- García-Gil M, Alarcón J, Cacho A, Yáñez-Vico R, Palma-Fernández J, Martín C. 2023. Association between eruption sequence of posterior teeth, dental crowding, arch dimensions, incisor inclination, and skeletal growth pattern. *Children (Basel)*, 10(4): 674.
- Gupta A, Gupta S, Katarya R. 2021. InstaCovNet-19: A deep learning classification model for the detection of COVID-19 patients using chest X-ray. *Appl Soft Comput*, 101: 107064.
- He K, Zhang X, Ren S, Sun J. 2016. Identity mappings in deep residual networks. *Proc Eur Conf Comput Vis (ECCV)*, Amsterdam, Netherlands, pp: 123-135.
- Huang G, Liu Z, Van Der Maaten L, Weinberger KQ. 2017. Densely connected convolutional networks. *Proc IEEE Conf Comput Vis Pattern Recognit (CVPR)*, Honolulu, HI, USA, pp: 4700-4708.
- Kanter R, Battistuzzi P, Truin G. 2018. Temporomandibular disorders: "Occlusion" matters! *Pain Res Manag*, 2018: 1-13.
- Khalaf K, Brook A, Smith R. 2022. Genetic, epigenetic and environmental factors influence the phenotype of tooth number, size and shape: Anterior maxillary supernumeraries and the morphology of mandibular incisors. *Genes (Basel)*, 13(12): 2232.
- Khanagar S, Al-Ehaideb A, Maganur P, Vishwanathaiah S, Patil S, Baeshen H, Bhandi S. 2021. Developments, application, and performance of artificial intelligence in dentistry – a systematic review. *J Dent Sci*, 16(1): 508-522.
- Kühnisch J, Meyer O, Hesenius M, Hickel R, Gruhn V. 2021. Caries detection on intraoral images using artificial intelligence. *J Dent Res*, 101(2): 158-165.
- Liu Z, Lin Y, Cao Y, Hu H, Wei Y, Zhang Z, Lin S, Guo B. 2022. A ConvNet for the 2020s. *Proc IEEE/CVF Conf Comput Vis Pattern Recognit (CVPR)*, New Orleans, LA, USA, pp: 11976-11986.
- Palkit T, Aggarwal I, Malhotra Y, Uppal M, Goyal M, Singh N. 2020. The relationship between maxillary and mandibular base lengths and dental crowding in patients with true class II malocclusions. *Int Healthc Res J*, 4(7): OR5-OR9.
- Rithanya M. 2023. Prevalence of dental caries in permanent second molars in teenagers using ICDAS. *J Pharm Res Int*, 35(35): 28-35.
- Sitaula C, Shahi TB. 2022. Monkeypox virus detection using pre-trained deep learning-based approaches. *J Med Syst*, 46(1): 1-9.
- Soundarya N, Jain V, Shetty S, Akshatha B. 2021. Sexual dimorphism using permanent maxillary and mandibular incisors, canines, and molars. *J Oral Maxillofac Pathol*, 25(1): 183-188.
- Szegedy C, Ioffe S, Vanhoucke V, Alemi A. 2017. Inception-v4, Inception-ResNet and the impact of residual connections on learning. *Proc AAAI Conf Artif Intell*, San Francisco, USA, pp: 4278-4284.
- Tan R, Zhu X, Chen S, Zhang J, Liu Z, Li Z, Yang L. 2024. Caries lesions diagnosis with deep convolutional neural network in intraoral qlf images by handheld device. *BMC Oral Health*, 24(1): 1-5.
- Ueno K, Kumabe S, Nakatsuka M, Tamura I. 2019. Factors influencing dental arch form. *Okajimas Folia Anat Jpn*, 96(1): 31-46.
- Vakili M, Ghamsari M, Rezaei M. 2020. Performance analysis and comparison of machine and deep learning algorithms for IoT data classification. *arXiv Preprint*, arXiv: 2001.09636.
- Wang S, Shen Y, Fuh L, Peng S, Tsai M, Huang H, Hsu J. 2020. Relationship between cortical bone thickness and cancellous bone density at dental implant sites in the jawbone. *Diagnostics (Basel)*, 10(9): 710.
- Wang Z, Hu M, Zhai G. 2018. Application of deep learning architectures for accurate and rapid detection of internal mechanical damage of blueberry using hyperspectral

- transmittance data. *Sensors (Basel)*, 18(4): 1126.
- Wimalarathna A, Thilakumara I, Jayasinghe V, Amaratunga P, Jayasinghe R. 2021. Location of vital structures and available bone for the placement of dental implants in clinically edentulous patients: A cohort study. *J Dent Implant Res*, 40(4): 151-157.
- Yotsuya M, Nakano M, Umehara K, Nomura T, Sato T. 2020. Implant and prosthetic treatment in esthetic zone with alveolar ridge preservation and autotransplantation: Clinical case report with 16-year follow-up. *Bull Tokyo Dent Coll*, 61(2): 145-150.