

Panoramik Diş Görüntülerinde Derin Evrişimsel Sinir Ağına Dayalı Gömülü Diş Tespiti ve Segmentasyonu

Meryem DURMUŞ*¹ ORCID 0000-0002-0558-2260

Burhan ERGEN² ORCID 0000-0003-3244-2615

Adalet ÇELEBİ³ ORCID 0000-0003-2471-1942

Muammer TÜRKÖĞLU⁴ ORCID 0000-0002-2377-4979

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

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

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

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

Geliş tarihi: 06.06.2023

Kabul tarihi: 29.09.2023

Atıf şekli/ How to cite: DURMUŞ, M., ERGEN, B., ÇELEBİ, A., TÜRKÖĞLU, M., (2023). Panoramik Diş Görüntülerinde Derin Evrişimsel Sinir Ağına Dayalı Gömülü Diş Tespiti ve Segmentasyonu. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 38(3), 713-724.

Öz

Gömülü diş tespiti, diş hekimliği uygulamalarında önemli bir adımdır ve doğru bir tespit süreci, tedavi planlaması ve teşhislerde büyük önem taşır. Geleneksel yöntemlerin sınırlamaları ve hata olasılıkları göz önüne alındığında, derin öğrenme modelleri gibi yapay zekâ temelli yaklaşımların kullanılması giderek daha yaygın hale gelmektedir. Bu çalışmada panoramik gömülü diş görüntülerinde derin öğrenme modellerinin performansı incelenmiştir Yedi farklı modelin (VGG16-Unet, VGG19-Unet, MobileNetV2, Unet-v1, Unet-v2, Unet-v3 ve Unet-v4) performansı değerlendirilmiştir. VGG16-Unet modelinin AUC (eğri altındaki alan) değeri %94.87 ile diğer modellere kıyasla daha yüksek bulunmuştur. Bu çalışma, diş hekimliği alanında daha doğru ve hassas segmentasyon yöntemleri geliştirilmesine katkı sağlayarak, diş tespiti ve tedavi planlaması süreçlerinde daha güvenilir sonuçlar elde edilmesini desteklemektedir.

Anahtar Kelimeler: Unet, Derin öğrenme, Gömülü diş, Panoramik diş görüntüleri

Impacted Tooth Detection and Segmentation Based on Deep Convolutional Neural Network in Panoramic Dental Images

Abstract

Impacted tooth detection is an important step in dental practice and an accurate fixation process is of great importance in treatment planning and diagnosis. Considering the limitations and error probabilities of traditional methods, the utilization of artificial intelligence-based approaches like deep learning models is becoming more common. In this study, the performance of deep learning models was evaluated for the

*Sorumlu yazar (Corresponding Author): Meryem DURMUŞ, meryem.durmus@samsun.edu.tr

detection and segmentation of impacted teeth in panoramic dental images. The performance of seven different models (VGG16-Unet, VGG19-Unet, MobileNetV2, Unet-v1, Unet-v2, Unet-v3 and Unet-v4) was evaluated. The AUC (area under the curve) value of the VGG16-Unet model was found to be higher with 94.87% compared to the other models. This study contributes to the advancement of more accurate and sensitive segmentation methods in the field of dentistry and supports more reliable results in tooth detection and treatment planning processes.

Keywords: Unet, Deep learning, Impacted tooth, Panoramic dental images

1. GİRİŞ

Günümüzde, yapay zekâ teknolojileri ve özellikle derin öğrenme yöntemleri, tıbbi görüntüleme, teşhis ve tedavi konularında önemli gelişmeler sağlamaktadır [1]. Bu teknolojiler, diş hekimliği gibi biyomedikal alanlarda da giderek yaygınlaşmaktadır.

Gömülü dişler, diş hekimliği pratiğinde sık karşılaşılan ve tedavi gerektiren önemli bir sorundur. Gömülü dişler, çene kemiği altında normal olarak yer alması gereken dişlerdir, ancak doğru bir şekilde gelişemez veya çene kemiği altında sıkışır. Bu durum, estetik, ağız sağlığı ve çene yapısı açısından ciddi sorunlara yol açabilir. Gömülü dişlerin doğru bir şekilde teşhis edilmesi ve tedavi edilmesi, hasta bakımı açısından büyük önem taşımaktadır [2].

Gömülü dişlerin teşhisinde ve tedavisinde dijital görüntüleme ve görüntü işleme teknikleri önemli bir rol oynamaktadır. Dijital görüntüleme yöntemleri, diş hekimlerine daha detaylı ve net bir şekilde görüntüleme yapma imkânı sağlar [3]. Bu görüntüler gömülü dişlerin konumunu, büyüklüğünü, çevresindeki dokuları ve komplikasyonları daha iyi değerlendirmek için kullanılabilir [2].

Önceki çalışmalar, diş segmentasyonu konusunda çeşitli yaklaşımlar sunmuştur. Bazı çalışmalar, geleneksel görüntü işleme yöntemleri kullanarak diş bölgelerini sınıflandırmaya çalışmıştır. Ancak bu yöntemler, genellikle karmaşık diş yapısı ve çeşitli görüntüleme koşulları nedeniyle istikrarlı sonuçlar elde etmekte zorlanmaktadır. Son zamanlarda, derin öğrenme tekniklerinin

gelişimiyle birlikte, evrimsel sinir ağları (Convolutional Neural Networks, CNN) tabanlı modeller diş segmentasyonunda başarıyla uygulanmıştır [4].

Bu çalışmada, VGG16-Unet, VGG19-Unet, MobileNetV2 ve 4 farklı katman derinliğine sahip Unet mimarisi olmak üzere yedi farklı model mimarisinin diş segmentasyonu üzerindeki etkinliği karşılaştırılmıştır. VGG16 ve VGG19, derin ve karmaşık bir yapıya sahip olan geleneksel CNN mimarileridir. MobileNetV2 ise hafif ve hızlı hesaplama özellikleriyle bilinen mobil tabanlı CNN mimarisidir. Unet ise özgün bir mimariye sahip olan ve hem kodlama hem de çözümleme aşamalarında simetrik bağlantılar kullanarak yüksek kalitede segmentasyon sonuçları üretebilen bir modeldir.

Bu çalışmanın önemi, gömülü dişlerin teşhis ve tedavisinde doğruluk, hassasiyet ve verimlilik sağlayabilen bir yöntem sunmaktır. Bu makalenin amacı, gömülü diş segmentasyonu alanında farklı model mimarilerini kıyaslayarak en iyi performans gösteren modeli belirlemektir. Diş segmentasyonu, diş görüntülerinin çene ve diş yapılarının doğru bir şekilde tanımlanması ve ayrıştırılması sürecidir. Bu alanda, doğru ve hassas bir segmentasyonun başarısı, diş hekimliği uygulamalarında teşhis ve tedavi planlamasının doğruluğunu artırabilir.

Önceki çalışmalara kıyasla bu araştırma, farklı iki gömülü diş veri kümesi üzerinde gerçekleştirilmiştir. Bu çalışmada kullanılan veri kümesi 273 adet panoramik diş görüntülerinden oluşmaktadır. Her bir görüntü, ayrıntılı diş bölgelerine sahip çeşitli diş yapısını temsil etmektedir. Eğitim sürecinde, her model ayrı ayrı eğitilmiş ve performansı değerlendirilmiştir.

Bu makalenin geri kalan kısmında, literatür taraması, metodoloji, deneyler ve sonuçlar, tartışma, sonuç ve gelecek çalışmalar bölümleri yer alacaktır. Metodoloji bölümünde, kullanılan veri kümesi, model mimarileri ve eğitim süreçleri detaylı bir şekilde açıklanmıştır.

2. LİTERATÜR TARAMASI

Huang ve arkadaşları, Unet mimarisi kullanarak diş veri kümesi üzerinde enfeksiyon tespiti yapmışlardır. Diş çürüklerinin derin öğrenme teknikleri kullanarak otomatik olarak teşhis edilmesi üzerine, farklı teknikler ile karşılaştırma yapmışlardır. %94.3 başarımla diğer tekniklere göre daha yüksek bir doğruluk oranı göstermişlerdir [5].

Elboroloy, 2414 panoramik radyografi görüntüsü kullanılarak mandibular üçüncü azı dişinin çıkarılma zorluğunu tahmin etmek amacıyla önceden eğitilmiş üç model uygulamıştır. VGG-16, VGG-19, MobileNetV2 ve ResNet50 gibi dört farklı modelin performansı değerlendirilmiş ve sonuçlar VGG-19 modelinin mandibular üçüncü azı dişinin çıkarılma zorluğunu %82 doğruluk ile tahmin ettiğini göstermiştir. Diğer modellerin doğruluk oranları ise sırasıyla %81, %79 ve %44 olarak verilmiştir [6].

Krois ve arkadaşları, dental panoramik radyografi görüntülerinde diş sınıflandırması için derin öğrenme modellerinin doğruluğunu etkileyen görüntü bağlamını değerlendirmişlerdir. Elde edilen sonuçlar, diş segmentlerinin boyutunun artmasıyla sınıflandırma doğruluğunun önemli ölçüde arttığını göstermiştir. F1 puanları, en küçük segment boyutunda %0.77 iken, en büyük segment boyutunda %0.93'e yükselmiştir ($p = 0.0083$; Mann-Kendall testi). Bu çalışma, dental radyografi görüntülerinde diş sınıflandırmasında bağlam bilgisinin kritik bir rol oynadığını vurgulamıştır [7].

Chen ve arkadaşları tarafından yapılan çalışmada, dental periapikal filmlerde diş tespiti ve numaralandırma için TensorFlow'un Faster R-CNN

yöntemi kullanılmıştır. Önerilen yöntem örtüşen kutuların filtrelenmesi, eksik dişlerin tespiti ve kurallara uygun sonuç düzenlemesi gibi üç aşamadan oluşmaktadır. Elde edilen sonuçlar, %90 üzerinde hassasiyet ve hatırlama değerleri ile yapay zekânın dental görüntüleme alanında etkili bir araç olduğunu göstermektedir. Bununla birlikte, mevcut literatürdeki metodolojik kısıtlamaların daha fazla araştırma gerektirdiği vurgulanmaktadır.

Tuzoff ve arkadaşları tarafından yapılan çalışmada, dental radyografinin analizi için CNN tabanlı bir yöntem önerilmiştir. Çalışmalarında, 1352 panoramik radyoloji görüntülerinden oluşan bir veri kümesi kullanılarak sistemin eğitimi gerçekleştirilmiş ve elde edilen sonuçlar, alanında uzman görüşüne yakın bir performans sergilediğini göstermiştir. Bu bulgular, dental radyografi analizinin pratik uygulama ve ileri değerlendirme potansiyeline sahip olduğunu vurgulamaktadır [8].

Hiraiwa ve arkadaşları tarafından yürütülen bu çalışmada, mandibular birinci azı dişinin distal köklerinin morfolojik sınıflandırması için derin öğrenme sisteminin tanısal performansına detaylı bir inceleme gerçekleştirilmiştir. Çalışma, CBCT (cone beam bilgisayarlı tomografi) görüntüleri ve panoramik radyografinin analiziyle gerçekleştirilmiş ve elde edilen sonuçlar, distal köklerin %21.4'ünde ek bir kök bulunduğunu göstermiştir. Derin öğrenme sistemi ise distal köklerin tek veya ek köklü olup olmadığını %86.9 doğruluk oranıyla tespit edebilme yeteneği göstermiştir. Bu bulguların mandibular birinci azı dişinin kök morfolojisinin ayırıcı tanısında derin öğrenme yönteminin potansiyelini ortaya koyduğunu vurgulamışlardır [9].

3. METODOLOJİ

Bu çalışmada, iki farklı veri kümesinden yüksek çözünürlüğe sahip diş görüntüleri uzman hekim tarafından seçildi ve bu iki veri kümesinin birleştirilmesiyle çalışmanın veri kümesi oluşturuldu. Oluşturulan yeni veri kümesi, yüksek kalitede panoramik gömülü diş görüntülerini

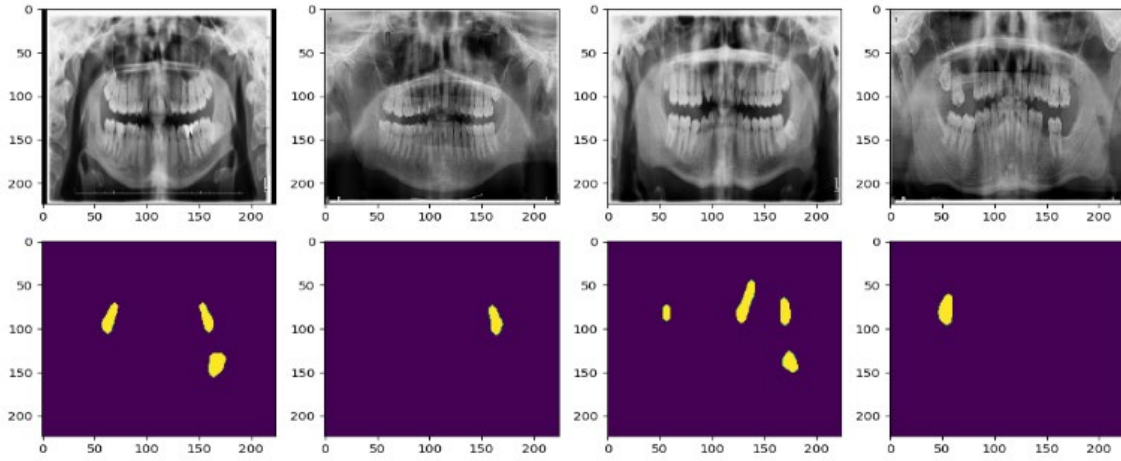
içermektedir. Bu yöntemle, çalışmanın sonuçlarının daha genel geçerlilik kazanması hedeflenmiştir.

Çizelge 1. Kullanılan veri kümeleri

Kaynak	Veri Sayısı	Veri Türü	Kullanılan Veri Sayısı
[10]	304 adet	540x380, png	150
[11]	598 adet	2041x1024, jpeg	123

Çizelge 1'de her iki veri kümesinin kullanımıyla ilgili detaylı bilgiler yer almaktadır. İlk veri

kümesinden 150 adet yüksek çözünürlüğe sahip veriler seçilerek daha spesifik bir diş popülasyonunu temsil etmesi sağlanmıştır [10]. Literatürde yaygın olarak kullanılan ikinci veri kümesinden ise 123 adet yüksek çözünürlüğe sahip veriler seçilmiştir [11]. İkinci veri kümesi, geniş bir diş popülasyonunu kapsayan yüksek kalitede görüntüler içermektedir. Bu çalışma için toplamda 273 adet yüksek çözünürlüğe sahip verilerden oluşan bir veri kümesi oluşturulmuş, diş segmentasyonu üzerinde daha özelleşmiş sonuçlar elde etmek amacıyla kullanılmıştır.



Şekil 1. Oluşturulan veri kümesinden örnek görüntüler

Şekil 1'de sunulan örnek veri kümesi görüntüleri, iki veri kümesinin birleştirilmesiyle oluşturulmuştur. Bu veri kümesi, farklı model ve yöntemlerin performansını karşılaştırmak amacıyla kullanılmıştır. Çalışmanın sonuçları, genel bir diş popülasyonu için geçerliliği sağlamakla birlikte daha spesifik bir diş alt grubu üzerindeki etkisini de değerlendirmek amacıyla analiz edilmiştir.

Bu veri kümesi, çalışmanın güvenilir sonuçlara ve karşılaştırmaların yapılmasına olanak sağlamıştır. Veri kümelerinin birleştirilmesi, çalışmanın daha kapsamlı bir temele dayandırılmasını sağlamış ve sonuçların daha genel geçerlilik kazanmasına yardımcı olacağı düşünülmektedir.


3.2. Model Mimarileri

Bu çalışmanın temelini oluşturan model mimarileri, VGG16-Unet, VGG19-Unet, MobileNetV2 ve

Unet (4 farklı katman derinliğine sahip) gibi yedi farklı derin sinir ağı modelini içermektedir. Bu modeller, görüntü sınıflandırma, nesne tanıma, hafif ve biyomedikal görüntü segmentasyonu gibi çeşitli görevlerde başarıyla kullanılmaktadır. Kapsamlı çalışmalarla gerçekleştirilen bu model mimarileri, derin öğrenme alanında öncü ve etkili çözümler sunmaktadır.

3.2.1. Unet

Biçimlendirilmiş veri segmentasyonunda yaygın olarak kullanılan bir derin öğrenme modelidir [12]. Bu mimari, evrişimsel sinir ağlarının hem yerel hem de global bağlantılarından faydalanır. Temel olarak, birçok evrişimsel katmandan oluşur ve birbirine geçişler sağlayan enkoder ve dekoder bölümlerinden oluşan bir yapıya sahiptir. Şekil 2'de Unet ağ mimarisi gösterilmektedir.



Şekil 2. Unet ağı mimarisi

Enkoder bölümü, hiyerarşik özelliklerin çıkarılması için evrişimsel ve örnekleme katmanlarından oluşur. Bu katmanlar, ölçek uzayında bir azalma sağlar ve daha yüksek seviyede soyutlanmış özelliklerin oluşmasını sağlar. Dekoder bölümü, enkoderin çıkışını alır ve görüntünün orjinal boyutuna geri dönmesini sağlar. Bu bölümde, evrişim geriye yayılımı, tersine örnekleme (upsampling) katmanları ve evrişimsel katmanlar bir arada kullanılır. Bu sayede, segmentasyon haritaları oluşturulur. Bu kapsamda bu çalışmada önceden eğitilmiş evrişimsel sinir ağı mimarilerine dayalı Unet modelleri kullanılmıştır.

Bu çalışmada, her biri farklı katman derinlikleri ve filtre sayılarına sahip 4 farklı Unet modeli uygulanmıştır. Bu modeller sırasıyla Unet-v1,

Unet-v2, Unet-v3 ve Unet-v4 olarak adlandırılmıştır. Bu çalışmada kullanılan Unet modellerinin ayrıntılı yapı ve özellikleri Çizelge 2’de sunulmuştur. Çizelgedeki bilgiler, her bir modelin katman derinliklerini ve filtre sayılarını göstermektedir. Katman derinliği, Unet mimarisindeki enkoder ve dekoder bölümlerindeki konvolüsyonel ve örnekleme katmanlarının sayısını ifade eder. Farklı katman derinlikleri, Unet modellerinin farklı özellik çıkarma yeteneklerine sahip olmasını sağlar. Aynı şekilde, filtre sayıları da Unet modellerinin öğrenme kapasitesini belirleyen önemli bir faktördür. Filtre sayısı, her bir katmandaki konvolüsyonel filtrelerinin sayısını ifade eder. Daha yüksek filtre sayıları, daha fazla özellik haritalarının üretilmesini ve daha karmaşık özelliklerin öğrenilmesini sağlar.

Çizelge 2. Kullanılan Unet modelleri

Unet modelleri	Filtre sayısı	Atlama bağlantısı	Katman sayısı
Unet v1	[16,32,64,128]	256	4
Unet v2	[32,64,128,256,512]	1024	5
Unet v3	[16,32,64,128,256,512]	1024	6
Unet v4	[32,64,128,256]	512	4

Bu farklı katman derinliklerine sahip Unet modelleri, gömülü dış görüntülerinin segmentasyonunda kullanılmış ve performanslarının karşılaştırılması yapılmıştır.

Katman sayılarındaki farklılıkların modellerin özellik çıkarma yeteneklerini etkilediği gözlemlenmiştir.

3.2.2. VGG16-Unet

VGG16 ve Unet mimarilerinin birleştirildiği bir hibrit modeldir [13]. VGG16'nın evrişim tabanlı özellik çıkarma yetenekleri ile Unet'in detaylı sonuçlar elde etme kabiliyeti bir araya getirilir. Bu model diş görüntülerinin hassas segmentasyonunu sağlar ve diş hekimliği alanında sınıflandırma ve ayırt etme için önemli bir araçtır. Kullanımıyla diş görüntülerinin analizi ve teşhisi ilerletilir, bu da dental alanda daha hassas sınıflandırma ve ayırt etme sağlar.

3.2.3. VGG19-Unet

VGG19 ve Unet mimarilerinin birleşimidir [14]. VGG19, derin sinir ağı mimarileri arasında popüler olan 19 katmanlı bir modeldir. Evrişim tabanlı katmanlarıyla görüntü sınıflandırma ve özellik çıkarma görevlerinde etkili sonuçlar verir. Unet ise segmentasyon görevleri için tasarlanmış bir mimaridir. VGG19-Unet, VGG19'un güçlü özellik çıkarma yeteneklerini Unet'in hassas ve lokalize edici segmentasyon kabiliyetiyle birleştirir. Bu model, diş görüntülerinin daha ayrıntılı analizi ve teşhisi için kullanılarak daha doğru sonuçlar elde edilmesini sağlar.

3.2.4. MobileNetV2

Hafif ve hızlı bir derin sinir ağı modelidir [15]. Evrişim tabanlı katmanlarda kullanılan daraltılmış (1x1) ve genişletilmiş (3x3) evrişimler sayesinde yüksek verimlilik sağlar. Ayrıca, derinlik ayrıştırma (depthwise separable) konvolüsyonları ile hesaplama maliyetini azaltır. 16 katmandan oluşan yapısı, 3.5 milyon parametre ve 300MB'dan daha az bellek kullanımı ile mobil cihazlar için idealdir. Bu model, yüksek hızda sınıflandırma ve nesne tespiti gibi görevlerde etkileyici sonuçlar elde etmek için tasarlanmıştır.

4. DENEYLER VE SONUÇLAR

4.1. Performans Metrikleri

Performans metrikleri, derin öğrenme modellerinin etkinliğini değerlendirmek ve karşılaştırmak için

kullanılan kritik araçlardır. Bu metrikler, modelin sınıflandırma veya tespit görevlerindeki performansını objektif bir şekilde değerlendirmemizi sağlar. Karmaşıklık matrisi, sınıflandırma modellerinin performansını değerlendirmek için kullanılan bir tablodur. Gerçek ve tahmin edilen sınıfların dört farklı durumunu içerir: doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif. Bu matris, modelin doğru ve yanlış tahminlerini göstererek hataları analiz etmeyi sağlar [16].

Kesinlik (precision), doğru tahmin edilen pozitif gözlemlerin toplam tahmin edilen pozitif gözlemlere oranıdır, yanlış pozitiflerin sayısını minimize etmeye odaklanır [17].

$$Kesinlik = \frac{DP}{DP + YP} \quad (1)$$

Duyarlılık (recall), doğru tahmin edilen pozitif gözlemlerin gerçek sınıftaki tüm gözlemlere oranıdır, gerçek pozitiflerin tespit edilme oranını ifade eder [17].

$$Duyarlılık = \frac{DP}{DP + YN} \quad (2)$$

DICE Katsayısı (DICE coefficient) benzerlik ölçüsü olarak kullanılır [18].

$$Dice = \frac{2 * DP}{2 * DP + YP + YN} \quad (3)$$

Son olarak AUC, alıcı çalışma karakteristiği (ROC) eğrisinin altında kalan alanı ifade ederek sınıflandırma modelinin genel performansını değerlendirmede kullanılır [19].

$$AUC = \int (DP - Oran) d(YP - Oranı) \quad (4)$$

Bu performans metrikleri, derin öğrenme modellerinin performansını objektif bir şekilde ölçmek ve karşılaştırmak için önemli bir rol oynamaktadır.

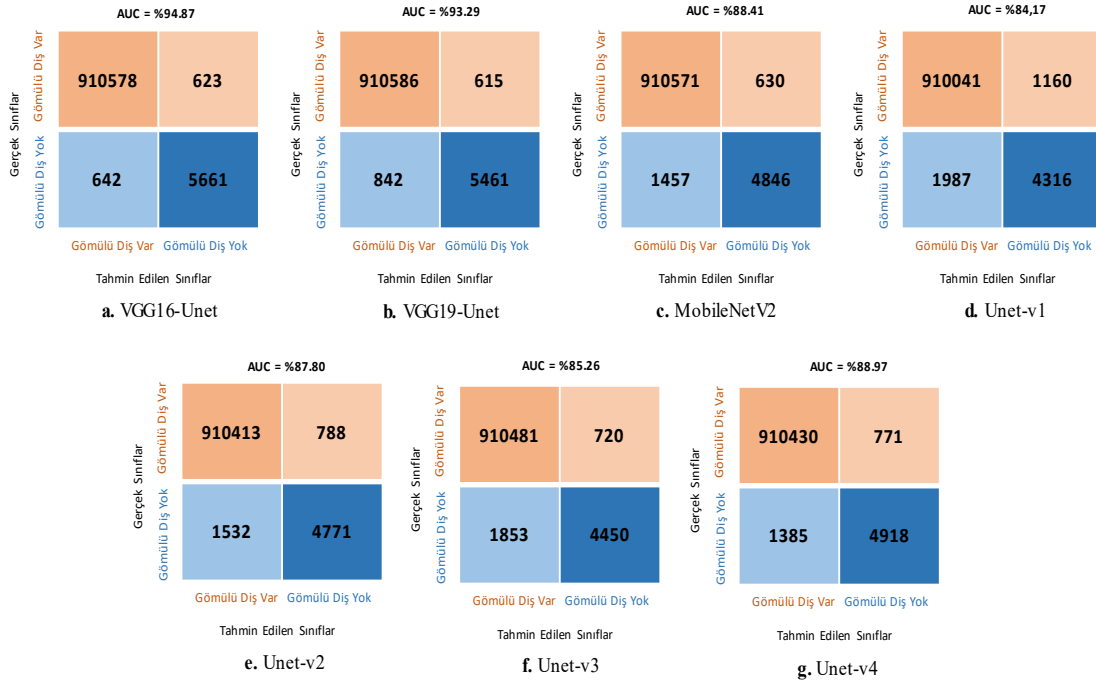
4.2. Modellerin Eğitimi ve Değerlendirilmesi

Bu çalışmada VGG16-Unet, VGG19-Unet, MobileNetV2 ve Unet modellerinin performansını ölçmek için çeşitli metrikler kullanılmıştır. Bu metrikler arasında (precision), duyarlılık (recall), Dice katsayısı ve AUC gibi önemli ölçümler yer almaktadır. Bu metrikler, modellerin sınıflandırma doğruluğunu, yanlış pozitif ve yanlış negatif tahminleri, hassaslık ve kapsamlılık gibi performans özelliklerini değerlendirmektedir. Bu çalışmada modellerin eğitiminde kullanılan veri kümesi, %90 eğitim, %5 doğrulama ve %5 test olarak bölünmüştür. Eğitim sürecinde epoch sayısı 100 olarak belirlenmiş, her bir eğitim adımında 16 örneklik bir batch boyutu kullanılmıştır. Optimizasyon için Adam optimizasyon algoritması tercih edilmiş ve öğrenme katsayısı 0.0001 olarak ayarlanmıştır. Bu derin parametreler kullanılarak modellerin eğitimi gerçekleştirilmiştir. Eğitim sürecinde, giriş görüntülerinin boyutu 256x256x3 olarak ayarlanmıştır.

Sonuçlar, her bir modelin sınıflandırma yeteneklerini, doğru tahmin oranlarını ve hata eğilimlerini anlamamıza yardımcı olmaktadır. Bu metriklerin kullanılması, modellerin karşılaştırılması ve en iyi performans sergileyen modelin belirlenmesi açısından kritik öneme sahiptir.

4.3. Performans Sonuçları ve Karşılaştırma

Bu çalışmada, panoramik gömülü dış görüntülerinden oluşan veri kümesine VGG16-Unet, VGG19-Unet, MobileNetV2 ve dört farklı katman ve filtre yapısına sahip Unet olmak üzere yedi farklı model uygulanmıştır. Her bir matris, gerçek sınıf değerleri ile modelin tahmin ettiği sınıf değerlerini karşılaştırır. Kullanılan farklı model yapılarına ait karmaşıklık matrisleri incelenmiştir. Çalışmamızda uyguladığımız her bir modele ait karmaşıklık matrisleri Şekil 3'te gösterilmektedir.



Şekil 3. Kullanılan modellerin karmaşıklık matrisleri

Çalışmamızda uygulanan bu modellerin performansını değerlendirmek için kesinlik, duyarlılık, Dice katsayısı ve AUC parametreleri kullanılmıştır. Elde edilen sonuçlar, araştırmacılara

ve diş hekimlerine daha iyi kararlar alabilmeleri için bir referans olma özelliği göstermektedir. Her bir model için bulunan performans ölçüt değerleri Çizelge 3'te sunulmuştur.

Çizelge 3. Kullanılan modellerin performans sonuçları (%)

Modeller	Kesinlik	Duyarlılık	Dice Katsayısı	AUC
VGG16-Unet	90.09	89.81	89.95	94.87
VGG19-Unet	89.88	86.64	88.23	93.29
MobileNetV2	88.50	76.88	82.28	88.41
Unet-v1	78.82	68.48	73.28	84.17
Unet-v2	85.82	75.69	80.44	87.80
Unet-v3	86.07	70.60	77.58	85.26
Unet-v4	86.45	78.03	82.02	88.97
















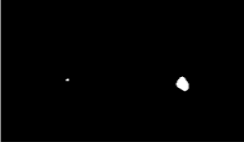








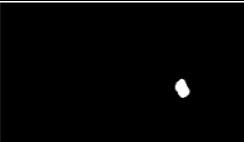


Çizelge 3'te farklı modellerin performansını gösteren bir karşılaştırma yapılmıştır. Kesinlik, duyarlılık, Dice Katsayısı ve AUC parametreleri kullanılarak elde edilen sonuçlar değerlendirilmiştir. VGG16-Unet modeli, en yüksek AUC değerine sahip olan modeldir (%94.87). Ayrıca kesinlik (%90.09), duyarlılık (%89.81) ve Dice Katsayısı (%89.95) açısından da diğer modellere kıyasla en iyi sonuçları elde etmiştir. Bu sonuçlar, VGG16-Unet modelinin diş görüntülerinin tespiti ve segmentasyonunda diğer modellere göre daha başarılı olduğunu göstermektedir.

Diğer modeller arasında, VGG19-Unet ve Unet-v4 modelleri de dikkate değer sonuçlar elde etmiştir. Bu modeller, genel olarak yüksek kesinlik ve Dice Katsayısı değerleriyle performans göstermiştir. Ancak MobileNetV2 ve diğer Unet modellerinin performansı daha düşüktür. Özellikle Unet-v1 modeli, diğer modellere göre daha düşük kesinlik, duyarlılık ve Dice Katsayısı değerleri elde etmiştir. Bu sonuçlar, Unet-v1 modelinin diş görüntülerinin doğru şekilde segmentasyonu konusunda geliştirilmesi gerektiğini göstermektedir. Unet-v2 ve Unet-v3 modelleri ise orta düzeyde performans

göstermiştir. Her iki model de diğer modellere kıyasla daha yüksek kesinlik, duyarlılık ve Dice Katsayısı değerlerine sahiptir. Bununla birlikte, Unet-v4 modeli diğer modellere göre daha iyi bir performans sergileyerek, diş hekimliği alanında tercih edilebilecek güvenilir sonuçlar sunmaktadır. Bu sonuçlar, Unet-v2 ve Unet-v3 modellerinin Unet-v1 modeline göre daha etkili bir diş segmentasyonu sağladığını göstermektedir. Unet-v4 modeli ise en yüksek performansı göstererek, daha kesin ve doğru segmentasyon sonuçları elde etmek için tercih edilebilir bir seçenektir.

Elde edilen sonuçlar Çizelge 4'te gösterilmiştir. Çizelge 4 incelendiğinde, bazı sonuçlarda modellerin gömülü dişin bulunduğu konumu kısmen doğru tespit ettiği, ancak boyutlarda farklılıklar olduğu görülmüştür. Bazılarında ise modellerin benzer sonuçlar verdiği ve VGG16-Unet modelinin daha iyi performans gösterdiği belirlenmiştir. Bu bulgular, gömülü diş görüntülerinin segmentasyonunda model seçiminin sonuçları üzerinde etkili olduğunu göstermektedir. Bu bilgiler, diş hekimliği alanında daha etkili segmentasyon yöntemlerinin geliştirilmesi için katkı sağlayabilir.

Çizelge 4. Farklı mimarilerin deneysel sonuçları

Model	Örnek-1	Örnek-2	Örnek-3
Gerçek Görüntü			
Gerçek Maske			
VGG16- Unet			
VGG19- Unet			
MobileNetV2			
Unet-v1			
Unet-v2			
Unet-v3			
Unet-v4			

5. TARTIŞMA

Çizelge 5. İncelenen literatür çalışmaları

Kaynak	Uygulanan model(ler)	Veri seti	Başarım alanı	Başarım metriği	Başarım sonucu
[20]	AI Model CranioCatch (Faster R-CNN Inception v2/COCO)	2019 - 2020 tarihli Eskişehir Osmangazi Üniversitesi'nden alınan panoramik görüntüler	Crown, İmplant, Gömülü Diş	Hassasiyet, Doğruluk, F1 Skoru	Hassasiyet: 0.9674-0.9658, Doğruluk: 0.9259-0.8947, F1 Skoru: 0.9433-0.9122
[21]	CNN algoritması	Eskişehir Osmangazi Üniversitesi Ağız ve Çene Radyolojisi Arşivi	Gömülü Diş	F1 Skoru, Hassasiyet, Doğruluk	Hassasiyet: > 95%
[22]	Deep-CNN	65 hastanın 130 gömülü üçüncü azı dişi CBCT verisi	Gömülü Üçüncü Azı Diş	Kappa, Gömülü Tespiti, Root/Canal Tespiti	Impacted Detection Başarısı: 86.2%, Impacted Tooth Root/Canal Başarısı: 78.6%, 68.1%
[23]	Faster RCNN, YOLOv3	Gömülü üçüncü azı dişleri olan 300 hastaya ait panoramik görüntüler	Gömülü Üçüncü Azı Diş	mAP@0.5, Hassasiyet, Doğruluk, Kesinlik	mAP@0.5: 0.91 (Faster RCNN - ResNet50), 0.96 (YOLOv3), Hassasiyet: 0.93, Kesinlik: 0.88
[24]	WideResNet (WRN), LaplaceNet (LN)	2016-2020 tarih aralığına ait Eunpyeong St. Mary's Hastanesi, St. Vincent Hastanesi ile Seoul St. Mary's Hastanesine ait gömülü diş panoramik görüntüleri	Mandibular Üçüncü Azı Diş Sınıflandırması	Derinlik, Uzamsal İlişki, Sinir Kanalı	F1 Skoru: 0.87, 0.87, 0.83 (WRN), 0.84, 0.94, 0.80 (LN)
Önerilen Çalışma	Unet, VGG16, VGG19, MobileNetV2	İki farklı veri kümesinden seçilen yüksek çözünürlüklü gömülü diş panoramik görüntüleri	Gömülü Diş	Kesinlik, Duyarlılık, Dice Katsayısı, AUC	En yüksek sonuç veren VGG16-Unet için Kesinlik: 90.09, Duyarlılık: 89.81, Dice Katsayısı: 89.95, AUC: 94.87

Gömülü diş tespiti alanında derin öğrenme tekniklerinin performansı araştırıldığında irdelenen çalışmalarda ortaya konan sonuçlar, derin öğrenme yöntemlerinin gömülü diş tespiti konusunda potansiyeli ve etkinliğini vurgulamaktadır. Başaran ve ark. panoramik radyografi görüntülerinde crown, implant ve gömülü dişlerin tespiti için geliştirilen yeni bir derin öğrenme modelinin performansını incelemiştirler [20]. Sonuçlar, bu modelin crown, implant ve gömülü dişlerin tespitinde yüksek duyarlılık ve kesinlik sağladığını göstermektedir. Çelik, derin öğrenme tekniklerinin, gömülü dişlerin tespitinde geleneksel yöntemlere kıyasla üstün bir performans sergilediğini vurgulamıştır [21]. Orhan

ve ark. tarafından geliştirilen çalışmada, Cone-beam Computed Tomography (CBCT) görüntülerinde gömülü üçüncü azı dişlerinin tespitinde derin öğrenme modelinin manuel muayeneye kıyasla yüksek başarımlı sağladığı vurgulanmıştır [22]. Çelik bir diğer çalışmasında, farklı derin öğrenme modellerinin kullanıldığı bir yöntem üzerinde durmuştur [23]. Bu çalışmada, Faster RCNN ve YOLOv3 gibi modellerin gömülü üçüncü azı dişlerin tespitinde yüksek performans sergilediği belirtilmiştir. Kim ve ark. ise çalışmalarında, mandibular üçüncü azı dişlerinin panoramik görüntüler üzerinde sınıflandırılmasında geleneksel denetimli öğrenme (SL) ve yarı

denetimli öğrenme (SSL) yöntemlerinin etkinliğini değerlendirmeyi amaçlamışlardır [24]. SL modeli olarak WideResNet (WRN) ve SSL modeli olarak LaplaceNet (LN) kullanılmıştır. LN modelinin WRN modeli gibi denetimli öğrenme yöntemine benzer başarı sağladığı vurgulanmıştır.

Önerilen çalışmamızda uygulanan modeller gömülü diş tespitinde başarılı sonuçlar elde edildiğini göstermektedir. Bu sonuçlar, derin öğrenme modellerinin gömülü diş tespiti alanında geleneksel yöntemlere kıyasla daha hassas ve güvenilir sonuçlar sağlayabileceğini ortaya koymaktadır. Bu çalışmaların toplu değerlendirmesi, derin öğrenme tekniklerinin diş hekimliği alanında klinik uygulamalarda ve tanısal süreçlerde potansiyel sağlayabileceğini göstermektedir.

6. SONUÇ VE GELECEK ÇALIŞMALAR

Bu çalışmada farklı katman derinliğine sahip 4 farklı Unet modeli, VGG16-Unet, VGG19-Unet ve MobileNetV2 modellerinin panoramik gömülü diş görüntülerinin segmentasyonu üzerindeki performansları incelenmiştir. Elde edilen bulgular, gömülü diş görüntülerinin doğru tespit edilmesi ve segmentasyonunun önemli olduğunu göstermektedir. Sonuçlara göre, bazı modeller gömülü dişin konumunu kısmen doğru tespit etmiş olsa da boyutlarında farklılıklar mevcuttur. VGG16-Unet modeli ise diğer modellere göre daha iyi sonuçlar vermiştir. Bu bulgular, gömülü diş görüntülerinin hassas bir şekilde segmente edilmesi için model seçiminin önemini vurgulamaktadır. Gelecekteki çalışmalar, farklı model türlerinin ve veri kümelerinin performansını karşılaştırmak için daha kapsamlı analizler yapabilir ve diş görüntülerinin segmentasyonunda daha ileriye yönelik geliştirmelere katkı sağlayabilir.

5. KAYNAKLAR

1. Narayan, V., Mall, P.K., Alkhayat, A., Abhishek, K., Kumar, S., Pandey, P., 2023. Enhance-Net: An Approach to Boost the Performance of Deep Learning Model Based on

- Real-Time Medical Images. *Journal of Sensors*, 15.
2. Kumar, A., Nag, A., Jain, N., Bandopadhyay, S., 2023. Surgical Management of Impacted Canine: A Case Series. *Journal of Dental Health & Research (JDHR)*, 4(1), 11-15.
3. Tetay-Salgado, S., Arriola-Guillén, L.E., Ruíz-Mora, G.A., Aliaga-Del Castillo, A., Rodríguez-Cárdenas, Y.A., 2021. Prevalence of Impacted Teeth and Supernumerary Teeth by Radiographic Evaluation in Three Latin American Countries: A Cross-Sectional Study. *Journal of Clinical and Experimental Dentistry*, 13(4), 363-368.
4. Singh, N.K., Raza, K., 2022. Progress in Deep Learning-Based Dental and Maxillofacial Image Analysis: A Systematic Review. *Expert Systems with Applications*, 199, 116968, 15.
5. Lee, J.H., Kim, D.H., Jeong, S.N., Choi, S.H., 2018. Detection and Diagnosis of Dental Caries using A Deep Learning-Based Convolutional Neural Network Algorithm. *Journal of Dentistry*, 77, 106-111.
6. Elboroloso, S.A., Salem, W.S., Hamed, M.O., Sayed, A.S., Helmy, B.E.D., Elngar, A.A., 2022. Predicting Difficulty Level of Surgical Removal of Impacted Mandibular Third Molar using Deep Learning Approaches. *Research Square*, 21.
7. Krois, J., Schneider, L., Schwendicke, F., 2021. Impact of Image Context on Deep Learning for Classification of Teeth on Radiographs. *Journal of Clinical Medicine*, 10(8), 1635, 9.
8. Tuzoff, D.V., Tuzova, L.N., Bornstein, M.M., Krasnov, A.S., Kharchenko, M.A., Nikolenko, S.I., Sveshnikov, M.M., Bednenko, G.B., 2019. Tooth Detection and Numbering in Panoramic Radiographs using Convolutional Neural Networks. *Dentomaxillofacial Radiology (DMFR)*, 48(4), 20180051, 15.
9. Hiraiwa, T., Arijji, Y., Fukuda, M., Kise, Y., Nakata, K., Katsumata, A., Fujita, H., Arijji, E., 2019. A Deep-Learning Artificial Intelligence System for Assessment of Root Morphology of the Mandibular First Molar on Panoramic Radiography. *Dentomaxillofacial Radiology (DMFR)*, 48(3), 20180218, 7.

10. Imak, A., Celebi, A., Polat, O., Turkoglu, M., Sengur, A., 2023. 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*, 1, 1-15.
11. Román, J.C.M., Fretes, V.R., Adorno, C.G., Silva, R.G., Noguera, J.L.V., Legal-Ayala, H., Mello-Román, J.D., Torres, R.D.E., Facon, J., 2021. Panoramic Dental Radiography Image Enhancement using Multiscale Mathematical Morphology. *Sensors*, 21(9), 3110, 19.
12. Ronneberger, O., Fischer, P., Brox, T., 2015. U-net: Convolutional Networks for Biomedical Image Segmentation, *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015: 18th International Conference, Munich, Germany*, 9351, 234-241.
13. Balakrishna, C., Dadashzadeh, S., Soltaninejad, S., 2018. Automatic Detection of Lumen and Media in the IVUS Images using U-Net with VGG16 Encoder. *arXiv preprint arXiv:1806.07554*, 10.
14. Ali, R., Hardie, R.C., Narayanan, B.N., De Silva, S., 2019. Deep Learning Ensemble Methods for Skin Lesion Analysis Towards Melanoma Detection. *2019 IEEE National Aerospace and Electronics Conference (NAECON)*, Dayton, 311-316.
15. Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., Chen, L.C., 2018. Mobilenetv2: Inverted Residuals and Linear Bottlenecks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Salt Lake City, 4510-4520.
16. Sokolova, M., Lapalme, G., 2009. A Systematic Analysis of Performance Measures For Classification Tasks. *Information Processing & Management*, 45(4), 427-437.
17. Theckedath, D., Sedamkar, R.R., 2020. Detecting Affect States using VGG16, ResNet50 and SE-ResNet50 Networks, *SN Computer Science*, 1(2), 79, 7.
18. Cheng, D., Lam, E.Y., 2021. Transfer learning U-Net Deep Learning for Lung Ultrasound Segmentation. *arXiv preprint arXiv:2110.02196*, 14.
19. Salama, W.M., Aly, M.H., 2021. Deep Learning in Mammography Images Segmentation and Classification: Automated CNN Approach. *Alexandria Engineering Journal*, 60(5), 4701-4709.
20. Basaran, M., Celik, O., Bayrakdar, I.S., Bilgir, E., Orhan, K., Odabas, A., Arslan, A.F., Jagtap, R., 2022. Diagnostic Charting of Panoramic Radiography using Deep-Learning Artificial Intelligence System. *Oral Radiology*, 38, 363-369.
21. Celik, O., 2021. Detection of Impacted Teeth using Deep Learning Technique. *Comptes Rendus de L'Academie Bulgare des Sciences*, 74(2), 269-277.
22. Orhan, K., Bilgir, E., Bayrakdar, I.S., Ezhov, M., Gusarev, M., Shumilov, E., 2021. Evaluation of Artificial Intelligence for Detecting Impacted Third Molars on Cone-Beam Computed Tomography Scans. *Journal of Stomatology, Oral and Maxillofacial Surgery*, 122(4), 333-337.
23. Celik, M.E., 2022. Deep Learning based Detection Tool for Impacted Mandibular Third Molar Teeth, *Diagnostics*, 12(4), 942, 31-43, 13.
24. Kim, J.Y., Kahm, S.H., Yoo, S., Bae, S.M., Kang, J.E., Lee, S.H., 2023. The Efficacy of Supervised Learning and Semi-Supervised Learning in Diagnosis of Impacted Third Molar on Panoramic Radiographs Through Artificial Intelligence Model. *Dentomaxillofacial Radiology (DMFR)*, 52(6), 12.