



# İnsan Omurgasına Ait Bilgisayarlı Tomografi Görüntülerinin İyileştirilmesi ve Omur Segmentasyonu

Murat Türkmen<sup>1\*</sup>, Zeynep Orman<sup>2</sup>

<sup>1\*</sup> İstanbul Üniversitesi-Cerrahpaşa, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul, Türkiye, (ORCID: 0000-0003-2375-5337), [muratturkmen@baskent.edu.tr](mailto:muratturkmen@baskent.edu.tr)

<sup>2</sup> İstanbul Üniversitesi-Cerrahpaşa, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul, Türkiye (ORCID: 0000-0002-0205-4198), [ormanz@iuc.edu.tr](mailto:ormanz@iuc.edu.tr)

(İlk Geliş Tarihi 4 Temmuz 2023 ve Kabul Tarihi 9 Eylül 2023)

(DOI: 10.5281/zenodo.10259100)

**ATIF/REFERENCE:** Türkmen, M., Orman, Z., (2023). İnsan Omurgasına Ait Bilgisayarlı Tomografi Görüntülerinin İyileştirilmesi ve Omur Segmentasyonu. *Avrupa Bilim ve Teknoloji Dergisi*, (52), 95-103.

## Öz

Günümüzde insan omurgası ile ilişkili birçok sağlık sorunu mevcuttur. Omurga rahatsızlıklarının tespitinde biyomedikal görüntüler sıklıkla kullanılmaktadır. Bunların önde geleni ise Bilgisayarlı Tomografi (BT) teknolojisidir. BT görüntülerinden omurga rahatsızlıklarının doğru ve hızlı tespit edilmesi hasta tedavisinde önemli rol oynar. Bunun için BT görüntülerinin değerlendirme aşamasında kaliteli görüntülere ihtiyaç duyulmaktadır. Bu çalışmada VerSe veri kümesi kullanılarak görüntü iyileştirilmesi amacıyla ayrık dalgacık dönüşüm (discrete wavelet transform) yöntemi kullanılmıştır. Bağlı bileşen yöntemi ile görüntüdeki omurlar etiketlenmiştir. İyileştirilmiş BT görüntülerindeki omurlar evrişimli sinir ağı olan U-Net yöntemi uyarlanarak segmente edilmiştir. İyileştirme ve segmentasyon yöntemi uygulandıktan sonra doğruluk oranı %99.4, özgüllük oranı %99.8 ve hassasiyet oranı %99.2 olarak elde edilmiştir. Dice segmentasyon skoru ham görüntülerin iyileştirilmesi sonucunda %65.1'den %74.5'e yükseltilmiştir. Çalışmanın sonuçları literatürde VerSe veri kümesi ile yapılan diğer segmentasyon sonuçları ile kıyaslanmış; farklılıkları belirtilmiş ve daha başarılı sonuçlar elde edildiği gösterilmiştir.

**Anahtar Kelimeler:** Görüntü işleme, CNN U-Net modeli, bilgisayarlı tomografi, omur segmentasyonu.

## Enhancement of Computed Tomography Images of the Human Spine and Spine Segmentation

### Abstract

Today, there are many health problems associated with the human spine. Biomedical images are frequently used in the detection of spinal disorders. Chief among these is IT technology. Accurate and rapid detection of spinal disorders from CT images plays an important role in patient treatment. For this, quality images are needed in the evaluation phase of CT images. In this study, the discrete wavelet transform method was used for image enhancement using VerSe dataset. The vertebrae in the image are labeled with the connected component method. The vertebrae in the enhanced CT images were segmented by adapting the convolutional neural network U-Net method. With respect to the enhancement and segmentation method, the proposed model had 99.4% accuracy rate, 99.8% specificity rate, and 99.2% sensitivity rate. The dice segmentation score was increased from 65.1% to 74.5% as a result of improving the raw images. The results of the study were compared with other segmentation results made with the VerSe data set in the literature; differences were stated and more successful results were shown.

**Keywords:** Image processing, CNN U-Net model, computed tomography, spine segmentation.

\* Sorumlu Yazar: [muratturkmen@baskent.edu.tr](mailto:muratturkmen@baskent.edu.tr)

## 1. Giriş

Geçmişten günümüze yapay zeka teknikleri sağlık alanında etkin bir biçimde kullanılmaktadır. Hastalık tespitlerinde ve analizlerinde biyomedikal görüntüleme yöntemlerine başvurulmaktadır. Söz konusu yöntemler, insan omurgası rahatsızlıklarının tedavi edilmesinde yardımcı çözümler olarak sunulmaktadır. İnsan omurgası ile ilişkili hastalıklar, gündelik hayatı etkileyen önemli sağlık sorunları arasında yer almaktadır. Omurgada meydana gelen pondilolistezis (bel kayması), kamburluk (kifoz), skalyoz (omurga eğriliği), travma, osteoporoz (kemik erimesi) ve omurga kırığı gibi hastalıklar sıklıkla rastlanan rahatsızlıklardır.

Son yıllarda, insan omurgası rahatsızlıklarının tespiti çalışmalarında çeşitli görüntüleme teknolojileri geliştirilmiştir. Görüntüleme teknolojilerinden bazıları Röntgen (X-ray) görüntüleme, BT, sayısal meme tomosentezi (DBT), manyetik rezonans görüntüleme (MRI), nükleer görüntüleme (PET-SPECT), ultrasonografi, elektriksel empedans tomografisi (EIT) ve termal kızılötesi görüntüleme (IRT) şeklinde sayılabilir. Görüntüleme teknolojilerinden BT, omurga rahatsızlıklarında iyonlaştırıcı radyasyon yaymasına rağmen tercih edilir. BT teknolojisi; sagittal (yan), koroner (ön ve arka) ve aksiyal (tepe) olarak omurga görüntülerini inceleme imkanı sunar.

Literatürde, görüntü iyileştirme yöntemleri görüntüden başarılı analizler yapmak ve sınıflandırma sonuçları elde etmek gibi amaçlarla kullanılmaktadır. Görüntü iyileştirme yöntemlerini mekânsal ve frekans alan teknikleri olarak ayırmak mümkündür.

Biyomedikal görüntülerde insan okumasını başarılı bir şekilde gerçekleştirmek için segmentasyon ile renklendirme yöntemleri kullanılmaktadır. Omurga görüntülerindeki omurların segmentasyonu çeşitli yöntemler aracılığıyla gerçekleştirilebilmektedir.

Görüntülerdeki omurların doğru bir şekilde segmentasyonunun yapıldığını ölçmek için dice coefficient, doğrusalık, hassasiyet, özgüllük ve ortalama birleştirme kesişimi (Intersection over Union - IOU) değerlendirme kriterleri kullanılabilir. Değerlendirme ölçütleri, segmentasyon çıktılarının başarısını ve güvenilirliğini ortaya koymaktadır.

Bu makalede VerSe veri kümesi kullanılarak dalgacık dönüşümü, etiketleme ve U-Net yöntemleriyle omurga segmentasyonu üzerine çalışılmıştır. Makalenin sonraki bölümleri şu şekilde düzenlenmiştir: Bölüm 2’de literatürde konuyla ilgili yapılan çalışmalar analiz edilerek çalışmanın özgünlüğü belirtilmiştir. Bölüm 3’de çalışmada kullanılan veri kümesi ve segmentasyon yöntemleri ele alınmıştır. Bölüm 4’de önerilen model detaylı bir şekilde anlatılmıştır. Bölüm 5’de çalışma sonucunda elde edilen sonuçlar sunulmuştur. Son olarak, Bölüm 6’da araştırma çıkarımları ve sonuçları tartışılmıştır.

## 2. İlgili Çalışmalar

İnsan omurgası ilişkili rahatsızlıkları tespit etmek amacıyla gerçekleştirilen bilgisayar destekli omur segmentasyonu çalışmaları geçmişten günümüze kadar devam etmiştir.

Literatürde omurga segmentasyonunda kullanılan yöntemler ile ilgili çeşitli çalışmalar mevcuttur. Mallat, çalışmalarında dalgacık dönüşümünün sinyal işleyebileceğini ortaya koymuştur (Mallat vd., 1999). DeVore ve arkadaşları dalgacık dönüşümü kodlaması yoluyla görüntü sıkıştırma çalışmalarını yapmışlardır (DeVore vd., 1992). Mihçak ve arkadaşları, dalgacık dönüşümü formülünü görüntülerde gürültü azaltma ve iyileştirmede kullanılabileceğini kanıtlamışlardır (Mihçak vd., 1999).

Sekuboyina ve arkadaşları, VerSe veri kümesini sunmakla birlikte Btrfly mimarisini geliştirmişlerdir ve bir omurga yerelleştirme modülü ile genişletmişlerdir. Eşzamanlı olarak, üretken çekişmeli öğrenme alanından ilham alarak, omurganın anatomik önceki bilgisini Btrfly ağına uygulayan bir öğrenme modülünü araştırmışlardır (Sekuboyina vd., 2021). Löffler ve arkadaşları VerSe veri kümesindeki kırıklar eğitilmiş öğrenme yöntemi CNN ile sınıflandırmışlardır (Löffler vd., 2020). Schinz ve arkadaşları, VerSe veri kümesi ile anatomik varyasyonlar ve çoklu tarayıcı verileri içeren bir bilgisayarlı tomografi omur veri kümesini segmente edilmiş şekilde tekrar oluşturmuşlardır (Liebl vd., 6).

Pang ve arkadaşları, lomber dar kanal teşhisi için eksenel MR görüntüleri üzerinde otomatik omurga indeksleri ölçümü elde etmek amacıyla bir segmentasyon kılavuzlu regresyon ağı (SGRNet) önermişlerdir. Segmentasyon aşamasını bir U-Net segmentasyon kodlayıcı ve kod çözücü içeren benzer ağ ile gerçekleştirmişlerdir (Pang vd., 2023). Qadri ve arkadaşları, yığılan seyrek otomatik kodlayıcı (SSAE) kullanarak etiketlenmemiş verilerden ayırt edici özellikleri çıkarmak için yama tabanlı bir derin öğrenme yaklaşımı önermektedir (Qadri vd., 2023). Yang ve arkadaşları, omurgayı bölümlere ayırmak için bir derin öğrenme yöntemi önermişlerdir. Segmentasyon sonuçlarını optimize etmek ve net segmentasyon kenarlarının etkisini elde etmek için bir ortak kayıp fonksiyonu kullanmışlardır (Yang vd., 2023). Cao ve arkadaşları, 3D Slicer tıbbi görüntü analiz platformu içinde derin öğrenme tabanlı segmentasyon modeli uygulayarak gerçek zamanlı spinal ultrason rekonstrüksiyonu ve görselleştirme sistemi oluşturmuşlardır (Cao vd., 2022). Fatima ve arkadaşları, vertebra lokalizasyonu ve omurga segmentasyonu için hibrit bir yaklaşım sunmuşlardır. Yerelleştirme sonuçları, YOLOv5'e göre ortalama kesinliğin 0,5 eşliğinde 0,94 olduğu görülmüştür (Fatima vd., 2022). Zhao ve arkadaşları, manyetik rezonans (MRI) görüntülerinden omurga sinir demeti segmentasyonu için yapay sinir ağı olan RA2 – Net yöntemini önermişlerdir (Zhao vd., 2022). Aydogdu ve arkadaşları, birkaç evrişimli Sinir Ağı (CNN) mimarisini tek aşamalı bir segmentasyon boru hattında değerlendirmişlerdir. BT taramaları ile veri kümesini voksel varyasyonunu ve yönünü düzeltmek için önceden işlemişlerdir (Aydogdu vd., 2022). Wang ve arkadaşları, MR görüntülerinde omurların ve omur disklerinin otomatik olarak bölümlenmesini sağlamak için bir omurga bölümlendirme önermişlerdir. Yöntemlerini, omur ve disk segmentasyonu için 172 MR hacimsel görüntüden oluşan genel bir omurga veri kümesi üzerinde test etmişlerdir (Wang vd., 2022). Yamakawa ve arkadaşları, MR görüntülerini Textonboost yöntemini diferansiyel evrim ve stokastik tepe tırmanma yöntemlerini kullanarak iyileştirmişlerdir (Yamakawa vd., 2022).


Literatürde yapılan çalışmalar incelendiğinde, omurga segmentasyonunun bilgisayar destekli teşhiste önemli bir adım olduğu görülmektedir. Bu sorunu çözmeyi amaçlayan mevcut yöntemler genellikle bir tür açık model kullanır. Bununla birlikte, yeterince güvenilir bir model oluşturmak için, yüksek miktarda uygun şekilde etiketlenmiş verilere ihtiyaç vardır. Veri kümelerinde yapılan etiketlemeler ve segmentasyon çıktıları her zaman erişilebilir değildir. Ayrıca, segmentasyon öncesinde biyomedikal görüntüler üzerinde ön iyileştirme ve onarma işlemleri gerekmektedir. Önerilen yöntemin literatürdeki çalışmalardan farklılıkları ve özgün yönleri aşağıda özetlenmiştir:

- U-Net segmentasyon yöntemi VerSe veri setine uyarlanarak 5 katmanlı biçimde kullanılmıştır.
- Ayrık dalgacık dönüşümü yöntemi ile ilk kez VerSe veri seti görüntüleri iyileştirilmiştir.
- Omur etiketlemek için ilk kez bağlı bileşen etiketleme yöntemi kullanılarak etiketler belirlenmiştir.
- Önerilen model omurganın bir parçası değil CT taramalarından elde edilen tüm omurga segmentasyonu oluşturmak amacıyla geliştirilmiştir. Omurga rahatsızlarından kemik erimesi ile sınırlı kalan problemler değil, bel fıtığı, disk kayması gibi diğer rahatsızlıkları da kapsayan omurlar renklendirilmiştir.
- Değerlendirme ölçütlerinden sadece Dice skoru değil, doğruluk, hassaslık, özgünlük gibi ölçütlerde kullanılmıştır.
- VerSe veri seti ile yapılan diğer çalışmalar bu çalışma ile kıyaslanarak verilmiştir.

### 3. Materyal ve Metot

#### 3.1. Veri Kümesi

Omur etiketleme ve segmentasyon, otomatik bir omurga işleme boru hattındaki iki temel görevdir. Omurga görüntülerinin güvenilir ve doğru bir şekilde işlenmesinin teşhis, cerrahi planlama ve omurga ve kemik sağlığının nüfusa dayalı analizi için klinik karar destek sistemlerine fayda sağlaması beklenmektedir. Bununla birlikte, omurga işleme için otomatik algoritmalar tasarlamak, ağırlıklı olarak anatomi ve edinim protokollerindeki önemli farklılıklar ve kamuya açık verilerin ciddi eksikliği nedeniyle zordur. Bu sınırlamaları ele alan büyük ölçekli Vertebra Segmentasyonu (VerSe), 2019 ve 2020 gerçekleştirilen Uluslararası Tıbbi Görüntü Hesaplama ve Bilgisayar Destekli Müdahale Konferansı'nda (MICCAI) gerekli etik kurul izinleri alınarak açık kaynak sunulmuştur (<https://osf.io/nqjyw/>). Bu amaçla, 355 hastadan alınan toplam 374 BT taramasını içeren iki veri kümesi hazırlandı ve 4505 omur, insan-makine hibrit algoritması tarafından vokselle seviyesinde ayrı ayrı kaydedildi (Sekuboyina vd., 2020). VerSe'nin temel çıkarımına göre bir omurga taramasını etiketleme ve bölümlere ayırmada bir algoritmanın performansı, nadir anatomik varyasyonların olduğu durumlarda omurları doğru bir şekilde tanımlama yeteneğine bağlıdır. Şekil 1'de veri kümesine ait görüntüler verilmiştir.



**Şekil 1.** Verse veri kümesi ham görüntü örneği (Sekuboyina vd., 2020) (Example of Verse dataset raw image)

Şekil 1'de görüldüğü üzere omur ve disklere yönelik gözle analiz yapmak oldukça güçtür. Bu nedenle ham verinin iyileştirilerek insan okumasına karar destek sağlayacak görüntüler elde etmek gerekmektedir.

#### 3.2. Görüntü Ön İyileştirme

Görüntü ön iyileştirmede kullanılan ayrık dalgacık dönüşümleri, özelliklerin farklı ölçeklerde değişiklik gösterdiği verileri analiz etmek için kullanılan matematiksel araçlardır. Sinyaller için, özellikler zaman içinde değişen frekanslar, geçişler veya yavaş değişen eğilimler olabilir. Görüntüler için özellikler, kenarları ve dokuları içerir. Ayrık dalgacık dönüşümleri, öncelikle Fourier dönüşümünün sınırlamalarını ele almak için yaratılmıştır. Eş sinyalleri, zaman serisi mali verileri ve biyomedikal sinyaller tipik olarak geçici olaylarla noktalanmış parçalı düzgün davranış sergiler. Benzer şekilde, görüntüler tipik olarak, kenarlar olarak görünen geçici olaylarla ayrılmış homojen, parçalı düz bölgeleri içerir. Hem sinyaller hem de görüntüler için, düzgün bölgeler ve geçişler, ayrık dalgacık dönüşümleriyle seyrek olarak temsil edilebilir.

Bir ayrık dalgacık, sinüs dalgasından farklı olarak, hızla azalan, dalga benzeri bir salınımdır. Bu, ayrık dalgacıkların verileri birden çok ölçekte temsil etmesini sağlar. Uygulamaya bağlı olarak farklı ayrık dalgacıklar kullanılabilir (Agboola ve Zacchters, 2023; Unser ve Aldroubi, 1996; Murala ve Mahaswari, 2012). Çalışma kapsamında kullanılan ayrık dalgacık dönüşümü Formül 1'de verilmiştir.


$$W(j, k) = \sum_j \sum_k x(k) 2^{\frac{j}{2}} \psi(2^{-j}n - k) \quad (1)$$

Formül 1'de verilen  $j$  ve  $k$  tam sayı olarak kaydırma parametreleri,  $x(k)$  noktanın izdüşümü,  $\psi$  fonksiyonu dalgacık katsayısı ve  $n$  kesme frekans değeridir.

### 3.3. Görüntü Ön İyileştirme


MRI ve BT gibi biyomedikal görüntülerde istenilen çerçeveyi elde etmek için bağlı bileşen etiketleme yöntemine başvurulabilmektedir (He vd., 2009; Javonmandi ve Tasdizen, 2018). Görüntü omur etiketlemede, bağlı bileşen yöntemi kullanılmıştır. Omur etiketleme ve sonrasında segmentasyona yardımcı olacak şekilde veri setine uyarlanmıştır.

Segmentasyon işleminde kullanılan U-net, görüntülerin hızlı ve hassas bir şekilde bölünmesi için geliştirilmiş evrişimli bir ağ mimarisidir. Şekil 2’de ağ mimarisinin uygulandığı ham görüntü ve çıktısı gösterilmiştir (Ronnerberger vd., 2015).



Şekil 2. U-Net uygulanan görüntü (Ronnerberger vd., 2015) (U-Net implemented image)

Şekil 3’de U-Net evrişimli sinir ağı mimarisi verilmiştir (Falk vd., 2019).



Şekil 3. U-Net evrişimli sinir ağı mimarisi (Falk vd., 2019) (U-Net convolutional neural network architecture)

Şekil 3’de verilen mimaride görüntünün önce bölündüğü daha sonra birleştiği açıkça görülmektedir. Girdi görüntüleri ve bunlara karşılık gelen segmentasyon haritaları, ağı Caffe’nin (Cia vd., 2014) stokastik gradyan iniş uygulamasıyla eğitmek için kullanılır. Ek yükü en aza indirmek ve GPU belleğinden maksimum düzeyde yararlanmak için, büyük toplu bir iş boyutu yerine büyük giriş kutucukları tercih edilmektedir; ve bu nedenle toplu iş tek bir görüntüye indirgenmektedir. Buna göre, daha önce görülen çok sayıda eğitim örneğinin mevcut optimizasyon adımıdaki güncellemeyi belirleyeceği şekilde yüksek bir momentum (0.99) kullanılmaktadır. Formül 2’de U-Net performans değerlendirmede kullanılan ikili çapraz entropi  $L_{bce}$  verilmiştir.

$$L_{bce} = \sum_i y_i \log o_i + (1-y_i) \log(1-o_i) \quad (2)$$

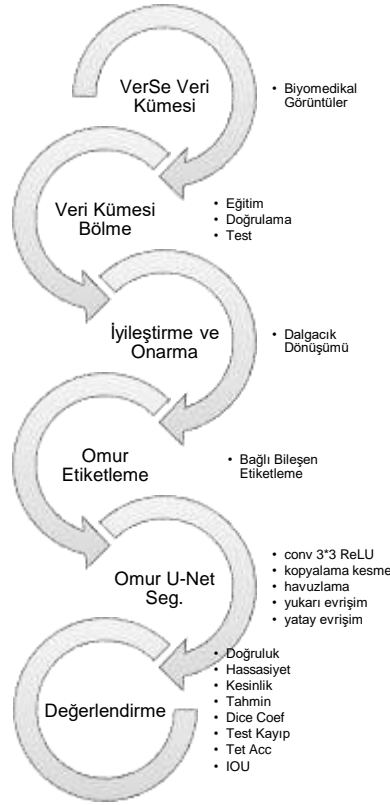
Formül 3’de U-Net değerlendirme ölçütlerinden bir diğeri Dice kayıp denklemi verilmiştir.

$$L_{Dice} = -\frac{2 \sum_i o_i y_i}{\sum_i o_i + \sum_i y_i} \quad (3)$$

Formül 2 ve Formül 3’de  $i$  indis değeri,  $y_i$  tahmin edilmeyen etiket fonksiyonu ve  $o_i$  ise tahmin edilmiş etiket fonksiyonunu temsil etmektedir.

## 4. Önerilen Model

Önerilen modelde VerSe omurga veri kümesi işlenmiştir. Bu veri kümesinin ön iyileştirme ve onarma aşamasında dalgacık dönüşümü yöntemi kullanılmıştır. Omur etiketleme için bağlı bileşen etiketleme yöntemine başvurulmuştur. Daha sonra U-Net evrişimli sinir ağı 5 katmanlı şekilde uyarlanarak görüntü omurları segmentasyonu gerçekleştirilmiştir. Son olarak, model performansı değerlendirilmiştir. Şekil 4’de önerilen modelin akış diyagramı verilmiştir.




Şekil 4. Önerilen model akış diagramı (Suggested model flowchart)

İlk olarak biyomedikal görüntü veri kümesi alınmıştır. Veri kümesi eğitim (%60), doğrulama (%20) ve test (%20) olarak bölünmüştür. Bir sonraki aşamada eğitim kümesi görüntüleri üzerinde dalgacık dönüşümü ile iyileştirme ve onarma yapılmıştır. Etiketleme işlemi her bir hasta görüntüsü için sagittal açıdan bağlı bileşen yöntemi ile gerçekleştirilmiştir. Omur U-Net segmentasyonunda U-Net 5 katmanlı olarak veri kümesine uyarlanmıştır. Görüntülerdeki omurların bölütlenmiş çıktıları elde edilmiştir. Son olarak, model performansı, değerlendirme ölçütleri kullanılarak irdelenmiştir.

## 5. Araştırma Sonuçları ve Tartışma


Veri kümesindeki hasta görüntülerine uygulanan dalgacık dönüşümü girdi ve çıktıları Şekil 5’de gösterilmiştir.



Şekil 5. Ayrık dalgacık dönüşümü iyileştirme girdi ve çıktıları (Discrete wavelet transform enhancement inputs and outputs)


Şekil 5’te orijinal görüntü, her biri orijinal görüntü parlaklıktaki yerel değişiklikleri baz alarak üç büyük görüntü sağlayan yüksek geçişli filtreden geçirilmiştir. Daha sonra düşük geçişli filtreden geçirilmiştir ve ölçeği küçültülmüştür. Şekil 5 incelendiğinde girdi görüntüsündeki koroner açıdan omurlar çıktı görüntüsünde daha belirgin hale gelmiştir ve aksiyal açıdan hatlar netleşmiştir. Böylece iyileştirilmiş çıktı görüntüsü elde edilmiştir.

Şekil 6’da omur görüntülerinin bağlı bileşen yöntemi ile etiketlenmesinin örnekleri verilmiştir. Burada bir hastaya ait sagittal açı omur etiketleri gösterilmiştir.




Şekil 6. Hataya ait omurların etiketlenmesi (Labeling of faulty vertebrae)

Sonraki adımda, omurlar etiketlenerek U-Net için semantik segmentasyona hazır hale getirilmiştir ve her omur farklı renk ile işaretlenmiştir. Şekil 7’de segmente edilmiş farklı hastalara ait omurga örnekleri gösterilmektedir.



Şekil 7. Segmente edilmiş hasta omurga görüntüleri (Segmented patient spine images)

Omurların tek başına incelenmesine fırsat tanımak için sadece omurgadan oluşan görüntüler de elde edilmiştir. Şekil 8’de omurga ve insan biyomedikal görüntüsü üzerinde segmente edilmiş omurlar gösterilmiştir.



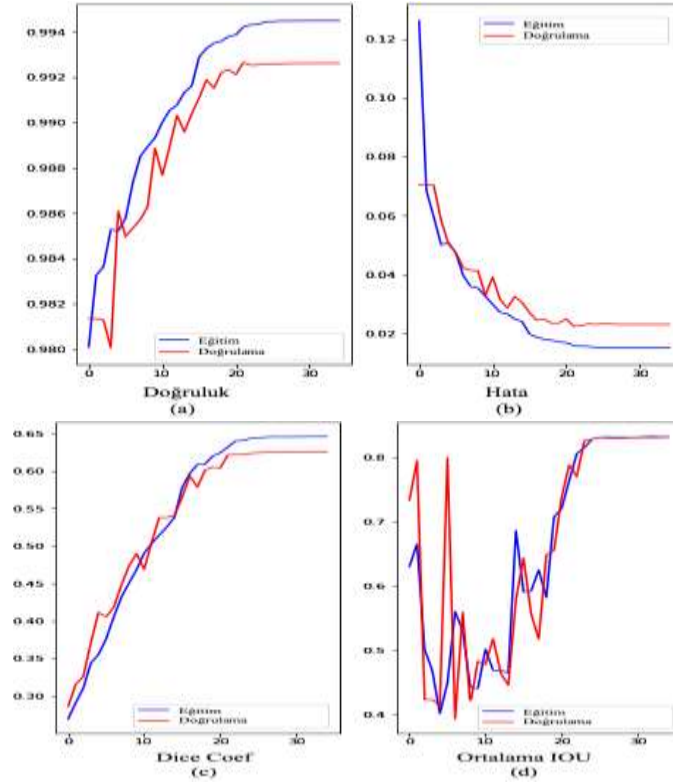
Şekil 8. Segmente edilmiş omurga dicom görüntüleri (Segmented spine dicom images)

Burada omurga ve ilişkili görüntünün tümü segmente edilmiştir. Şekil 9’da segmente edilen görüntülerin veri kümesi dağılımı gösterilmiştir.



Şekil 9. Veri kümesinin eğitim, doğrulama ve test olarak bölünmesi (Splitting the dataset into training, validation and testing)

Şekil 9’de gösterildiği üzere veri kümesinde çaprazlama amacıyla doğrulama kümesi de oluşturulmuştur. Aşırı uyum göstermenin önüne geçmek için bu küme ayrılmıştır. Eğitim aşamasında elde edilen modelin performansını değerlendirmek için kullanılan alt bir veri olan doğrulama seti oluşturulmuştur. Ayrıca, bu veri seti hangi modelin iyi olduğunu belirlemek ve modeller için en uygun parametreleri ayarlamak için bir test platformu sağlamıştır. Şekil 10’da U-Net ile segmentasyon edilmiş eğitim ve doğrulama verilerinin değerlendirme sonuçları verilmiştir.



**Şekil 10.** Eğitim ve doğrulama verilerinin segmentasyon değerlendirme grafikleri (Segmentation evaluation graphs of training and validation data)

Şekil 10'da vakalar için segmentasyon sonuçları doğruluk oranlarının eğitim kümesinde %99.4'ün ve doğrulama kümesinde %99.2'nin üzerine ulaştığı görülmektedir. Şekil 10.b'de eğitim ve doğrulama kümesinde hatanın sırasıyla 0.1 ve 0.2'nin altında olduğu gösterilmektedir. Şekil 10.c'de dice coef segmentasyon değerlendirme ölçütü için eğitim ve doğrulama kümelerinde %65'e yakın oranlar elde edilmiştir. Şekil 10.d'de eğitim ve doğrulama kümesi ortalama IOU değeri %80 değerinin üzerinde performans göstermiştir.

Tablo 1'de test, eğitim ve doğrulama segmentasyon değerlendirme sonuçları ve literatürdeki diğer çalışmalar ile karşılaştırılması verilmiştir.

**Tablo 1.** Önerilen modelin literatürdeki çalışmalar ile karşılaştırılması (Comparison of the proposed model with the studies in the literature)

| Değerlendirme Ölçütü     | Önerilen Model | Btrfly (Sekiboyuna vd., 2021) | Btrfly* (Zakharov vd., 2023) | Cor +Sag (Altini vd., 2021) |
|--------------------------|----------------|-------------------------------|------------------------------|-----------------------------|
| Doğruluk                 | <b>0.994</b>   | 0.834                         | 0.879                        | 0.795                       |
| Ortalama IOU             | 0.831          | -                             | -                            | -                           |
| Dice Coef                | 0.651          | -                             | -                            | -                           |
| Tahmin                   | <b>0.994</b>   | 0.802                         | 0.799                        | 0.795                       |
| Hassaslık (Sensitivity)  | <b>0.992</b>   | 0.879                         | 0.851                        | 0.825                       |
| Özgüllük (specificity)   | 0.998          | -                             | -                            | -                           |
| İyileştirilmiş Dice coef | 0.745          | -                             | -                            | -                           |
| Test loss                | 0.017          | -                             | -                            | -                           |
| Test acc                 | 0.994          | -                             | -                            | -                           |

Tablo 1'de literatürde segmentasyon değerlendirmede sıklıkla kullanılan doğruluk, tahmin ve hassaslık ölçütleri baz alınmıştır. İnsan sağlığını yakından ilgilendiren çalışmalara güvenilirliği arttırmak ve omurga rahatsızlıklarının tespitinde doğru kararlar verilmesine destek sağlayabilmek için segmentasyon sonuçlarının güvenilir olması önem teşkil etmektedir. Bu nedenle, çalışmada literatürde aynı veri kümesi ile yapılan araştırmalarda ele alınmayan ortalama IOU, Dice Coef, Özgüllük, test loss ve test acc değerlendirme ölçütlerine

de yer verilmiştir. Bu değerlendirme ölçütleri (Rahman ve Wang,2016; Worfield vd., 2004; Willetari vd., 2016; Waid vd., 2008) segmentasyon çalışmalarında da farklı veri kümeleri ve hastalıkların teşhisi için elde edilen sonuçların performans analizi için kullanılmıştır.

Segmentasyon değerlendirme sonucunda, %99.4 üzerinde doğruluk oranı ve %99.8 özgüllük oranı elde edilmiştir. İnsan omurlarının segmentasyonu %99.4 başarı oranıyla tahmin edilmiştir. Elde edilen tahmin, doğruluk ve hassaslık sonuçları VerSe veri kümesi kullanılarak gerçekleştirilmiş çalışmalarındaki sonuçlar ile kıyaslandığında daha başarılı sonuçlar elde edildiği görülmüştür. Segmentasyon değerlendirmenin önemli ölçütlerinden biri olan Dice coef ölçütü %65.1 olarak elde edilmiştir. VerSe ham görüntülerine dalgacık dönüşümü uygulandıktan sonra Dice skorunun iyileştiği görülmüş ve %74.5 skoru elde edilmiştir.

## 6. Sonuç

Çalışma sonucunda, omurga görüntülerinin işlenerek hastalık tespitinde karar desteği sağlanması için segmentasyonu gerçekleştirilmiştir. Segmentasyon çıktılarının doğruluk, ortalama IOU, dice coef, tahmin, Hassaslık, Özgüllük, test loss ve test acc değerlendirme ölçütleri ile performans analizi yapılmıştır. Çalışma bulguları analiz sonuçları literatürde elde edilen sonuçlar ile karşılaştırıldığında daha başarılı segmentasyon gerçekleştirildiği görülmüştür. Bununla birlikte, literatürde görüntülerin segmentasyonu çalışmalarında yaygın olarak kullanılan değerlendirme kriterlerinin omurga segmentasyonu çalışmalarında sınırlı şekilde kullanıldığı sonucuna varılmıştır. Bu çalışmada elde edilen sonuçların doğruluğunu desteklemek için VerSe veri kümesi üzerinde hali hazırda yapılmış çalışmalarda kullanılan değerlendirme kriterleri haricinde literatürde kullanılan farklı segmentasyon değerlendirme kriterlerine de yer verilmiştir.

Bu çalışmanın biyomedikal görüntülerde hasta tespiti aşamalarında, güvenilir sonuçlar elde etmek için gelecekteki çalışmalara temel oluşturması hedeflenmiştir. Elde edilen segmentasyon görüntüleri gelecek omurga görüntülerinden rahatsızlıkların tespiti çalışmaları için de kullanılabilir olacaktır. Çalışmada önerilen modelin özgün farklı veri kümeleri için kullanılabilmesi de mümkündür. Bununla birlikte, çalışmanın pratikte de kullanılması ile hasta tedavi aşamalarının hızlanması ve sağlık alanındaki yoğunluğun dolaylı yünden azaltılması amaçlanmıştır. İleriki çalışmalarımız için yeni ve özgün veri kümelerinin oluşturulması ve bu veri kümeleri kullanılarak yeni tekniklerin geliştirilmesi ve uygulanması hedeflenmektedir.

## Kaynakça

- Mallat, S. (1999). A wavelet tour of signal processing. Elsevier.
- DeVore, R. A., Jawerth, B., & Lucier, B. J. (1992). Image compression through wavelet transform coding. *IEEE Transactions on information theory*, 38(2), 719-746.
- Mihcak, M. K., Kozintsev, I., Ramchandran, K., & Moulin, P. (1999). Low-complexity image denoising based on statistical modeling of wavelet coefficients. *IEEE Signal Processing Letters*, 6(12), 300-303.
- Sekuboyina, A., Husseini, M. E., Bayat, A., Löffler, M., Liebl, H., Li, H., ... & Kirschke, J. S. (2021). VerSe: A vertebrae labelling and segmentation benchmark for multi-detector CT images. *Medical image analysis*, 73, 102166.
- Löffler, M. T., Sekuboyina, A., Jacob, A., Grau, A. L., Scharr, A., El Husseini, M., ... & Kirschke, J. S. (2020). A vertebral segmentation dataset with fracture grading. *Radiology: Artificial Intelligence*, 2(4), e190138.
- Liebl, H., Schinz, D., Sekuboyina, A., Malagutti, L., Löffler, M. T., Bayat, A., ... & Kirschke, J. S. (2021). A computed tomography vertebral segmentation dataset with anatomical variations and multi-vendor scanner data. *Scientific Data*, 8(1), 284.
- Pang, C., Su, Z., Lin, L., Lin, G., He, J., Lu, H., ... & Pang, S. (2023). Automated measurement of spine indices on axial MR images for lumbar spinal stenosis diagnosis using segmentation-guided regression network. *Medical Physics*, 50(1), 104-116.
- Qadri, S. F., Lin, H., Shen, L., Ahmad, M., Qadri, S., Khan, S., ... & Qamar, S. (2023). CT-Based Automatic Spine Segmentation Using Patch-Based Deep Learning. *International Journal of Intelligent Systems*, 2023.
- Yang, Z., Wang, Q., Zeng, J., Qin, P., Chai, R., & Sun, D. (2023). RAU-net: U-net network based on residual multi-scale fusion and attention skip layer for overall spine segmentation. *Machine Vision and Applications*, 34(1), 10.
- Cao, Y., Tan, C., Qian, W., Chai, W., Cui, L., Yang, W., ... & Shen, X. (2022, October). Automatic Spinal Ultrasound Image Segmentation and Deployment for Real-time Spine Volumetric Reconstruction. In *2022 IEEE International Conference on Unmanned Systems (ICUS)* (pp. 922-927). IEEE.
- Fatima, J., Mohsan, M., Jameel, A., Akram, M. U., & Muzaffar Syed, A. (2022). Vertebrae localization and spine segmentation on radiographic images for feature-based curvature classification for scoliosis. *Concurrency and Computation: Practice and Experience*, 34(26), e7300.
- Zhao, J., Sun, L., Zhou, X., Huang, S., Si, H., & Zhang, D. (2022). Residual-atrous attention network for lumbosacral plexus segmentation with MR image. *Computerized Medical Imaging and Graphics*, 100, 102109.
- Aydogdu, S., Stoyanov, D., Kalaskar, D., & Mazomenos, E. (2022, July). *Vertebral Column Segmentation Using Single-staged CNNs*. Cambridge University Press.
- Wang, D., Yang, Z., Huang, Z., & Gu, L. (2022, July). Spine Segmentation with Multi-view GCN and Boundary Constraint. In *2022 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)* (pp. 2136-2139). IEEE.
- Yamakawa, S., Ono, K., Makihara, E., Tawara, D., Yakushijin, S., & Ikushima, N. (2022, July). Textonmap optimization for spine segmentation using adaptive differential evolution. In *Proceedings of the Genetic and Evolutionary Computation Conference Companion* (pp. 75-76).
- Sekuboyina, A., Rempfler, M., Valentinitzsch, A., Menze, B. H., & Kirschke, J. S. (2020). Labeling vertebrae with two-dimensional reformations of multidetector CT images: an adversarial approach for incorporating prior knowledge of spine anatomy. *Radiology: Artificial Intelligence*, 2(2), e190074.



- Agboola, H. A., & Zaccheus, J. E. (2023). Wavelet image scattering based glaucoma detection. *BMC Biomedical Engineering*, 5(1), 1.
- Unser, M., & Aldroubi, A. (1996). A review of wavelets in biomedical applications. *Proceedings of the IEEE*, 84(4), 626-638.
- Murala, S., Maheshwari, R. P., & Balasubramanian, R. (2012). Directional binary wavelet patterns for biomedical image indexing and retrieval. *Journal of Medical Systems*, 36, 2865-2879.
- He, L., Chao, Y., Suzuki, K., & Wu, K. (2009). Fast connected-component labeling. *Pattern recognition*, 42(9), 1977-1987.
- Javanmardi, M., & Tasdizen, T. (2018, April). Domain adaptation for biomedical image segmentation using adversarial training. In *2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)* (pp. 554-558). IEEE.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III 18* (pp. 234-241). Springer International Publishing.
- Falk, T., Mai, D., Bensch, R., Çiçek, Ö., Abdulkadir, A., Marrakchi, Y., ... & Ronneberger, O. (2019). Author Correction: U-Net: deep learning for cell counting, detection, and morphometry. *Nature Methods*, 16(4), 351-351.
- Jia, Y., Shelhamer, E., Donahue, J., Karayev, S., Long, J., Girshick, R., ... & Darrell, T. (2014, November). Caffe: Convolutional architecture for fast feature embedding. In *Proceedings of the 22nd ACM international conference on Multimedia* (pp. 675-678).
- Zakharov, A., Pisov, M., Bukharaev, A., Petraikin, A., Morozov, S., Gombolevskiy, V., & Belyaev, M. (2023). Interpretable vertebral fracture quantification via anchor-free landmarks localization. *Medical Image Analysis*, 83, 102646.
- Altini, N., De Giosa, G., Fragasso, N., Coscia, C., Sibilano, E., Prencipe, B., ... & Bevilacqua, V. (2021, June). Segmentation and identification of vertebrae in CT scans using CNN, k-means clustering and k-NN. In *Informatics* (Vol. 8, No. 2, p. 40).
- Rahman, M. A., & Wang, Y. (2016). Optimizing intersection-over-union in deep neural networks for image segmentation. In *International symposium on visual computing* (pp. 234-244). Springer, Cham.
- Warfield, S. K., Zou, K. H., & Wells, W. M. (2004). Simultaneous truth and performance level estimation (STAPLE): an algorithm for the validation of image segmentation. *IEEE transactions on medical imaging*, 23(7), 903-921.
- Milletari, F., Navab, N., & Ahmadi, S. A. (2016, October). V-net: Fully convolutional neural networks for volumetric medical image segmentation. In *2016 fourth international conference on 3D vision (3DV)* (pp. 565-571). Ieee.
- Naik, S., Doyle, S., Agner, S., Madabhushi, A., Feldman, M., & Tomaszewski, J. (2008, May). Automated gland and nuclei segmentation for grading of prostate and breast cancer histopathology. In *2008 5th IEEE International Symposium on Biomedical Imaging: From Nano to Macro* (pp. 284-287). IEEE.