



Bilgisayarlı Tomografi Görüntülerinde Konvolüsyonel Sinir Ağları ile Dalak Sınıflandırılması

Spleen Segmentation on CT Using Convolutional Neural Network

Gökalp Tulum¹, Onur Osman¹

¹Elektrik-Elektronik Mühendisliği Bölümü, İstanbul Arel
Üniversitesi, İstanbul, Türkiye
gokalptulum@arel.edu.tr, onurosman@arel.edu.tr

Vural Taner Yılmaz²

²Akdeniz Üniversitesi Tıp Fakültesi Hastanesi, İç
Hastalıkları AD., Nefroloji BD., Prof. Dr. Tuncer
Karpuzoğlu Organ Nakli Merkezi, Antalya, Türkiye,
vuraltaneryl@yahoo.com.tr

Tuncer Ergin³, Ferhat Cüce³

³Radyoloji Bölümü, SBÜ Gülhane Eğitim ve Araştırma
Hastanesi, Ankara, Türkiye
tuncerergin@yahoo.com, ferhatcuce@hotmail.com

Özgür Dandin⁴

⁴Genel Cerrahi Servisi, Akdeniz Üniversitesi Tıp Fakültesi
Hastanesi, Antalya, Türkiye
dandinozgur@gmail.com

Abdullah Kısaoğlu⁵, İsmail Demiryılmaz⁵, Muhittin
Yaprak⁵, Bülent Aydın⁵

⁵Akdeniz Üniversitesi Tıp Fakültesi Hastanesi, Genel
Cerrahi AD., Prof. Dr.
Tuncer Karpuzoğlu Organ Nakli Merkezi, Antalya, Türkiye
kisaoglu.a@gmail.com, bulentaydinli@gmail.com,
ismail-2007@hotmail.com

Özetçe—Otomatik bölütleme sistemleri radyolojide deneysel çalışmalardan klinik uygulamalara doğru evrim geçirmektedir. Bu sayede radyologlar medikal görüntü yorumlamalarında teşhis başarılarını arttırabilmektedirler. Bu çalışmada konvolüsyonel sinir ağı tabanlı dalak bölütleme sistemi önerilmektedir. Otomatik olarak bölütlenen dalak için %76,7 duyarlılık, %99, özgüllük, %94,7 pozitif öngörü değeri, %99,9 negatif öngörü değeri ve %99,8 doğruluk değeri hesaplanmıştır.

Anahtar Kelimeler — Bilgisayarlı tomografi; dalak bölütleme; konvolüsyonel sinir ağı.

Abstract— The automated segmentation systems have been evolving from experimental to clinical applications in radiology. By taking advantage of these, radiologists can increase diagnostic accuracy in their interpretations. In this work we proposed a convolutional neural network based spleen segmentation system. Automatically segmented spleen had an 76.7% sensitivity, 99.8% specificity, 94.7% positive prediction value, 99.9% negative prediction value and 99.8% accuracy.

Keywords — Computed tomography; spleen segmentation; convolutional neural network.

I. GİRİŞ

Günümüzde medikal görüntü işleme teknikleri organ bölütleme, organ hacmi hesaplama, tümör tespiti gibi çalışmalarda sıklıkla kullanılan yöntemlerdendir. Bilgisayarlı

Tomografi (BT) görüntüleri ise abdominal organların görüntülenmesinde çoğunlukla tercih edilmektedir.

Dalak, göğüs kafesinin altında karnın sol üst kısmında yer alan aknyuvarların üretimi ve yaşlanan alyuvarların yıkımını sağlayan abdominal organdır. Medikal görüntü işleme yöntemleri ile dalağın otomatik olarak bölütlenmesi sayesinde cerrahi müdahaleler öncesinde organın hacmi, kistik lezyonların belirlenmesi veya dalak büyümesi olup olmadığı kolaylıkla anlaşılabilir. Ayrıca dalak, trafik kazaları nedeni ile oluşan travmatik iç organ yaralanmalarından en çok etkilenen ve iç kanamaya neden olan organdır [1]. Bu nedenle acil servislerde dalağın hızlı ve etkin bir şekilde bölütlenmesi ile organda laserasyon, kontüzyon veya hematoma olup olmadığı anlaşılabilir.

Literatürde dalak bölütleme ile ilgili çalışmalar incelendiğinde Jiang ve arkadaşları temel bileşen analizi ve isoperimetrik tabanlı geliştirdikleri yöntem ile dalak bölütleme işlemini gerçekleştirmişlerdir [2]. Linguraru ve arkadaşlarının çalışmalarında ise dört boyutlu yönlü graflar kullanılarak abdominal organların bölütlenmesi sağlanmıştır [3, 4]. Bölütleme işlemi sonrasında %6,5±5,3 hacim hata oranı, 2±0,75 mm ortalama karesel hata değeri gibi metrik sonuçlar elde edilmiştir. Gonzalo ve arkadaşları ise geliştirdikleri üç boyutlu eğri tabanlı parametrik aktif kontür (yılan) modeli ile dalak bölütleme işlemini gerçekleştirmişlerdir [5]. Campadelli ve arkadaşları hızlı yürüme (Fast Marching) algoritması

yardımları ile dalağın da içlerinde bulunduğu abdominal organları bölütlemişlerdir [6]. İstatistiksel bilgilere dayalı atlas tabanlı bölütleme yöntemlerini kullanan çalışmalarda ise Park ve arkadaşları otuz iki BT görüntüsünden elde ettikleri olasılıksal atlası kullanarak dalak bölütlemesini gerçekleştirmişlerdir [7]. Lingurar ve arkadaşları on BT görüntüsünden elde ettikleri dalak maskesi ile bölgesel aktif kontür yöntemini birleştirerek bölütleme başarısını arttırmaya çalışmış ve %3,3±2,7 hacim hata oranı, 1,1±0,3 mm ortalama karesel hata değeri hesaplamıştır [8]. Wolz ve arkadaşlarının geliştirdiği üç seviyeli atlas maskesi; global, organ ve voksel tabanlı atlasların birleştirilmesi ile oluşturulmuş ve model tabanlı grafik kesme (graph cut) yöntem ile bölütleme işlemi gerçekleştirilmiştir [9].

Dalağın belirlenmesi işlemi derin öğrenme tabanlı bölütleme yöntemleri açısından incelendiğinde; Splenomegaly Segmentation Network (SS-Net) mimarisi öne çıkmaktadır [10,11]. Huo ve arkadaşları tarafından tasarlanan bu mimaride spasyal ve anatomik varyasyonları belirleyebilmek için büyük boyutlu konvolüsyon çekirdek matrisleri tercih edilmiş, eğitim ve doğrulama adımları için T1 ve T2 ağırlıklı MRI görüntüleri kullanılmıştır. Moon ve arkadaşları ise, ön işlemler, derin öğrenme tabanlı dalak bölütleme ve morfolojik düzeltme olarak tanımlanabilecek 3 temel aşamadan oluşan bir bölütleme yöntemi önermişlerdir [12]. Bölütleme işlemi için bu çalışmada da SS-Net mimarisi kullanılmışlardır. Zhang ve arkadaşları tarafından önerilen “SequentialSegNet” mimarisinde ise BT kesitleri arasındaki ilişkiyi kurabilmek için uzun kısa süreli bellek mimarili konvolüsyon işlemi ağ mimarisine entegre edilmiş ve çoklu organ bölütleme işleminde kullanılmıştır [13]. Larsson ve arkadaşları tarafından abdominal organ bölütlemesi için önerilen “DeepSeg” mimarisinde ise öncelikle ilgi alanı bölgeleri çoklu atlas yöntemi ile belirlenmiş, daha sonra piksel tabanlı sınıflandırma işlemi konvolüsyonel sinir ağı mimarisi ile gerçekleştirilmiş ve son olarak bağlantı bileşen analizi ile sonuçlar etiketlenerek görüntü vokselleri yok edilmiştir [14].

Bu çalışmada, geliştirilen konvolüsyonel sinir ağı tabanlı dalak bölütleme mimarisi üç ana adımdan oluşmaktadır. Bölütleme işlemi öncesinde veri setine uygulanan ön işlemler birinci adımı oluştururken, geliştirilen konvolüsyonel sinir ağı ile bölütleme işlemi çalışmanın ikinci adımını oluşturmaktadır. Üçüncü adım ise bölütleme işlemini sonucunda elde edilen sonuç görüntülerinde gürültünün giderildiği son işlem adımıdır.

II. MATERYAL VE METOD

A. Veri seti

Çalışmada eğitim ve doğrulama adımları için BT görüntüleri Akdeniz Üniversitesi Organ Nakli Merkezinde böbrek donörlüğü yapmış on üç kişiden elde edilmiştir. Veri seti oluşturulurken dalakta herhangi bir hasar veya kistik lezyonun olmamasına dikkat edilmiştir. BT görüntülerinin on ikisi eğitim adımı, bir tanesi ise doğrulama adımı kullanılmıştır. BT görüntüleri 1,5 mm kesit kalınlıklı portal faz çekimleridir. Eğitim, doğrulama ve başarı hesaplama işlemleri için dalak, Radyologlar tarafından (F. Cüce, T. Ergin) ManSeg 2.6b programı ile yarı otomatik bir şekilde bölütlenmiştir [15].

B. Yöntem


BT görüntülerinde gerek kontrast maddenin varlığı, gerek iskelet sistemi gibi yüksek Hounsfield Unit (HU) değerine

sahip bölgelerin varlığı bölütleme işlemi zorlaştırmaktadır. Ayrıca derin öğrenme algoritmalarının eğitim adımı aşamasında yüksek işlem yükü yaratması büyük boyutlu verilerin işlenmesini zorlaştırmaktadır. Bu nedenle bölütleme işlemi öncesinde veri manipülasyonu yapılması gerekmektedir. Çalışmanın ilk adımında öncelikle BT görüntüleri kübik interpolasyon yöntemi ile üç boyutlu olarak 0.25 oranında küçültülmüştür. Daha sonra Otsu eşikleme yöntemi ile 3 sınıflı olarak eşikleme işlemi gerçekleştirilmiş ve doku sınıfını ifade eden sınıf etiketinin ortalaması her bir BT görüntüsü için hesaplanmıştır. Ortalama değerin ± 75 HU alt ve üst değerleri 0 olarak etiketlenmiştir. Son olarak karşıtlık pekiştirme (contrast enhancement) işlemi gerçekleştirilmiş ve yoğunluk değerleri 0-1 değer aralığına normalize edilmiştir. Ön işlemler sonrasında eğitim işlemi için 128x128 boyutlarında 996 adet eğitim görüntüsü elde edilmiştir. Test verisi için kullanılan BT görüntüsü ise ön işlemler sonucunda 128x128x85 boyutuna interpolate edilmiştir. Örnek BT görüntüsü Şekil 1'de verildiği gibidir.




Şekil 1. Ön işlem sonrası elde edilen görüntü

Çalışmanın otomatik bölütleme adımı otuz altı katmanlı bir ağ yapısı tasarlanmıştır. Mimarinin ilk katmanı giriş katmanı son iki katmanı ise “Softmax” ve piksel sınıflandırma katmanından oluşmaktadır. Ara katmanlar ise ardışıl olarak on bir kez sıralanan Konvolüsyon katmanı, Normalizasyon katmanı ve “Relu” katmanı kümesinden oluşmaktadır. Konvolüsyon çekirdek boyutları ilk dokuz konvolüsyon katmanında 31x31, onuncu katmanda 15x15 ve son konvolüsyon katmanında 7x7 olarak belirlenmiştir. Geliştirilen ağ mimarisinde havuzlama işlemi gerçekleştirilmemiş ve bu nedenle boyut indirgeme işlemi yapılmamıştır. Eğitim işlemi sırasında momentuma bağlı stokastik gradyan inişi kullanılmış, her 10 iterasyonda öğrenme oranı 0,05 oranında azaltılmıştır. Eğitim için deneysel olarak belirlenen 160 adımlık iterasyon kullanılmıştır. Eğitim işlemi Nvidia Quadro P4000, 8GB'lık ekran kartı ile gerçekleştirilmiştir. Eğitim işlemi 22 saat 24 dakika 4 saniye sürmüştür. Konvolüsyonel sinir ağı çıkışında elde edilen görüntü Şekil 2'de verildiği gibidir.



Şekil 2. Ağ çıkışında elde edilen görüntü

Çalışmada doğrulama adımında ise radyologlar tarafından yarı otomatik olarak çizilen referans sonuçları ile bölütleme sonuçlarını karşılaştırmak için sinir ağı çıkışları ikili görüntülere çevrilmiştir. Bu işlem için her bir BT görüntüsü için en yüksek yoğunluk değerine sahip rastgele 3 vokselle noktası olarak seçilmiş ve yayılım algoritması her bir vokselle noktası için 3 kez çalıştırılmıştır. Final bölütleme sonuçları ise yayılım algoritması çıkışlarının en büyük kümesi olarak belirlenmiştir. Şekil 3'de radyologlar tarafından çizilen referans görüntüsü ile bölütleme çıkışı verilmiştir. Şekil 4'te ise sinir ağı girişi ve bölütleme çıkışı bir arada verilmiştir.




Şekil 3. Üst görsel radyolog referans görüntüsü, alt görsel bölütleme işlem sonucu

III. SONUÇLAR

Çalışmada geliştirilen bölütleme sisteminin performansını değerlendirmek için duyarlılık, özgüllük, doğruluk, pozitif ve negatif öngörü değerleri ölçüt olarak kullanılmıştır (Tablo 1). Dalak ilgi alanı, BT görüntülerinin küçük bir bölümünü oluşturduğu için ilgi alanı dışındaki voksellerin (siyah vokseller) bölütlenme başarısını ifade eden özgüllük ve negatif öngörü değeri oldukça yüksek hesaplanmıştır. Gerçekçi bir değerlendirme için duyarlılık ve pozitif öngörü değerleri doğru birer ölçüm aracı olarak düşünülebilir. Duyarlılık başarısı incelendiğinde bölütleme algoritmasının dalağın %76,7'sini doğru olarak bölütlediği ifade edilebilir. Pozitif öngörü değeri açısından bakıldığında ise bölütleme işlemi sonucunda elde edilen dalak voksellerinin %94,7'sinin dalak bölgesinde olduğu görülmektedir. Bu değerler ışığında elde edilen bölütleme sonuçlarının radyologlar tarafından belirlenen referans BT görüntülerine göre küçük kaldığı söylenebilir. Doğruluk metriği açısından ise yine doğru negatif sayısının (siyah vokseller) oldukça yüksek olmasından dolayı yüksek bir başarı yüzdesi elde edilmiştir.

TABLO I. BAŞARI YÜZDELERİ

Duyarlılık %	Özgüllük %	Pozitif öngörü değeri %	Negatif öngörü değeri %	Doğruluk %
76,7	99,8	94,7	99,9	99,8



Şekil 4. Üst görsel sinir ağı girişi, alt görsel bölütleme işlem sonucu



IV. TARTIŞMA

Çalışmada mide veya dalak gibi BT kesitlerinde büyük alana sahip abdominal organların bölütlenmesinde yüksek boyutlu konvolüsyon çekirdek kullanımının bölütleme başarısını arttıracığı tezi üzerinde durulmuştur. Bu nedenle ağın ilk dokuz konvolüsyon katmanında BT görüntülerinin dörtte biri boyutlarında (31x31) konvolüsyon çekirdekleri tercih edilmiştir. Deneysel çalışmalarda giriş görüntü boyutları 512x512 ve konvolüsyon çekirdekleri bu boyutların dörtte biri olarak seçildiğinde ve iki havuzlama katmanı ile boyut indirgeme işlemi gerçekleştirilmeye çalışıldığında eğitim süresinin oldukça arttığı görülmüştür. Ayrıca BT görüntüleri 128x128 boyutlarından daha küçük boyutlara interpolate edildiğinde dalağa ait spasyal bilginin kaybolmaya başladığı gözlemlenmiştir. Bu nedene başarılı ve hızlı bir eğitim için giriş değerleri 128x128 boyutlarında seçilerek havuzlama işlemi gerçekleştirilmemiştir.

Bölütleme sonuçları incelendiğinde, dalağın alt ve üst kutuplarının belirlenemediği, bu nedenle duyarlılık ve pozitif öngörü değerinin düştüğü gözlemlenmiştir. Bunun nedeninin konvolüsyon çekirdeklerinin iki boyutlu yapıda olmasının neden olduğu düşünülmektedir. Üç boyutlu konvolüsyon çekirdek kullanımı ile dalağın alt ve üst kutuplarında daha iyi bir bölütleme başarısı elde edilebilir.

Son olarak, bölütleme işlemi sonucunda elde edilen dalak bölgelerinin aktif kontür gibi yayılım algoritmalarında maske olarak kullanılmasıyla bölütleme başarısının artırılacağı öngörülmektedir.

KAYNAKLAR

- [1] Nishijima D.K., Simel D.L., Wisner D.H., Holmes J.F. "Does this adult patient have a blunt intra-abdominal injury?", *JAMA*, 307(14):1517–1527, 2012
- [2] Jiang H., Ma Z., Zhang B., Zhang Y. "A spleen segmentation method based on PCA-ISO", *Proc. ICCIT* 6:928–933, 2011
- [3] Linguraru M.G., Pura J.A., Chowdhury A.S., Summers R.M. "Multi-organ segmentation from multi-phase abdominal CT via 4D graphs using enhancement, shape and location optimization", *Med. Image. Comput. Assist. Interv.*, 13:89–96, 2010
- [4] Linguraru M.G., Pura J.A., Pamulapati V., Summers R.M. "Statistical 4D graphs for multi-organ abdominal segmentation from multiphase CT", *Med. Image. Anal.* 16:904–914, 2012
- [5] Gonzalo R.D., Chenouard N., Unser M. "Spline-based deforming ellipsoids for interactive 3D bioimage segmentation", *IEEE Trans. on Image Process.* 22(10):3926–3940, 2013
- [6] Campadelli P., Casiraghi E., Pratisoli S. "Fully automatic segmentation of abdominal organs from CT images using fast marching methods", *21st IEEE international symposium on computer based med systems*, pp 554–559, 2008
- [7] Park H., Bland P.H., Meyer C.R. "Construction of an abdominal probabilistic atlas and its application in segmentation", *IEEE Trans. on Med. Imaging.* 22(4):483–492, 2003
- [8] Linguraru M.G., Sandberg J.K., Li Z.X., Shah F., Summers R.M. "Automated segmentation and quantification of liver and spleen from CT images using normalized probabilistic atlases and enhancement estimation", *Med. Phys.* 37(2):771–783, 2010
- [9] Wolz R., Chu C., Misawa K., Fujiwara M., Mori K., Rueckert D. "Automated abdominal multi-organ segmentation with subject-specific atlas generation", *IEEE Trans. on Med. Imaging.* 32(9):1723–1730, 2013
- [10] Huo Y., et al. "SplenoMegaly Segmentation Using Global Convolutional Kernels and Conditional Generative Adversarial Networks", *IEEE Transactions On Medical Imaging*, 38(5):1185-1196, 2019
- [11] Huo Y., et al. "Robust multicontrast MRI spleen segmentation for splenoMegaly using multi-atlas segmentation", *IEEE Trans. Biomed. Eng.*, 65 (2): 336-343, 2018
- [12] Moon H., Huo Y., Abramson R.G., et.al "Acceleration of spleen segmentation with end-to-end deep learning method and automated pipeline", *Comput. Biol. Med.*, 107:109-117, 2019
- [13] Zhang Y., et al. "SequentialSegNet: Combination with Sequential Feature for Multi-organ Segmentation", *Int. Conf. on Pattern Recogn.*, 3947-3952, 2018
- [14] Larsson M., Zhang Y., ve Kahl F., "DeepSeg: Abdominal Organ Segmentation Using Deep Convolutional Neural Networks," *Swedish Symposium on Image Analysis*, 2016
- [15] G. Tulum et al., "Assessment of ManSeg 2.6b application's accuracy," *2018 Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT)*, Istanbul, pp. 1-4, 2018