

SegNet Mimarisi ile Bilgisayarlı Tomografi Görüntülerinden Karaciğer Bölgesinin Bölütlenmesi

Ümit BUDAK*

Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Mimarlık Fakültesi, Bitlis Eren Üniversitesi, Bitlis, Türkiye
* umtbudak@gmail.com

(Geliş/Received: 03/12/2018;

Kabul/Accepted: 16/02/2019)

Özet: Son zamanlarda teknolojinin gelişmesiyle birlikte, tıbbi görüntüleme daha kaliteli bir hale gelmiştir. Bu durum doktorların işlerini hem kolaylaştırmakta hem de tanı ve tedavi işlemlerinin güvenilirliğini artırmaktadır. Bilgisayarlı Tomografi (BT) önemli bir medikal görüntüleme sistemidir ve karaciğer gibi bazı organların izlenmesinde önemli role sahiptir. Karaciğer tümörlerinin boyutlarının belirlenmesi veya karaciğer nakli öncesinde karaciğer hacminin hesaplanması oldukça önemlidir. BT görüntü serilerinden manuel olarak bu karaciğer hacminin hesaplanması doktorlar için hem zor hem de zaman alıcı bir işlemdir. Bu işlemlerin bilgisayar ile otomatik yapılması arzu edilmektedir. Bu çalışmada, BT görüntü serilerinden karaciğer bölgesinin bölütlenmesi için derin mimariye sahip bir yöntem önerilmiştir. Yöntem, ön işlemler ve derin SegNet mimarisine dayanmaktadır. Ön işlemler, SegNet öncesi BT görüntü serisinin daha elverişli hale getirilmesini amaçlarken, SegNet ile bölütleme işlemi yapılmaktadır. Çalışmada, Dokuz Eylül Üniversitesi Tıp Fakültesi Radyodiagnostik Anabilim Dalı'nın sağladığı 20 DICOM serisi kullanılmıştır. Elde edilen bölütleme sonuçları sırası ile hacimsel örtüşme, bağıl mutlak hacim farkı, ortalama simetrik yüzey mesafesi, etkin simetrik yüzey mesafesi ve en büyük simetrik yüzey mesafesi kriterleri olarak değerlendirilmiştir. Elde edilen sonuçlar cesaret vericidir.

Anahtar kelimeler: Bilgisayarlı Tomografi, Derin Öğrenme, SegNet, Karaciğer Bölütleme.

Segmentation of Liver Region from Computerized Tomography with SegNet Architecture

Abstract: In recent years, medical imaging has become better quality with the development of technology. This not only facilitates the work of doctors, but also increases the reliability of diagnostic and therapeutic procedures. Computerized Tomography (CT) is an important medical imaging system and has an important role in monitoring certain organs such as the liver. It is very important to determine the size of liver tumors or to calculate the liver volume before liver transplantation. Calculating of this liver volume manually from the CT image series is both difficult and time-consuming for physicians. It is desirable to do these operations automatically with the computer. In this study, a method with deep learning architecture for segmenting the liver region from a computerized tomography image has been proposed. The method is based on preprocessing and deep SegNet architecture. While pre-processing aims to make the CT image series more convenient before training, segmentation is being done with SegNet. 20 DICOM series provided by Dokuz Eylül University Faculty of Medicine Radiodiagnostic Department were used in the study. The obtained segmentation results are evaluated with the order of volume overlap, relative absolute volume difference, average symmetrical surface distance, effective symmetric surface distance and the largest symmetric surface distance criterion. The results are encouraging.

Key words: Computerized Tomography, Deep Learning, SegNet, Liver Segmentation.

1. Giriş

Medikal görüntüleme sistemlerinin gelişmesiyle birlikte Bilgisayarlı Tomografi (BT) görüntüleri tanı, biyopsi ve morfolojik anatomi gibi bazı önemli bilgilerin elde edilmesinde sıkça kullanılmaya başlanmıştır [1]. BT, karaciğer yapısının izlenmesinde ve karaciğer tümörlerinin teşhisinde kullanılan önemli bir görüntüleme sistemidir [2]. Hekimler genellikle BT görüntüleri üzerindeki değerlendirmeleri ve belirlemeleri manuel olarak yaparlar. Ancak yapılan bu değerlendirme ve belirleme, hekimin o anki fiziki durumuna bağlıdır. Yorgunluk, dalgınlık gibi nedenlerden dolayı dikkatten kaçabilecek bazı durumlar olabilir. Son zamanlarda BT görüntülerinin bilgisayar tabanlı akıllı sistemler aracılığıyla değerlendirilmesine imkân tanıyan birçok yeni yöntem ve algoritma geliştirilmiştir [2-10]. Linguraru ve diğ. [2], karaciğer BT görüntülerinden karaciğer bölgesinin otomatik olarak bölütlenmesi için olasılıksal atlas yöntemini kullanmışlardır. Hame [3], bulanık kümeleme ve geometrik deforme olabilen bir model kullanarak karaciğerde bulunan tümörlü bölgelerin belirlenmesini sağlamışlardır. Zayane ve diğ. [4], ön bilgi, konum ve şekil bilgisi kullanarak BT görüntülerinden

* Sorumlu yazar: umtbudak@gmail.com. ORCID Numarası: 0000-0003-4082-383X


karaciğer bölütlemesi yapmıştır. Avşar ve Arıca, yaptıkları çalışmada [5] su seviyesi ve histogram eşikleme yöntemlerini kullanarak karaciğer BT görüntülerinde benzer ve farklı dokuları belirlemişlerdir. Benzer bir çalışmada Liu ve diğ. [6] tarafından karaciğer BT görüntülerinin etkili bir şekilde bölütlenmesi için yine su seviyesi yöntemi kullanılmıştır. Wu ve diğ. [7], karaciğer BT görüntülerinde tümör tespiti yapabilmek için bulanık c-ortalamlar ve çizge kesim tabanlı yarı otomatik bir yöntem önermiştir. Linguraru ve diğ. [8], karın bölgesi BT görüntülerinden karaciğer tümör yükünün otomatik olarak hesaplanması için bir çalışma yapmıştır. Bağcı ve diğ. [9], böbrek ve dalağın da içinde bulunduğu BT görüntülerinden karaciğeri bölütlemek için şekil ve bölge tabanlı yöntemleri melez bir yaklaşımla birleştirmişlerdir. Karın bölgesi BT karaciğer görüntüleri için bilgisayar destekli bir tanı sistemi ise Sayed ve diğ. [10] tarafından önerilmiştir. Önerilen sistemde karaciğerin otomatik olarak bölütlenmesi için bulanık kümeleme ve gri kurt optimizasyonuna dayalı melez bir yaklaşım kullanılmıştır.

Son zamanlarda derin öğrenmenin BT görüntülerine uygulandığı birçok çalışma göze çarpmaktadır. Geliştirilen derin öğrenme tabanlı görüntü bölütleme yöntemleri, karaciğer görüntülerinin bölütlenmesinde de yüksek başarımlar göstermişlerdir [11-15]. Jin ve diğ. [11], karaciğer BT görüntülerinin bölütlenmesi için özel bir tam evrişimsel sinir ağı (TESA) yapısı önermiştir. Bellver ve diğ. [12], evrişimsel sinir ağlarını (ESA) kullanarak karaciğer BT görüntülerinde normal olmayan bölgelerin belirlenmesini sağlamışlardır. Önerilen ESA mimarisi kaskat bir yapıda olup, önce karaciğer bölgesinin bölütlenmesi, ardından da karaciğer bölgesi üzerindeki normal olmayan bölgenin bölütlenmesi gerçekleştirilmiştir. Hu ve diğ. [13], 3B ESA ve küresel yüzey evrim optimizasyonu temelli yeni bir karaciğer bölütleme algoritması önermiştir. Qin ve diğ. [14], otomatik karaciğer bölütlemesi için süper piksel ve sınır duyarlı ESA mimarisine dayalı yeni bir yöntem önermiştir. Zhou ve diğ. [15], karaciğer BT görüntülerinden karaciğerin bölütlenmesi için bir derin ESA mimarisini uçtan-uca öğrenme yaklaşımı ile eğitmişlerdir.

Konu ile alakalı teknik yazım incelendiğinde karaciğer görüntülerinden karaciğer ve normal olmayan bölgelerin bölütlenmesinde yeni trendin derin öğrenme yönüne doğru kaydığı görülmektedir. Bunun temel nedenini elde edilen yüksek başarımlar oluşturmaktadır. Bu çalışmada da yine derin öğrenme mimarisi kullanan yeni bir karaciğer bölütleme algoritması önerilmiştir. Önerilen algoritma öncelikle bazı ön-işlemler uygulayarak karaciğer BT görüntülerini bölütlemeye uygun hale getirmektedir. Daha sonra 5 katmanlı bir SegNet yapısı kullanılarak BT görüntülerinden karaciğer bölgeleri bölütlenmiştir. Çalışmada, Dokuz Eylül Üniversitesi Tıp Fakültesi Radyodiagnostik Anabilim Dalı'nın sağladığı 20 DICOM serisi kullanılmıştır. DICOM görüntüleri 12 bit derinliğe sahiptir ve her bir seride 70 ile 115 arasında kesit bulunmaktadır. Elde edilen bölütleme sonuçları sırası ile hacimsel örtüşme, bağıl mutlak hacim farkı, ortalama simetrik yüzey mesafesi, etkin simetrik yüzey mesafesi ve en büyük simetrik yüzey mesafesi kriterlerine bağlı olarak değerlendirilmiştir. Elde edilen sonuçlar cesaret vericidir.

2. Materyal ve Yöntem

Önerilen yöntemin grafiksel gösterimi Şekil 1'de gösterilmiştir. Şekil 1'den de görüleceği üzere giriş DICOM imgeleri ilk önce bir dizi ön işlemlerden geçirildikten sonra 5 katmanlı SegNet mimarisine girdi olarak verilmektedirler.



Şekil 1. Önerilen yöntemin grafiksel gösterimi. BT görüntüsü önce bir dizi ön işlemlerden geçirildikten sonra, 5 katmanlı SegNet mimarisine girdi olarak verilmektedir. SegNet mimarisi çıktısı, ikilik görüntü olarak elde edilmiştir.

SegNet mimarisinin aşağı yönlü örnekleme bölümündeki ilk iki katmanında iki evrişim ve bir havuzlama ve son üç katmanda ise üç evrişim ve bir havuzlama katmanı mevcut iken, yukarı yönlü örnekleme bölümünde ise aşağı yönlü örnekleme bölümünün simetriği formatında bir yapı mevcuttur. Son olarak softmax katmanı ile ağ nihayi bölütlemeyi üretmektedir.

2.1. Ön İşlemler

BT görüntü serileri sadece karaciğer bölgesini değil, aynı zamanda yağ dokusu, kaburgalar ve omurgalar gibi diğer bölgeleri de içermektedir. Ön işlem sürecindeki amaç, BT görüntü serilerinde karaciğere ait olmayan bölgelerin çıkarılmasıdır. Bu amaç doğrultusunda öncelikle Şekil 2(a)'da gösterilmiş olan ham BT görüntüleri, Hounsfield Unit (HU) aralığına pencerelemiştir [16]. HU değerleri, ilgili veri kümesinin 'info' bilgisinde yer almaktadır ve Algoritma 1'de ilgili işlemler verilmiştir;

Algoritma-1

```

dicomread → Giriş_BT_serileri
dicominfo → Giriş_BT_serileri
for i = 1 : row
    for j = 1 : column
        HUimage(i,j) = Giriş_BT_serileri(i,j) × info.RescaleSlope + info.RescaleIntercept
    end
end
end

```

Elde edilen yeni görüntü Şekil 2(b)'de gösterilmiştir. DICOM formatındaki piksel değerleri 0-4095 aralığında olduğu için HU pencereleme sonucu 0-255 aralığına dönüştürülmüştür ve ardından Şekil 2(c)'de gösterilen kontrast germe işlemi uygulanmıştır.



Şekil 2. Uygulanan ön işlem adımlarına genel bakış: a) Ham BT görüntüsü, b) İlgisiz bölgelerin çıkarılması için uygulanan HU pencereleme sonucu, c) Kontrast germe sonucu.

2.2. SegNet Mimarisi

SegNet, piksel tabanlı görüntü bölütlemesi için önerilmiş tam bağlı bir sinir ağ mimarisidir [17]. SegNet mimarisi, farklı çözünürlüklerin sınıflandırılması için kodlayıcı-kod çözücü çiftlerinin ürettiği özellik haritalarını kullanır. Şekil 1'de SegNet mimarisi verilmiştir. Şekil 1'den görüleceği üzere, her kodlayıcı sırası ile evrişim, yığın normalizasyon ve ReLu işlemlerini uyguladıktan sonra elde edilen sonuca maksimum havuzlama işlemi uygular. Kod çözücüler genelde kodlayıcılara benzerler ve ikisi arasındaki temel fark, doğrusal olmayan bir etkiye sahip değildir. Kod çözücüler kendilerine gelen girdiyi kodlama aşamasından gelen indeksleri kullanarak yukarı yönde örneklerler. Son kod çözücülerden elde edilen sonuç, softmax katmanına verilerek nihai çıktı elde edilir.

2.3. Veri Kümesi

Deneyisel çalışmalarda kullanılan veri kümesi, Dokuz Eylül Üniversitesi Tıp Fakültesi Radyodiagnostik Anabilim Dalı'ndan alınmıştır. 20 kişiden alınan görüntü serileri, damardan opak madde verilmesini takiben 3.2 mm kesit kalınlığında portal fazda çekilmiştir. Serilerdeki kesit sayıları 70 ile 115 arasındadır. Elde edilen görüntüler, DICOM formatında olup 12 bittir. Görüntü serilerinin standart bir forma dönüştürülmesi için 8 bit formatında yeniden kaydedilmiştir. Böylece standart gri seviye aralığı [0-255] elde edilmiştir. Bu işlem için gerekli olan pencere merkezi ve pencere genişliği bilgileri DICOM meta üstbilgisinden elde edilmiştir. Görüntü serilerindeki karaciğer bölgesi uzman bir radyolog tarafından manuel olarak bölütlenerek referans görüntü serileri üretilmiştir. Tablo 1'de veri kümesine ait detaylı bilgi verilmiştir.


Tablo 1. Veri kümesi ile ilgili teknik bilgiler.

Dosya İsimleri	Kesit Sayıları	Gerçek Bölütlenme Sonuçları	Kullanım Yeri
Set01	96	Var	Eğitim ve Test
Set02	81	Var	Eğitim ve Test
Set03	78	Yok	Test
Set04	94	Yok	Test
Set05	95	Yok	Test
Set06	88	Yok	Test
Set07	108	Yok	Test
Set08	123	Var	Eğitim ve Test
Set09	97	Yok	Test
Set10	110	Yok	Test
Set11	83	Yok	Test
Set12	104	Yok	Test
Set13	89	Yok	Test
Set14	95	Var	Eğitim ve Test
Set15	87	Yok	Test
Set16	91	Var	Eğitim ve Test
Set17	97	Yok	Test
Set18	111	Var	Eğitim ve Test
Set19	90	Yok	Test
Set20	105	Yok	Test

Tablo 1'den de görüleceği üzere veri kümesinde 20 farklı hastaya ait kesit görüntüleri mevcuttur. Bunlardan 6 tanesi (Set01, Set02, Set08, Set14, Set16, Set18) yarışmacılarla eğitim kümesi olarak ve manuel olarak bölütlenmiş ikili karaciğer bölgeleri ile birlikte paylaşılmıştır. Geriye kalan setlerin ise sadece BT kesit görüntüleri mevcuttur. Yarışma kuralları gereği katılımcılardan istenen, 6 küme üzerindeki eğitimin tüm kümelerde tahmin edilmesi ve tahmin edilen tüm setlerin uygulayıcı kuruluş tarafından her bir set için test edilmesidir.

3. Deneysel Çalışmalar

Deneysel çalışmalar Matlab ortamında gerçekleştirilmiştir ve elde edilen sonuçlar hem görsel hem de rakamsal olarak değerlendirilmiştir. Toplamda 597 kesit görüntüsünün eğitildiği SegNet mimarisinin eğitim parametreleri olarak başlangıç öğrenme oranı 0.1, maksimum yığın (devir) sayısı 200, yığın boyutu 6, öğrenme oranı düşme faktörü 0.5 ve öğrenme oranı düşme periyodu 20 olarak seçilmiştir. Elde edilen sonuçların bazıları Şekil 3'de verilmiştir. Şekil 3(a) veri kümesinin ham görüntülerini göstermektedir. Uygulanan ön işlemler sonrasında elde edilen görüntüler, Şekil 3(b)'de verilmiştir. Ayrıca, nihai bölütlenme sonuçları Şekil 3(c)'de ve Şekil 3(d)'de ise gerçek bölütlenme sonuçları verilmiştir.



Şekil 3. Elde edilen sonuçların gösterilmesi (a) Orijinal BT görüntüleri, (b) Ön işlemler sonucunda elde edilen görüntü, (c) Elde edilen sonuçlar, (d) Gerçek sonuçlar.

Elde edilen sonuçlara görsel olarak bakıldığında, sonuçların gerçek bölütleme sonuçlarına oldukça benzediği görülmektedir. Elde edilen sonuçlardan, önerilen yöntemin bölütlenen karaciğer bölgelerinin kenarlarını daha yumuşak bölütlediği görülmüştür. Diğer bir ifade ile elde edilen bölütlemelerde ince hatlar kaybedilmiştir.

Önerilen yöntem ile tahmin edilen bölütleme sonuçları, aşağıdaki beş farklı değerlendirme ölçütü ile hesaplanmaktadır:

1-) Hacimsel Örtüşme:

Referans görüntülerdeki vokseller ile tahmin edilen segmentasyon sonucundaki voksellerin kesişimlerinin birleşimlerine oranı ile hesaplanır. En başarılı durumda %100, en başarısız durumda ise %0 değerini almaktadır.

$$Hacimsel \ Örtüşme = \frac{Voksel \ Sayısı_{referans \cap \ tahmin}}{Voksel \ Sayısı_{referans \cup \ tahmin}} \times 100 \quad (1)$$

2-) Bağıl Mutlak Hacim Farkı:

Tahmin edilen bölütlenmiş nesnenin hacminin referans görüntülerdeki nesnenin hacmine oranı ile hesaplanır. En iyi durumda sıfır değerini almaktadır.

$$\text{Bağıl Mutlak Hacim Farkı} = \left(\frac{Hacim_{tahmin} - Hacim_{referans}}{Hacim_{referans}} \right) \times 100 \quad (2)$$

3-) Ortalama simetrik yüzey mesafesi:

Tahmin edilen nesnenin sınırına ait tüm voksellerin referans nesnedeki sınıra ait tüm voksellere olan en kısa uzaklıkları hesaplanır. Bu mesafe bilgilerinin aritmetik ortalaması ile ortalama simetrik yüzey mesafesi hesaplanır. En iyi durumda sıfır değerini almaktadır.

4-) Etkin simetrik yüzey mesafesi:

Ortalama simetrik yüzey mesafesine benzer şekilde hesaplanmaktadır. Ancak burada mesafe bilgilerinin etkin (ortalama karekök) değeri hesaplanır. En başarılı durumda ise sıfır değerini almaktadır.

5-) En büyük simetrik yüzey mesafesi:

Ortalama simetrik yüzey mesafesine benzer şekilde hesaplanmaktadır. Burada mesafe bilgilerinin en büyük olanı alınır. En iyi durumda sıfır değerini alır.

Hesaplanan bu beş farklı değerlendirme ölçütleri 0-100 arası puanlara dönüştürülmektedir. Yarışmadaki nihai puan ise bu beş ölçütün aritmetik ortalaması alınarak 100 üzerinden hesaplanan bir puan olarak belirlenmektedir. Tablo 2’de bu beş farklı değerlendirme ölçütünün puanlamaya dâhil edildiği minimum ve maksimum değerler gösterilmiştir.

Tablo 2. Bölütleme sonuçlarının her bir ölçüt için değerlendirilmeye dahil edilmesi için elde edilmesi istenilen başarımlar aralıkları.

Değerlendirme ölçütleri	Değerlendirmeye dahil edilen başarımlar aralığı (minimum – maksimum)
Hacimsel Örtüşme	%50 – %100
Bağıl Mutlak Hacim Farkı	%10 – %0
Ortalama simetrik yüzey mesafesi	10 piksel – 0 piksel
Etkin simetrik yüzey mesafesi	15 piksel – 0 piksel
En büyük simetrik yüzey mesafesi	50 piksel – 0 piksel

Hesaplanan bir metrik Tablo 2’deki minimum değerlerden daha başarısız bir sonuç üretiyorsa 100 üzerinden 0 puan almaktadır. Eğer minimum noktası ile aynı değeri alıyorsa 100 üzerinden 50 puan almaktadır. Eğer maksimum değerine ulaşırsa 100 üzerinden 100 almaktadır. Minimum ile maksimum arasındaki değerler ise 100 üzerinden 50-100 arasındaki değerlere atanmaktadır. Örneğin, Hacimsel örtüşmesi %35 olarak hesaplanan bir bölütleme sonucu bu aşamada 0 puan alır. Aynı bölütleme için ortalama simetrik yüzey mesafesi 5 piksel olarak hesaplandıysa bu aşamadan 75 puan almaktadır.

Beş farklı değerlendirme ölçütlerinin sonuçları 100 üzerinden ayrı ayrı hesaplandıktan sonra bunların aritmetik ortalaması alınarak nihai puan hesaplanmaktadır.

Diğer taraftan bütün bölütleme sonuçlarının rakamsal olarak değerlendirildiği sonuçlar Tablo 3’de verilmiştir. Tablo 3’den görüldüğü üzere her bir BT görüntüsü, veri kümesi için sırası ile hacimsel örtüşme, bağıl mutlak hacim farkı, ortalama simetrik yüzey mesafesi, etkin simetrik yüzey mesafesi ve en büyük simetrik yüzey mesafesi değerleri için hesaplanmıştır. Hacimsel örtüşme kriterine bakıldığında önerilen yöntemin %82,82 ile %96,71 aralığında değişen değerler ürettiği ve bu değerlerin ortalamasının %88,43 olduğu görülmüştür. Bu değer, önerilen yöntemin ürettiği bölütlemeleri hacimsel olarak gerçek sonuçlarla büyük oranda örtüşüğünü göstermektedir. Benzer şekilde bağıl mutlak hacim farkı kriterine göre bir değerlendirme yapılacak olunursa,

önerilen yöntemin %60,63 ile %99,61 aralığında değerler ürettiği ve Set09 veri kümesi için ise %0 değerini ürettiği görülmüştür. Dolayısıyla önerilen yöntemin ortalama bağıl mutlak hacim farkı değeri %79,62 olarak gerçekleşmiştir. Ortalama simetrik yüzey mesafesi dikkate alındığında, önerilen yöntemin %79,14 ile %96,27 aralığında değerler ürettiği gözlenmiştir. Ayrıca ortalama simetrik yüzey mesafesi değerlerinin ortalaması da %86,96 olarak hesaplanmıştır. Etkin simetrik yüzey mesafesi diğer bir değerlendirme kriteri olarak kullanılmış ve önerilen yöntemin %52,45 ile %96,52 aralığında değerler ürettiği gözlemlenmiştir.

Tablo 3. Elde edilen sonuçların rakamsal değerlendirilmesi.

Değerlendirme Kriterleri	Set01	Set02	Set03	Set04	Set05	Set06	Set07
Hacimsel Örtüşme	96,71	96,49	87,18	82,82	92,06	86,04	89,02
Bağıl Mutlak Hacim Farkı	86,29	83,82	60,63	98,25	99,61	91,59	72,14
Ortalama simetrik yüzey mesafesi	95,84	96,27	84,89	81,1	90,97	86,21	90,54
Etkin simetrik yüzey mesafesi	95,56	96,52	78,42	68,61	82,3	83,73	87,88
En büyük simetrik yüzey mesafesi	81,19	90,51	51,86	0	0	0	0
Sonuç	91,12	92,72	72,6	66,15	72,99	69,51	67,92
Değerlendirme Kriterleri	Set08	Set09	Set10	Set10	Set12	Set13	Set14
Hacimsel Örtüşme	96,05	83,72	90,91	88,1	86,86	89,62	96,47
Bağıl Mutlak Hacim Farkı	82,82	0	77,36	72,97	98,62	98,53	84,1
Ortalama simetrik yüzey mesafesi	95,58	84	88,91	88,74	85,34	79,14	95,9
Etkin simetrik yüzey mesafesi	95,54	72,98	80,69	81,78	78,23	52,45	95,66
En büyük simetrik yüzey mesafesi	0	0	0	0	0	0	54,96
Sonuç	74	48,14	67,57	66,32	69,81	63,95	85,42
Değerlendirme Kriterleri	Set15	Set16	Set17	Set18	Set19	Set20	Ortalama
Hacimsel Örtüşme	92,34	96,33	88,73	96,21	91,68	88,89	88,43
Bağıl Mutlak Hacim Farkı	90,45	83,95	93,35	82,87	96,17	64,95	79,62
Ortalama simetrik yüzey mesafesi	92,47	95,58	90,36	95,33	89,46	85,33	86,96
Etkin simetrik yüzey mesafesi	90,6	95,4	87,99	94,31	77,41	73,73	78,34
En büyük simetrik yüzey mesafesi	0	0	0	55,85	0	0	3,7
Sonuç	73,17	74,25	72,09	84,92	70,94	62,58	67,41

Ortalama etkin simetrik yüzey mesafesi ise %78,34 olarak hesaplanmıştır. Son olarak en büyük simetrik yüzey mesafesi kriterine bağlı olarak yapılan değerlendirme de önerilen yöntemin sadece Set01, Set02, Set03, Set14 ve Set18 veri kümeleri için değer ürettiği diğer bütün veri kümeleri için ise %0 değerini ürettiği görülmüştür. Bu durum genel ortalamanın önemli ölçüde düşmesine neden olmuştur.

3. Deneysel Çalışmalar

Bu çalışmada, BT görüntülerinden karaciğer bölgesinin belirlenmesi için derin ağ mimarisine sahip bir yöntem önerilmiştir. Yöntem temel olarak ön işlemler ve SegNet mimarisi dayalı etkili bir yöntemdir. Yöntemin değerlendirilmesi için 20 farklı BT görüntü serisi kullanılmış ve elde edilen sonuçlar sayısal (kuantitatif) olarak değerlendirilmiştir. Elde edilen sonuçlar önerilen yöntemin umut vaat eden bir yapı olduğunu göstermiştir. Önerilen yöntemin temel bir sakıncası derin SegNet mimarisinin eğitim için çok veri ve zamana ihtiyaç duymasıdır. Diğer taraftan elde edilen sonuçlar “Karaciğer bölütleme algoritmaları yarışıyor” [18] isimli yarışmada elde edilen sonuçlarla kıyaslandığında, en iyi üçüncü sonucun önerilen yöntem ile elde edildiği görülmüştür.

Kaynaklar

- [1] Campadelli, P., Casiraghi, E., & Pratisoli, S. A segmentation framework for abdominal organs from CT scans. *Artificial Intelligence in Medicine*, 2010; 50(1), pp. 3-11.
- [2] Linguraru, M. G., Sandberg, J. K., Li, Z., Shah, F., & Summers, R. M. Automated segmentation and quantification of liver and spleen from CT images using normalized probabilistic atlases and enhancement estimation. *Medical physics*, 2010; 37(2), pp. 771-783.
- [3] Häme, Y. Liver Tumor Segmentation Using Implicit Surface Evolution. *Proceedings of the MICCAI Workshop on 3D Segmentation in the Clinic: A Grand Challenge II 2008*.
- [4] Zayane, O., Jouini, B., & Mahjoub, M. A. Automatic liver segmentation method in CT images. *Canadian Journal on Image Processing & Computer Vision*, 2011; 2(8), pp. 92-85.
- [5] Avşar, T. S., & Arica, S. Automatic Segmentation of Computed Tomography Images of Liver Using Watershed and Thresholding Algorithms. In *EMBECC & NBC 2017*, pp. 414-417. Springer, Singapore.
- [6] Liu, J., Wang, Z., & Zhang, R. December. Liver cancer CT image segmentation methods based on watershed algorithm. In *Computational Intelligence and Software Engineering (CiSE)*, 2009. International Conference on IEEE, pp. 1-4.
- [7] Wu, W., Wu, S., Zhou, Z., Zhang, R., & Zhang, Y. 3D liver tumor segmentation in CT images using improved fuzzy C-means and graph cuts. *BioMed research international*, 2017.
- [8] Linguraru, M. G., Richbourg, W. J., Liu, J., Watt, J. M., Pamulapati, V., Wang, S., & Summers, R. M. Tumor burden analysis on computed tomography by automated liver and tumor segmentation. *IEEE transactions on medical imaging*, 2012; 31(10), pp. 1965-1976.
- [9] Bağcı, U., Chen, X., & Udupa, J. K. Hierarchical scale-based multiobject recognition of 3-D anatomical structures. *IEEE Transactions on Medical Imaging*, 2012; 31(3), pp. 777-789.
- [10] Sayed, G. I., Hassanien, A. E., & Schaefer, G. An automated computer-aided diagnosis system for abdominal CT liver images. *Procedia Computer Science*, 2016; 90, pp. 68-73.
- [11] Jin, X., Ye, H., Li, L., & Xia, Q. December. Image Segmentation of Liver CT Based on Fully Convolutional Network. In *Computational Intelligence and Design (ISCID)*, 2017 10th International Symposium on IEEE, Vol. 1, pp. 210-213.
- [12] Bellver, M., Maninis, K. K., Pont-Tuset, J., Giró-i-Nieto, X., Torres, J., & Van Gool, L. Detection-aided liver lesion segmentation using deep learning. 2017; arXiv preprint arXiv:1711.11069.
- [13] Hu, P., Wu, F., Peng, J., Liang, P., & Kong, D. Automatic 3D liver segmentation based on deep learning and globally optimized surface evolution. *Physics in Medicine & Biology*, 2016; 61(24), 8676.
- [14] Qin, W. et al. Superpixel-based and boundary-sensitive convolutional neural network for automated liver segmentation. *Physics in Medicine & Biology*, 2018; 63(9), 095017.
- [15] Zhou, X., Takayama, R., Wang, S., Hara, T., & Fujita, H. Deep learning of the sectional appearances of 3D CT images for anatomical structure segmentation based on an FCN voting method. *Medical physics*, 2017; 44(10), pp. 5221-5233.
- [16] Tustison, N. J., Avants, B. B., Cook, P. A., Zheng, Y., Egan, A., Yushkevich, P. A., & Gee, J. C. N4ITK: improved N3 bias correction. *IEEE transactions on medical imaging*, 2010; 29(6), pp. 1310-1320.
- [17] Badrinarayanan, V., Kendall, A., & Cipolla, R. Segnet: A deep convolutional encoder-decoder architecture for image segmentation. 2015; arXiv preprint arXiv:1511.00561.
- [18] Yarışma erişim linki, <http://webb.deu.edu.tr/tb/2izmirbulusmasi/yarisma.html>, Son erişim: 01.04.2018