

# Panoramik Radyograflarda Diş Tiplerinin Sınıflandırılması için Derin Öğrenme Yöntemlerinin Karşılaştırılması

## Comparison of Deep Learning Methods for Classification of Tooth Types in Panoramic Radiographs

    
Berrin Çelik<sup>1\*</sup>, Mehmet Zahid Genç<sup>2</sup>, Mahmut Emin Çelik<sup>2,3</sup>

<sup>1</sup> Oral and Maxillofacial Radiology Department, Faculty of Dentistry, Ankara Yıldırım Beyazıt University, Ankara, Turkey

<sup>2</sup> Electrical Electronics Engineering Department, Faculty of Engineering, Gazi University, Ankara, Turkey

<sup>3</sup> Biomedical Calibration and Research Center, Gazi University Hospital, Gazi University, Ankara, Turkey

### ÖZ

Diş tipi sınıflandırması teşhis, tedavi ve planlamada rutin olarak gerçekleştirilir. Dijital diş hekimliğine doğru, zaman alan geleneksel yaklaşımlar yerine işlemlerin otomatik olarak gerçekleştirilmesi değerlidir. Bu çalışma, diş tiplerini sınıflandırmak için yeni bir derin öğrenme modeli önermektedir. Bu çalışma, diş türlerini sınıflandırmak için yeni bir model olan ZNet'i önermekte ve performansını önde gelen derin öğrenme modelleriyle karşılaştırmaktadır. Panoramik görüntülerdeki diş türleri köpek diş, kesici diş, ön azı diş ve azı diş olmak üzere 4 sınıfa ayrılmıştır. Bu çalışmada ResNet-50, VGG-19, EfficientNet, Densenet, Inception, Xception ve önerilen ZNet olmak üzere 7 farklı derin öğrenme modelinin performansı incelenmiştir. Model performansları Accuracy, Precision, Recall ve F1-score metrikleri kullanılarak değerlendirilmiştir. Önerilen model ZNet için Doğruluk, Kesinlik, Duyarlılık ve F1-skoru sırasıyla %95,79, %84,10, %94,80 ve %87,60'tır.

Önerilen model diğerlerinden daha iyi performans göstermiştir. Bulgular, derin öğrenme modellerinin diş türlerinin sınıflandırılmasında doğru tahminler sağlayan güvenilir araçlar olduğunu göstermiştir.

*Anahtar kelimeler:* diş, sınıflandırma, yapay zeka, derin öğrenme, panoramik radyografi

### ABSTRACT

Tooth type classification is routinely performed in diagnosis, treatment, and planning. Towards digital dentistry, it is valuable to perform processes automatically instead of time-consuming conventional approaches. This work suggests a novel deep learning model to classify tooth types. This study proposes a new model, ZNet, for classifying tooth types and compares its performance with the leading deep learning models. The tooth types in panoramic images are categorized into 4 classes: incisor, canine, premolar and molar. This study investigates the

performance of 7 different deep learning models, namely ResNet-50, VGG-19, EfficientNet, Densenet, Inception, Xception and the proposed ZNet. Model performances are evaluated using Accuracy, Precision, Recall and F1-score metrics. Accuracy, Precision, Recall and F1-score for the proposed model ZNet are 95.79%, 84.10%, 94.80% and 87.60% respectively. The proposed model outperformed the others. Findings showed deep learning models have been shown to be reliable tools providing accurate predictions in the classification of tooth types.

*Keywords:* teeth, classification, artificial intelligence, deep learning, panoramic radiograph

## Giriş

Diş tiplerinin belirlenmesi, günümüz diş hekimliği uygulamalarında basit ve temel bir adımdır. Diş tipleri hekimler arasında teşhis, tedavi ve ileri planlama süreçlerinde kullanılır. Diş tipi sınıflandırması, dişlerin şekil, fonksiyon ve konum gibi çeşitli özelliklerine göre kategorize edilmesi ve gruplandırılmasıdır. İnsan dişleri dört ana tipte sınıflandırılır: kesici dişler, köpek dişleri, küçük azı dişleri ve azı dişleri. Her türün kesme, yırtma, öğütme gibi belirli bir işlevi vardır. Bu diş türleri farklı şekilde konumlandırılır ve kendi özel amaçlarına hizmet etmek için farklı şekillere sahiptir.

Diş hekimliğinde yapay zeka (AI), röntgen, BT taramaları ve ağız içi görüntüler gibi tanısal görüntüleri analiz eden algoritmalar aracılığıyla manuel süreçleri otomatikleştirerek diş sorunlarını tanımlar. Ayrıca yapay zeka, hasta verilerine dayalı olarak potansiyel ağız sağlığı sorunlarının erken tespitine yardımcı olarak önleyici analitiğe katkıda bulunur ve sonuçta önleyici bakım stratejilerini optimize eder [1-3]. Benzer şekilde, tüm dişlerin tanımlanmasının geleneksel yöntemlerle manuel olarak yürütülmesi yalnızca zaman alıcı olmakla kalmaz, aynı zamanda uzman gücünün rehberliğini de etkileyebilir.


Diş hekimliğinde manuel süreçlerin otomatikleştirilmesi çeşitli avantajlar sunmaktadır: (i) otomasyonun çeşitli görevler için gereken süreyi azaltması sayesinde artan verimlilik, (ii) otomatik görevlerin manuel işlerle ilişkili işgücü maliyetlerini azaltabilmesi sayesinde maliyet tasarrufu, (iii) diş hekimleri ve personelinin diğer görevlere aşırı zaman harcamak yerine hasta bakımı ve karmaşık prosedürlere daha fazla odaklanabilmesi sayesinde artan verimlilik. Bu bağlamda, yapay zeka teknolojilerinin, özellikle de derin öğrenme alanındaki gelişmeler, diş sınıflandırma

süreçlerinin otomatikleştirilmesi ve bu alandaki verimliliğin artırılması için önemli bir fırsat sunmaktadır.

Gelişen yapay zekâ teknolojileri, çeşitli diş türlerini içeren büyük bir veri kümesi üzerinde uygulanarak sınıflandırma modellerinin gerçek dünyadaki çeşitliliğe daha etkin bir şekilde uyum sağlamasına olanak tanımıştır. Bu çalışma, diş türlerini sınıflandırmak için yeni bir derin öğrenme modeli önermektedir. Ayrıca, performanslar son teknoloji sınıflandırma modelleri ile karşılaştırılmıştır. ResNet-50, VGG-19, EfficientNet, Densenet, Inception, Xception ve Znet olmak üzere yedi farklı derin öğrenme modeli bu sınıflandırma problemini çözmek için eğitilmiştir. Bu modellerin performansı doğruluk, kesinlik, duyarlılık ve F1-skor metrikleri kullanılarak değerlendirilmiştir.

## Materyal Metot

Veri kümesi, Tufts Dental Dataset'in [4] panoramik radyografilerinden kırılmış 10.876 diş görüntüsünü içermektedir. Görüntüler köpek diş, kesici diş, ön azı diş ve azı diş olmak üzere 4 farklı diş türüne göre sınıflandırılmıştır. Sınıf dağılımları kesici diş, köpek dişi, ön azı diş ve azı diş için sırasıyla 3176, 1621, 2745 ve 3334'tür. Görüntüler bir ağız diş ve çene radyoloji (en az 7 yıllık deneyime sahip) uzmanı diş hekimi tarafından kırılmış ve kontrol edilmiştir. Şekil 1 bu kategorilere ait farklı örnekleri sırasıyla sunmaktadır. Veri kümesi eğitim için %70, doğrulama için %20 ve test için %10'a bölünmüştür. Görüntü boyutları eğitim sürecinden önce standartlaştırılmıştır.




Şekil 1. Köpek diş, kesici diş, ön azı diş ve azı diş örnekleri

Önerilen model ZNet'e ek olarak bu çalışmada uygulanan farklı derin öğrenme modelleri vardı. Bunlar

ResNet-50, VGG-19, EfficientNet, Densenet, Inception ve Xception'dır. Eğitim için transfer öğrenmesi, yani önceden eğitilmiş modeller kullanılmıştır. Modeller TensorFlow ve Pytorch gibi farklı kütüphaneler tarafından uygulanmıştır.

Sınıflandırma için yeni bir model olan ZNet, özellik çıkarma ve öğrenme için çift evrişimli bloklar, maksimum havuzlama katmanları ve Z noktası birleştirme katmanları içeriyordu. Model mimarisi Şekil 2'de sunulmuştur. Model, giriş katmanı renkli görüntüleri alacak şekilde yapılandırılmıştır. Çift Evrişimli Bloklar, iki ardışık evrişimli katman, toplu normalizasyon ve ReLU aktivasyon fonksiyonlarından oluşmuştur. Maksimum Havuzlama Katmanları, hesaplama maliyetini ve öğrenilebilir parametrelerin sayısını azaltmak için özellik haritalarının boyutunu azaltmıştır. Z noktası Birleştirme Katmanları, farklı boyutlara sahip özellik haritalarını birleştirmek için kullanılmıştır. Toplu Normalleştirme Katmanları ağırlık eğitimi hızlandırmış ve aşırı uyum riskini azaltmıştır. Sınıflandırma Katmanı özellik haritalarını düzleştirmiş ve diş tipini tahmin etmek için tam bağlı katmanlar kullanmıştır.



Şekil 2. ZNet mimarisi

Atlanan bağlantılar, U-Net mimarisinden esinlenerek düşük seviyeli özellikleri doğrudan yüksek seviyeli özelliklere ileterek performansı artırmayı amaçlamaktadır. Modelimizin düşük seviyeli özellikleri yüksek seviyeli katmanlardaki daha karmaşık özelliklere iletmesini sağladılar. Düşük seviyeli özellikler tipik olarak daha temel ve yerel bilgilere sahipken, yüksek seviyeli özellikler özet bilgileri temsil ediyordu.

Modellerin performansı doğruluk, kesinlik, duyarlılık ve F1-skoru gibi iyi bilinen sınıflandırma metrikleriyle değerlendirilmiştir. Modeller ayrıca bu metriklere göre karşılaştırılmıştır. Doğruluk, doğru tahmin edilen örneklerin toplam örneklere oranını hesaplayarak modelin genel doğruluğunu ölçer. Kesinlik, pozitif tahminlerin doğruluğuna odaklanır. Doğru tahmin edilen pozitif gözlemlerin toplam tahmin edilen pozitiflere oranını ölçer. Yüksek hassasiyet, düşük yanlış pozitif oranını gösterir. Duyarlılık, modelin tüm pozitif örnekleri yakalama yeteneğini değerlendirir. Doğru tahmin edilen pozitif gözlemlerin toplam gerçek pozitiflere oranını ölçer. Yüksek duyarlılık, düşük yanlış negatif oranını gösterir. F1 puanı, hassasiyet ve duyarlılığın harmonik ortalamasıdır. Hassasiyet ve duyarlılık arasında bir denge sağlar. Yüksek değerlerin hassasiyet ve duyarlılık arasında daha iyi bir denge olduğunu gösterdiği 0 ile 1 arasında değişir. Tablo 1 kullanılan metriklere dair formülleri göstermektedir.

Tablo 1. Sınıflandırma performansında kullanılan değerlendirme metrikleri

Değerlendirme Metrikleri	
Doğruluk	(Doğru Tahmin Sayısı) / (Toplam Tahmin Sayısı)
Hassasiyet	(Doğru Pozitifler) / (Doğru Pozitifler + Yanlış Pozitifler)

Duyarlılık	(Doğru Pozitifler) / (Doğru Pozitifler + Yanlış Negatifler)
F1-Skor	$2 * (\text{Hassasiyet} * \text{Duyarlılık}) / (\text{Hassasiyet} + \text{Duyarlılık})$

## Sonuçlar

Modeller aynı eğitim, doğrulama ve test seti kullanılarak ayrı ayrı eğitilmiştir. Model tahminleri karışıklık matrisi ile hesaplanmıştır. Tablo 2'de tüm modeller için test seti, görülmeyen veriler ile çıktı metrikleri sunulmuştur.

Tablo 2. Tüm modeller için sınıflandırma performansı

Model	Doğruluk (%)	Hassasiyet (%)	Duyarlılık (%)	F1 Skor (%)
<i>DenseNet</i>	87.25	82.20	83.30	82.60
<i>EfficientNet</i>	76.03	66.70	70.20	%68.40
<i>Inception</i>	65.14	54.70	58.10	68.40
<i>ResNet-50</i>	80.05	73.80	75.90	74.60
<i>VGG-19</i>	83.99	72.20	78.90	74.30
<i>Xception</i>	81.52	70.00	76.40	73.30
<i>ZNet</i>	95.79	84.10	94.80	87.60

Sınıflandırma doğrulukları %65,14 ile %95,79 arasında değişirken F1 skoru %68,4 ile %87,6 arasındadır. 7 modelden 5'i %80'in üzerinde sınıflandırma doğruluğu sağlamıştır. En iyi performans, diğerlerine kıyasla nispeten önemli bir farkla ZNet tarafından sağlanmıştır. Bulgular ayrıca her bir sınıf bazında analiz edilmiştir. Tablo 3, ortalama doğruluğa ek olarak her sınıf için sınıflandırma doğruluğunu göstermektedir. ZNet, %98,12 ile kesici diş sınıfı için en

yüksek doğruluğu ve %88,96 ile köpek sınıfı için en düşük doğruluğu vermiştir.

Tablo 3. Her bir kategori için sınıflandırma doğruluğu (%)

Model	Ort. Doğruluk	Köpek	Kesici	Azı Diş	Ön Azı Diş
<i>DenseNet</i>	87.25	64.42	91.22	93.43	80.80
<i>EfficientNet</i>	76.03	44.17	85.58	87.46	69.93
<i>Inception</i>	65.14	18.40	77.43	81.49	58.70
<i>ResNet-50</i>	80.05	46.01	90.28	91.64	74.28
<i>VGG-19</i>	83.99	58.28	94.36	92.54	76.81
<i>Xception</i>	81.52	50.92	88.09	89.85	81.88
<i>ZNet</i>	95.79	88.96	98.12	96.12	96.74

## Tartışma

Derin öğrenme modelleri diş hekimliğinin çeşitli alanlarında, özellikle de görüntü analizinde önemli başarılar göstermiştir. Dental radyolojide, konvolüsyonel sinir ağları (CNN'ler) çürükler de dahil olmak üzere çeşitli diş vakalarını tespit etme, sınıflandırma ve segmentlere ayırma, periodontal hastalıkları tanımlama ve hatta diş ve anatomik yapıları yardımcı olma gibi görevler için kullanılmıştır [5-7]. Ayrıca, derin öğrenme modellerinin teşhis süreçlerinin doğruluğunu artırmada etkili olduğu kanıtlanmıştır [8-12]. Bu modeller, karmaşık kalıpları ve özellikleri öğrenmek için büyük veri kümelerinden yararlanarak incelikli ve doğru tahminler yapmalarını sağlar.

Diş sınıflandırması ile ilgili yakın zamanda yapılmış birkaç çalışma bulunmaktadır. Sathya ve arkadaşları AlexNet kullanarak panoramik radyografları iki adımda sınıflandırmıştır [13]. Dişlerin konumu önce üst veya alt çene olarak sınıflandırılmış, daha sonra dişler kesici, köpek, küçük azı ve büyük azı olmak üzere dört sınıftan

herhangi birine sınıflandırılmıştır. Kesici, köpek, küçük azı ve büyük azı dişleri için sırasıyla %95, %94,5, %94 ve %97,5 olmak üzere bireysel doğruluk dahil genel doğruluk %95 olarak bulunmuştur. Krois ve arkadaşları, dişlerin dört farklı kategoride sınıflandırılması için küresel ortalama ve maksimum havuzlama tekniklerini içeren yedi katmanlı bir derin evrişimli sinir ağı (CNN) kullanılmasını önermiştir: molar, premolar, kanin ve kesici diş [14]. Ortalama %87 doğruluk oranı ile diğer üç çağdaş tekniğe göre üstün performanslar elde edilmiştir. Li ve arkadaşları CBCT görüntülerini kullanarak küresel ortalama ve maksimum havuzlama ile yedi katmanlı derin CNN uygulamıştır [15]. Dişler molar, kanin, premolar ve kesici diş olmak üzere dört sınıftan herhangi birine sınıflandırılmıştır. Ortalama hassasiyet %87,0 olarak bildirilmiştir. Estai ve arkadaşları 591 ortopantomogram (OPG) görüntüsü ile kalıcı diş sınıflandırması ve tespiti için evrişimli sinir ağları (CNN) kullanan otomatik bir sistemi değerlendirmeyi amaçlamıştır [16]. Tespit için U-Net ve Faster R-CNN kullanılırken, diş sınıflandırması için VGG-16 uygulanmıştır. Diş sınıflandırması, yani numaralandırma için duyarlılık ve kesinlik 0.98'dir. Muramatsu, otomatik diş çizelgeleri için bilgisayarlı bir sistem önermiştir [17]. Dişleri tespit etmek için 100 panoramik radyografi kullanılmış, daha sonra sınırlayıcı kutular kesici dişler, köpek dişleri, premolarlar ve molarlar dahil olmak üzere dört diş tipine sınıflandırılmıştır. Diş türleri için ortalama sınıflandırma doğruluğu %93,2 olmuştur. Tuzoff, 1352 panoramik radyografi kullanarak diş tespiti ve numaralandırma için CNN'leri kullanmıştır [18]. Diş önce Faster R-CNN tarafından tespit edilmiş, ardından her bir FDI numaralandırması için sınıflandırılmıştır. Sınıflandırma VGG-16 tarafından sezgisel algoritma ile gerçekleştirilmiştir. Duyarlılık ve özgüllüğün sırasıyla 0.98 ve 0.99 olduğu bildirilmiştir. Kilic ve arkadaşları 421 panoramik radyografi kullanarak çocuklar için otomatik tespit ve numaralandırma sistemi geliştirmeyi

amaçlamışlardır [19]. Faster R-CNN ve Inception v2 kullanılmıştır. Duyarlılık, kesinlik ve F1 skoru sırasıyla 0.98, 0.95 ve 0.96 olarak raporlanmıştır. Tablo 4 mevcut çalışmanın performansını daha önceki çalışmalarla amaç, kullanılan görüntü tipi, uygulanan yöntem ve elde edilen sonuçlar olmak üzere karşılaştırmaktadır.

Tablo 4. Daha önceki çalışmalar ile mevcut çalışmanın sonuçlarının karşılaştırılması

Ref	Amaç	Görüntü	Yöntem	Sonuçlar
13	Sınıflandırma	Panoramik	AlexNet	Ortalama doğruluk: %95
14	Sınıflandırma	Panoramik	Evrişimsel Sinir Ağı	Ortalama doğruluk: %87
15	Sınıflandırma	CBCT	Evrişimsel Sinir Ağı	Ortalama doğruluk: %87
16	Tespit	Ortopantom ogram	U-Net Faster R-CNN VGG-16	Duyarlılık: 0.98 Precision: 0.98
17	Tespit	Panoramik	Evrişimsel Sinir Ağı	Doğruluk: %93.2
18	Tespit	Panoramik	Faster R-CNN VGG-16	Duyarlılık: 0.98
19	Tespit	Panoramik	Faster R-CNN Inception v2	Duyarlılık: 0.98 Kesinlik: 0.95 F1 Skor: 0.96
Bu çalışmada	Sınıflandırma	Panoramik	DenseNet EfficientNet Inception ResNet-50 VGG-19	Ortalama doğruluk: 0.65-0.95

			Xception ZNet (önerilen)	
--	--	--	--------------------------------	--

Diş hekimliğinde derin öğrenme uygulamaları büyük bir potansiyel göstermekle birlikte çeşitli sınırlamaları da beraberinde getirmektedir. Derin öğrenme modelleri eğitim için büyük miktarlarda yüksek kaliteli dengeli veri gerektirir. Belirli veri kümeleri üzerinde eğitilen modeller yeni veya farklı popülasyonlara iyi genelleme yapamayabilir. Hasta demografisi, genetiği ve coğrafi konumlardaki farklılıklar derin öğrenme modellerinin performansını ve genelleştirilebilirliğini etkileyebilir. Bu nedenle, büyük veri kümeleri çok merkezli olmalıdır. Sağlık hizmetlerinde, gizlilik endişeleri, veri siloları ve açıklamalı veya etiketli verilere sınırlı erişim gibi sorunlar nedeniyle çeşitli ve kapsamlı veri kümeleri elde etmek zor olabilir. Hasta mahremiyetini ve güvenliğini sağlarken sağlık hizmetlerinde yapay zekayı uygulamak karmaşık olabilir ve dikkatli bir değerlendirme gerektirir. Derin öğrenme modelleri, değerlendirme metrikleri açısından literatürde genellikle standart raporlamadan yoksundur. Bir raporlama formatı üzerinde fikir birliğine varılmalıdır.

## Sonuç

Diş sınıflandırmasında derin öğrenme tekniklerinin uygulanması, diş türlerini kategorize etme sürecini otomatikleştirmede dikkate değer bir potansiyel ve etkinlik göstermiştir. Potansiyel olarak diş hekimlerine ve araştırmacılara teşhisleri, tedavi planlamasını hızlandırmak ve genel hasta bakımını iyileştirmek için değerli bir araç sunmaktadır.

## Referanslar

- [1] Mohammad-Rahimi, H, Rokhshad, R, Bencharit, S, Krois, J, & Schwendicke, F “Deep learning: a primer for dentists and dental researchers”, *J Dent* 130:104430, 2023.
- [2] Park, W, Huh, J. K, & Lee, J H, “Automated deep learning for classification of dental implant radiographs using a large multi-center dataset”, *Sci Rep* 13(1):4862, 2023
- [3] de Queiroz Tavares Borges Mesquita, G, Vieira, W A, Vidigal, M T C, Travençolo, B A N, Beaini, T L, Spin-Neto, R, ... & de Brito Júnior, R B, “Artificial Intelligence for Detecting Cephalometric Landmarks: A Systematic Review and Meta-analysis”, *J Digit Imaging* 36(3):1158-1179, 2023
- [4] Panetta, K, Rajendran, R, Ramesh, A, Rao, S P, & Agaian, S, “Tufts dental database: a multimodal panoramic x-ray dataset for benchmarking diagnostic systems”, *IEEE J Biomed Health* 26(4):1650-1659, 2021
- [5] Huang, C, Wang, J, Wang, S, & Zhang, Y, “A review of deep learning in dentistry”, *Neurocomputing* 554:126629, 2023
- [6] Çelik, B, Savaştaer, E F, Kaya, H I, & Çelik, M E, “The role of deep learning for periapical lesion detection on panoramic radiographs”, *Dentomaxillofac Rad* 52(8):20230118, 2023.
- [7] Mohammad-Rahimi, H, Motamedian, S R, Rohban, M H, Krois, J, Uribe, S E, Mahmoudinia, E, ... & Schwendicke, F, “Deep learning for caries detection: A systematic review.”, *J Dent* 122:104115, 2022.
- [8] Jung, W, Lee, K E, Suh, B J, Seok, H, & Lee, D W, “Deep learning for osteoarthritis classification in temporomandibular joint”, *Oral Dis* 29(3):1050-1059, 2023
- [9] Umer, F, Habib, S, & Adnan, N, “Application of deep learning in teeth identification tasks on panoramic radiographs”, *Dentomaxillofac Rad* 51(5):20210504, 2022.
- [10] Çelik, B, & Çelik, M E, “Automated detection of dental restorations using deep learning on panoramic radiographs”, *Dentomaxillofac Rad* 51(8):20220244, 2022.
- [11] Celik, M E, “Deep learning based detection tool for impacted mandibular third molar teeth”, *Diagnostics* 12(4):942, 2022
- [12] Çelik, B, & Çelik, M E, “Root Dilaceration Using Deep Learning: A Diagnostic Approach”, *Appl Sci-Basel* 13(14):8260, 2023
- [13] Sathya, B, & Neelaveni, R, “Transfer learning based automatic human identification using dental traits-an aid to forensic odontology”, *J Forensic Leg Med* 76:102066, 2020.
- [14] Krois, J, Garcia Cantu, A, Chaurasia, A, Patil, R, Chaudhari, P K, Gaudin, R, ... & Schwendicke, F, “Generalizability of deep learning models for dental image analysis”, *Sci Rep* 11(1):6102, 2021
- [15] Li, Z, Wang, S H, Fan, R R, Cao, G, Zhang, Y D, & Guo, T, “Teeth category classification via seven-layer deep convolutional neural network with max pooling and global average pooling”, *International Journal of Imaging Systems and Technology* 29(4):577-583, 2019
- [16] Estai, M, Tennant, M, Gebauer, D, Brostek, A, Vignarajan, J, Mehdizadeh, M, & Saha, S, “Deep learning for automated detection and numbering of permanent teeth on panoramic images”, *Dentomaxillofac Rad* 51(2):20210296, 2022
- [17] Muramatsu, C, Morishita, T, Takahashi, R, Hayashi, T, Nishiyama, W, Arijji, Y, ... & Fujita, H, “Tooth detection and classification on panoramic radiographs for automatic dental chart filing: improved classification by multi-sized input data”, *Oral Radiol* 37:13-19, 2021.
- [18] Tuzoff, D V, Tuzova, L N, Bornstein, M M, Krasnov, A S, Kharchenko, M A, Nikolenko, S I, ... & Bednenko, G B, “Tooth detection and numbering



in panoramic radiographs using convolutional neural networks”, Dentomaxillofac Rad 48(4):20180051, 2019.

- [19] Kılıc, M. C, Bayrakdar, I S, Çelik, Ö, Bilgir, E, Orhan, K, Aydın, O B, ... & Yılmaz, A B, “Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs”, Dentomaxillofac Rad 50(6):20200172, 2021.

### Özgeçmişler



**Dr. Öğr. Üyesi Berrin Çelik**, doktorasını Gazi Üniversitesi’nde Diş Hekimliği Fakültesi Ağız, Diş ve Çene Radyolojisi anabilim dalında 2019 yılında tamamlamıştır. Ankara Yıldırım Beyazıt Üniversitesi Diş Hekimliği Fakültesi’nde Dr. Öğretim Üyesi olarak görev yapmaktadır. İlgili alanları ağız, diş ve çene hastalıkları, diagnostik görüntüleme, fraktal analiz ve yapay zekâ konularını kapsamaktadır.



**Mehmet Zahid Genç**, lisans eğitimini Gazi Üniversitesi Elektrik-Elektronik Mühendisliği’nde sürdürmektedir. Lisans eğitimi süresince çeşitli proje ve endüstriyel çalışmalara katılmıştır. İlgili alanları arasında Tıpta Yapay Zekâ ve Biyomedikal Görüntü İşleme konuları bulunmaktadır.



**Dr. Öğr. Üyesi Mahmut Emin Çelik**, doktorasını 2017 yılında Gazi Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği Anabilim Dalında tamamlamıştır. Doktora sonrası çalışmalarını 2018 ve 2022 yılları arasında Paris Göz Araştırmaları Enstitüsü ve Michigan Üniversitesinde görsel algının geri kazanılması konularında yapmıştır. Çalışma alanları nöral sinyallerin uyartım ve kayıt süreçleri, hesaplamalı modelleme, yapay zekâ, artırılmış ve sanal gerçeklik uygulamaları olarak sıralanabilir.