

# Görüntü işleme teknikleri ve evrişimsel sinir ağı kullanılarak bilgisayar destekli diş segmentasyonu

## Computer-aided tooth segmentation using image processing techniques and convolutional neural network

Ismail KAYADİBİ<sup>1,2\*</sup>, Utku KÖSE<sup>2</sup>, Gür Emre GÜRAKSIN<sup>3</sup>

<sup>1</sup>Yönetim Bilişim Sistemleri Bölümü, İktisadi ve İdari Bilimler Fakültesi, Afyon Kocatepe Üniversitesi, Afyonkarahisar, Türkiye.

ikayadibi@aku.edu.tr

<sup>2</sup>Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Süleyman Demirel Üniversitesi, Isparta, Türkiye.

utkukose@sdu.edu.tr

<sup>3</sup>Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Afyon Kocatepe Üniversitesi, Afyonkarahisar, Türkiye.

emreguraksin@aku.edu.tr

Geliş Tarihi/Received: 28.08.2023

Düzeltilme Tarihi/Revision: 10.11.2023

doi: 10.5505/pajes.2024.22237

Kabul Tarihi/Accepted: 22.01.2024

Araştırma Makalesi/Research Article

### Öz

Panoramik diş röntgeni, diş problemlerinin teşhisi için kullanılan yaygın bir görüntüleme yöntemidir. Ancak, bu görüntüleme ile elde edilen panoramik diş röntgen görüntülerinin çözünürlüğü nispeten düşüktür. Bu nedenle, dişte oluşan problemler gözden kaçabilmektedir. Bu amaçla, bu çalışmada panoramik diş röntgen görüntülerinden bilgisayar destekli klinik karar destek sistemlerinde diş segmentasyonu için görüntü önileme yöntemi ve evrişimsel sinir ağı (ESA) içeren bir yöntem önerilmiş ve bu önerilen yöntemin performans değerlendirilmesi için Güneybatı Bahia Eyalet Üniversitesi (UESB) veri seti kullanılmıştır. İlk olarak, U-Net, SegNet ve DeepLabv3+ mimarileri UESB veri seti üzerinde eğitilmiş ve ardından test edilmiştir. Sonrasında, UESB veri setine sırasıyla Histogram Eşitleme (HE), Kontrast Germe (KG) ve Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (KSUHE) görüntü önileme yöntemleri uygulanmıştır. Görüntü önileme yöntemlerinin performansa etkisini ölçmek için, elde edilen önileme veri setleri U-Net, SegNet ve DeepLabv3+ mimarileri üzerinde tekrar eğitilmiş ve test edilmiştir. Elde edilen test sonuçlarına göre KG, bu çalışmada kullanılan diğer önileme yöntemlerine kıyasla DeepLabv3+ ve SegNet mimarilerinde en fazla performansı iyileştiren önileme yöntemi olmuştur. En yüksek performansı ise, KG önileme veri seti ile eğitilmiş SegNet mimarisi elde etmiş ve diş segmentasyonu için önerilmiştir. Karşılaştırmalı performans analizinde KG hem panoramik diş görüntülerinin iyileştirilmesinde hem de ESA mimarileri üzerinde performans artırıcı yönde etkiye sahip olduğunu göstermiştir. Ayrıca, önerilen yöntemden elde edilen bulgular, UESB veri setinde yapılan önceki çalışmalarla karşılaştırılmış ve bu yöntem, literatürdeki benzer geliştirilen en son teknoloji yöntemlere göre kayda değer bir performans gösteren yöntemlerden birisi olmuştur. Sonuç olarak, önerilen yöntemin diş segmentasyonu için geliştirilecek bilgisayar destekli karar destek sistemlerinde güçlü bir araç olarak kullanılabilirliği görülmüştür.

**Anahtar kelimeler:** Diş segmentasyonu, Derin öğrenme, Evrişimsel sinir ağı, Görüntü işleme, Karar destek sistemleri.

### Abstract

Panoramic dental radiography is a common imaging technique used to diagnose dental problems. However, the resolution of panoramic dental radiographs taken with this imaging method is relatively low. As a result, dental problems may be missed. Against this background, this study proposes a method involving image preprocessing techniques and a convolutional neural network (CNN) for tooth segmentation in computer-aided clinical decision support systems using panoramic dental radiographs. The performance of the proposed method is evaluated using the dataset of the Southwest Bahia State University (UESB). First, the U-Net, SegNet and DeepLabv3+ architectures are trained and then tested on the UESB dataset. Then, pre-processing methods such as Histogram Equalisation (HE), Contrast Stretching (CS), and Contrast Limited Adaptive Histogram Equalisation (CLAHE) are applied to the UESB dataset. To evaluate the impact of these preprocessing methods on the performance, the pre-processed datasets are retrained and tested on the U-Net, SegNet and DeepLabv3+ architectures. Based on the test results obtained, it is evident that CS is the preprocessing method that significantly improves the performance of the DeepLabv3+ and SegNet architectures compared to the other preprocessing methods used in this study. The best performance is achieved by the SegNet architecture trained on the CS preprocessed dataset and is subsequently proposed for tooth segmentation. The comparative performance analysis shows that CS has a performance-enhancing effect on both panoramic dental images and ESA architectures. Furthermore, the results obtained from the proposed method are compared with previous studies on the UESB dataset and this method is one of the methods that performs remarkably well compared to similar state-of-the-art methods in the literature. In conclusion, the proposed method can be used as a powerful tool in computer-aided decision support systems that can be developed for tooth segmentation.

**Keywords:** Tooth segmentation, Deep learning, Convolutional neural network, Image processing, Decision support systems.

## 1 Giriş

Son yıllarda tıpta bilgisayarlı tomografi ve X-ışını görüntülemeye dayalı ileri teknolojilerin kullanılması, çeşitli hastalıkların teşhisine ve tedavisine yardımcı olmuştur. Diş hekimliğinde yüksek çözünürlüklü görüntüleme teknolojilerinin kullanılması, ön teşhis veya tedavi planlaması

için diş hekimlerine yardımcı olabilecek çok büyük miktarda verinin üretilmesine yol açmıştır [1]. Bu verilerin, diş hekimleri tarafından diş hastalıklarının tespiti için detaylı bir şekilde analiz edilmesi gerekmektedir. Diş hekimlerinin elde edilen diş görüntülerini analiz etmesi uzun zamanlar alabilmektedir. Bu yüzden, günümüzde diş hekimliğinde, diş hastalıklarının tespiti

\*Yazışılan yazar/Corresponding author

ve tedavi planlamalarının hızlandırılması için teşhis araçlarına olan ihtiyaç günden güne artmaktadır.

Diş hekimliğinde kullanılan radyografiler ağız içi ve ağız dışı olarak iki kategoride sınıflandırılabilir. En yaygın diş röntgen türleri de ağız içi olan ısıрма (bitewing), periapikal (periapical) ve ağız dışı olan panoramiktir. Panoramik diş röntgeni ya da başka bir adıyla Ortopantomogram (OPG), diş hekimleri tarafından günlük uygulamalarda ve hastanın tedavi planlamasının yapılmasında sık kullanılan görüntüleme yöntemlerinden birisidir. Panoramik diş röntgeni, çene-yüz kemikleri ve dişleri düşük radyasyon dozu kullanarak ucuz ve hızlı bir şekilde görüntülemesinden dolayı, diş hekimliğinde kullanılan diğer radyografilere göre çeşitli avantajlara sahiptir [2]. Ayrıca, bu röntgen tüm dişlerin görülebildiği tüm ağız bölgesini, çeneleri ve kafatasını gösterdiği için, diş hekimine hastaya ilişkin genel bir bakış sunar [3].

Son zamanlarda, görüntü sınıflandırma ve bölütleme (segmentasyon), nesne tespiti gibi çeşitli görevleri yerine getirmek için yapay zekâ yöntemlerinden makine öğrenimi (ML) ve derin öğrenme (DL) kullanımına artan bir ilgi vardır [4]. DL, verilerin öğrenme temsillerine dayalı daha geniş bir ML yöntemlerinin bir parçasıdır [5] ve geri yayılım algoritması kullanarak çok boyutlu veri setlerinin karmaşık yapısını keşfedebilir. Bu yüzden, çok yüksek veri potansiyeline sahip doğal dil işleme, görüntü işleme, görsel nesne tespiti, ilaç keşfi vb. alanlarda DL, önemli başarılar elde etmiştir [6]. DL yöntemlerinden Evrişimsel Sinir Ağları (ESA), yüksek veri potansiyeline sahip medikal görüntü işleme oldukça önemli bir yere sahiptir. Medikal görüntü işleme ESA ile retina görüntülerinden retina rahatsızlıkları ve damar tespiti [7],[8] gibi çeşitli sağlık problemlerinin tespiti için erken tanı sistemleri geliştirilmiş ve geliştirilen bu sistemlerin üstün başarılar gösterdiği raporlanmıştır. DL, klinik verilerden insan gözünüyle tam anlamıyla görülemeyen ilişkileri hızlı ve doğru bir şekilde çıkarılmasını sağlar. Bu doğrultuda, klinikte nesnel değerlendirmeler aracılığıyla veriler arasındaki ilişkilerin tekrar edilebilirliği sağlanır [10]. Diş hekimliği de ön tanı ve teşhis için ilk kararın önemli olduğu medikal alanlardan birisidir. DL diş hekimliğinde, hastanın ön tanısı için alınan radyografileri otomatik analiz ederek, diş hekimleri için görüntüleme teknolojileri ile elde edilen diş görüntülerinin analiz edilmesi için harcanan süreyi azaltabileceği muhtemeldir. Ayrıca DL diş hekimlerinin klinik kararlarını destekleyerek, klinik hizmetlerinin verimliliğini de doğrudan arttırabilir.

Diş hekimleri gizli diş yapısını, kemik kaybını, kötü huylu veya iyi huylu kitleleri ve görsel muayene ile incelenemeyen boşlukları bulmak için hastanın panoramik röntgenini kullanmaktadır. Bu yüzden, panoramik röntgenler diş hastalıklarının teşhisinde kritik bir rol oynar. Panoramik görüntülerin analizinde hekim, öncelikle diş bölgelerini tespit eder ve ardından ilgili diş üzerinde incelemelerde bulunmaktadır. Bu doğrultuda, panoramik görüntü analizi için geliştirilen bilgisayar destekli sistemlerde diş segmentasyonu popüler hale gelmeye başlamıştır. Ayrıca, dişlerin segmentasyonu endodonti, ortodonti ve adli diş hekimliği uygulamaları gibi diş hekimliğinin alt dallarında detaylı analiz kullanılmaktadır [9]. Bu yüzden, yüksek performansa sahip bir yapay zekâ destekli diş segmentasyon sistemi, hekimlerin kararını kolaylaştıracak önemli bir araç özelliğine sahiptir. Bu bağlamda son yıllarda, yapay zekâdaki gelişmeler ile birlikte diş hekimliğinde kullanılan radyografilerin analizi için DL ve ML tabanlı yöntemler, araştırmacılar tarafından önerilmiştir.

Bu çalışmalardan birinde panoramik görüntülerden dişlerin otomatik tespiti ve numaralandırılması için, Estai ve diğ. üç adımlı ESA'nın farklı türlerinin (U-Net, Faster R-CNN ve VGG16) kullanımını içeren DL sistemi önermişlerdir. Önerilen yöntemin panoramik görüntülerden diş algılama ve diş numaralandırmada, yüksek duyarlılık ve hassasiyet değerlerine sahip olduğunu belirtmişlerdir [10]. Bir başka çalışmada, Lee ve diğ. dental panoramik radyografi ve konik ışınli bilgisayarlı tomografik (CBCT) görüntülerinden üç tip odontojenik kistik lezyonun teşhisi için GoogLeNet Inception v3 mimarisinden türetilen önceden eğitilmiş derin bir ESA mimarisi kullanmışlardır [11]. Silva ve diğ. panoramik diş görüntülerinden otomatik diş tespiti için Güneybatı Bahia Eyalet Üniversitesi (UESB) Teşhis Görüntüleme Merkezinden 1500 panoramik diş görüntüsü toplamışlar ve toplanan bu görüntüleri, kullanıma açık bir şekilde literatüre yeni bir veri seti olarak sunmuşlardır. Bu veri seti üzerinde, çeşitli segmentasyon algoritmalarının performansını test etmişler ve test sonucunda, en yüksek performansı %92.08 doğruluk oranı ile bir DL yöntemi olan tekrarlayan ESA ile elde etmişlerdir [12]. Zhu ve diğ. panoramik radyografilerden farklı çürük derecelerini (sığ çürükler, orta çürükler ve derin çürükler) tanımlamak için CariesNet adlı yeni bir DL mimarisi önermişlerdir. Önerilen yöntemin karşılaştırma ve ablyasyon testi sonuçlarına göre, CariesNet mimarisinin panoramik X-ray görüntülerinden çürük lezyonlarını ayırmada çok iyi performans gösterdiğini belirtmişlerdir [13]. Panoramik diş röntgeni görüntülerinden diş tespiti ve dental problemlerin ön tanısı için, Muresan ve diğ. DL ve görüntü işleme teknikleri kullanan bir yaklaşım sunmuşlardır [14].

Son zamanlarda araştırmacılar tarafından diş segmentasyonu için semantik segmentasyon tabanlı ESA mimarileri sıklıkla tercih edilmektedir. Bu sebeple, ilgili problemed semantik ESA mimarilerinin kullanımı yaygınlaşmıştır. Örnek çalışmaların birinde, Koch ve diğ. dental radyografilerden diş segmentasyonu için semantik bölümlenme tekniklerine dayanan U-Net tabanlı Tamamen Evrişimli Sinir Ağını (FCN) kullanmışlardır [31]. Zhao ve diğ. dental panoramik röntgen görüntülerinden diş lokalizasyonu ve segmentasyonunun otomatik tespiti için İki Aşamalı Dikkat Segmentasyon Ağını (TSASNet) geliştirmişlerdir [32]. Aynı şekilde, Lee ve diğ. panoramik radyografilerden otomatik diş segmentasyonu için maske R-CNN modelini kullanan tamamen derin bir öğrenme yöntemi uygulamışlardır [33]. Da Silva Rocha ve Endo segmentasyon konusunda tıp literatüründe öne çıkan dört segmentasyon algoritmasını (U-Net, DCU-Net, DoubleU-Net ve Nano-Net) kullanarak diş segmentasyonu probleminde karşılaştırmalı bir çalışma gerçekleştirmiş ve DoubleU-Net mimarisinin diğerlerine kıyasla en yüksek performansı elde ettiğini raporlamıştır [34]. Lin ve diğ. X-ışını görüntüleme sistemlerinde bulut bilişimi kullanmadan hızlı ve hafif segmentasyon algoritmalarının uygulanmasının gerektiğini belirtmiş ve diş segmentasyonu için düşük ağırlığa sahip (lightweight) DL yöntemleri geliştirmişlerdir. Ayrıca, önerilen bilgi tutarlılığı sinir ağıının (KCNet) diğerlerine kıyasla üstün performans elde ettiğini göstermişlerdir [35]. Sonuç olarak, literatürde diş segmentasyonu için semantik segmentasyon tabanlı DL yöntemlerinin elde ettiği performanslar ön plana çıkmaktadır.

Yukarıdaki literatür örneklerinden de görüldüğü gibi son zamanlarda, panoramik diş görüntüleri kullanılarak birçok çalışma yapılmış ve diş lezyonu tespiti [11], diş segmentasyonu [12],[32]-[35], çürük tespiti [13],[14] gibi çeşitli diş

problemleri için çeşitli sınıflandırma yöntemleri önerilmiştir. Önceki çalışmalarda kullanılan çeşitli sınıflandırma yöntemleri arasında ESA tabanlı yöntemler, diğerlerine kıyasla önemli sınıflandırma performansı elde etmiştir. Bir başka açıdan, ESA tabanlı yöntemlerde, performans artırımı için görüntü ön işleme ve ML yöntemlerinin birlikte kullanımını içeren hibrit yöntemlerde erken tanı sistemlerinin geliştirilmesi için önerilmiş ve üstün başarılar elde ettiği raporlanmıştır [7],[15], [17]. Bu çalışmada ise segmentasyon problemlerinde sık kullanılan DeepLabv3, U-Net ve SegNet mimarileri, diş segmentasyonu için kullanılmış ve bir panoramik X-ray diş görüntü veri seti üzerinde test edilmiştir. Ayrıca, bu veri setindeki görüntülere kontrast iyileştirme tabanlı ön işleme yöntemleri de uygulanarak, kullanılan ESA mimarilerinin performansı test edilmiştir. Elde edilen test sonuçları doğrultusunda, en yüksek performansa sahip ön işleme yöntemi ve ESA mimarisi belirlenmiş ve bu çalışmada diş segmentasyonu problemi için önerilmiştir. Bu çalışmanın amacı ve literature ana katkıları aşağıda verilmiştir.

- 1) Diş segmentasyonu problemi için DeepLabv3, U-Net ve SegNet mimarilerinin UESB veri seti üzerinde performansları değerlendirilmiştir,
- 2) DeepLabv3, U-Net ve SegNet mimarileri üzerinde görüntü ön işleme yöntemlerinin performansa etkisi ölçülmüş ve en yüksek performansa sahip görüntü ön işleme yöntemi belirlenmiştir,
- 3) En yüksek başarıya sahip ESA mimarisinin, UESB veri seti üzerinde yapılan önceki çalışmalara göre bir performans karşılaştırması verilmiştir.

Bu çalışmanın geri kalanında; Bölüm 2, çalışmada kullanılacak materyal ve metotların detaylı açıklaması sunulmuştur. Bölüm 3'te gerçekleştirilen deneyler ve elde edilen bulgular, Bölüm 4 çalışmanın literatüre kıyasla bir tartışmasını sağlarken, son olarak Bölüm 5'te, bu çalışmada elde edilen bulguların bir genel değerlendirmesini sunan bir sonuç bölümü sunulmuştur.

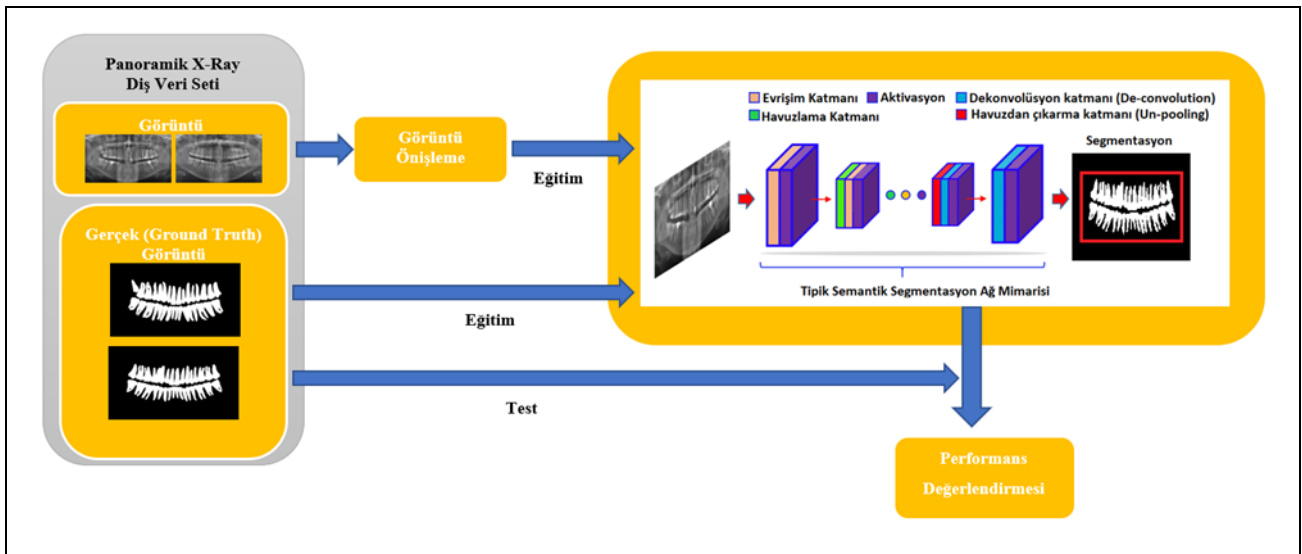
## 2 Materyal ve metot

Bu çalışmada panoramik diş görüntülerinden diş segmentasyonu için, görüntü ön işleme yöntemleri ve ESA mimarilerinin birlikte kullanımını içeren bir yöntem önerilmiştir. Önerilen yöntem için akış diyagramı Şekil 1'de verilmiştir.

Şekil 1'de görüldüğü gibi öncelikle, görüntü ve referans görüntüleri (ground truth) içeren iki bölüme sahip bir panoramik X-ray diş veri setine kontrast iyileştirmeye dayalı görüntü ön işleme yöntemleri uygulanır ve elde edilen ön işleme veri seti üzerinde segmentasyon için kullanılan ESA mimarileri eğitilmiştir. Eğitim sonrasında, ESA mimarileri veri setinin test için ayrılmış bölümünde test edilmiştir. Buna ek olarak, karşılaştırma için hiç ön işleme uygulanmamış veri seti üzerinde de ESA mimarilerinin performansı test edilmiştir. Sonuç olarak, ön işleme ve ön işlemsiz kullanılan panoramik diş veri seti üzerinde eğitilen ESA mimarilerinin test edilmesi sonucunda performans değerlendirmesi yapılmıştır. Yapılan değerlendirme sonucunda, en yüksek performansa sahip ön işleme yöntemi ve ESA mimarisi belirlenmiştir. En yüksek performansa sahip bu ESA mimarisi ve ön işleme yöntemi, bu çalışmada diş segmentasyonu için önerilmiştir.

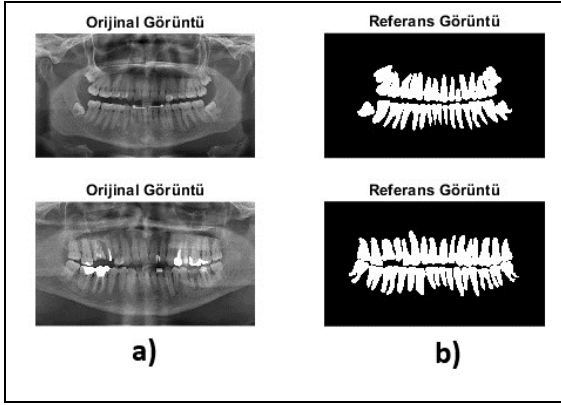
### 2.1 Panoramik diş veri seti

Bu çalışmada Silva ve diğ. tarafından Güneybatı Bahia Eyalet Üniversitesi'nin (UESB) Tanısal Görüntüleme Merkezinde elde edilen ve dişlerin yapısal özelliklerinin çeşitlerine göre 10 farklı kategoride 1500 adet panoramik diş röntgen görüntüsünden (2440 x 1292 piksel) oluşan veri seti kullanılmıştır. Bu görüntüler ayrıca yazarlar tarafından araştırmacıların kullanımı için açık erişimde kullanıma sunulmuştur [12]. Bu çalışmada kullanılan ön işleme yöntemleri ve ESA mimarilerinin performans değerlendirmesi için UESB veri seti kullanılmıştır. Ancak, UESB veri seti eğitim, test gibi ayrı bölümlere ayrılmamıştır. Bu yüzden, bu çalışmada kullanılan ESA mimarilerinin eğitimi, doğrulama ve test aşamaları için UESB veri seti, %80'i eğitim, %10'u doğrulama (validation) ve %10'u test olmak üzere üç ayrı bölüme ayrılmıştır. UESB veri setinde bulunan bazı örnek panoramik görüntüler ve referans görüntüler Şekil 2'de gösterilmiştir.



Şekil 1. Akış diyagramı.

Figure 1. Flow diagram.



Şekil 2(a): Örnek panoramik görüntü. (b): Örnek referans görüntü.

Figure 2(a): Sample panoramic image. (b): Sample ground truth image.

## 2.2 Görüntü önleme yöntemleri


Görüntü önleme yöntemleri görüntü iyileştirmek için kullanılan ve dijital görüntü işlemedeki en karmaşık ve önemli görevlerden biridir [18]. Görüntü önleme veya iyileştirme yöntemleri, genel histogram değiştirme yaklaşımı, yerel işleme yaklaşımı ve çok ölçekli işleme yaklaşımı olarak üç tipe gruplandırılabilir [19]. Bu çalışmada ise panoramik diş görüntülerinde, medikal görüntülerin iyileştirilmesi için sık kullanılan görüntü önleme yöntemlerinden Histogram Eşitleme (HE), Kontrast Germe (KG) ve Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (KSUHE) kullanılmıştır.

HE, görüntünün histogramını kullanarak görüntünün dinamik aralığını genişleterek, görüntüdeki kontrastı iyileştirir. Yüksek etkinliği ve basitliği sebebiyle HE, görüntü işlemede yaygın kullanılan bir kontrast geliştirme tekniği olarak da bilinmektedir [20]. HE, kontrast arttırmaya yardımcı olduğu için medikal görüntülerde ilgili bölgenin arka plandan daha iyi görselleştirilmesine yardımcı olur.

KG, bir görüntünün arka ve ön plan gri seviye dağılımında piksel değerlerini daha geniş bir aralığa yayılmasını sağlayarak kontrastı iyileştiren basit bir görüntü önleme yöntemidir [20]. HE gibi KG'de, düşük kontrastlı medikal görüntülerde, görüntünün kontrastını arttırarak ilgili bölgenin ön plana çıkmasına olanak sağlar. Ayrıca, KG'nin hesaplama hızı da yüksektir.

Kontrast geliştirme için kullanılan yöntemlerden birisi de KSUHE'dir. KSUHE, görüntüdeki gürültü amplifikasyonunu azaltmak için kontrast amplifikasyonunu sınırlayan bir uyarlamalı HE çeşididir [21]. Bu yöntem, görüntüyü, alt görüntüye böler ve alt görüntülerde, yüksek doğruluk ve kontrast sınırlaması ile HE gerçekleştirir. Aynı zamanda, görüntünün arka planı da ön plan olarak geliştirilerek yüksek kontrastlı bir görüntü elde edilir [22]. Medikal görüntülerde KSUHE, gürültüyü bastırır ve bu sayede, görüntünün kontrastını önemli bir şekilde geliştirir. Ayrıca, görüntünün kenar özelliklerinin keskinliğini korur ve HE ile karşılaştırıldığında, daha az hesaplama süresi gerektirir [23].

Bu çalışmada panoramik diş görüntülerinin iyileştirilmesi için kullanılan HE, KG ve KSUHE kontrast iyileştirme yöntemlerinin, UESB veri setindeki örnek görüntüler üzerinde uygulanmış hali Şekil 3'te gösterilmiştir.




Şekil 3(a)-(c)-(e): Orijinal test görüntüsü. (b): HE önlenmiş görüntü. (d): KSUHE önlenmiş görüntü. (f): KG önlenmiş görüntü.

Figure 3(a)-(c)-(e): Original test image. (b): HE preprocessed image. (d): KSUHE preprocessed image. (f): KG preprocessed image.

Panoramik görüntülerde, X-ışını yardımıyla elde edildiği için görüntüde hem gürültü hem de az kontrast bulunmaktadır. Hem gürültü gidermek hem görüntüdeki kontrastı arttırarak ilgili bölgeyi ön plana çıkartmak için, Şekil 3'te görüldüğü gibi panoramik görüntülere HE, KSUHE ve KG görüntü ön işlemleri uygulanmıştır. Önlenmiş panoramik görüntülere bakıldığında, kontrastı iyileştirme sonrasında diş bölgelerinin daha belirgin hale geldiği görülmektedir. Bu bölgelerin daha net olması, hekimin analizini kolaylaştırabilmektedir. Bu çalışmada UESB veri seti üzerinde görüntü önleme yöntemlerini uygulayarak kullanılan ESA mimarilerinin performans analizleri yapılacaktır. Performans analizi sonrasında, diş segmentasyonu probleminde kullanılacak ESA'larda en yüksek başarıma sahip görüntü ön işlem yöntemi belirlenecektir.

ESA, DL'de görüntüleri analiz etmek için kullanılan yaygın olarak kullanılan bir yapay sinir ağıdır. Son zamanlarda ESA'lar, kanser tespiti, patoloji tespiti gibi çeşitli tıbbi görüntü segmentasyonu problemleri için en gelişmiş performansı göstermiştir [24]. Semantik segmentasyon görevleri için, piksel bazında tahmin için uçtan uca (end-to-end) eğitilmiş DL mimarilerinden biri de tam evrişimli sinir ağlarıdır. Bu çalışmada karşılaştırmalı performans değerlendirmesi için yaygın kullanılan ESA mimarilerinden U-Net [25], SegNet ve DeepLabv3+ mimarileri seçilmiş ve her bir ESA mimarisine ilişkin detaylar aşağıda verilmiştir.

Geleneksel ESA mimarilerinden tasarlanan U-Net mimarisi ilk olarak 2015 yılında biyomedikal görüntüleri işlemek için tasarlanmış ve bu görüntüler üzerinde de U-Net, önemli performans elde etmiştir [25]. Bu mimarinin temsili yapısı Şekil 4'te gösterilmiştir.



Şekil 4. U-Net mimarisi [25].

Figure 4. U-Net architecture [25].

Şekil 4'te görüldüğü gibi, U-Net mimarisinin katman yapısı simetrik ve iki ana bölüme ayrılmıştır. U-Net'in yapısının sol kısmı, genel evrimsel süreçten oluştuğu için "contracting path" ve sağ kısmı ise transpoze 2-boyutlu evrim katmanlarından oluştuğu için de "expansive path" olarak isimlendirilmiştir. U-Net'in sol kısmında evrim katmanlarında, giriş görüntüsünün çözünürlüğünü artırmak için maksimum havuzlama katmanları kullanılmıştır. Sonrasında, bu katmanları, diğer kısımda giriş görüntüsünün çözünürlüğünü artırmak için üst örnekleme işlemleri ile bir dizi evrimli katmanlar takip eder. Bu iki seri kısmın birleştirilmesi U şeklinde bir grafik oluşturur ve bu mimarinin ismi olarak kullanılmıştır. Sonuç olarak U-Net mimarisi evrim, maksimum havuzlama, derinlik birleştirme ve piksel sınıflandırma çıktı katmanları dahil olmak üzere 58 katman içeren bir tam evrimsel sinir ağıdır [25].

Badrinarayanan ve diğ. (2017) tarafından SegNet adında semantik piksel bazında bölütleme (segmentasyon) için, derin ve tamamen evrimli bir sinir ağı mimarisi sunulmuştur. SegNet, kodlayıcı-kod çözücü (encoder-decoder) tipi bir mimari kullanan bir görüntü segmentasyon ve "Tamamen Evrimli Ağ" mimarisidir. Bu mimari, kodlayıcı kısmında VGG16 modelindeki 13 evrim katmanının tümünü kullanır. Her kodlayıcı katmanı için, görüntüyü orijinal boyutuna yukarı örnekleme üzere karşılık gelen bir kod çözücü ağı bulunmaktadır. Bu mimaride kod çözücü ağı son olarak piksel bazlı sınıflandırma katmanı için Softmax fonksiyonu takip etmektedir [26]. SegNet mimarisinin temel yapısı da Şekil 5'te gösterilmiştir.

DeepLabv3+, Chen ve diğ. (2018) tarafından nesne sınırlarını geliştirerek segmentasyon sonuçlarını iyileştirmek için DeepLabv3 mimarisine basit bir kod çözücü eklenmesiyle genişletilen yeni bir kodlayıcı-kod çözücü tabanlı bir segmentasyon mimarisidir [27]. Bu mimari, Atrous uzamsal piramit pooling (ASPP) ve alt omurga ağı (backbone network) kullanarak çok ölçekli bağlamsal bilgileri kodlayabilirler. Kodlayıcı, çok ölçekli bağlamsal bilgileri işlemek için genişletilmiş evrim kullanırken, kod çözücü de nesne sınırlarında segmentasyon sonuçlarını iyileştirir.

DeepLabv3+ ağının bir parçası olarak ResNet, GoogLeNet, VGG gibi çeşitli önceden eğitilmiş ESA mimarileri alt omurga ağı

(backbone network) olarak kullanılmaktadır. Bu çalışmada DeepLabv3+ mimarisinin alt omurga ağı olarak ResNet18 tercih edilmiştir. Bu çalışmada kullanılan DeepLabv3+ mimarisinin temel yapısı ise Şekil 6'da gösterilmiştir. Şekil 6'da "Atrous Conv" ve "Conv" evrim katmanını, "Image Pooling" havuzlama katmanını, "UpSample" örnekleme katmanını ve "Concat" birleştirme katmanını ifade etmektedir.

### 3 Deneysel Sonuçlar

Bu çalışmada diş segmentasyonu ESA mimarileri ve görüntü önileme yöntemlerinin kullanımını esas alan bir yöntem önerilmiştir. Önerilen yöntemde en yüksek başarıyı elde eden ESA mimarisi ve görüntü önileme yöntemi belirlenmiştir.

Bu çalışmadaki tüm deneyler Intel (R) Core i7 & 2.6 GHz işlemci, NVIDIA GTX 1650Ti grafik kartı ve Windows 10 işletim sistemine sahip bir bilgisayar üzerinde MATLAB (R2022a) yazılım ortamında gerçekleştirilmiştir.

#### 3.1 Performans Metrikleri

Bu çalışmada gerçekleştirilen deneylerin performans değerlendirmesinde sıklıkla segmentasyon problemlerinde kullanılan karışıklık matrisinden hesaplanan performans metrikleri kullanılmıştır.

Bu performans metriklerinden doğruluk (Eşitlik 1), özgüllük (Eşitlik 2), duyarlılık (Eşitlik 3), kesinlik (Eşitlik 4) ve F1 skor (Eşitlik 5) performans metriklerinin matematiksel ifadesi aşağıda verilmiştir.

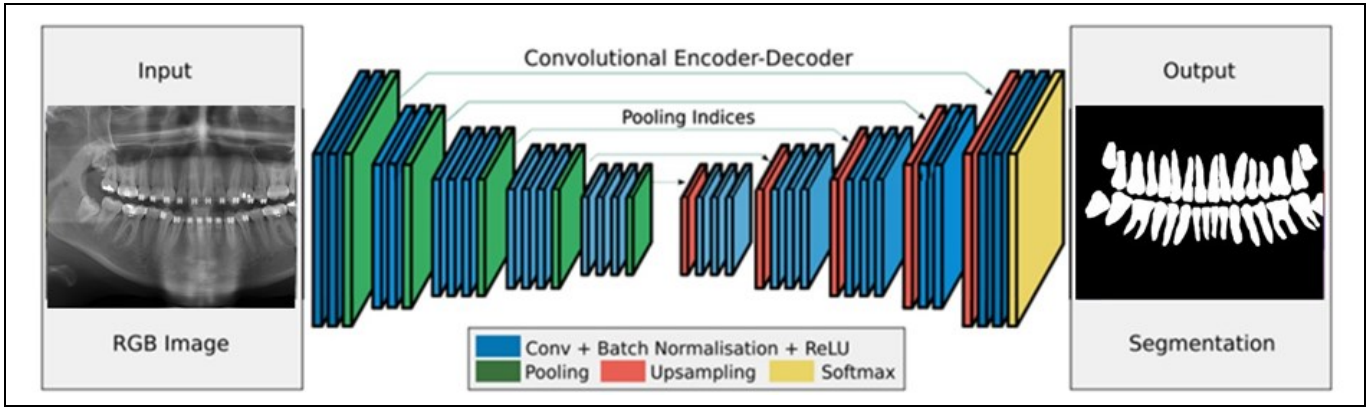
$$\text{Doğruluk} = (TP + TN) / (TP + TN + FP + FN) \quad (1)$$

$$\text{Özgüllük} = TN / (TN + FP) \quad (2)$$

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

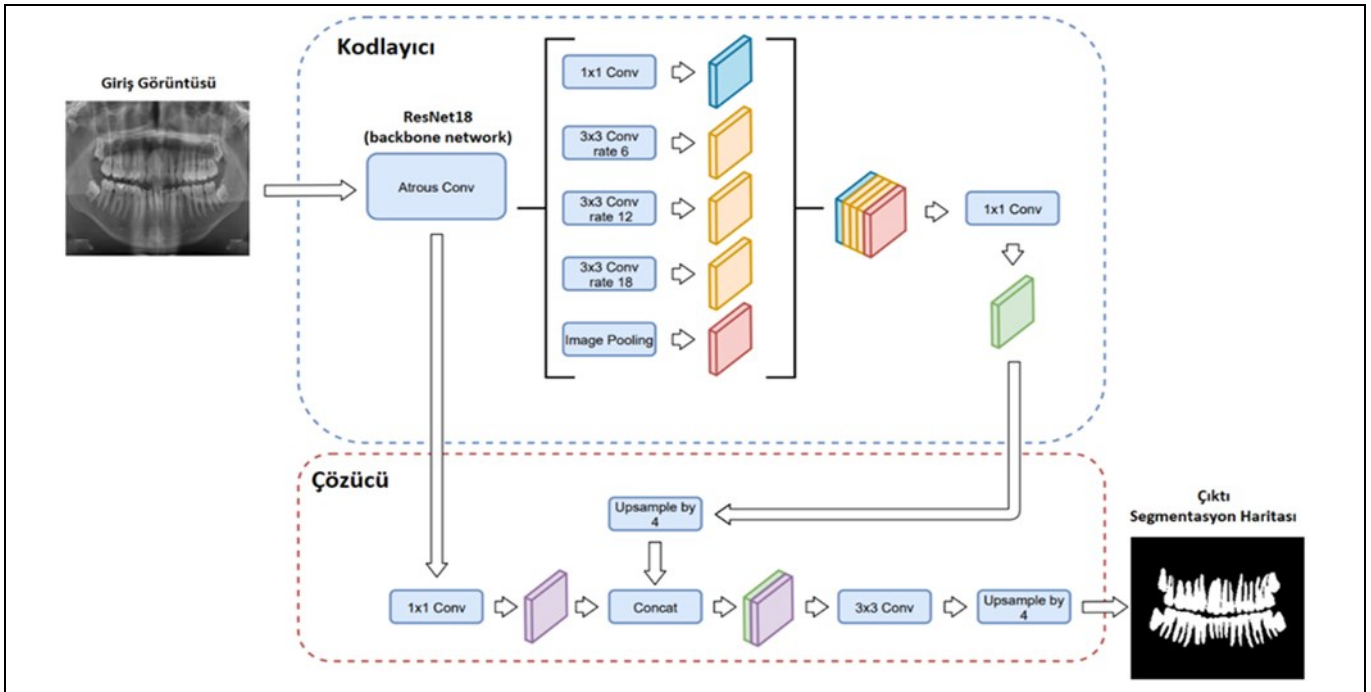
$$\text{Kesinlik} = TP / (TP + FP) \quad (4)$$

$$F_1 \text{ skor} (Dice) = 2 \times (\text{Kesinlik} \times \text{Duyarlılık}) / (\text{Kesinlik} + \text{Duyarlılık}) \quad (5)$$



Şekil 5. SegNet Mimarisi [26].

Figure 5. SegNet architecture [26].



Şekil 6. DeepLabv3+ mimarisinin temel yapısı [27].

Figure 6. Basic structure of the DeepLabv3+ architecture [27].

Bu eşitliklerdeki Doğru Pozitif (TP), pozitif sınıftaki doğru sınıflandırılmış piksel sayısı, Doğru Negatif (TN) negatif sınıftaki doğru etiketlenmiş piksel sayısı, Yanlış Pozitif (FP) negatif sınıftaki pozitif etiketlenmiş piksel sayısı ve Yanlış Negatif (FN) pozitif sınıftaki negatif etiketlenmiş piksel sayısıdır [28].

Medikal segmentasyon problemlerinde sıklıkla, Dice ve Jaccard katsayısı performans ölçümlerinde kullanılmaktadır [29]. F1 skor (Eşitlik 5) olarak da bilinen Dice katsayısı, kesinlik (precision) ve hatırlatmanın (recall) harmonik ortalamasıdır. Başka bir deyişle, segmentasyon tahmini ile referans görüntünün kesişiminin iki katının her iki görüntüdeki piksel sayısına bölünmesiyle hesaplanır.

Birleşim Üzerinden Kesişme (IoU) olarak da bilinen Jaccard benzerlik katsayısı, tahmin edilen segmentasyon bölgesi ile referans bölgenin birleşimi üzerindeki kesişimi ifade eder ve

benzerliğin ölçülmesi için kullanılan bir metriktir. Jaccard katsayısının matematiksel ifadesi, Eşitlik 6'da verilmiştir.

$$Jaccard (IoU) = TP / (TP + FP + FN) \quad (6)$$

Bu çalışmaya konu olan diş segmentasyonu problemi için eğitilen ESA mimarilerinin performans değerlendirmesinde, doğruluk, duyarlılık, özgüllük, kesinlik, F1-skor (Dice katsayısı) ve Jaccard benzerlik katsayısı performans metrikleri kullanılmıştır.

### 3.2 ESA'ların eğitimi için hiper parametre ayarı

ESA'ların eğitimi için kayıp kriteri, optimizasyon yöntemi, öğrenme oranı, L2 düzenleme, parti boyutu, gradyan bozunma faktörü ve epok sayısı gibi bazı ayarlanması gerekli hiperparametreler bulunmaktadır [30]. Bu çalışmada medikal görüntülerin eğitiminde sıklıkla kullanılarak başarısını kanıtlanmış hiperparametreler [36] öncelikle tercih edilmiş ve

bu hiper parametrelere ilişkin detaylar Tablo 1’de verilmiştir. Ayrıca, bu çalışmada kullanılan tüm ESA mimarilerinin performans değerlendirmesinde uygun performans karşılaştırması yapılabilmesi için, tüm kullanılan ESA mimarilerinin eğitiminde aynı hiper parametreler ayarlanmış ve uygun karşılaştırma ortamı sağlanmıştır.

Tablo 1. ESA mimarileri için kullanılan hiper parametrelerin detayları.

Table 1. Details of hyperparameters used for ESA architectures.

Parametre	Value/type
Kayıp Kriteri	Çapraz Entropi
Optimizasyon Yöntemi	Adam
Öğrenme Oranı	0,001
L2 Düzenleme	0,0001
Parti Boyutu	8
Gradyan Bozunma Faktörü	0,9
Epok	20
Çıktı	Diş /Arka Plan (Tooth / Background)

### 3.3 ESA mimarilerinin performans değerlendirmesi

Bu çalışmada diş segmentasyonu için U-Net, SegNet ve DeepLabv3+ mimarileri kullanılmıştır. İlk olarak, tüm ESA mimarileri, Tablo 1’deki hiper parametrelere ayarlanarak panoramik diş görüntüleri içeren UESB veri seti üzerinde eğitilmiştir. Eğitim sonrasında, elde edilen ESA mimarileri, UESB veri setinin test için ayrılmış bölümünde test edilmiştir. Ayrıca bu çalışmada, kontrast iyileştirme görüntü önışlem yöntemlerinin ESA mimarilerinde performansa etkisi de incelenmiştir. Bu amaçla, UESB veri setine ayrı ayrı MATLAB ortamında HE, KG (üst %1’i ve alt %1’i doyuran varsayılan sınırlar [0,01 0,99]) ve KSUHE (rayleigh dağılımlı) görüntü önışlem yöntemleri uygulanarak önışlemli veri setleri elde edilmiştir.

Sonrasında, elde edilen önışlemli veri setleri de U-Net, SegNet ve DeepLabv3+ mimarilerinde eğitilmiş ve UESB veri setinin test bölümünde test edilmiştir. Bu ESA mimarilerinin önışlemli ve önlemsiz UESB veri setinde testi sonucunda elde ettiği performans metrikleri Tablo 2’de verilmiştir (Her sütunda performans metriklerine göre en yüksek başarıma sahip alan, kalın yazı tipi ile belirtilmiştir).

Tablo 2’ye göre doğruluk metriğine bakıldığında, DeepLabv3+ ve SegNet mimarisinde KG önışlemi performansı iyileştirmiştir.

Tablo 2. Görüntü önışlem yöntemlerinin DeepLabv3+, U-Net ve SegNet mimarileri üzerinde performans değerlendirmesi.

Table 2. Performance evaluation of image preprocessing methods on DeepLabv3+, U-Net and SegNet architectures.

Ağ	Önışlem	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	Dice	Jaccard	Doğruluk (Validation)
DeepLabv3+	-	0,9533	0,8923	<b>0,9700</b>	<b>0,8915</b>	0,8903	0,8029	87,72
	HE	0,9529	0,8975	0,9681	0,8854	0,8905	0,8031	87,29
	KSUHE	0,9533	0,9010	0,9674	0,8841	0,8912	0,8043	88,19
	KG	0,9612	0,9471	0,9650	0,8813	0,9117	0,8387	89,50
U-Net	-	0,9629	0,9674	0,9618	0,8734	0,9117	0,8482	91,10
	HE	0,8863	0,6901	0,9405	0,7597	0,7205	0,5647	65,05
	KSUHE	0,9567	0,9274	0,9650	0,8779	0,9010	0,8211	87,56
	KG	0,9594	<b>0,9792</b>	0,9540	0,8529	0,9115	0,8376	<b>95,00</b>
SegNet	-	0,9641	0,9616	0,9648	0,8815	0,9196	0,8514	92,57
	HE	0,9631	0,9665	0,9622	0,8744	0,9179	0,8485	92,69
	KSUHE	0,9638	0,9636	0,9639	0,8792	0,9192	0,8506	92,94
	KG	<b>0,9660</b>	0,9664	0,9659	0,8853	<b>0,9239</b>	<b>0,8587</b>	92,64

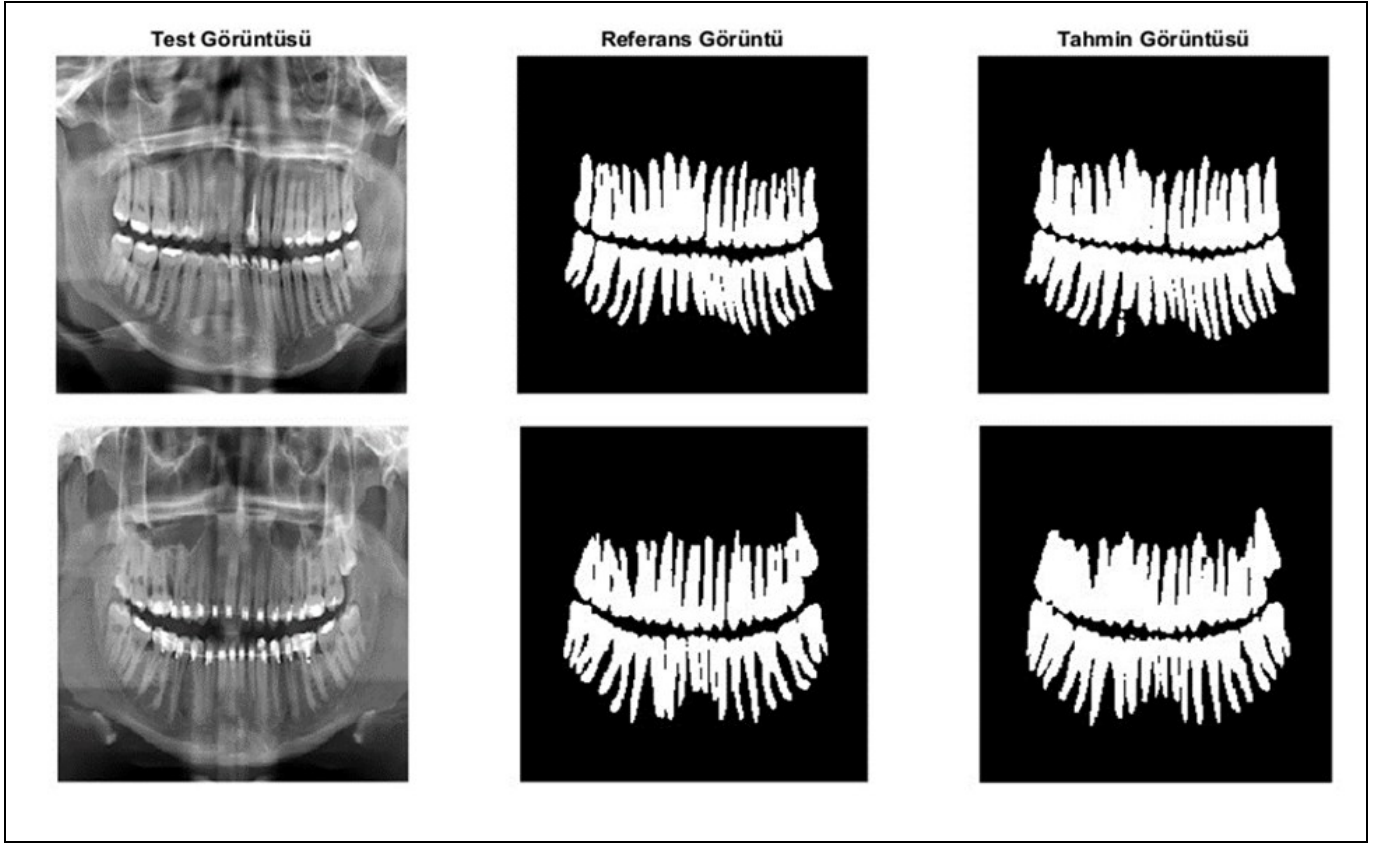
U-Net mimarisinde ise kullanılan ön işlemler doğrulukta iyileştirme göstermezken duyarlılık metriğinde KG ile en yüksek performans elde edilmiştir. Genel olarak bakıldığında, KG önışlemi ile eğitilmiş SegNet mimarisi, diğerlerine kıyasla doğruluk, dice ve jaccard performans metriklerinde en üstün performans göstermiştir. Ayrıca, U-Net mimarisi de duyarlılık ve validasyon doğruluğunda en üstün performans elde etmiştir.

Önışlem yöntemlerinin ESA mimarilerinde performansa etkisi bakıldığında, DeepLabv3+ ve SegNet mimarisi için KG önışlemi sırasıyla %0,79 ve %0,19 oranda performansı iyileştirmiştir. Bu çalışmada, KG önışlem yöntemi kullanılarak eğitilen SegNet mimarisi de diğerlerine kıyasla %96,60 doğruluk oranı ile en yüksek başarıma elde eden ESA mimarilerinden birisi olmuştur. En yüksek performansa sahip SegNet mimarisinin test veri seti üzerindeki test görüntüleri üzerindeki segmentasyon tahminine ilişkin bir örnek Şekil 7’de verilmiştir.

Şekil 7’de görüldüğü gibi, SegNet mimarisi referans görüntüye kıyasla az hata payı ile panoramik görüntülerinden diş bölgelerini doğru segmentasyon etmiştir. Bu çalışmada kullanılan SegNet, DeepLab ve U-Net mimarileri birbirlerine göre benzer özellikler içermektedir. Ancak, SegNet yapısında bir kodlayıcı ağına ve buna karşılık gelen bir kod çözücü ağına sahip olduğu için diğer ESA mimarilerine kıyasla üstün performanslar gösterebilmektedir. Ayrıca, SegNet eğitim sırasında düşük ağırlıklar kullanmakta ve bu durumda SegNet’I çeşitli problemlerde ön plana çıkartmaktadır. Bu çalışmadaki diş segmentasyonu problemi için de SegNet mimarisi, U-Net ve DeepLabv3+ mimarilerine göre en üstün performansı elde etmiştir. En yüksek performansa sahip KG önışlemli SegNet mimarisinin performansının, bu çalışmada diş segmentasyonu için kullanılan UESB veri seti üzerinde önceki çalışmalarda geliştirilmiş yöntemlerle karşılaştırması da tartışma bölümünde verilmiştir.

## 4 Tartışma

Diş segmentasyonu için çeşitli DL teknikleri geliştirilmiş ve literature sunulmuştur. Bu çalışmada kullanılan yöntem ve geliştirilen DL tabanlı ESA mimarileri UESB veri seti üzerinde kullanılarak geliştirilmiştir. Bu amaçla, bu çalışmada en yüksek performansı elde eden önerilen SegNet mimarisinin literature göre performans karşılaştırması için önceki çalışmalarda sadece UESB veri seti üzerinde önerilen yöntemler esas alınarak bir karşılaştırma yapılmıştır. Önerilen yöntemin, önceki çalışmalar ile performans metriklerine göre bir performans karşılaştırması da Tablo 3’te verilmiştir.



Şekil 7. SegNet mimarisinin test görüntüsü üzerindeki diş segmentasyonu tahmini

Figure 7. Prediction of tooth segmentation on the test image of the SegNet architecture

Tablo 3. Önerilen yöntemin UESB veri seti üzerindeki önceki çalışmalar ile performans karşılaştırması.

Table 3. Performance comparison of the proposed method with previous studies on the UESB dataset.

Kaynak	Yöntem	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	Dice	Jaccard
Silva ve diğ. (2018)	Mask RCNN	0.9208	0.7619	0.9612	0.8373	0.7944	-
Koch ve diğ. (2019)	FCN	0.9521	0.9437	0.9614	0.9331	<b>0.9363</b>	-
Zhao ve diğ. (2020)	TSASNet	<b>0.9694</b>	0.9377	<b>0.9781</b>	<b>0.9497</b>	0.9272	-
Lee et al. (2020)	R-CNN	-	0.893	-	0.858	0.875	-
da Silva Rocha ve diğ. (2022)	DoubleU-NET	0.9659	0.9270	-	0.9301	0.9287	-
Lin ve diğ. (2023)	KCNet	-	-	-	-	0.890	-
<b>Önerilen Yöntem</b>	<b>KG+SegNet</b>	0.9660	<b>0.9664</b>	0.9659	0.8853	0.9239	<b>0.8587</b>

Tablo 3'e bakıldığında, önerilen yöntem literatüre göre duyarlılık ve jaccard metriğinde en üstün performansı elde eden yöntemlerden birisi olmuştur. Ancak, önerilen yöntem doğruluk, özgüllük, kesinlik metriğinde TSASNet yöntemine ve dice performans metriğinde ise FCN yöntemine yakın performanslar elde ederek en başarılı yöntemlerden birisi olmuştur. Ayrıca, önerilen yöntemin diğer yöntemlere kıyasla bir farkı da, segmentasyon tabanlı DL mimarileri ve görüntü ön işlem yöntemlerinin birlikte kullanımı doğrultusunda kapsamlı gerçekleştirilen deneylerin sonucunda en başarılı yöntemin belirlenmiş olmasıdır. Bu yönde, önerilen yöntem görüntü ön işlem yöntemlerinden KG'nin SegNet mimarisi ile birlikte diş segmentasyonu problemlerinde başarımın artırılması için kullanılabilir etkili bir yöntem olduğunu da göstermiştir.

Özetle, yapılan deneyler ve elde edilen performans karşılaştırmaları doğrultusunda önerilen yöntem, UESB veri

seti üzerinde literature kıyasla kayda değer performans göstererek en etkili yöntemlerden birisi olduğunu göstermiştir. Ek olarak, KG ön işlem yönteminin de medikal görüntülerde özellikle diş segmentasyonu probleminde performansa yönelik önemli iyileştirmeler sağlayabileceği görülmüştür.

## 5 Sonuçlar

Panoramik diş röntgeni, düşük radyasyon dozu kullanarak ucuz ve hızlı bir şekilde tüm dişlerin görülebildiği görüntüleme sağlanmasından dolayı diş hekimliğinde tedavi planlamasında sıklıkla kullanılan yöntemlerden birisi olmuştur. Bu çalışmada ise panoramik diş röntgeni görüntülerinden diş segmentasyonu için son zamanlarda popüler olan U-Net, SegNet ve DeepLabv3+ mimarileri kullanılmış ve performans değerlendirmesi de UESB veri seti üzerinde yapılmıştır. Ayrıca, panoramik diş röntgen görüntüleri üzerinde HE, KSUHE ve KG gibi kontrast iyileştirme görüntü ön işlem yöntemlerini de



kullanarak, görüntü önışlem yöntemlerinin ESA mimarileri üzerindeki performansa etkisi ölçülmüştür. Elde edilen sonuçlara göre, bu çalışmada kullanılan tüm ESA mimarilerinin KG önışlem yöntemi kullanılarak yapılan performans değerlendirmesinde, diğer önışlem yöntemlerine kıyasla en üstün performanslar elde edilmiştir. Elde edilen performanslar arasından da en yüksek başarıyı, KG önışlemi ile eğitilmiş SegNet mimarisi göstermiştir. Bu amaçla, önerilen yöntemde KG önışlem yöntemi ve SegNet mimarisi tercih edilmiştir. Ayrıca, önerilen yöntem, diş segmentasyonu problemi için UESB veri seti üzerinde yapılan önceki çalışmalarla bir performans karşılaştırması yapılmıştır.

Performans karşılaştırmasından elde edilen bulgulara göre, önerilen yöntem literatüre göre en üstün ve kayda değer performans gösteren yöntemlerden biri olmuştur. Yapılan karşılaştırmalı sonuçlara göre önerilen yöntemde kullanılan SegNet mimarisi ve KG önışlem yöntemi, bilgisayar destekli diş segmentasyonu veya çeşitli diş problemlerin tespiti için geliştirilecek uygulamalarda kullanılabilecek güçlü bir araç olma potansiyeline sahip olduğu görülmüştür.

## 6 Conclusions

Panoramic dental radiography has become one of the most frequently used methods in dentistry for treatment planning, as it provides cost-effective and rapid imaging of all teeth while utilizing a low radiation dose. In this study, the recently popular U-Net, SegNet, and DeepLabv3+ architectures are employed for tooth segmentation from panoramic images, and their performance is evaluated using the UESB dataset. Additionally, contrast enhancement image preprocessing methods such as HE, CLAHE, and CS were applied to panoramic images to assess the impact of these image preprocessing methods on the performance of ESA architectures. Based on the results obtained, when evaluating the performance of all ESA architectures used in this study with the KG preprocessing method, the most superior performances were achieved compared to other preprocessing methods. Among the performance results, the SegNet architecture trained with the CS preprocessing exhibited the highest level of success. Therefore, the proposed method favors the utilization of the CS preprocessing method and the SegNet architecture. Furthermore, a performance comparison of the proposed method with previous studies on the UESB dataset for the tooth segmentation problem is conducted. According to the results obtained from this performance comparison, the proposed method stands out as one of the most superior and remarkable methods in the literature. Based on the comparative results, it is evident that the SegNet architecture and the CS preprocessing method employed in the proposed approach have the potential to serve as powerful tools for applications aimed at computer-aided tooth segmentation or the detection of various dental issues.

## 7 Yazar katkı beyanı

Gerçekleştirilen çalışmada İsmail KAYADİBİ fikrin oluşturulması, tasarım ve kod yazımı, literatür taraması, deneylerin gerçekleştirilmesi, makalenin yazılması ve sonuçların değerlendirilmesi hususunda; Utku KÖSE elde edilen sonuçların değerlendirilmesi, literatür taraması, yazım denetimi ve içeriğin kontrol edilmesi hususunda; Gür Emre GÜRAKSIN deneylerin gerçekleştirilmesi, elde edilen sonuçların değerlendirilmesi, yazım denetimi ve içeriğin kontrol edilmesi hususunda katkıda bulunmuştur.

## 8 Etik kurul onayı ve çıkar çatışması beyanı

"Hazırlanan makalede etik kurul izni alınmasına gerek yoktur".  
"Hazırlanan makalede herhangi bir çıkar çatışması bulunmamaktadır".

## 9 Kaynaklar

- [1] Mendonça EA. "Clinical decision support systems: perspectives in dentistry". *Journal of dental education*, 68(6), 589-597, 2004.
- [2] Terlemez A, Tassoker M, Kizilcakaya M, Gulec M. "Comparison of cone-beam computed tomography and panoramic radiography in the evaluation of maxillary sinus pathology related to maxillary posterior teeth: Do apical lesions increase the risk of maxillary sinus pathology?". *Imaging Science in Dentistry*, 49(2), 115-122, 2019.
- [3] Muresan MP, Barbura AR, Nedevschi S. "Teeth detection and dental problem classification in panoramic X-ray images using deep learning and image processing techniques". In *2020 IEEE 16th International Conference on Intelligent Computer Communication and Processing (ICCP)*, Cluj-Napoca, Romania, 03-05 September 2020.
- [4] Ward IR, Laga H, Bennamoun M. *RGB-D Image-Based Object Detection: From Traditional Methods to Deep Learning Techniques*. Editors: Rosin P, Lai YK, Shao L, Liu Y. RGB-D Image Analysis and Processing, 169-201, Springer Cham, 2019.
- [5] Ongsulee P. "Artificial intelligence, machine learning and deep learning". In *2017 15th international conference on ICT and knowledge engineering (ICT&KE)*, Bangkok, Thailand, 22-24 November 2017.
- [6] LeCun Y, Bengio Y, Hinton G. "Deep learning". *Nature*, 521(7553), 436-444, 2015.
- [7] Uysal E, Güraksin GE. "Computer-aided retinal vessel segmentation in retinal images: convolutional neural networks". *Multimedia Tools and Applications*, 80, 3505-3528, 2021.
- [8] Kayadibi I, Güraksin GE. "An early retinal disease diagnosis system using OCT images via CNN-based stacking ensemble learning". *International Journal for Multiscale Computational Engineering*, 21(1), 1-15, 2023.
- [9] Şener E, Gürses B. "Diş hekimliği pratiğinde yapay zekânın ilk basamağı: Segmentasyon uygulamaları". *Current research in dental sciences*, 33(1), 40-49, 2023.
- [10] 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". *Dentomaxillofacial Radiology*, 51(2), 1-8, 2022.
- [11] Lee JH, Kim DH, Jeong SN. "Diagnosis of cystic lesions using panoramic and cone beam computed tomographic images based on deep learning neural network". *Oral diseases*, 26(1), 152-158, 2020.
- [12] Silva G, Oliveira L, Pithon M. "Automatic segmenting teeth in X-ray images: Trends, a novel data set, benchmarking and future perspectives". *Expert Systems with Applications*, 107, 15-31, 2018.
- [13] Zhu H, Cao Z, Lian, L, Ye G, Gao H, Wu J. "CariesNet: a deep learning approach for segmentation of multi-stage caries lesion from oral panoramic X-ray image". *Neural Computing and Applications*, 35, 16051-16059, 2022.

- [14] Muresan MP, Barbura AR, Nedeveschi, S. "Teeth detection and dental problem classification in panoramic X-ray images using deep learning and image processing techniques". In *2020 IEEE 16th International Conference on Intelligent Computer Communication and Processing (ICCP)*, Cluj-Napoca, Romania, 3-5 September 2020.
- [15] Kayadibi İ, Güraksın GE, Ergün U. "ESA tabanlı göz durumu tespitinde görüntü ön işleme yöntemlerinin etkisi". *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 11 (3), 496-505, 2022.
- [16] Kayadibi İ, Güraksın GE. "An explainable fully dense fusion neural network with deep support vector machine for retinal disease determination". *International Journal of Computational Intelligence Systems*, 16(1), 1-20, 2023.
- [17] Deperlioglu O, Kose U, Gupta D, Khanna A, Giampaolo F, Fortino G. "Explainable framework for Glaucoma diagnosis by image processing and convolutional neural network synergy: analysis with doctor evaluation". *Future Generation Computer Systems*, 129, 152-169, 2022.
- [18] Vasuki P, Kanimozhi J, Devi MB. "A survey on image preprocessing techniques for diverse fields of medical imagery". In *2017 IEEE International Conference on Electrical, Instrumentation and Communication Engineering (ICEICE)*, Karur, Tamilnadu, India, 27-28 April 2017.
- [19] Cheng HD, Shi XJ, Min R, Hu LM, Cai XP, Du HN. "Approaches for automated detection and classification of masses in mammograms". *Pattern Recognition*, 39(4), 646-668, 2006.
- [20] Annadurai S. *Fundamentals of Digital Image Processing*. 1<sup>st</sup> ed. Tamil Nadu, India, Pearson Education, 2007.
- [21] Pisano ED, Zong S, Hemminger BM, DeLuca M, Johnston R E, Muller K, Pizer SM. "Contrast limited adaptive histogram equalization image processing to improve the detection of simulated spiculations in dense mammograms". *Journal of Digital imaging*, 11, 193-200, 1998.
- [22] Daubechies I. Orthonormal bases of compactly supported wavelets. *Communications on pure and applied mathematics*, 41(7), 909-996, 1988.
- [23] Sheba KU, Raj SG. "Objective quality assessment of image enhancement methods in digital mammography—a comparative study". *Signal & Image processing: An International Journal*, 7(4), 1-13, 2016.
- [24] Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, Sánchez CI. "A survey on deep learning in medical image analysis". *Medical Image Analysis*, 42, 60-88, 2017.
- [25] Ronneberger O, Fischer P, Brox T. "U-net: Convolutional networks for biomedical image segmentation". In *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015: 18th International Conference*, Munich, Germany, 5-9 October 2015.
- [26] Badrinarayanan V, Kendall A, Cipolla R. "Segnet: A deep convolutional encoder-decoder architecture for image segmentation". *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(12), 2481-2495, 2017.
- [27] Chen LC, Zhu Y, Papandreou G, Schroff F, Adam H. "Encoder-decoder with atrous separable convolution for semantic image segmentation", In *Proceedings of the 15th European conference on computer vision (ECCV)*, Munich, Germany, 8-14 September 2018.
- [28] Goutte C, Gaussier E. "A probabilistic interpretation of precision, recall and F-score, with implication for evaluation". In *Advances in Information Retrieval: 27th European Conference on IR Research*, Santiago de Compostela, Spain, 21-23 March 2005.
- [29] Eelbode T, Bertels J, Berman M, Vandermeulen D, Maes F, Bisschops R, Blaschko MB. "Optimization for medical image segmentation: theory and practice when evaluating with dice score or jaccard index". *IEEE Transactions on Medical Imaging*, 39(11), 3679-3690, 2020.
- [30] Akalın F, Yumusak N. "Derin öğrenme tabanlı topluluk sınıflandırıcı yaklaşımı ile gastrointestinal anomalilerin tespiti". *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 30(3), 366-373, 2024.
- [31] Koch TL, Perslev M, Igel C, Brandt SS. "Accurate segmentation of dental panoramic radiographs with U-Nets". In *2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019)*, Venice, Italy, 8-11 April 2019.
- [32] Zhao Y, Li P, Gao C, Liu Y, Chen Q, Yang F, Meng D. "TSASNet: Tooth segmentation on dental panoramic X-ray images by two-stage attention segmentation network". *Knowledge-Based Systems*, 206, 1-10, 2020.
- [33] Lee JH, Han SS, Kim YH, Lee C, Kim I. "Application of a fully deep convolutional neural network to the automation of tooth segmentation on panoramic radiographs". *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, 129(6), 635-642, 2020.
- [34] da Silva Rocha É, Endo PT. "A comparative study of deep learning models for dental segmentation in panoramic radiograph". *Applied Sciences*, 12(6), 1-12, 2022.
- [35] Lin S, Hao X, Liu Y, Yan D, Liu J, Zhong M. "Lightweight deep learning methods for panoramic dental X-ray image segmentation". *Neural Computing and Applications*, 35(11), 8295-8306, 2023.
- [36] Kayadibi İ, Güraksın GE, Köse U. "A hybrid R-FTCNN based on principal component analysis for retinal disease detection from OCT images". *Expert Systems with Applications*, 230, 1-15, 2023.