



Automated liver segmentation using Mask R-CNN on computed tomography scans

Emre Dandil^{1*}, Mehmet Süleyman Yıldırım², Ali Osman Selvi^{3,4}, Süleyman Uzun⁵

¹Department of Computer Engineering, Faculty of Engineering, Bilecik Seyh Edebali University, Bilecik, 11230, Turkey

²Department of Computer Technology, Sogut Vocational School, Bilecik Seyh Edebali University, Bilecik, Turkey

³Department of Computer Technology of Vocational School, Bilecik Seyh Edebali University, Bilecik, 11230, Turkey

⁴Department of Electrical-Electronics Engineering, Institute of Graduate, Sakarya University of Applied Sciences, Sakarya, Turkey

⁵Department of Computer Engineering, Faculty of Technology, Sakarya University of Applied Sciences, Sakarya, Turkey

Highlights:

- Computer-aided automatic segmentation of the liver on CT scans
- The proposed Mask R-CNN model based on soft parameter selection for region of interest
- Generating an original liver CT image dataset

Keywords:

- Computed Tomography
- Liver Scans
- Image Segmentation
- Mask R-CNN
- Liver Segmentation

Article Info:

Research Article

Received: 26.07.2020

Accepted: 02.05.2021

DOI:

10.17341/gazimmfd.774200

Acknowledgement:

This study was supported by Bilecik Seyh Edebali University BAPK with Project No: 2019-01.BŞEÜ.25-02

Correspondence:

Author: Emre Dandil
e-mail:

emre.dandil@bilecik.edu.tr
phone: +90 228 214 1613

Graphical/Tabular Abstract

Due to changes such as shape, border and density that occur in the slices of CT images, liver segmentation remains a difficult process. Compared to other segmentation methods, more successful segmentation results with deep learning models are general phenomenon. The Mask Regional-Convolutional Neural Networks (Mask R-CNN) framework is a method proposed for detecting key points on the image and segmentation. In this study, an automated computer-aided segmentation approach based on Mask R-CNN assisted by soft parameter selection for the region of interest (ROI) is proposed for high-accuracy segmentation and detection of the liver on CT images of the abdomen in three different datasets.

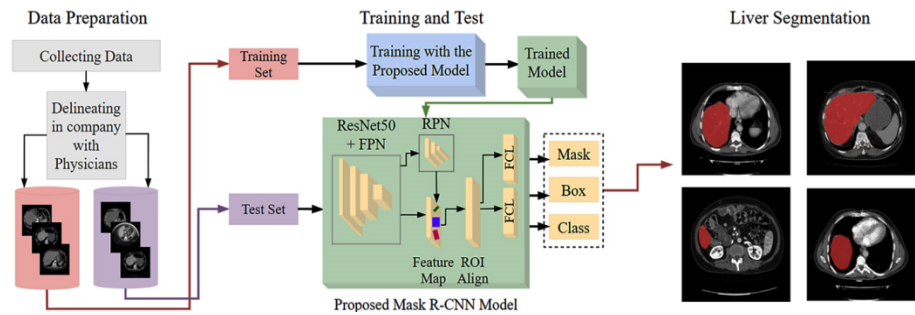


Figure A. The methodology of the proposed Mask R-CNN model for the segmentation of the liver on CT images

Purpose: Liver segmentation on slices of the scans acquired from abdomen region plays an important role in the clinical diagnosis and follow-up of the related diseases. Radiologists and physicians traditionally segment the liver or its region by manual segmentation. However, this process is highly time-consuming and the accuracy rate of the results may vary depending on the physician experience and skill. The aim of this study is to develop an automated computer-aided approach for high-accuracy segmentation and detection of the liver on CT images of the abdomen.

Theory and Methods: In this study, a state-of-the-arts method based on Mask R-CNN is proposed that can assist physicians and specialists for segmentation of the liver on CT scans. It is observed that the proposed method is quite successful in the segmentation of the liver in experimental studies performed on a dataset of different sizes, with different scanning parameters and created specifically for this study, and two different publicly available datasets. In addition, the effectiveness and validity of the proposed method are verified by comparing the results of Mask R-CNN, supported by the proposed soft parameter selection for ROI, with the results of another popular segmentation algorithm, U-Net.

Results: Experimental studies are conducted on three different liver CT image datasets, one of which is prepared specific for this study and two of them are public (Sliver07 and 3Dircadb), with both single and double GPU hardware structure. Thus, the change in segmentation performance depending on time is observed. The results obtained using the proposed method and the segmentation results realized by the specialist physician compared with parameters such as Dice similarity coefficient (DSC), Jaccard similarity coefficient (JSC), volumetric overlap error (VOE), average symmetric surface distance (ASD) and relative volume difference (RVD) metrics. In experimental studies carried out on liver CT dataset with the proposed Mask R-CNN approach, DSC, JSC, VOE, ASD and RVD segmentation performance metrics are gained as 96.16%, 93.11%, 6.89%, 1.56 mm, -4.76%, respectively.

Conclusion: With these results, it is seen that the proposed method in this study can be used as a secondary tool in the decision making processes of physicians for the segmentation of the liver.



Bilgisayarlı tomografi taramaları üzerinde maskeli bölgesel-evrişimsel sinir ağları ile karaciğerin otomatik bölütlenmesi

Emre Dandil^{1*}, Mehmet Süleyman Yıldırım², Ali Osman Selvi^{3,4}, Süleyman Uzun⁵

¹Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Bilecik Şeyh Edebali Üniversitesi, Bilecik, 11230, Türkiye

²Bilgisayar Teknolojileri Bölümü, Söğüt Meslek Yüksekokulu, Bilecik Şeyh Edebali Üniversitesi, Bilecik, Türkiye

³Bilgisayar Teknolojileri Bölümü, Meslek Yüksekokulu, Bilecik Şeyh Edebali Üniversitesi, Bilecik, 11230, Türkiye

⁴Elektrik-Elektronik Mühendisliği Anabilim Dalı, Sakarya Uygulamalı Bilimler Üniversitesi, Sakarya, Türkiye

⁵Bilgisayar Mühendisliği Bölümü, Teknoloji Fakültesi, Sakarya Uygulamalı Bilimler Üniversitesi, Sakarya, Türkiye

Ö N E Ç İ K A N L A R

- BT taramalarından karaciğerin bilgisayar destekli otomatik bölütlenmesi
- İlgili bölge için esnek parametre seçimi destekli Maskeli Bölgesel-Evrişimsel Sinir Ağları modelinin önerilmesi
- Özgün bir karaciğer BT görüntü verisetinin oluşturulması

Makale Bilgileri

Araştırma Makalesi

Geliş: 26.07.2020

Kabul: 02.05.2021

DOI:

10.17341/gazimmfd.774200

Anahtar Kelimeler:

Bilgisayarlı tomografi,
karaciğer taramaları,
görüntü bölütleme,
maskeli bölgesel-evrişimsel
sinir ağları,
karaciğer bölütleme

ÖZ

Bilgisayarlı Tomografi (BT) görüntülerinde her bir kesitte ortaya çıkan şekil, sınır ve yoğunluk gibi değişikliklerden dolayı karaciğerin bölütlenmesi zor bir süreç olarak durmaktadır. Bu çalışmada, abdomen bölgesinden alınmış BT taramalarındaki kesitlerden karaciğerin bilgisayar destekli otomatik bölütlenmesinde, ilgili bölge için esnek parametre seçimi ile desteklenmiş Maskeli Bölgesel-Evrişimsel Sinir Ağları (Maskeli B-ESA) tabanlı bir yöntem önerilmiştir. Birisi bu çalışmaya özgü hazırlanan ve ikisi de açık olmak üzere (Sliver07 ve 3Dircadb) üç farklı karaciğer BT görüntü veriseti üzerinde, çoklu GPU donanımsal yapısı ile deneysel çalışmalar yürütülerek, zamansal olarak başarımın değişimi izlenmiştir. Önerilen yöntem kullanılarak elde edilen sonuçlar ile uzman hekim tarafından bulunan bölütleme sonuçları Dice benzerlik katsayısı (DSC), Jaccard benzerlik katsayısı (JSC), volumetrik örtüşme hatası (VOE), ortalama simetrik yüzey mesafesi (ASD) ve oransal hacim farkı (RVD) ölçüm parametreleri ile karşılaştırılmıştır. Önerilen Maskeli B-ESA yaklaşımı ile bu çalışma kapsamında oluşturulan veriseti görüntüleri üzerinde yürütülen deneysel çalışmalarda DSC, JSC, VOE, ASD ve RVD bölütleme başarımleri, sırasıyla %96,16, %93,11, %6,89, 1,56 mm, -%4,76 olarak hesaplanmıştır. Ek olarak, Maskeli B-ESA yöntemi ile verisetlerinde başarılı bölütleme sonuçları, bir başka popüler bölütleme algoritması olan U-Net ile karşılaştırılmıştır. Bu sonuçlar ile bu çalışma kapsamında önerilen yöntemin, karaciğerin bölütlenmesi için hekimlerin karar verme süreçlerinde yardımcı bir araç olarak kullanılabileceği görülmüştür.

Automated liver segmentation using Mask R-CNN on computed tomography scans

H I G H L I G H T S

- Computer-aided automatic segmentation of the liver on CT scans
- The proposed Mask R-CNN model based on soft parameter selection for region of interest
- Generating an original liver CT image dataset

Article Info

Research Article

Received: 26.07.2020

Accepted: 02.05.2021

DOI:

10.17341/gazimmfd.774200

Keywords:

Computed tomography,
liver scans,
image segmentation,
mask R-CNN,
liver segmentation

ABSTRACT

Due to changes such as shape, border and density that occur in the slices of computed tomography (CT) images, liver segmentation remains a difficult process. In this study, a method based on Mask Regional-Convolutional Neural Networks (Mask R-CNN) assisted by soft parameter selection for the region of interest (ROI) is proposed for computer-aided automatic segmentation of the liver on CT scans obtained from the abdominal region. Experimental studies are conducted on three different liver CT image datasets, one of which is prepared specific for this study and two of them are public (Sliver07 and 3Dircadb), with multi GPU hardware structure. Thus, the change in segmentation performance depending on time is observed. The results obtained using the proposed method and the segmentation results realized by the specialist physician compared with parameters such as Dice similarity coefficient (DSC), Jaccard similarity coefficient (JSC), volumetric overlap error (VOE), average symmetric surface distance (ASD) and relative volume difference (RVD) metrics. In experimental studies carried out on liver CT dataset with the proposed Mask R-CNN approach, DSC, JSC, VOE, ASD and RVD segmentation performance metrics are gained as 96.16%, 93.11%, 6.89%, 1.56 mm, -4.76%, respectively. With these results, it is seen that the proposed method in this study can be used as a secondary tool in the decision making processes of physicians for the segmentation of the liver.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : *emre.dandil@bilecik.edu.tr, mehmet.yildirim@bilecik.edu.tr, aliosman.selvi@bilecik.edu.tr, suleymanuzun@subu.edu.tr / Tel: +90 228 214 1613

1. GİRİŞ (INTRODUCTION)

Tıbbi görüntü bölütleme, görüntü analiz çalışmalarında önemli bir yere sahip olup, tıp alanında bilgisayar destekli teşhis için büyük bir öneme sahiptir [1]. Başta radyoloji olmak üzere, tıpın birçok alanında elde edilen görüntülerden, ilgi bölgesinin bölütlenmesi, hastalıkların teşhisi ve tedavi planlaması için kayda değer önceliğe sahiptir. Organ, lezyon veya tümör gibi ilgi bölgesi olarak değerlendirilebilecek görüntüler üzerindeki radyolojik yapılar, görüntü bölütleme ile çıkarılabilir [2]. Böylece, hekimlerin karar süreçlerinde ikincil bir araç olan destekleyici nitelikte ek materyaller elde edilmiş olmaktadır. Görüntü bölütlemenin, ilgi bölgesinin yerinin belirlenmesi ve nesne bölgesinin sınırının tanımlanması olarak, iki ilişkili işlemlerden oluştuğu düşünülebilir [3].

Tıbbi görüntüleme yöntemleri kullanılarak alınan tarama verilerinin boyutunun artmasına bağlı olarak organdaki anomalinin başka dokuların arasına gizlenebilmesi, dokuların kontrast değerlerinin birbirine benzer olması, görüntü hacmindeki büyüklüklerin ortaya çıkması, hekimde göz yorgunluğunun oluşabilmesi gibi sebeplerden dolayı tanı konulması zorlaşabilmektedir. Bu gibi durumlarda, anomalinin gözden kaçırılması gibi sonuçlar ortaya çıkabilmektedir. Böyle vakalarda, bilgisayar destekli teşhis sistemlerinin görüntü analizinde ve tespitinde kullanılmasının gerekliliği ortaya çıkmaktadır [4]. İnsan vücudunun anatomik yapısı başta BT olmak üzere çeşitli görüntüleme yöntemleri ile etkin bir biçimde belirlenebilmektedir [5].

Abdomen (karın) bölgesinden alınmış tarama kesitleri üzerinde karaciğer organının bölütlenmesi, bağlı hastalıkların klinik teşhisi ve takibi için önemli rol oynamaktadır. Radyologlar ve hekimler geleneksel olarak tıbbi görüntüler üzerinde karaciğer veya bölgesinin bölütlenmesini el yordamıyla gerçekleştirmektedir [6]. Ancak bu süreç çok fazla zaman kaybına neden olabilmektedir ve hekim tecrübesine ve becerisine göre sonuçların doğruluk oranı değişebilmektedir. Ayrıca, abdomen görüntüleri üzerinde karaciğer organının bölütlenmesi başlı başına bazı zorluklar içermektedir. Karaciğerin çevresindeki organlara göre karaciğerin daha düşük kontrasta sahip olması, sınırlarının keskinliğinin aksine bulanıklıklar içermesi, farklı görünümde çok yakın damarsal yapıların olması ve heterojen yoğunluklara sahip patolojiler barındırabilmesi bu zorluklardan bazılarıdır [7]. Ek olarak, her bir BT kesitinde karaciğer organının farklı şekil, boyut ve pozisyonunun olması, otomatik bölütlemeyi daha da zorlaştırmaktadır. Karaciğer, çok fazla değişken yapıda olması ve komşu diğer organlara yakınlığından dolayı dokuların iç içe geçmesi gibi nedenlerle, bölütleme yapılırken en çok zorlanılan organların başında gelmektedir. Ayrıca karaciğer yağlanması, demir birikmesi, fibroz, ve tümör gibi patolojik durumlar, dokusal ve sinyal yoğunluğunun bozulması bakımından, karaciğerin anatomik yapısının bozulmasına da maruz bırakabilmektedir [8].

Karaciğer bölütlemesi, genellikle birçok segment üreterek görüntüler üzerinde karaciğer parankimalarına bağlı voksellerin tanınmasını içermektedir. Karaciğerin bölütlenmesinde kullanılan güncel yöntemler kabaca piksel tabanlı, şekil modeli destekli, deformasyon modelleri tabanlı, graf biçimli ve makine öğrenmesi algoritmalarına dayalı olarak sınıflandırılabilir [7]. Piksel tabanlı yöntemler karaciğerin şekil ve sınır bölgelerindeki değişikliklere bağlı olarak, taramanın tüm kesitlerinde başarılı olamamaktadır. Ayrıca, bu yöntemler karaciğer bölgesinin bölütlenmesinde doğruya yakın sonuçlar verememektedir ve komşu organları da bölütlemeye dahil edecek şekilde kısıtlar barındırmaktadırlar [9, 10]. Atlas model ve istatistiksel modellere dayalı şekil tabanlı yöntemler ise, özellikle atlas modeller üzerinde şekillerin eğitilmesi aşamasında çok fazla süre gerektirmektedir [11]. Bunun yanında, şekil tabanlı yöntemlerde bölütleme için başlangıç noktasının çok iyi seçilmesi ve ilerletilmesi beklenmektedir. Düzey ayarlamaya dayalı deformasyon modelleri ile işletilen yöntemlerde fazla parametre bulunmaktadır ve bu parametreler ile organa ait başlangıç dış hatlarının hassas bir şekilde belirlenmesi şarttır [12]. Graf tabanlı yöntemlerde şekillerden ve sınırlardan elde edilen özelliklerin birleştirilmesi ile görüntü bölütleme işlemi yürütülmektedir [13]. Bu yöntemde de graf bölgelerinin oluşturulmasını sağlayan parametrelerin uygun bir şekilde optimize edilmesi gereklidir. Son zamanlarda popüler olan makine öğrenmesi tabanlı yöntemlerde, çıkarılan özellikler ile çok başarılı bölütleme sonuçları elde edilebilmektedir. Makine öğrenmesi tabanlı görüntü bölütleme yöntemlerinde, başarılı bir bölütleme süreci için çok iyi bir eğitim aşaması yürütülmelidir ve donanım yapılarının oldukça güçlü olması beklenir [14]. Bu yöntemde derin öğrenme modellerinin gelişmesiyle diğer bölütleme yöntemlerine göre daha başarılı sonuçlar elde etmek mümkün olmuştur. Son yıllarda, derin evrimsel sinir ağları (ESA), sağlam ve başarılı öğrenme yeteneğinden dolayı bilgisayarlı görü alanında yaygın olarak kullanılmaktadır [15, 16]. Büyük görsel verilerden ESA'nın eğitimi sayesinde elde edilen uzamsal ve anlamsal bilgiler, görüntülerde bölütleme işlemi için kullanılabilir [17].

Maskeli B-ESA çatısı (framework), görüntü üzerinde anahtar noktaların tespiti ve bölütleme için önerilen bir yöntemdir. Bu doğrultuda, BT görüntüleri üzerinde karaciğerin bölütlenmesi ve tespiti için maske destekli olarak önerilen son çalışmaların kullanılabileceği görülmektedir. Bunun yanında, farklı tipte görüntüler üzerinde maske destekli bölütleme için önerilen çeşitli derin öğrenme yaklaşımları da mevcuttur [18-20]. Bu çalışmada, üç farklı verisetinde bulunan abdomen BT görüntüleri üzerinde karaciğerin yüksek doğrulukla bölütlenmesi ve tespiti için, ilgi bölgesi için önerilen esnek parametre seçimi ile desteklenmiş Maskeli B-ESA tabanlı otomatik bir bilgisayar destekli otomatik bölütleme yaklaşımı önerilmektedir. Çalışmanın sonraki bölümleri şu şekilde organize edilmiştir. İkinci bölümde konu ile ilgili önceki çalışmaların genel bir değerlendirmesi sunulmuştur. Üçüncü bölüm materyal ve yöntemleri içermektedir. Deneysel çalışmalar dördüncü

bölümde sunulmuş olup, sonuçlar ve tartışmalar beşinci bölümde detaylandırılmıştır. Son bölümde ise çalışmanın genel bir değerlendirmesi yapılarak sonuçlar vurgulanmıştır.

2. ÖNCEKİ ÇALIŞMALAR (LITERATURE REVIEW)

Aynı veya farklı verisetleri kullanılarak BT taramaları üzerinde karaciğerin bölütlenmesi için literatürde birçok çalışmanın önerildiği görülmektedir. Bu çalışmalarda bazılarında tam otomatik bölütleme yapılırken, bazılarında ise melez modeller ile yarı otomatik bölütleme tavsiye edilmektedir. Huang vd. [7] çalışmalarında, BT görüntüleri üzerinde karaciğerin bölütlenmesi için, geliştirilmiş graf biçimli bir algoritma ve özellik çıkarımı kullanarak bir metot önermişlerdir. Tam otomatik, hızlı ve doğru bir şekilde bölütleme yapılabilen yöntemin, klinik uygulamalarda da kullanılabileceği vurgulanmıştır. Graf biçimli bir yöntemle karaciğerin bölütlenmesi için önerilen bir diğer çalışmada, Wu vd. [21] volumetrik BT görüntülerinden yararlanmıştır. Liao vd. [22] ise, BT görüntüleri üzerinde karaciğerin bölütlenmesi için yine graf biçimli bir yöntem geliştirerek, darboğaz tespiti ile çalışmasını desteklemiştir. Liao vd. [23] karaciğerin bölütlenmesi için yürüttükleri bir başka çalışmada, yine graf biçimli bir yöntemi sınır ilerlemesi tekniği ile birleştirerek, BT görüntüleri üzerinde otomatik bir yaklaşım sunmuşlardır.

Zeng vd. [24] çalışmalarında, 3B bölge büyütme ve melez aktif sınıf modeli kullanarak karaciğer damalarının bölütlenmesi için bir yaklaşım sunmuşlardır. Yang vd. [25] çalışmalarında, ameliyat planlaması için BT görüntülerinin üzerinde karaciğer ve damalarının bölütlenmesini yarı otomatik bir yöntem ile sağlamışlardır. Karaciğerin bölütlenmesi için önerilen bir başka çalışmada, Zareei ve Karimi [12] aktif sınır modelini kullanan danışmanlı bir yöntem önermişlerdir. Çalışmada hem bölütleme başarımları oranları hem de hata değişim oranları karşılaştırılmıştır. Lu vd. [26] ise çalışmalarında, BT görüntüleri üzerinde karaciğerin bölütlenmesi için bölge büyütme algoritması tabanlı bir çalışma ve uygulama önermişlerdir. Foruzan vd. [27] ise bir diğer çalışmada, BT görüntüleri üzerinde karaciğerin bölütlenmesi için anatomik bilgi-tabanlı bir teknik sunmuşlardır. Lim vd. [28] ise çalışmalarında,

morfolojik prosedürler, kümeleme, etiketleme ve temel görüntü işleme teknikleri ile BT görüntüleri üzerinde karaciğerin otomatik bölütlenmesini uygulamışlardır. Bir başka çalışmada, Huang vd. [29] BT görüntüleri üzerinde karaciğerin otomatik bölütlenmesi için tek-blok doğrusal tespit yöntemini önermişlerdir.

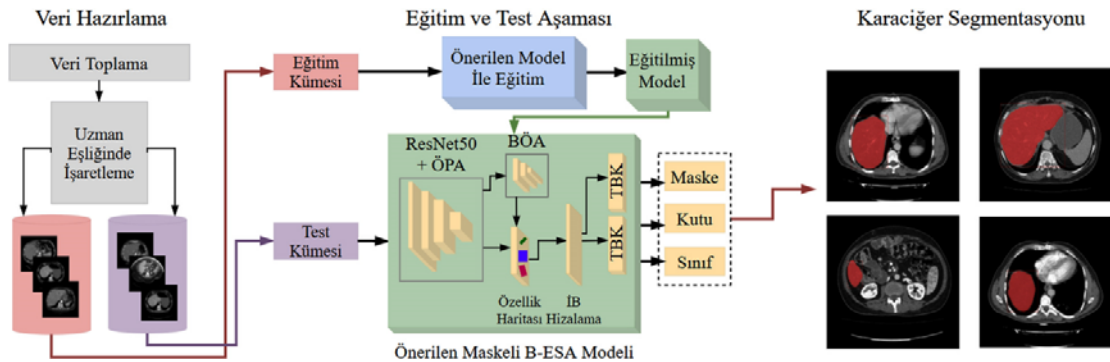
Karaciğerin bölütlenmesinde, son yıllarda ESA tabanlı modellerin de yaygın olarak kullanıldığı görülmektedir. Bu şekilde önerilen çalışmaların birinde, Lu vd. [14], BT görüntüleri üzerinde karaciğerin otomatik bölütlenmesi için ESA ve graf oluşumu tabanlı bir yöntem geliştirmiştir. Liu vd. [30] ise çalışmalarında, karaciğerin BT kesitleri üzerinde bölütlenmesi için bir ESA modeli olan U-Net ve graf tabanlı bir yöntem önermişlerdir. Bir diğer çalışmada, Budak vd. [31] kodlayıcı-kod çözücü bir ESA modeli kullanarak BT görüntüleri üzerinde karaciğerin bölütlenmesini uygulamışlardır. Mulay vd. [32] çalışmalarında, BT ve MR taramalarından oluşan çok-modlu görüntüler üzerinde, bütüncül-yuvalı kenar tespiti ile Maskeli B-ESA yöntemlerini birleştirerek karaciğerin bölütlenmesini sağlamışlardır.

3. MATERYAL VE YÖNTEM (MATERIAL AND METHOD)

Bu çalışmada, abdomen BT görüntüleri üzerinde karaciğerin otomatik bölütlenmesi için Maskeli B-ESA mimarisine dayalı bir yöntem önerilmiştir. Önerilen modelin metodolojisini gösteren genel blok diyagram Şekil 1'de gösterildiği gibi veri hazırlama, eğitim ile test aşaması ve bölütleme aşaması olmak üzere üç aşamada özetlenmiştir. Bu mimarideki ÖPA kısaltması Özellik Piramit Ağını, BÖA kısaltması Bölge Öneri Ağını ve TBK kısaltması ise Tam Bağlantılı Katmanı temsil etmek için kullanılmıştır.

3.1. Verisetleri (Datasets)

BT taramalarından elde edilen karın bölgesine ait kesitlerden alınan görüntüler üzerinde karaciğerin bölütlenmesi için bu çalışma kapsamında özel olarak oluşturulan Karaciğer BT verisetimiz kullanılmıştır. Bunun yanında, bu veriseti




Şekil 1. BT görüntüleri üzerinde karaciğerin bölütlenmesi için önerilen Maskeli B-ESA modelinin metodolojisini gösteren genel blok diyagram

(General block diagram showing the methodology of the proposed Mask R-CNN model for the segmentation of the liver on CT images)

üzerinde yürütülen deneysel çalışmalar sonucunda ulaşılan sonuçlar, SLIVER07 [10, 33] ve 3DIRCADb [34, 35] olmak üzere iki farklı açık veriseti ile elde edilen sonuçlarla karşılaştırılarak, hem önerilen yöntemin hem de hazırlanan verisetinin karaciğerin tespit edilmesi açısından etkinliği değerlendirilmiştir.

3.1.1. Karaciğer BT veriseti (Liver CT dataset)

Çalışma kapsamında oluşturulan BT görüntü veriseti bu çalışma için özel oluşturulmuş olup, farklı hastalara ait abdomen BT görüntüleri Dr. Nafiz Körez Sincan Devlet Hastanesinin Radyoloji bölümünden uzmanlar eşliğinde toplanmıştır. BT taramalarının elde edildiği BT cihazı General Electric (GE) marka olup 16 kesite kadar görüntü oluşturabilmektedir. BT cihazının edinim parametrelerinden olan kesit toplamı 1,0 mm ve kesit genişliği ise 1,0 mm'dir. BT taramaları 130 kV ve 75 mA'da elde edilmiştir. Karın (abdomen) bölgesinden alınan BT görüntüleri 26 farklı hastadan alınmış olup hastaların yaşları 32 ile 67 arasında değişmektedir. BT görüntüleri cihazdan DICOM formatında alındıktan sonra 512x512 piksel boyutuna dönüştürülerek kullanılmıştır. Her bir hastadan aksiyel düzlemde 28 ile 132 arasında değişen farklı sayılarda karın bölgesinin kesiti toplanmıştır. Çalışmada kullanılmak üzere, her hastadan en az bir kesit olmak üzere, toplamda 310 en uygun kesit uzman eşliğinde belirlenmiştir. Bu BT kesitlerinin bir kısmı önerilen ağı eğitim için, bir kısmı ise test aşaması için kullanılmıştır. Hazırlanan verisetinde bulunan karaciğer BT görüntülerinin bir bölümü Şekil 2'de gösterilmiştir. Belirlenen BT görüntüleri üzerinde karaciğerin ilgi bölgesinin sınırları, Şekil 3'te sunulan bu çalışma kapsamında geliştirilen bir uygulama aracılığıyla uzman tarafından çizilmiştir. Her bir taramadaki uygun kesitler yine aynı uzman tarafından, karaciğer bölgesinin uygun pozisyonunu temsil etmek üzere seçilmiştir. Daha sonra ön-işleme teknikleri kullanılarak BT görüntülerinin iyileştirilmesi ve görüntüler üzerindeki gürültülerin giderilmesi sağlanmıştır.




Şekil 2. Çalışma kapsamında hazırlanan verisetinde bulunan karaciğer bölgesine ait bazı BT görüntüleri örnekleri

(Some samples of CT images of the liver region in dataset prepared for this study)

3.1.2. Açık verisetleri (Public datasets)

Bu çalışmada, karaciğer BT veriseti kullanılarak elde edilen deneysel sonuçların değerlendirilmesi için SLIVER07 ve 3DIRCADb olmak üzere açık iki veriseti üzerinde de aynı test işlemleri gerçekleştirilmiştir. Her iki açık verisetinde de BT görüntüleri üzerinde uzmanların el yordamı ile belirlemiş olduğu karaciğer bölgeleri de işaretlenmiş olarak


sunulmaktadır. Ayrıca, bu çalışma kapsamında oluşturulan verisetinde olduğu gibi, her iki açık veriseti için aksiyel eksende 260 eğitim ve 50 test kümesi için karaciğerin olduğu BT kesitleri seçilmiştir.



Şekil 3. BT taramalarında bulunan karaciğer bölgesinin sınırlarının çizilmesinde uzmanın kullanımı için geliştirilen uygulama. (a) ilgi bölgesinin işaretlenmesi, (b) karaciğerin sınırlarının uzman tarafından çizilmesi

(The developed application for the use of the expert in drawing the boundaries of the liver region in CT scans. (a) marking the region of interest, (b) drawing the borders of the liver by the expert)

SLIVER07, klinik ortam verilerinde 3B bölütleme sağlayan MICCAI 2007 konferansı ile birlikte sunulan açık bir BT karaciğer veritabanıdır. Bu verisetinin eğitim kümesinde bazıları da patolojik görüntüler içeren kontrastlanarak iyileştirme yapılmış 20 ciltlik (yığın) BT tarama görüntüleri bulunmaktadır. Test kümesinde ise 10 ciltlik BT taramaları mevcuttur. Hem eğitim hem de test kümelerindeki tarama kesitleri 512x512 piksel çözünürlüğe sahiptir. Ancak test kümesindeki verilerin uzman tarafından çıkarılmış etiketleri olmadığından, test kümesi eğitim için ayrılmış verilerden seçilmiştir. Verisetindeki görüntülerin iç-kesit piksel aralığı 0,5762 ile 0,8125 mm arasında değişmekte olup, kesit kalınlığı ise 0,7 mm ile 5,0 mm arasında değişiklik göstermektedir [22]. Her bir ciltteki kesit sayısı ise 64 ile 394 arasında değişmektedir. SLIVER07 veritabanından alınmış bazı örnek BT görüntüleri Şekil 4'te gösterilmiştir.




Şekil 4. SLIVER07 açık verisetinden seçilen aksiyel düzlemdeki BT kesit örnekleri

(Samples of CT slices in the axial plane obtained from the SLIVER07 public dataset)

3DIRCADb veritabanı ise 10 erkek ile 10 kadın olmak üzere toplamda 20 BT taraması içeren bir başka açık verisetidir. Bu veriseti 3B BT taramalarından oluşmakta olup, vakaların %75'i karaciğere ait tümörlerle ilgilidir. Verisetindeki her bir görüntü kesiti 512x512 piksel çözünürlüğe sahiptir. 3DIRCADb verisetinde kesit piksel aralığı 0,56 ile 0,86 mm arasında değişmekte olup, kesit kalınlığı ise 1,0 ile 4,0 mm arasında değişiklik göstermektedir. Her bir ciltteki kesit sayısı ise 184 ile 260

arasında değişmektedir [7]. 3DIRCADb veritabanından alınmış bazı örnek BT görüntüleri Şekil 5'te gösterilmiştir.



Şekil 5. 3DIRCADb açık verisetinden seçilen aksiyel düzlemdeki BT kesit örnekleri
(Samples of CT slices in the axial plane selected from the 3DIRCADb public dataset)

3.2. Veri artırma (Data augmentation)


Sağlam derin öğrenme modelleri oluşturmak için, eğitim aşaması boyunca eğitim hatasının sürekli azalması oldukça kritiktir. Bu aşamayı sürdürülebilir kılmak ve daha kapsamlı bir veri noktasına temas etmek için, en başta veri artırma/zenginleştirme yöntemleri kullanılmaktadır. Görüntü tabanlı veri artırma işlemleri, farklı veri dönüşümlerini sağlayarak, ağ üzerinde bir genelleştirme oluşturmaktadır ve ağı başarım performansını yükseltmektedir. Literatürde veri artırımı sağlamak için, yaygın olarak kullanılan birçok veri işleme tekniği bulunmaktadır. Çevirme, görüntü uzayına aktarma, kesme, döndürme, öteleme, gürültü ekleme bunlardan bazılarıdır [36]. Keras [37] kütüphanesi veri artırma için yaygın olarak kullanılan paketlerden birisidir. Bu çalışmada, görüntüler üzerinde veri artırma için Keras kütüphanesi [38] kullanılmıştır. Veri artırma için 'rotation range=0,2, width shift range=0,05, height shift range=0,05, shear range=0,05, zoom range=0,05, horizontal flip=True, fill mode="nearest"' işlemleri uygulanmıştır. Bu çalışmada kullanılan tüm verisetleri için aksiyel ekseninde 260 eğitim ve 50 test kümesi için karaciğerin olduğu BT kesitleri seçilmiştir. Veri artırma ile hem eğitim hem de test kümeleri 4 katına çıkarılmıştır. Şekil 6'da bu çalışma kapsamında oluşturulan Karaciğer BT verisetinde veri artırma sonrası bazı kesitlerde oluşan değişiklikler verilmiştir.

3.3. Maskeli B-ESA (Mask R-CNN)

Maskeli B-ESA, nesne tanımda ve nesnenin doğru bir şekilde bölütlenmesi için kullanılan derin öğrenme modelinin farklı bir türüdür. Ek olarak bu algoritma hedef nesnelere doğru ve kesin bir şekilde bölütleyen en güncel

yöntemlerden birisidir [39]. Maskeli B-ESA, aynı zamanda Daha Hızlı B-ESA (DHB-ESA)'nın sezgisel bir uzantısı olup eğitilmesi oldukça kolay olan bir ağıdır [40, 41]. DHB-ESA, girişine uygulanan görüntülerin özellik haritalarını çıkartarak aday çerçeveleri oluşturmak için Bölge Öneri Ağından (BÖA) geçirir. Temelde Hızlı B-ESA olarak bilinen ikinci aşamada ise, her bir aday bölgeyi aynı boyuta getirmek için aday sınırlayıcı çerçevelerine bir İlgi Bölgesi Havuzlama Katmanı uygulanarak ilgi bölgesi hizalama işlemi (İBHizalama) gerçekleştirilir. Son aşamada nesnelere sınırlayıcı çerçevelerini sınıflandırmak için Tam Bağlantı Katmanından (TBK) geçirilir. Maskeli B-ESA, DHB-ESA'da olduğu gibi tüm aşamaları kendi bünyesinde bulundurmaz. Ancak DHB-ESA, her bir aday çerçeveyi aynı boyuta getirmek için aday sınırlayıcı çerçevelerine bir İlgi Bölgesi Havuzlama Katmanı uygularken, Maskeli B-ESA bu işleme ek olarak, her bir aday sınırlayıcı için bir maske çıkartır. Bu işlem DHB-ESA'ya göre biraz iş yükü maliyeti oluştursa da nesne tespitinde oldukça iyi sonuçlar vermektedir [40].

Maskeli B-ESA yapısında, ilk olarak, nesne tespiti için BÖA ile tüm olası bölgeler belirlenmektedir. Bu aşamada Maskeli B-ESA'da, genel olarak görüntülerden özellik çıkarımı yapmak için genellikle ResNet mimarisi kullanılmaktadır. Bu çalışmada, giriş verileri üzerinde özellikleri çıkarmak ve bir özellik haritası oluşturmak için ResNet50 omurgası kullanılmıştır. Özellik haritası oluşturulduktan sonra, ilgi bölgelerindeki (İB) nesnelere sınıfları BÖA ile kesinleştirilmektedir. İkinci olarak, nesne bölge önerileri sınıflandırılır ve eşzamanlı olarak maske ile sınır kutuları tahmin edilir. Ancak Maskeli B-ESA'da, her İB için bir sınır kutusu ve ilgili bir etiket üretilir [20]. Böylece, sınıflandırma doğruluğunu azaltacak birçok ilgisiz İB üretilebilmektedir. Maskeli B-ESA'da sınıflandırma doğrudan üretilen maskeler ile ilgili olduğundan, İB'lerin doğru ve en az hata ile tahmin edilmesi gereklidir. Bu çalışmada kullanılan verisetlerinde de farklı boyutlarda birçok karaciğer kapalı bölgesi olduğundan, en uygun İB'lerin seçilmesinin gerekliliği açıktır. Bu yüzden önerilen çalışmada, farklı boyutlardaki karaciğer bölgelerine daha iyi uyum sağlaması amacıyla, İB tespit aşaması için esnek parametre seçimi önerilmiştir. İB için önerilen esnek parametre seçiminde, İB ve uzman etiketlemelerinin karşılaştırılmasından sonra, İB sayısı maksimum olmayan durdurma kullanarak, dinamik bir eşik değerine göre seçilmektedir. Standart Maskeli B-ESA'da, 16x16 pencere genişliğinden küçük İB'lerin tespit



Şekil 6. Karaciğer BT verisetinde veri artırma işlemi sonrası görüntülerde oluşan değişiklikler. (a) orijinal kesit, (b) yatay döndürme, (c) kesme aralığı, (d) kesme aralığı genişliği ve yatay döndürme

(Manipulations in images after data augmentation in the liver CT dataset. (a) original slice, (b) horizontal flip, (c) shear range, (d) width shift range and horizontal flip)

edilme başarımı düşükken, İB için önerilen esnek parametre seçimi ile 4x4 pencere genişliğine kadar kapalı İB'lerin olduğu karaciğer bölgeleri başarılı bir şekilde tahmin edilmektedir. Ayrıca, standart Maskeli B-ESA'da İB tespiti 32, 64, 128, 256 ve 512 piksel boyutlarına kadar yapılabiliyorken, İB için önerilen esnek parametre seçiminde 4, 8, 16 piksel boyutlarındaki İB'ler de tespit başarımı artırılmaktadır. Şekil 7' de Maskeli B-ESA'nın genel blok mimarisi gösterilmiştir. Maskeli B-ESA çatısı üç aşamadan oluşmaktadır [42]. Bu mimaride ilk önce, özellikleri çıkarmak ve özellik haritasını üretmek için, giriş görüntüsü ESA ile işlenir. Daha sonra, ilişkili aday bölgeleri işlemek için BÖA uygulanır. Sonraki aşamada, ilgi bölgesi çıkarım metotları işletilerek, farklı boyutlardaki aday çerçevelerin boyutları aynı ölçeğe getirilir. Böylece, çıkarılan ilgi bölgesinin kayıpları, sınıf kaybı, bağlı kutu kaybı ve üretilen maske kaybı ile hesaplanmış olur [43]. Özellik Piramit Ağı (ÖPA) doğru konumlama için, hem yüksek çözünürlüklü özellik uzayı hem de yüksek düzeyde anlamsal bilgi barındırdığından [44], bu çalışmada, bir ÖPA tabanlı ResNet50 omurgası kullanılmıştır. Böylece deneysel çalışmalarda hem yüksek doğruluk elde etmenin önu açılmış, hem de hız bakımından avantaj sağlanmıştır [45]. Bu durum ResNet50 omurgasında bulunan daha fazla özelliğin kullanılması ile gerçekleşmektedir. Burada, öncelikle her abdomen BT görüntüsü için, ESA özellikleri ResNet50 omurgası kullanılarak çıkarılır ve daha sonra ÖPA, özellik haritası üzerinde bağlı kutu önerilerini belirlemek için pencere kaydırma yöntemini kullanır. Maskeli B-ESA'da, maske bölümü (baş) için Eş. 1'de sunulan kayıp fonksiyonu kullanılmıştır. Bu eşitlikte L_{maske} hedef maske ve tahmin edilen maske arasında piksel bazlı çapraz entropi değerini hesaplar. $L_{maskeliB-ESA}$ DHB-ESA kayıp fonksiyonu tabanlı çoklu-görevli bir kayıp fonksiyonudur [46].

$$L_{maskeliB-ESA} = L_{sınıf} + L_{kutu} + L_{maske} \quad (1)$$

4. DENEYSEL ÇALIŞMALAR VE ANALİZLER (EXPERIMENTAL STUDIES AND ANALYSES)

Bu çalışmada, üç farklı verisetinde bulunan BT görüntüleri üzerinde karaciğer tespitinde ilgi bölgesi için önerilen esnek parametre seçimi ile desteklenmiş Maskeli B-ESA tabanlı

modelin başarımını doğrulamak birçok deneysel çalışma yapılmış ve elde edilen sonuçlar ile bulgular analiz edilmiştir. Önerilen model üzerinde yapılan tüm uygulamalar Python programlama dili ile Linux ortamında oluşturulan uygulamalar üzerinde gerçekleştirilmiştir. Bu deneysel çalışmalar için özellikleri Tablo 1'de donanımsal konfigürasyonları sunulan iş istasyonu kullanılmıştır. Çalışmada tek ve çift GPU ile çeşitli deneysel çalışmalar yapılmıştır. Kullanılan model açık kaynak kodlu Maskeli B-ESA çatısı [47] üzerine kurularak geliştirilmiş ve deneysel analiz sonuçları değerlendirilmiştir.

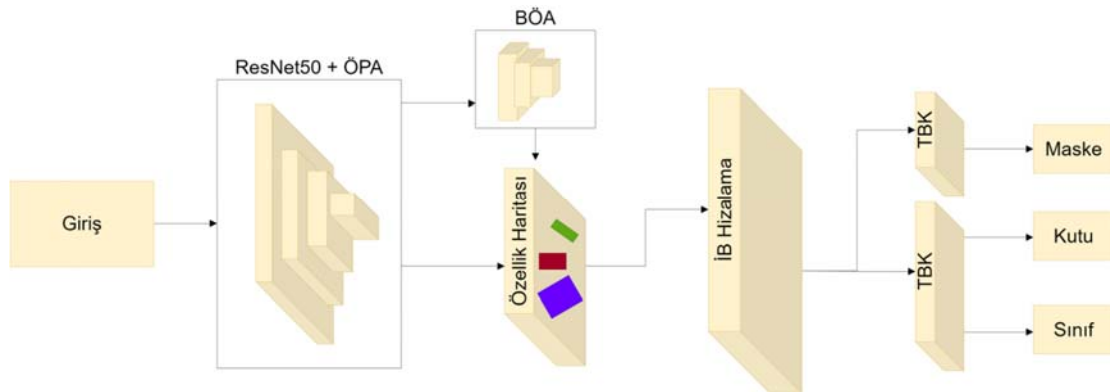
Bu çalışmada ilgi bölgesi için önerilen esnek parametre seçimi ile desteklenmiş Maskeli B-ESA mimarisi için belirlenen özel ayarlar Tablo 2'de sunulmuştur. Bu ayarlar, yürütülen deneysel çalışmalarda yapılan testlere bağlı olarak en iyi sonuçlar ile belirlenmiştir. Çift GPU ile yapılan denemeler için en uygun iterasyon sayısının 1000, tur sayısının ise 100 olduğu testlerin başarımı ile doğrulanmıştır. Bu çalışmada, açık kaynak kodlu çatı üzerinde geliştirilen model kullanılarak test incelemeleri ve eğitim için çeşitli geliştirmeler yapılmıştır.

Tablo 1. Deneysel çalışmalar için kullanılan iş istasyonu bilgisayarın donanımsal özellikleri

(Hardware specifications of the workstation computer used for experimental studies in this study)

Donanım	Özellik
Bilgisayar	İş İstasyonu
Merkezi İşlemci (CPU)	Intel Core i9-9900K @ 5 Ghz (8 Core / 16 Thread)
Bellek (RAM)	32 GB (DDR4 2666 Mhz)
Anakart	ASUS WS Z390 PRO
GPU (x2)	NVIDIA GeForce RTX 2080Ti 11 GB GDDR6
Harddisk sürücü	256 GB SSD HDD + 3 TB SATA 6Gb 3.5'' HDD

Bu çalışma kapsamında hazırlanan verisetinde hastalardan toplanan BT abdomen görüntülerinden, karaciğer bölgesinin belli olduğu uygun kesitler uzman eşliğinde seçilmiştir. BT taramalarından elde edilen kesitlerden alınan görüntüler üzerinde karaciğerin bölütlenmesi için bu çalışma kapsamında özel olarak oluşturulan Karaciğer BT veriseti



Şekil 7. BT görüntüleri üzerinde karaciğerin otomatik bölütlenmesi için önerilen Maskeli B-ESA çatısı
(The proposed Mask R-CNN framework for automatic segmentation of the liver on CT images)

Tablo 2. Maskeli B-ESA modelinin uygulanması için omurga üzerinde belirlenen spesifik ayarlar
(Specific settings determined on the backbone for Mask R-CNN model)

Donanım	Özellik	Açıklaması
backbone	ResNet50	Kullanılacak olan ön eğitilmiş omurga ağ modeli
gpu_count	1 veya 2	Ağın çalışacağı GPU sayısı
image_min_dim	512	Verisetindeki görüntülerin minimum kenar uzunluğu
image_max_dim	512	Verisetindeki görüntülerin maksimum kenar uzunluğu
train_rois_per_image	100	Eğitimde her resim için çıkartılacak tahmini bölgelerin adedi
max_gt_instances	50	Bir görüntüde bulunacak en fazla lezyon sayısı
images_per_gpu	2	GPU başına düşen görüntü sayısı
num_classes	2	Kesitler üzerindeki sınıf sayısı(1 karaciğer + 1 arkaplan)
steps_per_epoch	1000	Her turdaki tekrar sayısı
epoch_count	30	Tur sayısı
threshold	0,5	Tespitin başarılı sayılması için geçerli eşik değeri

kullanılmıştır. Bunun yanında, bu veriseti üzerinde yürütülen deneysel çalışmalar sonucunda ulaşılan sonuçlar, SLIVER07 ve 3DIRCADb olmak üzere iki farklı açık veriseti ile elde edilen sonuçlarla karşılaştırılarak, önerilen yöntemin ve hazırlanan verisetinin BT görüntüleri üzerinde karaciğerin tespit edilmesi açısından etkinliği de çeşitli analizler ile değerlendirilmiştir. Her üç veriseti için, deneysel çalışmalarda kullanılmak üzere, her hastadan en az bir kesit alınarak, toplamda 310 BT görüntüsü belirlenmiştir. Bu görüntülerden 260 tanesi (~%84) Maskeli B-ESA ağının eğitim aşaması için, kalan 50 tanesi (~%16) ise test aşaması için kullanılmıştır. Bunun yanında, her üç verisetinde çeşitli veri artırma işlemleri uygulanarak, veri sayıları 4 katına yükseltilmiştir. Çalışmada önerilen Maskeli B-ESA modeli ve U-Net algoritması için, eğitim seti üzerinde, tek ve çift GPU kullanılarak 100 ve 1000 tekrarlı 100 tur (epok) ile ResNet50 ön-eğitilmiş omurga ağları üzerinde eğitim aşaması yürütülmüştür. Eğitim aşamasının süre/performans değerlendirmeleri yapılmıştır. Önerilen modelin test aşamasında, eğitim sürecindeki elde edilen ağırlıkları hesaba tabi tutan bir yapı hazırlanmış ve her tur için ölçümler ayrı ayrı yapılmıştır.

Bu çalışmada, aynı zamanda, ulaşılan sonuçların etkinliğinin değerlendirilmesi için, BT görüntüleri üzerinde önerilen Maskeli B-ESA ile elde edilen bölütleme sonuçları, bir diğer popüler bölütleme algoritması olan U-Net kullanılarak elde edilen bölütleme sonuçları ile karşılaştırılmıştır. U-Net mimarisinde, ağın her iki tarafından kısalma ve genişleme yolları bulunmaktadır [48, 49]. Bu yüzden, kodlayıcı ve kod çözücü özellik çıkarma ve çözünürlük iyileştirme prosedürlerini gerçekleştirmektedir [50]. U-Net ile yürütülen deneysel çalışmalarda, epok (adım) sayısı=100 ve yığın boyutu 2 olarak belirlenmiş olup, ağ 'adam' optimizasyonu [51] ile eğitilmiştir ve kayıp fonksiyonu olarak 'mse' fonksiyonu kullanılmıştır.

Çalışmada BT görüntüleri üzerinde karaciğer bölütlemesi için, önerilen Maskeli B-ESA yöntemi ve U-Net algoritması kullanılarak elde edilen sonuçlar ile uzman hekim tarafından bulunan bölütleme sonuçları Dice benzerlik katsayısı (DSC), Jaccard benzerlik katsayısı (JSC), volumetrik örtüşme hatası (VOE), ortalama simetrik yüzey mesafesi (ASD) ve oransal hacim farkı (RVD) ölçüm parametreleri ile karşılaştırılarak,

yapılan bölütlemenin başarımı ortaya koyulmuştur. Bu metrikler sırasıyla Eş. 2, Eş. 3, Eş. 4, Eş. 5 ve Eş. 6'da verilmiştir. Kullanılan ölçütler için verilen eşitliklerde referans alınan uzman görüşü alanı A_{ref} , önerilen model sonucunda maskelenen alan A_{seg} olarak isimlendirilmiştir. DSC referans alan ile maskelenen alanın örtüşme miktarını hesaplayan bir ölçüttür [10, 52]. Referans alan ile maskelenen alanın kesişimi ile toplam eleman sayısının bölünmesi ile başka bir açıdan örtüşme oranı hesabı yapan JSC ile yapılabilmektedir [53]. VOE örtüşme hatasını belirlemek için kullanılırken, iki alan arasında fiziksel olarak oluşan fark ASD ile hesaplanır. Son olarak RVD ise iki alan arasında hacimsel farkları göstermektedir [22].

$$DSC(A_{seg}, A_{ref}) = \frac{2|A_{seg} \cap A_{ref}|}{|A_{seg} \cup A_{ref}|} \quad (2)$$


$$JSC(A_{seg}, A_{ref}) = \frac{|A_{seg} \cap A_{ref}|}{|A_{seg}| + |A_{ref}| - |A_{seg} \cap A_{ref}|} \quad (3)$$

$$VOE(A_{seg}, A_{ref}) = 100 \times \left(1 - \frac{|A_{seg} \cap A_{ref}|}{|A_{seg} \cup A_{ref}|}\right) \quad (4)$$

$$ASD(A_{seg}, A_{ref}) = \frac{1}{|S(A_{seg})| + |S(A_{ref})|} \left(\sum_{S_{A_{seg}} \in S(A_{seg})} d(S_{A_{seg}}, S(A_{ref})) + \sum_{S_{A_{ref}} \in S(A_{ref})} d(S_{A_{ref}}, S(A_{seg})) \right) \quad (5)$$

$$RVD(A_{seg}, A_{ref}) = 100 \times \left(\frac{|A_{seg}| - |A_{ref}|}{|A_{ref}|}\right) \quad (6)$$

Önerilen model ile veriseti üzerinde yapılan eğitimler sonucunda her turun ağırlıkları ayrı ayrı kaydedilmiştir. Testler ise, test kümesi üzerinde eğitim aşamasında elde edilen ağırlıklar ile gerçekleştirilmiştir. Maskeli B-ESA modeli üzerinde karaciğerin bölütlenme aşamaları Şekil 8'de adım adım gösterilmiştir. Başlangıç aşamasında Şekil 8a ve Şekil 8b'de görüldüğü gibi görüntü üzerinde, bölge olması muhtemelen önemli bölgelerin tespiti için özellik çıkarımı sonrasında ilgi bölgesinin hizalanması (İBHizalama) işlemi yapılmıştır. Şekil 8c'deki ikinci aşamada, bölgelerin içinde karaciğer ihtimali bulunalar pozitif olarak işaretlenmiştir. Sonraki aşamada, Şekil 8d'de görüldüğü gibi karaciğerin olabileceği olası en yüksek bölgeler belirlenmiştir. Şekil 8e

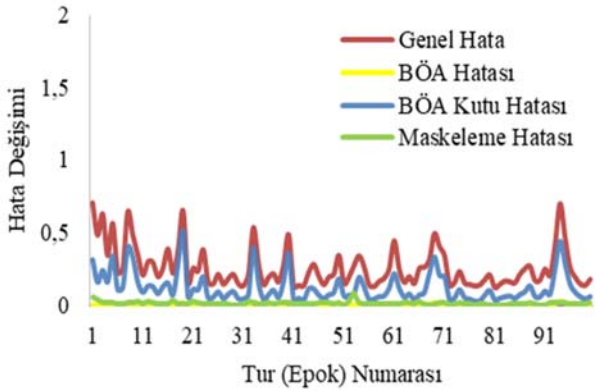


Şekil 8. Önerilen Maskeli B-ESA modeli kullanılarak karaciğerin adım adım bölütlenme aşamaları. (a, b) bölge olması muhtemel önemli bölgelerin tespiti, (c) bölgelerin içinde karaciğer ihtimali bulunanların pozitif olarak işaretlenmesi, (d) karaciğerin olabileceği olası en yüksek bölgelerin belirlenmesi, (e) görüntü üzerinde karaciğerin bulunduğu bölgenin sınırlarının çizilmesi, (f) bölge sınırları belirlenmesi ve bölütleme işleminin tamamlanması
(Step-by-step segmentation of the liver using the proposed Mask R-CNN model. (a, b) detection of important regions likely to be regions, (c) positive marking of those with possible liver in the regions, (d) determination of the highest possible areas of the liver, (e) drawing the boundaries of the region where the liver is located on the image, (f) determining the boundaries of the region and completing the segmentation process)

ile görüntü üzerinde karaciğerin bulunduğu bölgenin sınırları çizilmiştir. Son aşamada, Şekil 8f'de görüldüğü gibi bölge sınırları belirlenmiştir ve bölütleme işlemi tamamlanmıştır.

4.1. Karaciğer BT Verisetinde Deneysel Sonuçlar (Experimental Results on Liver CT Dataset)

Bu çalışma kapsamında oluşturulan BT veriseti üzerinde önerilen Maskeli B-ESA tabanlı model ile eğitim aşamasında oluşan Kayıp (Loss) fonksiyonlarının tur numarasına bağlı hata değişimi Şekil 9'da sunulmuştur. Genel hata eğitim sürecinde karaciğer tespitindeki genel hatanın değişimini, BÖA hatası nesnelerin bulunduğu bölgelerin belirlenmesindeki hatanın düşüşünü, BÖA kutu hatası nesnelerin bulunduğu bölgelerin sınırlarını çizen kutuların hatasının değişimini ve Maskeleme hatası eğitim seti üzerindeki maskelenme hatasının değişimini göstermektedir.



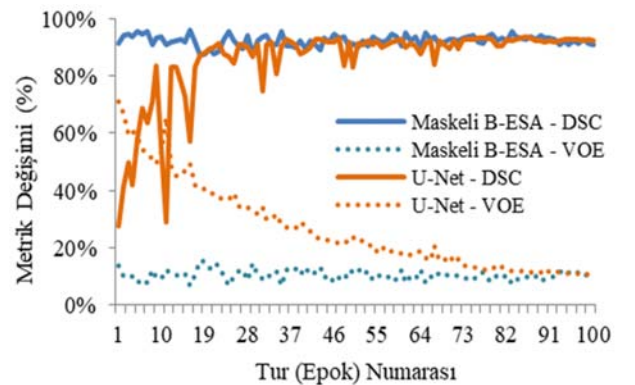
Şekil 9. Karaciğer BT verisetinde önerilen Maskeli B-ESA yöntemi ile eğitim aşaması boyunca kayıp fonksiyonlarının tur sayısına göre değişimi

(Change of loss functions according to the number of epoch during the training phase using the proposed Mask R-CNN method on the liver CT dataset)

Karaciğer BT veriseti üzerinde, sistemin bölütleme başarımının ölçümünde kullanılan ölçütlerden DSC ve VOE için elde edilen değişim grafiği hem önerilen Maskeli B-ESA hem de U-Net bölütleme algoritması için Şekil 10'da gösterilmiştir. BT görüntü veriseti üzerinde, önerilen

Maskeli B-ESA yöntemi kullanarak, GPU üzerinde yapılan eğitimlerinde elde edilen ağırlıklar test edildiğinde, tur numarasına bağlı olarak DSC için başarımların %91,55'ten başlayarak %96,16'ya kadar ulaştığı görülebilmektedir. Aynı şekilde VOE metriğinin sonuçları ise %6,89'a kadar düşmüştür. Aynı veriseti üzerinde, U-Net algoritması kullanılarak DSC sonuçlarının, Maskeli B-ESA sonuçlarına göre daha fazla salınım göstererek %93,48 ile en yüksek sonucuna ulaştığı görülebilmektedir. U-Net algoritması ile yürütülen karaciğer bölütleme deneysel çalışmalarında, VOE değeri en düşük %10,31 olarak ölçülmüştür.

Karaciğer BT veriseti üzerinde, önerilen Maskeli B-ESA ve U-Net bölütleme algoritmaları ile elde edilen metriklerin ortalama değerleri Tablo 3'te verilmiştir. Bu tablodan görülebileceği gibi, başarımların ölçümü için kullanılan tüm metriklerin sonuçlarından bu çalışmada İB için önerilen esnek parametre seçimi ile önerilen Maskeli B-ESA yönteminin daha başarılı olduğu öne çıkmaktadır. Karaciğer BT veriseti üzerinde Maskeli B-ESA ile DSC ile VOE sonuçları sırasıyla %96,16 ve %6,89 iken, aynı metriklerin U-Net ile elde edilen sonuçları yine sırasıyla %93,48 ve %11,96 olarak elde edilmiştir.



Şekil 10. Karaciğer BT veriseti üzerinde Maskeli B-ESA ve U-Net yöntemleri kullanılarak elde edilen DSC ve VOE değerlerinin tur numarasına göre değişimi

(Variation of DSC and VOE values obtained by using Mask R-CNN and U-Net methods on liver CT dataset according to epoch number)

Tablo 3. Karaciğer BT veriseti üzerinde, önerilen Maskeli B-ESA ve U-Net bölütleme algoritmaları ile metrik sonuçlarının ortalama değerleri

(Average values of metric results on liver CT dataset with the proposed Mask R-CNN and U-Net segmentation algorithms)

Bölütleme Yöntemi	DSC [%]	JSC [%]	VOE [%]	ASD [mm]	RVD [%]
U-Net	93,48	88,30	11,96	9,78	6,12
Maskeli B-ESA	96,16	93,11	6,89	1,56	-4,76


Önerilen Maskeli B-ESA modeli ve U-Net kullanılarak veriseti üzerindeki en iyi turda yapılan testlerde, en iyi sonuçların alındığı 5 görüntü için DSC, JSC, VOE, ASD ve RVD ölçüm metriklerinin sonuçları detaylı olarak Tablo 4'te sunulmuştur. Çalışma kapsamında, aynı görüntüler için yürütülen deneysel çalışmalar sonucunda, önerilen Maskeli B-ESA yönteminin, karaciğer BT görüntüleri daha başarılı olduğu sonucu çıkarılabilir. Önerilen Maskeli B-ESA modeli ile yürütülen testlerde BT görüntüleri üzerinde karaciğerin bölütlenmesi başarıyla gerçekleştirilmiştir. Karaciğerin diğer organlar ile benzer renk tonlarına sahip olması ve bazı görüntülerde sınırlarının kesin olmamasına rağmen önerilen model üzerinde maskelenmesinin başarıyla sağlandığı Şekil 11'de sunulan bazı görüntülerin bölütlenmesi sonuçları üzerinde izlenebilmektedir. Şekil 11'deki ilk satırda orijinal görüntüler, ikinci satırda ise BT görüntüleri üzerinde karaciğerin uzman tarafından sınırlarının çizilmesi ile oluşan kapalı alan yeşil renk ile gösterilmiştir. Uzman tarafından karaciğerin işaretlenmesi işlemi, çalışma kapsamında geliştirilen bir uygulama arayüzü üzerinden sağlanmıştır. Şekil 11'in üçüncü satırında ise bu çalışma kapsamında

önerilen Maskeli B-ESA modeli ile elde edilen bölütlenmiş karaciğer bölgesi gösterilmiştir. Buradan da görülebileceği gibi önerilen Maskeli B-ESA modeli tarafından bulunan karaciğer bölgesi kırmızı renk ile temsil edilmiştir. Şekil 11'in dördüncü satırında ise, örtüşme benzerliği sunulmuştur. Burada, uzman hekim tarafından işaretlenen yeşil renkli karaciğer bölgesi ile Maskeli B-ESA tarafından bölütlenen karaciğer bölgesi üst üste örtüştürülerek (birleşim), birbirlerine ne kadar benzediklerinin karşılaştırılması yapılmıştır. Örtüşme benzerliğinde, uzman ile modelin bölütleme bölgelerinin dışında kalan alanlar yeşil veya kırmızı olarak görüntüler üzerinden görülebilmektedir. Ayrıca örtüşme benzerliğinde ortaya çıkanın bölgenin rengi kahverengi ile gösterilmiştir. Ayrıca burada uzmanın bölütleme sonucu ile Maskeli B-ESA'nın örtüşme oranları (ÖÖ) sayısal olarak gösterilmektedir. Bu bölüm incelendiğinde, örtüşme oranlarının oldukça yüksek ve bölütlemenin başarılı olduğu görülmektedir.

Şekil 12'de ise, karaciğer BT görüntü veriseti üzerinde, Şekil 11'deki aynı kesitler ile, bir diğer popüler bölütleme algoritması olan U-Net ile başarılı olarak bölütlenmiş karaciğer görüntüleri görülmektedir. Bu çalışmada önerilen Maskeli B-ESA yöntemi ile U-Net algoritması ile elde edilen bölütleme sonuçları karşılaştırıldığında, Maskeli B-ESA yöntemi kullanarak ulaşılan bölütleme sonuçlarının daha başarılı olduğu açıkça görülmektedir. Şekil 12'deki uzman seçimi ve U-Net ile karaciğer bölütleme sonuçları detaylıca değerlendirildiğinde, bazı kesitlerin bölütlenmesinde uzman kararından olmayan ilgisiz kalıntıların kaldığı tespit edilmektedir.

Tablo 4. Önerilen Maskeli B-ESA modeli ve U-Net kullanılarak veriseti üzerindeki en iyi turda yapılan testlerde en iyi sonuçların alındığı 5 görüntü için DSC, JSC, VOE, ASD ve RVD ölçüm metriklerinin sonuçları (Results of DSC, JSC, VOE, ASD and RVD metrics for 5 images with the best results in the best epoch tests on the dataset using the proposed Mask R-CNN model and U-Net)


Görüntü No	DSC [%]		JSC [%]		VOE [%]		ASD [mm]		RVD [%]	
	Maskeli B-ESA	UNet	Maskeli B-ESA	UNet	Maskeli B-ESA	UNet	Maskeli B-ESA	UNet	Maskeli B-ESA	UNet
image_33_2060175	98.30	92.51	96.66	86.07	3.35	6.68	1.78	1.71	0.73	11.13
image_44_6741490	98.17	93.56	96.41	87.89	3.59	8.31	1.97	2.21	-1.96	5.79
image_47_2056936	98.16	96.38	96.38	93.01	3.62	6.26	2.81	1.42	-1.14	5.10
image_43_4000629	98.09	92.44	96.26	85.95	3.74	8.09	1.99	1.80	-1.26	9.81
image_26_1430464	98.06	95.43	96.20	91.27	3.80	6.49	2.82	1.89	-0.59	5.09




Şekil 11. Önerilen Maskeli B-ESA modeli ile karaciğer BT veriseti üzerinde başarılı olarak bölütlenmiş bazı örnek görüntüler (Some sample images successfully segmented on liver CT dataset using the proposed Mask R-CNN model)

4.2. SLIVER07 Verisetinde Deneysel Çalışmalar (Experimental Results on SLIVER07 Dataset)

Bu çalışmada, BT görüntüleri üzerinde karaciğer bölütlenmesi için, bu çalışmaya özel olarak oluşturulan karaciğer BT görüntü verisetinin yanında, iki farklı açık veriseti üzerinde de, önerilen Maskeli B-ESA yönteminin etkinliğini değerlendirmek için deneysel çalışmalar gerçekleştirilmiştir. Kullanılan açık verisetlerinden birisi ise alanda çok yaygın olarak kullanılan SLIVER07 veritabanıdır. SLIVER07 veriseti üzerinde önerilen Maskeli B-ESA tabanlı model ile eğitim aşamasında oluşan genel hata, BÖA hatası, BÖA kutu hatası ve Maskeleme hatasının değişimi Şekil 13'te sunulmuştur. Karaciğer BT verisetinde oluşan kayıp grafikleri ile karşılaştırıldığında, SLIVER07 verisetindeki eğitim aşamasında alınan grafiklerde salınım ve değişimin daha fazla olduğu görülmektedir.



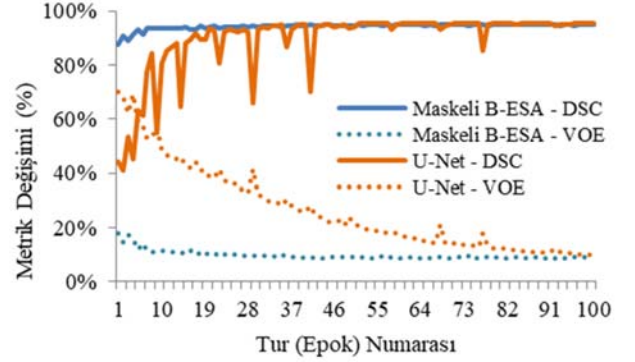
Şekil 12. U-Net bölütleme algoritması ile karaciğer BT verisetinde bölütleme sonuçları
(Segmentation results on liver CT dataset using U-Net segmentation algorithm)



Şekil 13. SLIVER07 verisetinde önerilen Maskeli B-ESA yöntemi ile eğitim aşaması boyunca kayıp fonksiyonlarının değişimi
(Variation of loss functions during the training phase using the proposed Mask R-CNN method on SLIVER07 dataset)

SLIVER07 veriseti üzerinde, sistemin bölütleme başarımının ölçümünde kullanılan ölçütlerden DSC ile VOE için elde edilen değişim grafiği, önerilen Maskeli B-ESA ve U-Net bölütleme algoritması için Şekil 14'te çizilmiştir. Veriseti üzerinde, önerilen Maskeli B-ESA yöntemi DSC için başarımlarının %88,29'dan başlayarak %96,07'ye kadar

yükseldiği, VOE metriğinin %18,39'dan başlayıp %7,53'e kadar düştüğü görülmektedir. Aynı veriseti üzerinde, U-Net algoritması kullanılarak DSC'nin %95,52'ye kadar yükseldiği, VOE değeri en düşük %9,47 olarak ölçüldüğü görülmektedir. Bu sonuçlardan, SLIVER07 veriseti üzerinde önerilen Maskeli B-ESA yönteminin daha başarılı olduğu çıkarılmaktadır. Buna bağlı olarak, SLIVER07 veriseti üzerinde, önerilen Maskeli B-ESA ve U-Net bölütleme algoritmaları ile elde edilen DSC, JSC, VOE, ASD ve RVD metriklerinin ortalama değerleri Tablo 5'te verilmiştir.



Şekil 14. SLIVER07 veriseti üzerinde Maskeli B-ESA ve U-Net yöntemleri ile elde edilen DSC ve VOE sonuçları
(Variation of DSC and VOE values obtained by using Mask R-CNN and U-Net on SLIVER07 dataset)

Tablo 5. SLIVER07 veriseti üzerinde, önerilen Maskeli B-ESA ve U-Net bölütleme algoritmaları ile metriklerin ortalama sonuçları
(Average results of metrics on SLIVER07 dataset using the proposed Mask R-CNN and U-Net algorithms)

Bölütleme Yöntemi	DSC [%]	JSC [%]	VOE [%]	ASD [mm]	RVD [%]
U-Net	95,52	92,04	9,47	3,94	3,66
Maskeli B-ESA	96,07	92,47	7,53	1,25	2,44


Önerilen Maskeli B-ESA modeli ve U-Net kullanılarak SLIVER07 veriseti üzerinde en iyi sonuçların alındığı 5 görüntü için DSC, JSC, VOE, ASD ve RVD ölçüm metriklerinin sonuçları detaylı olarak Tablo 6'da sunulmuştur.

Önerilen Maskeli B-ESA modeli ile SLIVER07 veriseti yürütülen testlerde BT görüntüleri için karaciğerin bölütlenmesinin başarıyla gerçekleştirildiğine ilişkin bazı kesitler Şekil 15'te gösterilmiştir. Buradan, orijinal BT kesiti, kesit üzerinde uzmanın karaciğer bölgesini seçimi, Maskeli B-ESA ile başarılı bölütleme sonucu ve uzman seçimi ile Maskeli B-ESA'nın örtüşme benzerliği görülebilmektedir.

Şekil 16'da ise, SLIVER07 veriseti üzerinde, Şekil 15'teki aynı kesitlerle U-Net ile başarılı olarak bölütlenmiş karaciğer görüntüleri görülmektedir. SLIVER07 veriseti üzerinde, Maskeli B-ESA yöntemi ile U-Net algoritmasının sonuçları karşılaştırıldığında, Maskeli B-ESA yönteminin bölütleme sonuçlarının daha başarılı olduğu görülmektedir.

4.3. 3DIRCADb Verisetinde Deneyler (Experimental Results on 3DIRCADb Dataset)

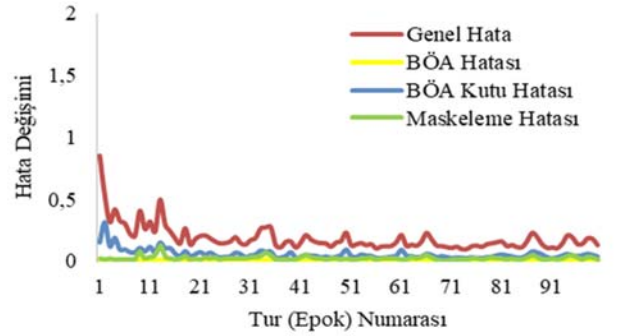
Bu çalışmada, BT görüntüleri üzerinde karaciğer bölütlenmesi için kullanılan açık verisetlerinden bir diğeri ise yaygın olarak kullanılan 3DIRCADb verisetidir. 3DIRCADb veriseti üzerinde önerilen Maskeli B-ESA tabanlı model ile eğitim aşamasında oluşan genel hata, BÖA hatası, BÖA kutu hatası ve Maskeleme hatasının değişimi Şekil 17’de sunulmuştur.



Şekil 16. U-Net bölütleme algoritması ile SLIVER07 verisetinde bölütleme sonuçları (Segmentation results on SLIVER07 dataset using U-Net segmentation algorithm)

3DIRCADb verisetinde, bölütleme başarımın ölçümünde kullanılan ölçütlerden DSC ile VOE için elde edilen değişim grafiği, önerilen Maskeli B-ESA ve U-Net bölütleme algoritması için Şekil 18’de çizilmiştir. Maskeli B-ESA

yöntemi DSC için başarımlarının %78,04’ten başlayarak %96,27’ye kadar yükseldiği, VOE metriğinin %32,63’ten başlayıp %6,76’ya kadar düştüğü görülmektedir. Aynı veriseti üzerinde, U-Net algoritması kullanılarak DSC’nin %95,60’a kadar yükseldiği, VOE değerinin ise %7,16’ya kadar düştüğü görülmektedir. Buradan, 3DIRCADb veriseti üzerinde önerilen Maskeli B-ESA yönteminin daha başarılı olduğu çıkarılmaktadır. Bunun sonucunda, 3DIRCADb veriseti üzerinde, önerilen Maskeli B-ESA ve U-Net bölütleme algoritmaları ile elde edilen DSC, JSC, VOE, ASD ve RVD metriklerinin ortalama değerleri Tablo 7’de verilmiştir.

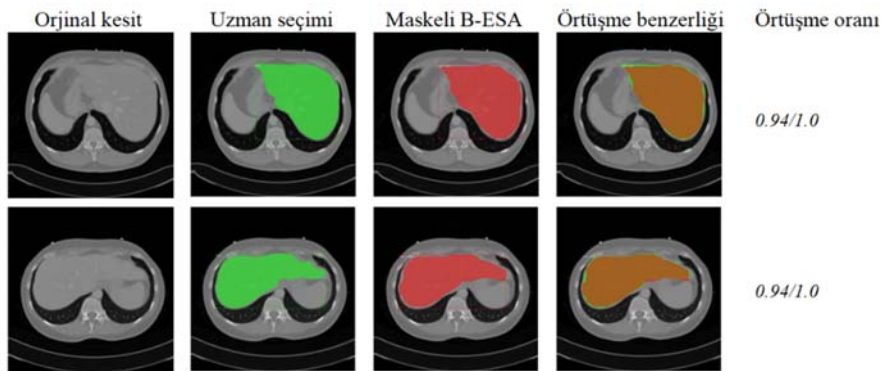


Şekil 17. 3DIRCADb verisetinde önerilen Maskeli B-ESA yöntemi ile eğitim aşaması boyunca kayıp fonksiyonlarının değişimi (Variation of loss functions during the training phase using the proposed Mask R-CNN method on 3DIRCADb dataset)

Bu çalışmada önerilen Maskeli B-ESA modeli ve U-Net kullanılarak, 3DIRCADb veriseti üzerinde en iyi sonuçların


Tablo 6. Maskeli B-ESA modeli ve U-Net kullanılarak SLIVER07 veriseti üzerindeki en iyi turdaki sonuçların alındığı 5 görüntü için DSC, JSC, VOE, ASD ve RVD metriklerinin sonuçları (Results of DSC, JSC, VOE, ASD and RVD for 5 images with the best results on the SLIVER07 dataset using the proposed Mask R-CNN model and U-Net)

Görüntü No	DSC [%]		JSC [%]		VOE [%]		ASD [mm]		RVD [%]	
	Maskeli B-ESA	UNet	Maskeli B-ESA	UNet	Maskeli B-ESA	UNet	Maskeli B-ESA	UNet	Maskeli B-ESA	UNet
image_34_1107818	97.92	98.01	95.92	96.10	4.08	5.04	0.91	0.89	-2.94	0.79
image_11_284252	97.86	98.66	95.81	97.36	4.19	3.99	0.48	5.64	-3.46	1.19
image_11_3769065	97.73	98.59	95.55	97.23	4.45	3.89	0.16	6.13	-4.16	1.03
image_33_2449269	97.65	97.15	95.41	94.46	4.59	5.87	1.78	10.65	-2.73	2.99
image_18_558312	97.59	97.16	95.30	94.48	4.69	5.76	0.80	22.22	-3.67	2.31



Şekil 15. Önerilen Maskeli B-ESA modeli ile SLIVER07 veriseti üzerinde başarılı olarak bölütlenmiş örnek görüntüler (Sample images successfully segmented on SLIVER07 dataset using the proposed Mask R-CNN model)

alındığı 5 görüntü için DSC, JSC, VOE, ASD ve RVD ölçüm metriklerinin sonuçları detaylı olarak Tablo 8’de sunulmuştur. Buradan da görülebileceği üzere, Maskeli B-ESA yöntemi, bu veriseti üzerinde, karaciğerin bölütlenmesinde daha başarılı olmuştur.



Şekil 18. 3DIRCADb veriseti üzerinde Maskeli B-ESA ve U-Net yöntemleri ile elde edilen DSC ve VOE sonuçları (Variation of DSC and VOE values obtained by using Mask R-CNN and U-Net on 3DIRCADb dataset)

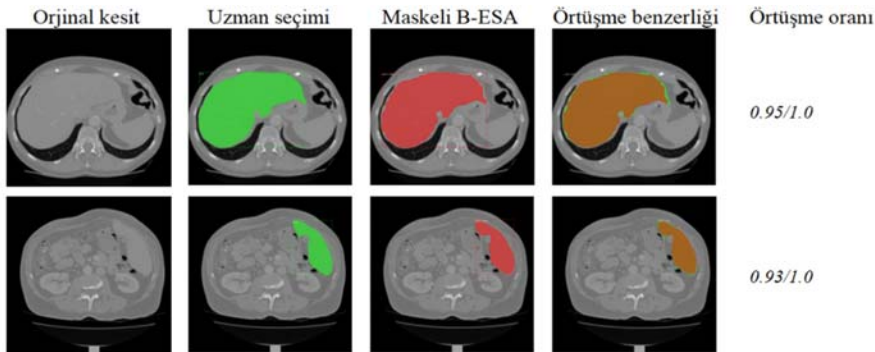
Tablo 7. 3DIRCADb veriseti üzerinde, önerilen Maskeli B-ESA ve U-Net ile metriklerin ortalama sonuçları (Average results of metric on 3DIRCADb dataset using the proposed Mask R-CNN and U-Net)

Bölütlenme Yöntemi	DSC [%]	JSC [%]	VOE [%]	ASD [mm]	RVD [%]
U-Net	95,60	91,60	7,16	3,03	6,08
Maskeli B-ESA	96,27	92,84	6,76	1,03	1,62

Tablo 8. Maskeli B-ESA modeli ve U-Net kullanılarak 3DIRCADb veriseti üzerinde 5 görüntü için DSC, JSC, VOE, ASD ve RVD metriklerinin sonuçları

(Results of DSC, JSC, VOE, ASD and RVD for 5 images on the 3DIRCADb dataset using the proposed Mask R-CNN model and U-Net)

Görüntü No	DSC [%]		JSC [%]		VOE [%]		ASD [mm]		RVD [%]	
	Maskeli B-ESA	UNet	Maskeli B-ESA	UNet	Maskeli B-ESA	UNet	Maskeli B-ESA	UNet	Maskeli B-ESA	UNet
image_1_5500557	98.22	94.43	96.51	89.47	3.48	6.57	1.57	0.87	-0.95	9.48
image_39_9228415	98.04	96.11	96.16	92.51	3.84	4.91	1.99	1.34	-1.89	6.79
image_13_6094294	97.99	97.10	96.07	94.37	3.93	5.15	1.55	1.64	-2.12	3.15
image_7_9633786	97.98	96.04	96.06	92.39	3.94	5.65	0.45	1.06	-3.21	7.27
image_1_1394107	97.87	94.51	95.83	89.59	4.17	7.71	3.79	0.81	0.15	9.22



Şekil 19. Önerilen Maskeli B-ESA modeli ile 3DIRCADb veriseti üzerinde başarılı olarak bölütlenmiş örnek görüntüler (Sample images successfully segmented on 3DIRCADb dataset using the proposed Mask R-CNN model)


Bu çalışma kapsamında önerilen Maskeli B-ESA modeli ile 3DIRCADb veriseti yürütülen testlerde BT görüntüleri için karaciğerin bölütlenmesinin başarılı bir şekilde gerçekleştirildiğine ilişkin bazı kesitler Şekil 19’da sunulmuştur. Bu bölütleme sürecinde, orijinal BT kesiti, kesit üzerinde uzmanın karaciğer bölgesini seçimi, Maskeli B-ESA ile başarılı bölütleme sonucu ve uzman seçimi ile Maskeli B-ESA’nın örtüşme benzerliği görülebilmektedir.

Şekil 20’de ise, 3DIRCADb veriseti üzerinde, Şekil 19’daki aynı kesitlerle U-Net ile başarılı olarak bölütlenmiş karaciğer görüntüleri gösterilmiştir. Bu veriseti üzerinde, Maskeli B-ESA yöntemi ile U-Net algoritmasının sonuçları karşılaştırıldığında, Maskeli B-ESA yönteminin bölütleme sonuçlarının daha başarılı olduğu, U-Net ile yapılan bölütleme sonuçlarındaki kesitlerde kalıntılar olduğundan, açıkça görülmektedir.


5. TARTIŞMALAR (DISCUSSIONS)

Bu çalışmada, üç farklı veriseti üzerinde yürütülen deneysel çalışmaların sonuçları değerlendirilecek olursa, Maskeli B-ESA yöntemi ile karşılaştırıldığında, Maskeli B-ESA yönteminin bölütleme sonuçlarının, U-Net algoritması ile elde edilen bölütleme sonuçlarından daha başarılı olduğu açıkça söylenebilir. Verisetleri üzerinde oldukça yüksek bölütleme başarımlarının elde edildiği, metrik sonuçları ile her ne kadar doğrulanmış olsa da, Şekil 21’de, önerilen Maskeli B-ESA modeli ile yürütülen testlerde BT görüntüleri üzerinde karaciğerin bölütlenmesinde, bazı görüntülerin bölütlenmesi sonuçlarının beklenen düzeyde olmadığı görülmektedir. Bu görüntülerde genellikle bölütlemenin eksik kısımlarının kaldığı ortadadır. Her ne

kadar görüntüler üzerindeki bölütleme sonuçları makul düzeyde olsa da, bu ve benzeri sorunların birçok farklı nedeni olabilir. İlgili görüntülerde gürültülerin bulunması, karaciğer bölgesi ile başka organların dokusal renklerinin iç içe geçmesi, karaciğer bölgesinin birden fazla parçaya sahip olması, uzman tarafından işaretleme de yapılan hatalar, Maskeli B-ESA ağının eğitimindeki tur sayısının bu görüntülerdeki karaciğer bölgelerini tespit etmek için yetersiz kalması gibi birçok neden değerlendirilebilir.



Şekil 20. U-Net bölütleme algoritması ile 3DIRCADb verisetinde bölütleme sonuçları (Segmentation results on 3DIRCADb dataset using U-Net segmentation algorithm)



Şekil 21. Önerilen Maskeli B-ESA modeli ile karaciğer BT veriseti, SLIVER07 ve 3DIRCADb verisetleri üzerinde beklenen düzeyde bölütlenmemiş bazı örnek görüntüler (Some sample images not segmented to the expected level using the proposed Mask R-CNN model on the liver CT dataset, SLIVER07 and 3DIRCADb datasets)

Bu çalışmada önerilen Maskeli B-ESA modeli ile tek ve çift GPU kullanımının zaman açısından bölütleme başarımına etkisi değerlendirilmiştir ve çift GPU kullanımının BT görüntüleri üzerinde karaciğer bölgesinin bölütlenmesinde birçok ölçüm metriği bakımından daha başarılı olduğu sonucuna ulaşılmıştır. Deneysel çalışmalarda tek ve çift GPU kullanımının hız ve eğitim süresine etkisi ise Tablo 9'da verilmiştir. Bu tabloda, eğitim sürecinde GPU sayısı, GPU başına işlenen görüntü sayısı (GBGS), tur (epok) başına adım sayısı (TBAS), eğitim sürecinde belirlenen yığın (batch) miktarı (YM) parametrelerine bağlı olarak, turdaki her bir adımın süresi (AS) ve turun toplam süresi (TS) hesaplanmıştır. Çalışma kapsamındaki deneysel çalışmalarda, her bir veriseti için, veri artırma ile eğitim kümelerindeki veri sayısı 4 katına çıkarılarak, GPU testleri 1042 görüntüden oluşan görüntüler ile yapılmıştır. Böylece GPU testleri ile yığın miktarına göre en uygun adım sayısı

belirlenmiştir. Buradan, yığın büyüklüğü değişiminin ve GPU sayısının, toplam işlem süresinin azaltılmasında büyük bir avantaj sağladığı çıkarılabilir. Ayrıca adım işleme süresinin, GPU işleme süresine göre arttığı gözlenmiş olsa da, aynı anda işlenen görüntü sayısının fazlalığı nedeniyle toplam sürede büyük kazanç sağlandığı görülmüştür.

Tablo 9. Veriseti üzerinde tek ve çift GPU kullanımının eğitim süresine etkisi (The effect of single and dual GPU usage on the dataset on training time)

GPU sayısı	GBGS	TBAS	YB	AS (ms)	TS (s)
1	1	1042	1	111	116
1	2	521	2	187	97
2	1	521	2	103	54
2	2	261	4	179	47

BT görüntüleri üzerinde karaciğerin bilgisayar destekli bölütlenmesi konusunda daha önceki çalışmaları, verisetinin aynı olmaması, kullanılan algoritmaların farklı olması ve farklı benzerlik ölçütleri kullanılması gibi nedenlerle karşılaştırmak oldukça zordur. Ancak bu çalışmada ikisi açık olmak üzere, üç farklı verisetinde karaciğerin bölütlenmesi için deneysel çalışmalar yürütülmüştür. Literatürde bu çalışma kapsamında kullanılan SLIVER07 ve 3DIRCADb açık verisetleri üzerinde farklı yöntemlerle karaciğerin bölütlenmesi konusunda birçok çalışma önerilmiştir. Bu çalışmada, karaciğer BT veriseti, SLIVER07 ve 3DIRCADb verisetleri üzerinde karaciğerin bölütlenmesinde sırasıyla %96,16, %96,07 ve %96,27 DSC benzerlik oranı ile bölütleme doğruluklarına ulaşılmıştır. Ancak bu sonuçların anlamlı olabilmesi için, literatürdeki sonuçlarla bu çalışmada elde edilen sonuçların istatistiksel olarak anlamlılığının bakılması ve sonuçların buna göre değerlendirilmesi yerinde olacaktır. Veriler arasındaki anlamlılığı değerlendiren birçok test bulunmaktadır. Wilcoxon işaretli-sıralar testi, bağımlı gruplar *t*-test'inde olduğu gibi, parametrik bir test olmayıp, iki değişkene ait verilerin ortancaları arasındaki farkı değerlendiren parametrik olmayan istatistiksel bir testtir [54]. Bu çalışmada açık verisetleri üzerinde elde edilen sonuçların, literatürdeki sonuçlarla kıyaslanması için iki-tarafli Wilcoxon işaretli-sıralar testi kullanılmıştır. SLIVER07 veriseti üzerinde, Zareei ve Karimi (2016) [12], Al-Shaikhli vd. (2016) [55], Moghbel vd. (2016) [56], Ben-Cohen vd. (2016) [57], Bal vd. (2018) [58], Kriston vd. (2018) [59], Ahmad vd. (2019) [60] ve Hassanzadeh vd. (2020) [61] ve bu çalışmada elde edilen DSC değerleri üzerinden yürütülen Wilcoxon işaretli-sıralar testinde *p*-değeri ($p=0.0234 < .05$) olarak hesaplanmıştır. 3DIRCADb veriseti üzerinde ise, Moghbel vd. (2016) [56], Christ vd. (2017) [62], Alirri vd. (2018) [63], Ahmad vd. (2019) [60], Nasiri vd. (2019) [64] ve Budak vd. (2020) [31] ve bu çalışmada elde edilen DSC değerleri üzerinden yürütülen Wilcoxon işaretli-sıralar testinde *p*-değeri ($p=0.0312 < .05$) olarak hesaplanmıştır. Böylece, her iki açık veriseti üzerinde, bu çalışmada önerilen Maskeli B-ESA yöntemi ile elde edilen sonuçların, literatürde bulunan benzer çalışmaların sonuçlarına göre istatistiksel olarak anlamlılığı doğrulanmıştır. Ancak yine de bu çalışmanın sonuçları ile daha önce literatürde önerilen bazı çalışmaların DSC benzerlik katsayısı ve VOE ölçütüne göre karşılaştırılması Tablo 10'da gösterilmiştir. Bu tablodan da görülebileceği gibi, farklı

Tablo 10. Önerilen çalışmanın sonuçları ile önceki çalışmaların sonuçlarının ölçüm metrikleri ile karşılaştırılması
(Comparison of the results of the proposed study with the results of previous studies in terms of the measurement metrics)

Çalışma	Veriseti	Algoritma	Performans Sonuçları	
			DSC(%)	VOE(%)
Zareei ve Karimi (2016) [12]	Sliver07	Aktif sınır modeli	97,14	2,24
Huang vd. (2018) [7]	3DIRCADb Sliver07	Graf biçimli ve özellik çıkarımı	-	8,6±2,0 5,3±1,4
Ahmad vd. (2019) [60]	3DIRCADb Sliver07	Derin kanı ağı	91,83 94,8	6,09 4,31
Wang vd. (2019) [65]	Özgün veriseti	Çok-modlu ESA	95,00 ± 3	-
Liu vd. (2019) [30]	Codalab+ Riverside	ESA ve graf tabanlı	95,05 ± 1,32	7,07 ± 2,37
Cheema vd. (2019) [66]	Sliver07	Artan ESA	96,5	4,30
Mulay vd. (2019) [32]	Chaos	Bütüncül-yuvalı kenar tespiti tabanlı Maskeli B-ESA	94,0	-
Budak vd. (2020) [31]	3DIRCADb	Kodlayıcı-Kod çözücü ESA	95,22	9,05
Önerilen çalışma	Özgün veriseti		96,16	6,89
	Sliver07	Maskeli B-ESA	96,07	7,53
	3DIRCADb		96,27	6,76

verisetlerinde bulunan BT görüntüleri üzerinde karaciğerin bölütlenmesinde, bu çalışmanın sonuçlarının kayda değer olduğu çıkarılabilir.

6. SONUÇLAR (CONCLUSIONS)

BT görüntüleri üzerinde karaciğerin bölütlenmesinin yapılmasında hekimlere yardımcı olacak bilgisayar destekli ikincil araçların katkısı, son yıllarda artarak devam etmektedir. Hekimler tarafından el ile seçilerek yapılan bölütlemelerin, insan hatasına açık, zaman harcayan çok fazla prosedürel silsilelerden oluştuğu görülmektedir. Bu nedenle BT görüntüleri üzerinde karaciğerin otomatik bölütlenmesi hem zaman hem de maliyet bakımından önemli avantajlar içermektedir. Bu çalışmada, BT taramaları üzerinde karaciğerin bölütlenmesi için hekimlere ve uzmanlara yardımcı olabilecek Maskeli B-ESA tabanlı güncel teknolojiler içeren bir yöntem önerilmiştir. Farklı boyutlarda, farklı tarama parametreleri ile edinilmiş ve bu çalışmaya özgü oluşturulan bir veriseti ve açık iki farklı veriseti üzerinde yapılan deneysel çalışmalarda önerilen yöntemin, karaciğerin bölütlenmesinde oldukça başarılı olduğu görülmüştür. Ayrıca ilgi bölgesi için önerilen esnek parametre seçimi ile desteklenmiş Maskeli B-ESA'nın sonuçları, bir diğer popüler bölütleme algoritması olan U-Net'in sonuçları ile karşılaştırılarak, önerilen yöntemin etkinliği ve geçerliliği doğrulanmıştır.

Bu çalışmanın katkıları şu şekilde özetlenebilir. (1) Birisi bu çalışma kapsamında oluşturulmuş, ikisi ise açık olmak üzere, toplamda üç farklı verisetinde bulunan BT taramaları üzerinde karaciğerin bölütlenmesi için önerilen bu çalışmada, ResNet50 omurgası üzerinde başarımlı performansı karşılaştırmaları yapılmış ve ilgi bölgesi için önerilen esnek parametre seçimi ile desteklenmiş Maskeli B-ESA modelinin ile yürütülen deneysel çalışmalarda DSC, JSC, VOE, ASD ve RVD bölütleme başarımlı metrikleri, sırasıyla %96,16, %93,11, %6,89, 1,56 mm, -%4,76 olarak hesaplanmıştır. (2) Karaciğerin bölütlenmesinde hekimlere yardımcı olacak bilgisayar destekli bir destek sistemi ikincil bir araç olarak sunulmuştur. (3) Çalışma kapsamında önerilen Maskeli B-ESA modeli ile tek GPU ve çift GPU

donanım yapıları için hız ile performans testleri de yürütülmüştür. Gerçekleştirilen performans testleri ile çift GPU için en verimli çalışma yapısı belirlenmiş ve sonuçları detaylıca ortaya konmuştur. (4) Çalışmada ayrıca Maskeli B-ESA mimarisinin iterasyon sayısı, GPU sayısı ve GPU başına düşen görüntü sayısına göre çalışma hızının değişimi incelenmiştir.

Gelecekteki çalışmalarda, farklı çözünürlük, boyut ve tarayıcılardan elde edilen BT taramalarından yeni bir verisetinin oluşturulması ve bu veriseti üzerinde yapılacak çalışmalarda yüksek tespit başarımlı elde edilmesi planlanmaktadır. Ayrıca, tek GPU ve çift GPU performansı konusunda kesin sonuçlara ulaşmak için standart bir veriseti üzerinde birbirinden farklı konfigürasyonlarda testler yapılacaktır. Ek olarak, sonraki çalışmalarda Maskeli B-ESA modelinin kısıtlarını ortadan kaldıracak yeni bir model ile karaciğerin bölütleme başarımlının artırılmasına ağırlık verilmesi planlanmaktadır.

TEŞEKKÜR (ACKNOWLEDGEMENT)

Çalışmanın yazarları olarak, çalışmada kullanılan BT verilerini sağladığı ve kullanımına izin verdiği için T.C. Sağlık Bakanlığı Türkiye Kamu Hastaneleri Kurumu ve Sincan Nafiz Körez Devlet Hastanesi yönetimine teşekkür ederiz. Ayrıca çalışma kapsamında deneysel çalışmaların yürütüldüğü iş istasyonu bilgisayarı 2019-01.BŞEÜ.25-02 proje numarası ile destekleyen Bilecik Şeyh Edebali Üniversitesi Bilimsel Araştırmalar Koordinatörlüğüne ve Biyoteknoloji Uygulama ve Araştırma Merkezine teşekkür ederiz.

KAYNAKLAR (REFERENCES)

1. Bogovic J. A., Prince J. L. Bazin P.-L., A multiple object geometric deformable model for image segmentation, Computer Vision and Image Understanding, 117 (2), 145-157, 2013.
2. Lu X., Wu J., Ren X., Zhang B. Li Y., The study and application of the improved region growing algorithm for liver segmentation, Optik-International Journal for Light and Electron Optics, 125 (9), 2142-2147, 2014.

3. Kaya H., Çavuşoğlu A., Çakmak H. B., Şen B. Delen D., Supporting the diagnosis process and processes after treatment by using image segmentation and image simulation techniques: Keratoconus example, *Journal of The Faculty of Engineering and Architecture of Gazi University*, 31 (3), 737-747, 2016.
4. Dandil E., An Application for Computer-Assisted Automatic Segmentation of Liver on Computed Tomography Images, *Gazi University Science Journal: PART:C 'Design and Technology'*, 7 (3), 712-728, 2019.
5. Selvi E., Selver M. A., Kavur A., Güzeliş C. Dicle O., Segmentation of Abdominal Organs from MR Images using Multi-Level Hierarchical Classification, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 30 (3), 533-546, 2015.
6. Von Landesberger T., Bremm S., Kirschner M., Wesarg S. Kuijper A., Visual analytics for model-based medical image segmentation: Opportunities and challenges, *Expert Systems with Applications*, 40 (12), 4934-4943, 2013.
7. Huang Q., Ding H., Wang X. Wang G., Fully automatic liver segmentation in CT images using modified graph cuts and feature detection, *Computers in biology and medicine*, 95, 198-208, 2018.
8. Gotra A., Sivakumaran L., Chartrand G., Vu K.-N., Vandenbroucke-Menu F., Kauffmann C., Kadoury S., Gallix B., de Guise J. A. Tang A., Liver segmentation: indications, techniques and future directions, *Insights into imaging*, 8 (4), 377-392, 2017.
9. Moghbel M., Mashohor S., Mahmud R. Saripan M. I. B., Review of liver segmentation and computer assisted detection/diagnosis methods in computed tomography, *Artif. Intell. Rev.*, 50 (4), 497-537, 2018.
10. Heimann T., Van Ginneken B., Styner M. A., Arzhaeva Y., Aurich V., Bauer C., Beck A., Becker C., Beichel R. Bekes G., Comparison and evaluation of methods for liver segmentation from CT datasets, *IEEE transactions on medical imaging*, 28 (8), 1251-1265, 2009.
11. Kainmüller D., Lange T. Lamecker H., Shape constrained automatic segmentation of the liver based on a heuristic intensity model, *Proc. of the MICCAI Workshop 3D Segmentation in the Clinic: A Grand Challenge*, 109-116, 2007.
12. Zareei A. Karimi A., Liver segmentation with new supervised method to create initial curve for active contour, *Computers in Biology and Medicine*, 75, 139-150, 2016.
13. Boykov Y. Funka-Lea G., Graph cuts and efficient ND image segmentation, *International journal of computer vision*, 70 (2), 109-131, 2006.
14. Lu F., Wu F., Hu P., Peng Z. Kong D., Automatic 3D liver location and segmentation via convolutional neural network and graph cut, *Int. J. Comput. Assist. Radiol. Surg.*, 12 (2), 171-182, 2017.
15. Qiao Y., Cappelle C., Ruichek Y. Yang T., ConvNet and LSH-Based Visual Localization Using Localized Sequence Matching, *Sensors*, 19 (11), 2439, 2019.
16. Elmas B., Identifying species of trees through bark images by convolutional neural networks with transfer learning method, *Journal of The Faculty of Engineering and Architecture of Gazi University*, 36 (3), 1253-1270, 2021.
17. Andrew W., Greatwood C. Burghardt T., Visual localisation and individual identification of holstein friesian cattle via deep learning, *Proc. of the IEEE International Conference on Computer Vision*, 2850-2859, 2017.
18. Pinheiro P. O., Collobert R. Dollár P., Learning to segment object candidates, *Proc. of the 28th International Conference on Advances in Neural Information Processing Systems (NIPS'15)*, 1990-1998, 2015.
19. Pinheiro P. O., Lin T.-Y., Collobert R. Dollár P., Learning to refine object segments, *Proceedings of the European Conference on Computer Vision (ECCV 2016)*, 75-91, 2016.
20. He K., Gkioxari G., Dollár P. Girshick R., Mask r-cnn, *Proceedings of the IEEE international conference on computer vision*, 2961-2969, 2017.
21. Wu W., Zhou Z., Wu S. Zhang Y., Automatic liver segmentation on volumetric CT images using supervoxel-based graph cuts, *Computational and mathematical methods in medicine*, vol. 2016, 2016.
22. Liao M., Zhao Y.-q., Wang W., Zeng Y.-z., Yang Q., Shih F. Y. Zou B.-j., Efficient liver segmentation in CT images based on graph cuts and bottleneck detection, *Physica Medica*, 32 (11), 1383-1396, 2016.
23. Liao M., Zhao Y.-q., Liu X.-y., Zeng Y.-z., Zou B.-j., Wang X.-f. Shih F. Y., Automatic liver segmentation from abdominal CT volumes using graph cuts and border marching, *Computer methods and programs in biomedicine*, 143, 1-12, 2017.
24. Zeng Y.-z., Liao S.-h., Tang P., Zhao Y.-q., Liao M., Chen Y. Liang Y.-x., Automatic liver vessel segmentation using 3D region growing and hybrid active contour model, *Computers in biology and medicine*, 97, 63-73, 2018.
25. Yang X., Do Yang J., Hwang H. P., Yu H. C., Ahn S., Kim B.-W. You H., Segmentation of liver and vessels from CT images and classification of liver segments for preoperative liver surgical planning in living donor liver transplantation, *Computer methods and programs in biomedicine*, 158, 41-52, 2018.
26. Lu X., Wu J., Ren X., Zhang B. Li Y., The study and application of the improved region growing algorithm for liver segmentation, *Optik*, 125 (9), 2142-2147, 2014.
27. Foruzan A. H., Zoroofi R. A., Hori M. Sato Y., A knowledge-based technique for liver segmentation in CT data, *Computerized Medical Imaging and Graphics*, 33 (8), 567-587, 2009.
28. Lim S.-J., Jeong Y.-Y. Ho Y.-S., Automatic liver segmentation for volume measurement in CT Images, *Journal of Visual Communication and Image Representation*, 17 (14), 860-875, 2006.
29. Huang L., Weng M., Shuai H., Huang Y., Sun J. Gao F., Automatic liver segmentation from CT images using

- single-block linear detection, *BioMed research international*, vol. 2016, 2016.
30. Liu Z., Song Y.-Q., Sheng V. S., Wang L., Jiang R., Zhang X. Yuan D., Liver CT sequence segmentation based with improved U-Net and graph cut, *Expert Systems with Applications*, 126, 54-63, 2019.
 31. Budak Ü., Guo Y., Tanyildizi E. Şengür A., Cascaded deep convolutional encoder-decoder neural networks for efficient liver tumor segmentation, *Medical hypotheses*, 134, 109431, 2020.
 32. Mulay S., Deepika G., Jeevakala S., Ram K. Sivaprakasam M., Liver Segmentation from Multimodal Images Using HED-Mask R-CNN, *Int. Workshop on Multiscale Multimodal Medical Imaging*, 68-75, 2019.
 33. Segmentation of the Liver Competition 2007 (SLIVER07). <https://sliver07.grand-challenge.org/>. Erişim Tarihi: 15/12/2020.
 34. 3Dircadb. <https://www.ircad.fr/research/3dircadb/>. Erişim Tarihi: 15.12.2020.
 35. Soler L., Hostettler A., Agnus V., Charnoz A., Fasquel J., Moreau J., Osswald A., Bouhadjar M. Marescaux J., 3D image reconstruction for comparison of algorithm database: A patient specific anatomical and medical image database, IRCAD, Strasbourg, France, Tech. Rep, 2010.
 36. Kusrini K., Suputa S., Setyanto A., Agastya I. M. A., Priantoro H., Chandramouli K. Izquierdo E., Data augmentation for automated pest classification in Mango farms, *Computers and Electronics in Agriculture*, 179, 105842, 2020.
 37. Keras. <https://keras.io>. Erişim Tarihi: 26.12.2020.
 38. Chollet F., Image preprocessing – Keras documentation. <https://keras.io/api/preprocessing/image/>. Erişim Tarihi: 26.12.2020.
 39. Jia W., Tian Y., Luo R., Zhang Z., Lian J. Zheng Y., Detection and segmentation of overlapped fruits based on optimized mask R-CNN application in apple harvesting robot, *Computers and Electronics in Agriculture*, 172, 105380, 2020.
 40. He K., Gkioxari G., Dollár P. Girshick R., Mask R-CNN, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42 (2), 386-397, 2020.
 41. Dandil E. Polattimur R., Dog Behavior Recognition and Tracking based on Faster R-CNN, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35 (2), 819-834, 2020.
 42. Yu Y., Zhang K., Yang L. Zhang D., Fruit detection for strawberry harvesting robot in non-structural environment based on Mask-RCNN, *Computers and Electronics in Agriculture*, 163, 104846, 2019.
 43. Jiang J., Bie Y., Li J., Yang X., Ma G., Lu Y. Zhang C., Fault diagnosis of the bushing infrared images based on mask R-CNN and improved PCNN joint algorithm, *High Voltage*, 6, 116-124, 2021.
 44. Lin T.-Y., Dollár P., Girshick R., He K., Hariharan B. Belongie S., Feature pyramid networks for object detection, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2117-2125, 2017.
 45. Qiao Y., Truman M. Sukkarieh S., Cattle segmentation and contour extraction based on Mask R-CNN for precision livestock farming, *Computers and Electronics in Agriculture*, 165, 104958, 2019.
 46. Zimmermann R. S. Siems J. N., Faster training of Mask R-CNN by focusing on instance boundaries, *Computer Vision and Image Understanding*, 188, 102795, 2019.
 47. Abdulla W., Mask R-CNN for object detection and instance segmentation on Keras and TensorFlow: matterport/Mask_RCNN, https://github.com/matterport/Mask_RCNN, 2017, Erişim Tarihi: 26.12.2020.
 48. Ronneberger O., Fischer P. Brox T., U-net: Convolutional networks for biomedical image segmentation, *Proc. of the Int. Conference on Medical image computing and computer-assisted intervention*, 234-241, 2015.
 49. Jeevakala S., Sreelakshmi C., Ram K., Rangasami R. Sivaprakasam M., Artificial intelligence in detection and segmentation of internal auditory canal and its nerves using deep learning techniques, *International Journal of Computer Assisted Radiology and Surgery*, 15, 1859-1867, 2020.
 50. Hu X. Yang H., DRU-net: a novel U-net for biomedical image segmentation, *IET Image Processing*, 14 (1), 192-200, 2019.
 51. Kingma D. P. Ba J., Adam: A method for stochastic optimization, *arXiv preprint arXiv:1412.6980*, 2014.
 52. Dice L. R., Measures of the amount of ecologic association between species, *Ecology*, 26 (3), 297-302, 1945.
 53. Yuan Y., Chao M. Lo Y.-C., Automatic skin lesion segmentation using deep fully convolutional networks with jaccard distance, *IEEE transactions on medical imaging*, 36 (9), 1876-1886, 2017.
 54. Ohlyver M., Moniaga J. V., Sungkawa I., Subagyo B. E. Chandra I. A., The Comparison Firebase Realtime Database and MySQL Database Performance using Wilcoxon Signed-Rank Test, *Procedia Computer Science*, 157, 396-405, 2019.
 55. Al-Shaikhli S. D. S., Yang M. Y. Rosenhahn B., 3D automatic liver segmentation using feature-constrained Mahalanobis distance in CT images, *Biomedical Eng./Biomedizinische Technik*, 61 (4), 401-412, 2016.
 56. Moghbel M., Mashohor S., Mahmud R. Saripan M. I. B., Automatic liver segmentation on computed tomography using random walkers for treatment planning, *EXCLI journal*, 15, 500, 2016.
 57. Ben-Cohen A., Diamant I., Klang E., Amitai M. Greenspan H., Fully convolutional network for liver segmentation and lesions detection, *In: Deep learning and data labeling for medical applications*, Springer, Cham, 77-85, 2016.
 58. Bal E., Klang E., Amitai M. Greenspan H., Automatic liver volume segmentation and fibrosis classification, *Medical Imaging 2018: Computer-Aided Diagnosis*, 1057506, 2018.
 59. Kriston A., Czipczer V., Manno-Kovács A., Kovács L., Benedek C. Szirányi T., Segmentation of multiple

- organs in Computed Tomography and Magnetic Resonance Imaging measurements, 3D Conference Engineering Section Pécs, Hungary, 51, 2018.
60. Ahmad M., Ai D., Xie G., Qadri S. F., Song H., Huang Y., Wang Y. Yang J., Deep belief network modeling for automatic liver segmentation, *IEEE Access*, 7, 20585-20595, 2019.
 61. Hassanzadeh T., Essam D. Sarker R., Evolutionary Attention Network for Medical Image Segmentation, *Proc. of the Int. Conf. on Digital Image Computing: Techniques and Applications (DICTA)*, 1-8, 2020.
 62. Christ P. F., Ettliger F., Grün F., Elshaera M. E. A., Lipkova J., Schlecht S., Ahmaddy F., Tatavarty S., Bickel M. Bilic P., Automatic liver and tumor segmentation of CT and MRI volumes using cascaded fully convolutional neural networks, *arXiv preprint arXiv:1702.05970*, 2017.
 63. Alirr O. I. Rahni A., Automatic liver segmentation from ct scans using intensity analysis and level-set active contours, *J Eng Sci Technol*, 13 (11), 3821-3839, 2018.
 64. Nasiri N., Foruzan A. H. Chen Y.-W., A controlled generative model for segmentation of liver tumors, 2019 *Proc. of the 27th Iranian Conference on Electrical Engineering (ICEE)*, 1742-1745, 2019.
 65. Wang K., Mamidipalli A., Retson T., Bahrami N., Hasenstab K., Blansit K., Bass E., Delgado T., Cunha G. Middleton M. S., Automated CT and MRI liver segmentation and biometry using a generalized convolutional neural network, *Radiology: Artificial Intelligence*, 1 (2), 180022, 2019.
 66. Cheema M. N., Nazir A., Sheng B., Li P., Qin J. Feng D. D., Liver Extraction Using Residual Convolution Neural Networks From Low-Dose CT Images, *IEEE Transactions on Biomedical Engineering*, 66 (9), 2641-2650, 2019.