

ResNet Tabanlı PSPNet Kullanarak Panoramik Görüntülerde Gömülü Diş Segmentasyon Analizi

Meryem DURMUŞ^{1*}, Burhan ERGEN², Adalet ÇELEBİ³, Muammer TÜRKÖĞLU⁴

¹ Uzaktan Eğitim, Uygulama ve Araştırma Merkezi, Rektörlük, Samsun Üniversitesi, Samsun, Türkiye

² Bilgisayar Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

³ Ağız, Diş ve Çene Cerrahisi Anabilim Dalı, Diş Hekimliği Fakültesi, Mersin Üniversitesi, Mersin, Türkiye

⁴ Yazılım Mühendisliği, Mühendislik Fakültesi, Samsun Üniversitesi, Samsun, Türkiye

*¹meryem.durmus@samsun.edu.tr, ²bergen@firat.edu.tr, ³adalet_celebi@hotmail.com,

⁴muammer.turkoglu@samsun.edu.tr

(Geliş/Received: 14/12/2023;

Kabul/Accepted: 13/02/2024)

Öz: Diş sağlığı, genel sağlık ve yaşam kalitesi üzerinde önemli bir etkiye sahiptir. Gömülü dişlerin segmentasyonu, diş hekimliğinde erken teşhis ve tedavi için kritik öneme sahip bir adımdır. Bu çalışmada, panoramik diş görüntülerindeki gömülü dişlerin doğru bir şekilde tanımlanması amacıyla derin öğrenme tekniklerinin kullanılması ele alınmıştır. Bu kapsamda, gömülü diş segmentasyonu için ResNet omurga ağına dayalı Piramit Sahne Ayrıştırma Ağı (PSPNet) geliştirilmiştir. Önerilen mimaride, önceden eğitilmiş ResNet omurga ağının ResNet18, ResNet34, ResNet50, ResNet101 ve ResNet152 versiyonları adapte edilmiştir. Bu çalışmada elde edilen bulgular göz önüne alındığında, diş görüntülerindeki segmentasyon ve tanıma süreçlerinde en yüksek başarıyı ResNet18 modeli ile elde edilmiştir (%92.09 F1 Skor, %93.88 Kesinlik, %90.39 Duyarlılık, %85.34 IoU Skor ve %96.89 Dice Katsayısı). Bu araştırma, panoramik diş görüntüleri üzerinde yapılan çalışmalar sonucunda, yetişkin hastalarda gömülü dişlerin başarıyla tespit edilme oranının yüksek olduğunu ortaya koymaktadır. Bu bulgular, yapay zekanın diş hekimleri için etkili bir yardımcı araç olabileceğini vurgulamakta ve sağlık sektöründeki yapay zeka gelişimine olan güveni artırmaktadır.

Anahtar kelimeler: Gömülü diş tespiti, derin öğrenme, ağız sağlığı, ResNet, PSPNet.

Impacted Tooth Segmentation Analysis in Panoramic Images Using ResNet Based PSPNet

Abstract: Dental health has a significant impact on overall health and quality of life. Segmentation of impacted teeth is a critical step for early diagnosis and treatment in dentistry. In this study, we investigate the use of deep learning techniques to accurately identify impacted teeth in panoramic dental images. In this context, a Pyramid Scene Segmentation Network (PSPNet) based on ResNet backbone network is developed for embedded tooth segmentation. In the proposed architecture, ResNet18, ResNet34, ResNet50, ResNet101 and ResNet152 versions of the pre-trained ResNet backbone network are adapted. Considering the findings obtained in this study, the ResNet18 model achieved the highest success in segmentation and recognition processes in dental images (92.09% F1 Score, 93.88% Precision, 90.39% Recall, 85.34% IoU Score and 96.89% Dice Coefficient). This research reveals that the rate of successful detection of impacted teeth in adult patients is high as a result of studies on panoramic dental images. These findings emphasize that AI can be an effective tool for dentists and increase confidence in the development of AI in the healthcare sector.

Key words: Impacted tooth detection, deep learning, oral health, ResNet, PSPNet.

1. Giriş

Diş tespiti, modern diş hekimliğinde önemli bir rol oynamakta ve sağlık sektöründe tanı yöntemlerinin gelişmesine öncülük etmektedir [1]. Geleneksel diş hekimliği uygulamalarında röntgen görüntüleme, hastaların ağız sağlığı durumunu değerlendirmede kritik bir araç olarak kabul edilmektedir. Ancak, bu görüntülerin hızlı ve doğru bir şekilde analiz edilmesi, zaman ve uzmanlık gerektiren bir süreçtir [2]. Yapay zekâ ve görüntü işleme teknolojilerinin gelişimi, diş tespiti alanında önemli ilerlemeler sağlamaktadır. Bu teknolojiler, oral röntgen görüntülerini otomatik olarak analiz ederek, diş yapılarını tespit etme ve değerlendirme yetenekleriyle diş hekimlerine önemli destek sağlamaktadır [3].

Diş tespiti, derin öğrenme modelleri ile özellikle büyük veri kümelerinin eğitilmesi sayesinde gelişmiş hassasiyet ve özgüllük sağlamaktadır. Bu teknolojiler, çeşitli diş sorunlarını tespit etme ve teşhis etme konusunda

* Sorumlu yazar: meryem.durmus@samsun.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0002-0558-2260, ² 0000-0003-3244-2615, ³ 0000-0003-2471-1942, ⁴ 0000-0002-2377-4979

yetenekli olup, diş hekimlerinin daha etkili ve hızlı kararlar almasına olanak tanınmaktadır. Bu gelişmeler, hasta bakımının iyileştirilmesi ve tedavi süreçlerinin optimize edilmesi açısından önemli bir potansiyel sunmaktadır [4]. Bu bağlamda, yapay zekâ destekli diş tespiti, diş hekimlerinin hasta odaklı bakım standartlarını yükseltmek ve sağlık endüstrisindeki dönüşümü hızlandırmak adına önemli bir potansiyele sahiptir.

Erken teşhis, tedavi başarısı ve maliyet etkinliği açısından diş problemlerinin önemli olduğu bilinmektedir. Gömülü dişler gibi anatomik bozuklukların ve diş problemlerinin tespiti, diş sağlığı açısından önem arz etmektedir. Diş sağlığı alanında, diş hekimleri geleneksel olarak diş problemlerini teşhis etmek için görsel muayene, radyografi ve diğer tanı yöntemlerine başvururlar. Ancak, bu yöntemler zaman alıcı olabilir ve öznel değerlendirmelere dayanabilir. Bu sebeple, panoramik diş görüntüleri, özellikle gömülü dişler gibi karmaşık durumların tespitinde kritik bir rol oynamaktadır. Bu geniş açılı görüntüler, detaylı bir anatomik değerlendirme sağlayarak erken teşhisi kolaylaştırabilir ve tedavi planlamasına değerli bilgiler ekleyebilir [5].

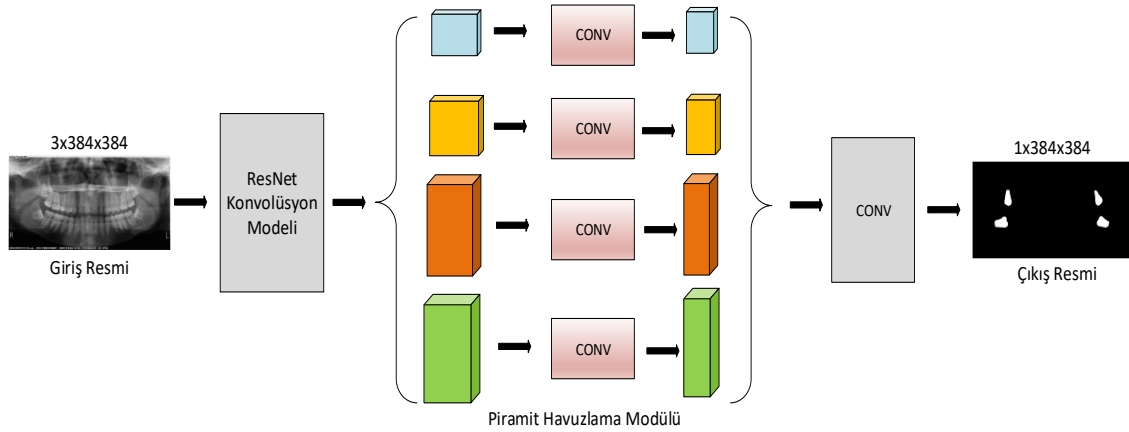
Dişin çene kemiği içinde doğru bir şekilde tespit edilmesi, tedavi planlaması ve olası komplikasyonların önlenmesi açısından önemli olduğu bilinmektedir. Derin öğrenme algoritmaları, özellikle ResNet tabanlı PSPNet gibi ağ yapıları, gömülü dişlerin hassas bir şekilde tespit edilmesini sağlayabilir ve bu da diş hekimliği pratiğinde önemli bir avantaj sağlayabilir. ResNet mimarileri, farklı derinlik seviyelerindeki öğrenme bloklarını içeren ve öğrenme sürecindeki kaybolan gradyan problemini (vanishing gradient problem) azaltan yapısıyla bilinmektedir. PSPNet ise piksel düzeyinde segmentasyon yapabilen ve çok ölçekli öznelik bilgisi kullanarak nesne sınıflandırmasını gerçekleştirebilen bir ağ yapısı olarak öne çıkmaktadır [6].

Yapay zekâ algoritmaları, diş tespiti alanında önemli bir ilerleme sağlamaktadır. Özellikle çeşitli diş hastalıklarının teşhisinde, panoramik röntgen görüntüleri üzerinde yapay zekâ destekli analizler, hastaların erken tanı almasına ve tedavi sürecini hızlandırmasına olanak sağlamaktadır. Diş hastalıklarının erken teşhisi, genel sağlık durumu ve yaşam kalitesi açısından büyük önem taşımaktadır. Mevcut literatürde, diş hastalıklarının teşhisi üzerine birçok çalışma bulunmakla birlikte, özellikle gömülü dişlerin teşhisi üzerine sınırlı sayıda araştırma yapılmıştır [7-10]. Chen ve ark., çalışmalarında TensorFlow ile Faster R-CNN kullanarak diş röntgenlerinde diş tespiti ve numaralandırma yapmışlardır. Faster R-CNN'in bu alandaki tercih edilen model olduğunu ve önerilen post-processing tekniklerinin başarıyla kullanıldığını savunmuşlardır. %90 üzerinde hassasiyet ve duyarlılık elde etmişlerdir [11]. Kuwada ve ark., panoramik görüntülerde gömülü dişleri tespit etmek için Evrişimli Sinir Ağları (CNN) uygulayarak maksiller sinüs (maxillary sinüs) lezyonları ve gömülü üçüncü azı dişlerinin ve anatomik yapılarla olan ilişkilerinin tespitinde yüksek doğruluk elde etmişlerdir. Üç farklı modelle deneyler yaparak %96 ile en yüksek doğruluğu DetectNet ile elde etmişlerdir [12]. Imak ve ark., derin evrişimli sinir ağları kullanarak panoramik diş görüntülerinde gömülü dişlerin tespiti için U-net modeli geliştirmişlerdir. Önerdikleri yöntem %99,82 doğruluk, %91,59 F1 Skor, %84,48 IoU Skor ve %90,71 oranlarında Duyarlılık değerlerini elde etmişlerdir [13].

Derin öğrenme teknikleri, diş hekimlerine diş tespiti ve gömülü dişlerin hızlı ve hassas belirlenmesinde yardımcı olurken, aynı zamanda hataların en aza indirgenmesine olanak sağlamaktadır. Derin öğrenme ile geleneksel yöntemlere kıyasla, görüntülerin derinlemesine analizi daha hızlı gerçekleştirilmektedir. Derin öğrenme teknikleri, gömülü dişler gibi karmaşık durumları daha doğru bir şekilde tanımlayabilir, böylece hekimlerin tedavi planlarını daha etkili bir şekilde geliştirmelerine yardımcı olabilmektedir. Bu çalışma, diş segmentasyonu için farklı model mimarilerinin performanslarını değerlendirmiştir. PSPNet mimarisi ve ResNet (ResNet18, ResNet34, ResNet50, ResNet101 ve ResNet152) omurga ağları, diş görüntülerindeki segmentasyon ve tanıma süreçlerindeki başarılarını değerlendirmek amacıyla kullanılmıştır.

2. Metodoloji

Bu çalışmada, gömülü diş segmentasyonu için ResNet omurga ağına dayalı Piramit Sahne Ayırıştırma Ağı (PSPNet) geliştirilmiştir. Önerilen mimarinin genel bir çerçevesi, Şekil 1'de gösterilmiştir. ResNet, derin öğrenme modelinde ağı daha derin olmasını sağlayan bir tür konvolüsyonel sinir ağıdır. Bu çalışmada, ResNet omurga ağı, diş segmentasyonu için temel bir yapı olarak kullanılmış ve PSPNet ile birleştirilerek daha hassas sonuçlar elde edilmiştir. PSPNet, derin öğrenme tabanlı bir görüntü segmentasyon yöntemidir ve genellikle karmaşık sahnelerde yüksek doğruluk sağlamak için tercih edilir. Bu çalışmada, PSPNet'in diş segmentasyonu için uyarlanmış bir versiyonu kullanılmıştır. Önerilen mimari, PSPNet'in çok katmanlı ölçekli özellik haritaları oluşturma yeteneği sayesinde, dişlerin çeşitli boyutları ve şekilleriyle başa çıkabilme yeteneğini artırmaktadır. Sonuç olarak, bu çalışma, gömülü dişlerin hassas bir şekilde tanımlanması için etkili bir derin öğrenme tabanlı yöntem olan PSPNet'in kullanımını önermektedir. Önerilen mimari, diş segmentasyonu alanında gelecekteki araştırmalara ve uygulamalara ilham verecek önemli bir adımdır.



Şekil 1. Önerilen ResNet tabanlı PSPNet mimarisi

2.1. PSPNet (Piramit Sahne Ayrıştırma Ağı)

PSPNet, ilk olarak Zhao ve ark. tarafından önerilmiştir [14]. PSPNet temel olarak, yerel özellikleri bir araya getirerek piksel düzeyinde sahne ayrıştırma için yeterli bağlamsal bilgiyi sağlamaya dayanmaktadır. PSPNet, piramit pooling modülü aracılığıyla global bağlam bilgisini içselleştiren ve sahne ayrıştırmaya odaklanan bir semantik segmentasyon modelidir. Model, global bağlam bilgisini etkili bir şekilde kullanabilmesi için piramit analiz modülünü içerir [15]. Matematiksel olarak ifade edildiğinde, Y_i çıkış, X_i giriş ve θ ise model parametrelerini temsil etmek üzere PSPNet şu formülle ifade edilebilmektedir:

$$Y_i = PSP(X_i; \theta) \quad (1)$$

Pyramid pooling, farklı bölgelerdeki bağlam bilgisini birleştirerek ayrıntılı segmentasyon görevlerinde modelin performansını artırır. Bu modül, ResNet ile entegre edildiğinde, ResNet'in özellik haritalarını piramit pooling ile zenginleştirir. PSPNet Piramit Havuzlama Modülleri sayesinde çok ölçekli özellikleri bir araya getirebilmektedir. Bu modüller, ağırlıklı olarak farklı ölçeklerde bağlamsal bilgileri yakalamasına olanak sağlayarak, özellikle değişen nesne boyutlarına sahip senaryolarda segmentasyon doğruluğunu arttırmaktadır. Ayrıntıları daha da iyileştirmek için PSPNet'te genişletilmiş evrişimli katmanlar kullanılmaktadır. Bu katmanlar, hassas dış sınırlarının belirlenmesi için çok önemli olan alt örnekleme işlemi sırasında bilgilerin korunmasına yardımcı olmaktadır [14,15].

2.2. Omurga ağı: ResNet

ResNet, derin ağlarda karşılaşılan kayıp fonksiyonlarını azaltmak ve eğitim sırasında oluşan gradient kaybını önlemek için residual blokları içeren bir omurga ağıdır. Bu residual bloklar, önceki katmanların çıktılarını doğrudan geçiren bağlantılar içerir, bu da ağı daha derin olmasına izin verir. ResNet'teki atlama bağlantıları, bilgilerin düzgün akışını kolaylaştırarak bağlamsal ayrıntıların doğru şekilde yakalanmasına yardımcı olmaktadır [16]. Y çıkış, X giriş ve W_i ise residual blok parametreleri olmak üzere ResNet şu şekilde ifade edilebilmektedir:

$$Y = F(X, \{W_i\}) + X \quad (2)$$

Önceden var olan bilgilerden yararlanmak için, ResNet omurgasının büyük veri kümeleri üzerinde eğitilmiş ağırlıklarla (ImageNet) başlatılması ile transfer öğrenimi kullanılır. Bu durum, eğitim sürecinde modelin daha hızlı yakınsamasına olanak tanımaktadır [17]. Segmentasyon aşamasında, ResNet'in farklı versiyonları (ResNet18, ResNet34, ResNet50, ResNet101 ve ResNet152) omurga ağı olarak kullanılmıştır. ResNet'in derin yapısı, hiyerarşik özelliklerin çıkarılmasını sağlayarak ağırlıklı olarak dış segmentasyonu ilgili karmaşık modelleri öğrenmesine olanak sağlamaktadır. Bu özellik ile gömülü dış tespiti gibi dental görüntüleme uygulamalarında daha hassas sonuçlar elde edilerek ResNet omurgasının detaylı görüntü bilgisini daha etkin bir şekilde öğrenmesine ve analiz etmesine olanak tanımaktadır. Bu nedenle, ResNet'in transfer öğrenimi ve derin yapısal özellikleri, dental görüntüleme alanında çeşitli uygulamalarda kullanılabilecek güçlü bir araç haline gelmektedir.

3. Deneysel Sonuçlar

3.1. Değerlendirme metrikleri

Performans ölçümleri, özellikle yapay zekâ ve görüntü işleme alanlarında, derin öğrenme modellerinin başarısını değerlendirmek için segmentasyon sorunlarına odaklanır. Bu ölçümler, modelin nesne sınırlarını doğru bir şekilde belirleme, bölümlendirme görevlerinde karmaşık ayrıntıları yakalama ve bölümlere ayrılmış bölgelerdeki performansını değerlendirmek için kullanılır [18]. Bu çalışmada önerilen modelin performansının hesaplanması ve karşılaştırılması için IoU Skor (Intersection Over Union), Dice Katsayısı (Dice Coefficient), Kesinlik (Precision), Duyarlılık (Recall) ve F1 Skor gibi performans metrikleri kullanılmıştır. Bu metrikler, Denklem 3-7’de verilmiştir.

$$\text{IoU Skoru} = \frac{DP}{DP + YP + YN} \quad (3)$$

$$\text{Dice Katsayısı} = \frac{2 * DP}{2 * DP + YP + YN} \quad (4)$$

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (5)$$

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (6)$$

$$\text{F1 Skor} = 2 * \frac{\text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (7)$$

Denklem 3-7’de verilen DP, DN, YP ve YN terimleri sırasıyla, doğru pozitif (true positive), doğru negatif (true negative), yanlış pozitif (false positive) ve yanlış negatif (false negative) olarak ifade edilmektedir. Bu çalışmada elde edilen sonuçlarda IoU Skor dikkate alınarak karşılaştırmalar yapılmıştır. Bu metrik, sınıflar veya örnekler geneline tahmin edilen ve temel doğruluk maskelerinin kesişimi ve birleşimi arasındaki ortalama oranı hesaplar. Tahmin edilen ve gerçek bölgeler arasındaki örtüşmeyi ölçer [18,19].

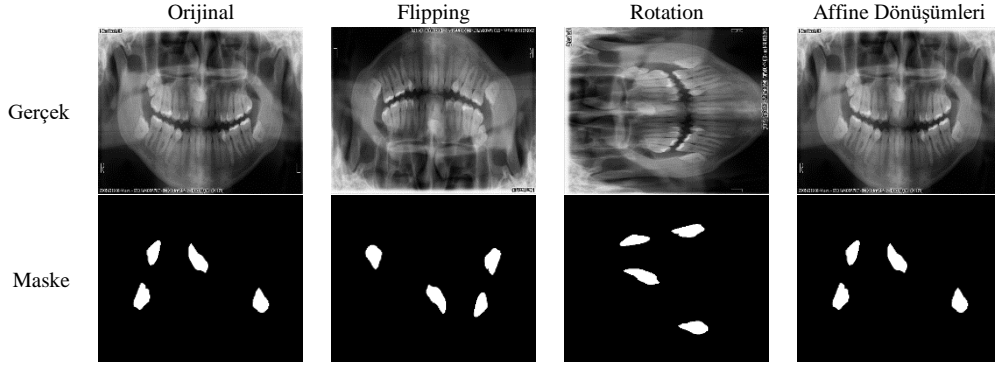
3.2. Veri kümesi

Bu çalışma, iki farklı panoramik dış görüntüsü veri kümesini kullanmaktadır. Her iki veri kümesinin kullanımıyla ilgili detaylı bilgiler Tablo 1’de sunulmuştur. Yüksek çözünürlüğe ve gömülü dışlara sahip görüntüler titizlikle seçilmiş ve birleştirilerek çalışmanın temel veri kümesi oluşturulmuştur. İlk veri kümesi, 598 panoramik görüntüden oluşmaktadır ve bu setten 53 görüntü seçilmiştir [20]. İkinci veri kümesi ise literatürde yaygın olarak kullanılan 116 panoramik görüntüye sahiptir ve bu setten 50 görüntü seçilmiştir [21]. Toplamda 103 adet yüksek çözünürlüklü görüntüden oluşan veri kümesi, uzman bir dış hekim tarafından dikkatlice etiketlenmiştir. Bu süreç, görüntülerin analizini ve sonuçların güvenilirliğini sağlamıştır.

Tablo 1. Kullanılan veri kümeleri

Kaynak	Veri Sayısı	Veri Türü	Kullanılan Veri Sayısı
[20]	598 adet	2041x1024, jpg	53 adet
[21]	116 adet	3100x1300, png	50 adet

Derin öğrenme, sinir ağlarını kullanarak verilerden karmaşık kalıpları öğrenmeye odaklanan makine öğreniminin bir alt dalıdır. Model performansını etkileyen önemli faktörlerden biri, eğitim verilerinin miktarı ve çeşitliliğidir. Veri artırma, mevcut verilere çeşitli dönüşümler uygulayarak yeni eğitim örnekleri oluşturur ve modelin sağlamlığı ile genelleme yeteneğini artırır. Özellikle sınırlı sayıda etiketlenmiş veri örneğiyle çalışıldığında, veri artırma modelin öğrenme performansını artırır ve aşırı uyum riskini azaltır. Bu çalışmada, eğitim veri setini genişletmek için çevirme (flipping), döndürme (rotation) ve affine dönüşümler gibi veri artırma teknikleri kullanılmıştır. Bu tekniklere ilişkin örnek görüntüler Şekil 2’de gösterilmektedir.



Şekil 2. Veri artırma tekniklerinin örnek gösterimleri

3.3. Sayısal ve görsel sonuçlar

Bu çalışmada, gömülü diş tespiti için ResNet tabanlı PSPNet mimarisi geliştirilmiştir. Deneysel çalışmalar, Python programlama dili kullanılarak Google Colab platformunda gerçekleştirilmiştir. Önerilen modelin eğitim parametreleri manuel olarak belirlenmiş ve Tablo 2’de sunulmuştur.

Tablo 2. PSPNet mimarisine ait parametreler

Parametre	Değer
Epoch Sayısı	150
Batch-Size	4
Optimizasyon	ADAM
Piramit Seviyesi	4
Aktivasyon	PReLU


Tüm deneysel çalışmalarda, Tablo 2’de verilen derin parametreler kullanılmıştır. Ayrıca, deneysel çalışmalarda, eğitim, doğrulama ve test setleri yalnızca bir kez gerçekleştirmek üzere sırasıyla %80, %10 ve %10 olarak rastgele bölünmüştür. Tüm uygulamalar için aynı test ve eğitim veri seti kullanılarak, gelişigüzel bölünmüş verilerin performans üzerindeki etkileri en aza indirilmiştir. Bu kapsamda, omurga ağı olarak kullanılan ResNet versiyonlara dayalı PSPNet modellerinden elde edilen performans sonuçları Tablo 3’te verilmiştir.

Tablo 3. PSPNet mimarisine ait başarımları

Model	F1 Skor	Kesinlik	Duyarlılık	Dice Katsayısı	IoU Skor
PSPNet+ResNet18	0.92090	0.93882	0.90392	0.96896	0.85340
PSPNet+ResNet34	0.87608	0.92868	0.83094	0.90177	0.78002
PSPNet+ResNet50	0.90391	0.95904	0.85483	0.89078	0.82469
PSPNet+ResNet101	0.90032	0.93273	0.87041	0.88464	0.81926
PSPNet+ResNet152	0.89334	0.92651	0.86258	0.88676	0.80791

Tablo 3’teki sonuçlara göre, ResNet ağlarının farklı versiyonlarından en yüksek performansı, %92.09 F1 skor, %93.88 kesinlik, %90.39 duyarlılık, %85.34 IoU Skor ve %96.89 Dice katsayısı ile ResNet18 modelinin gösterdiği gözlemlenmiştir. Ayrıca, ResNet50, ResNet101 ve ResNet152 modelleri yaklaşık olarak %80-82 ortalama IoU Skoru üretirken, ResNet34 modeli %78 ortalama IoU Skoru ile en düşük performansı sergilemiştir.

Tablo 3'te sunulan sayısal sonuçlara ek olarak, Şekil 3'te yer alan görsel sonuçlar bulunmaktadır. Görsellerin ilk sütununda orijinal görüntüler yer alırken, ikinci sütunda ise maskeler bulunmaktadır. Sonraki sütunlarda ise her bir omurga ağının uygulandığı modellerin segmentasyon sonuçları görüntülenmektedir.



Şekil 3. Önerilen mimarinin görsel sonuçları

Şekil 3'teki görsel sonuçlara göre, genellikle ResNet modelleri gömülü dişlerin konumunu doğru bir şekilde tespit etmiştir. Ancak, bazı örneklerde (örnek 3 ve 5), ResNet34 modeli eksik gömülü dişleri tespit etmede başarısız olmuştur. Bu, modelin belirli koşullarda daha düşük doğruluk oranlarına sahip olabileceğini göstermektedir. Ayrıca, ResNet50, ResNet101 ve ResNet152 modelleri örnek 8'de gömülü olmayan bir diş yanlışlıkla gömülü olarak tespit etmiştir. Bu bulgular, ResNet modellerinin performansının değerlendirilmesi sırasında dikkate

alınması gereken önemli hususlardır. Sonuç olarak, ResNet18 modelinin diğer tüm modellere göre daha iyi görsel sonuçlar sunduğu açıkça görülmektedir.

4. Sonuçlar

Derin öğrenme tekniklerinin diş segmentasyonunda başarılı uygulanması, ağız sağlığı alanında önemli bir ilerleme sağlamaktadır. Bu teknikler, diş hekimlerine teşhis ve tedavi süreçlerinde önemli bir destek sunarak, hastaların tedavi deneyimini iyileştirmekte ve ağız sağlığına olumlu katkılar sağlamaktadır. Bu çalışmanın sonuçları, derin öğrenme tekniklerinin diş segmentasyonunda etkili bir şekilde kullanılabilirliğini ve doğru teşhis ile tedavi yöntemlerine katkı sağlayabileceğini göstermektedir. Derin öğrenme algoritmalarının kullanımı, diş hekimlerinin iş yükünü azaltmakta ve ayrıca zaman tasarrufu sağlamaktadır. Bu tekniklerin kullanımıyla birlikte, diş hekimleri hastaların teşhis ve tedavilerini daha hassas bir şekilde gerçekleştirebilirken, aynı zamanda diş sağlığı sorunlarının erken teşhisine olanak tanımaktadır. Bu durum, tedavi süreçlerinin iyileştirilmesinin yanı sıra hastaların ağız sağlığı ile ilgili yaşam kalitesini artırıcı bir etki yaratmaktadır. Derin öğrenme tekniklerinin diş segmentasyonunda kullanımı, dental alandaki uygulamaları daha etkili hale getirerek, genel olarak ağız sağlığının iyileştirilmesine katkıda bulunmaktadır.

Gelecek çalışmalarda, derin öğrenme tekniklerinin diş segmentasyonunda kullanımının daha geniş bir yelpazede incelenmesi ve farklı diş yapılarıyla daha kapsamlı test edilmesi planlanmaktadır. Ayrıca, bu tekniklerin klinik uygulamalarda gerçek zamanlı olarak nasıl entegre edilebileceği ve klinik sonuçlara nasıl etki edebileceği üzerine daha fazla araştırma gerçekleştirilecektir.

Kaynaklar

- [1] Özkesici MY, Yılmaz S. Oral ve maksillofasiyal radyolojide yapay zekâ. Sağlık Bilimleri Dergisi. 2021; 30(3): 346-351.
- [2] Martins MV, Baptista L, Luís H, Assunção V, Araújo MR, Realinho V. Machine learning in x-ray diagnosis for oral health. A Review of Recent Progress, Computation, 2023; 11(6): 115.
- [3] Chen YW, Stanley K, Att W. Artificial intelligence in dentistry: current applications and future perspectives. Quintessence Int, 2020; 51(3): 248-257.
- [4] Durmuş M, Ergen B, Çelebi A, Türkoğlu M. Panoramik diş görüntülerinde derin evrimsel sinir ağına dayalı gömülü diş tespiti ve segmentasyonu. Çukurova Üniversitesi Mühendislik Fakültesi Dergisi, 2023; 38(3): 713-724.
- [5] Kweon HHI, Lee JH, Youk TM, Lee BA, Kim YT. Panoramic radiography can be an effective diagnostic tool adjunctive to oral examinations in the national health checkup program. Journal of periodontal & implant science, 2018. 48(5): 317-325.
- [6] Schneider L, Arsiwala-Scheppach L, Krois J, Meyer-Lückel H, Bressen KK, Niehues SM, Schwendicke F. Benchmarking deep learning models for tooth structure segmentation. Journal of dental research, 2022; 101(11): 1343-1349.
- [7] Zhu J, Chen Z, Zhao J, Yu Y, Li X, Shi K, Zhang F, Yu F, Shi K, Sun Z, Lin N, Zheng, Y. Artificial intelligence in the diagnosis of dental diseases on panoramic radiographs: a preliminary study. BMC Oral Health, 2023; 23(1): 358.
- [8] Lee S, Oh SI, Jo J, Kang S, Shin Y, Park JW. Deep learning for early dental caries detection in bitewing radiographs. Scientific reports, 2021; 11(1): 16807.
- [9] Zadrożny Ł, Regulski P, Brus-Sawczuk K, Czajkowska M, Parkanyi L, Ganz S, Mijiritsky E. Artificial intelligence application in assessment of panoramic radiographs. Diagnostics, 2022; 12(1): 224.
- [10] Musri N, Christie B, Ichwan SJA, Cahyanto A. Deep learning convolutional neural network algorithms for the early detection and diagnosis of dental caries on periapical radiographs: A systematic review. Imaging science in dentistry, 2021; 51(3): 237.
- [11] Chen H, Zhang K, Lyu P, Li H, Zhang L, Wu J, Lee CH. A deep learning approach to automatic teeth detection and numbering based on object detection in dental periapical films. Scientific reports, 2019; 9(1): 3840.
- [12] Kuwada C, Ariji Y, Fukuda M, Kise Y, Fujita H, Katsumata A, Ariji E. Deep learning systems for detecting and classifying the presence of impacted supernumerary teeth in the maxillary incisor region on panoramic radiographs. Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology, 2020; 130(4): 464-469.
- [13] Imak A, Çelebi A, Polat O, Türkoğlu M, Şengür A. ResMIBCU-Net: an encoder-decoder network with residual blocks, modified inverted residual block, and bi-directional ConvLSTM for impacted tooth segmentation in panoramic X-ray images. Oral Radiology, 2023; 1-15.
- [14] Zhao H, Shi J, Qi X, Wang X, Jia J. Pyramid scene parsing network. Proceedings of the IEEE conference on computer vision and pattern recognition, 2017; 2881-2890.
- [15] Yang C, Guo H. A method of image semantic segmentation based on pspnet. Mathematical Problems in Engineering, 2022.
- [16] Hossain MB, Iqbal SHS, Islam MM, Akhtar MN, Sarker, IH. Transfer learning with fine-tuned deep CNN ResNet50 model for classifying COVID-19 from chest X-ray images. Informatics in Medicine Unlocked, 2022; 30: 100916.

- [17] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. Proceedings of the IEEE conference on computer vision and pattern recognition, 2016; 770-778.
- [18] Haque IRI, Neubert J. Deep learning approaches to biomedical image segmentation. Informatics in Medicine Unlocked, 2020; 18: 100297.
- [19] Ahmed I, Ahmad M, Khan FA, Asif M. Comparison of deep-learning-based segmentation models: Using top view person images. IEEE Access, 2020; 8: 136361-136373.
- [20] Román JCM, Fretes VR, Adorno CG, Silva RG, Noguera JLV, Legal-Ayala H, Román JDM, Torres RDE, Facon J. Panoramic dental radiography image enhancement using multiscale mathematical morphology. Sensors, 2021; 21(9): 3110.
- [21] Abdi AH, Kasaei S, Mehdizadeh M. Automatic segmentation of mandible in panoramic x-ray. Journal of Medical Imaging, 2015; 2(4): 044003-044003.