

Derin Sinir Ağları Kullanarak Medikal Görüntü Bölütleme

Medical Image Segmentation Using Deep Neural Networks

Musa AYDIN

Fatih Sultan Mehmet Vakıf Üniversitesi

Bilgisayar Mühendisliği

İstanbul, Türkiye

Email: maydin@fsm.edu.tr

Özetçe —Medikal görüntülerin otomatik bölütlenmesi, bu görüntüler kullanılarak çeşitli hastalıkların teşhis edilmesinde önemli bir rol oynamaktadır. Görüntü bölütleme, bir çok medikal görüntüye ayrı ayrı uygulanarak farklı analizlerin ve teşhislerin yapılması sağlanabilmektedir. Örneğin, bir hücre kültüründeki hücrelerin otomatik bölütlenmesi ile, hücrelerin miktarı, canlılığı, her bir hücrenin çapı veya şeklinin ayrı ayrı analiz edilmesi sağlanabilmektedir. Ayrıca bir dokudaki kan damarlarının otomatik bölütlenmesi ile, damarların uzunluğu, yoğunluğu, her damarın ayrı ayrı yarı çapı gibi analizler yapılabilmektedir. Bu sayede incelen görüntüden, bir hastalığın erken teşhisi, hastalığın türü gibi çıkarımlar gerçekleştirilir. Bu çalışmada çeşitli hücre görüntülerinden ve retina görüntülerinden oluşan iki ayrı veri seti kullanılarak, bu veri setindeki görüntüler ayrı ayrı bölütlenmiştir. Otomatik bölütleme için, bir evrişimsel sinir ağı modeli olan U-Net kullanılmış ve gerçek referans değerler ile U-Net ağı ile bölütlenen çıktılar karşılaştırılmıştır. Her iki veri seti için elde edilen yüzdesel doğruluk değerleri sırası ile; retina veri seti için 95.2, hücre veri seti için 97.25 olarak hesaplanmıştır.

Anahtar Kelimeler—Görüntü Bölütleme; Derin Sinir Ağları; Kan Damarı Bölütlemesi; Hücre Çekirdeği Bölütlemesi.

Abstract—Automatic segmentation of medical images plays an important role in diagnosing various diseases using these images. Image segmentation can be applied separately through many medical samples to make different analyses and diagnoses. For example, by auto-segmentation cells in a cell culture, the amount, vitality, diameter or shape of the cells in the cell culture can be analysed separately. In addition, by automatic segmentation of blood vessels in a tissue, analyses such as the length and density of the vessels, and the radius of each vessel can be made separately. In this way, inferences such as early diagnosis of a disease and the type of the disease can be made from the examined image. In this study, using two different data sets consisting of various cell images and retinal images, the images in this data set were segmented separately. For automatic segmentation, a convolutional neural network model U-Net is used. The existing ground truth images and the images segmented using the U-Net network were compared. Percentage accuracy values obtained for both data sets, respectively; 95.2 for retina data set and 97.25 for cell data set.

Keywords—Image Segmentation; Deep Neural Networks; Blood Vessel Segmentation; Cell Nuclei Segmentation.

978-1-6654-3649-6/21/\$31.00 ©2021 IEEE

I. GİRİŞ

Medikal görüntüler elde edilirken oluşan gürültüler, görüntüdeki arka plan ile incelenen bölgenin kontrastındaki farklılıkların ayrıştırılamaması, dokudaki damar yapısındaki yoğunluk gibi etkenlerden dolayı, alanında uzman kişiler tarafından manuel olarak gerçekleştirilen bölütleme performansı düşmektedir. Bu tip sorunlardan ötürü, manuel olarak yapılan bölütlemenin hem başarımı düşmekte hemde bölütleme için gereken süre uzamaktadır. Manuel bölütleme, uzman bilgisi ve bilgi birikimi gerektiren, zaman alıcı, tekrarlanabilirlikten yoksun zahmetli bir süreçtir. Manuel bölütlemedeki iş yükünü azaltmak, klinik uygulamadaki damar ve hücre bölütlemesinin işlem hızını ve tekrarlanabilirliğini artırmak için makine öğrenmesi yaklaşımları ile bölütleme konusunda çok fazla araştırmaya yer verilmiştir [1], [2]. Evrişimli sinir ağının çok katmanlı özellik çıkarımı, görüntü üzerinde uygulanan farklı filtreler ile, ağın katmanları boyunca taşınan öz niteliklerinden görüntü ile ilgili önemli özelliklerin ortaya çıkarılmasını sağlamaktadır. Derin öğrenmedeki bu gelişim, hücre ve damar görüntülerin bölütlenmesine uyarlanmıştır [3], [4]. Genel olarak biyomedikal görüntülerin analizinde, yüksek başarımlı olan U-Net modelinin kullanıldığı görülmektedir [5], [6]. Bu çalışmada, geliştirilen algoritma ile, çok kısıtlı sayıda retina verisi kullanılarak yüksek oranda (%95.2) bölütleme doğruluğu elde edilmiştir.

II. DENEYSEL ÇALIŞMA

Bu bölümde Derin sinir ağı ile medikal görüntülerin bölütlenmesi için kullanılan veri setleri, kullanılan yöntem ve algoritmadan bahsedilecektir. Veri setindeki görüntüler derin sinir ağında eğitilmeden önce bir dizi ön işlemden geçirilmiştir. Veri setindeki görüntüler üzerinde yapılan ön işlemler sırası ile;


- Histogram eşleştirme (ing: histogram matching),
- Orta değer filtresi (ing: median filter)

Bir görüntü histogramının başka bir görüntü histogramı ile eşleşeceği şekilde dönüştürülmesi yöntemine histogram eşleştirme denir [7]. Histogram eşleştirme ile veri setindeki görüntülerin her birini, yine veri seti içerisinde bulunan görüntülerden

bir tanesinin, ortalama ışık şiddeti değeri en yüksek olan tek bir görüntüye ait histogram fonksiyonu dağılımına eşleştirilmiştir. Bu sayede, görüntüler arasındaki ışık şiddeti farklılıkları giderilmiştir. Daha sonra tüm görüntülere 3×3 boyutunda bir orta değer filtresi uygulanarak, arka plan görüntülerinin giderilmesi sağlanmıştır. Bu çalışmada kullanılan veri setlerine ve geliştirilen tüm kodlara github¹ adresinden erişilebilir.

A. Veri Seti

Bu çalışmada, U-Net derin sinir ağı kullanılarak iki adet veri seti üzerinde ayrı ayrı bölütleme uygulaması yapılmıştır. Retina damarlarının bölütlenmesi için DRIVE veri setinden yararlanılmıştır [8]. Bu veri setinde RGB renk uzayında tanımlanmış *tif* uzantılı toplam 40 adet retina görüntüsü bulunmaktadır, Şekil 1’ de retina veri setine ait örnek görüntüler görülmektedir. Retina veri setindeki görüntülerin boyutları 565×584 ’ tür, görüntü ön işleme aşamasında, görüntüler 512×512 boyutlarında ilgilenilen bölgelerinden (region of interest) kesilmiştir. DRIVE veri setindeki 40 görüntünün ilk 20’ si test kalan 20 tanesi ise eğitim olarak ayrılmıştır. Eğitim ve test verisi olarak kullanılan 40 adet görüntünün aynı zamanda manuel olarak, uzmanlar tarafından bölütlenmiş gerçek referansları (ing:ground truth) bulunmaktadır.



Şekil 1: Retina damar bölütlenmesi için kullanılan DRIVE (a) veri seti ve hücre çekirdekleri (b) bölütlenmesi için kullanılan veri setinden örnek görüntüler

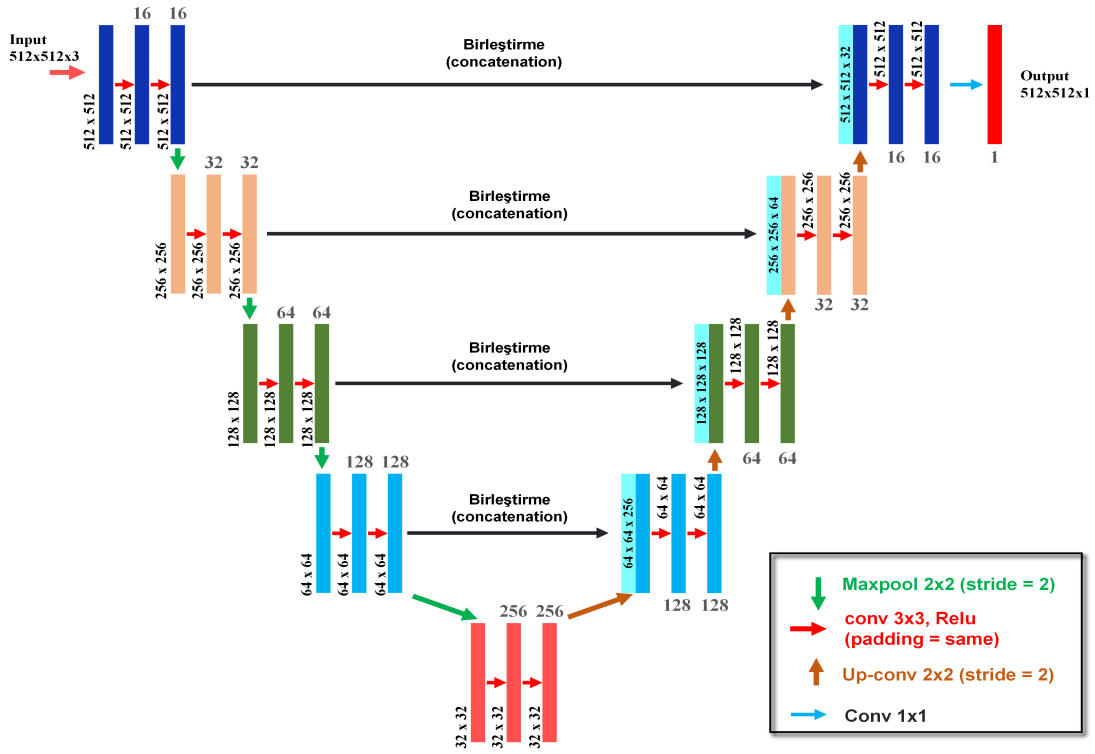
Farklı tipteki hücrelerden oluşturulmuş görüntülerdeki, hücrelerin bölütlenmesi için kullanılan veri setinde [9], RGB renk uzayında tanımlanmış *png* uzantılı toplam 670 adet görüntü bulunmaktadır. Şekil 1’ de hücre veri setine ait örnek görüntüler görülmektedir. Hücre veri setindeki görüntülerin boyutları birbirinden farklıdır. Görüntü ön işleme aşamasında, tüm görüntüler öncelikle 256×256 boyutlarına yeniden boyutlandırılmıştır. Hücre veri setindeki 670 görüntünün %80’ i eğitim, %20’ si test için ayrılmıştır. Eğitim ve test verileri,

¹<https://github.com/msaaydin/U-net-Segmentation>

tüm veri setinden rastgele seçilmiştir. Eğitim ve test için ayrılan her görüntünün aynı zamanda manuel olarak, uzmanlar tarafından bölütlenmiş gerçek referansları (ing:ground truth) bulunmaktadır. Gerçek referanslar üzerinde, görüntü ön işleme aşamasında birleştirme işlemi yapılmıştır. Orijinal veri setinde, her bir görüntüye ait gerçek referans görüntüsü, orijinal görüntüde bulunan her bir hücre çekirdeği için, görüntüde bulunan hücre adedince tek tek bir görsele dönüştürülecek şekilde manuel olarak bölütlenmiş ve ayrı bir görüntü dosyası olarak kaydedilmiştir. Buda bir görüntüye ait birden fazla sayıda bölütlenmiş gerçek referans görüntüsünün oluşmasına neden olmuştur, görüntü ön işleme adımında her bir görüntüye ait gerçek referans görüntüleri tek bir görüntü olarak birleştirilerek veri seti güncellenmiştir ve güncellenmiş veri setine buradan¹ erişilebilir.

B. Yöntem

Retina damarları ve hücre çekirdeklerinin bölütlenmesi amacıyla yapılan bu çalışmada, bir evrişimsel sinir ağı modeli olan ve biyomedikal görüntü bölütlenmesinde oldukça yüksek başarımlar sunan U-Net ağı kullanılmıştır [10]. U-Net ağı bir evrişimsel sinir ağı modelidir ve iki ana bölümden oluşur. Bunlardan ilki kodlayıcı bölümdür, küçülme-daralma yolu olarak adlandırılır. Küçülme yolu geleneksel evrişimsel sinir ağındaki evrişim adımını temsil eder, katmanlar boyunca giriş bilgisinin boyutu azaltılır. Küçülme bölümünde veri boyutu, 2×2 ’ lik maksimum havuzlama işlemi (adım sayısı (stride)= 2) ile aşağı örnekleme yapılır. Aşağı örnekleme (ing:down sampling) yapıldığı kodlayıcı(küçülme yolu) bölümünde her basamakta 3×3 ’ lük filtre boyutunda, aktivasyon fonksiyonu ReLU olan 2 adet evrişim katmanı bulunmaktadır (sıfır doldurma ile-zero padding). Giriş katmanında çıkartılan özellik sayısı 16’ dır ve bu sayı küçülme yolunda her adımda 2 katına çıkartılır. Kod çözücü-genişleme yolunun her adımında ise 2×2 ’ lik yukarı örnekleme (ing:up sampling) yapılır ve elde edilen özellik kanalları, aynı basamakta bulunan küçülme yolundaki özellik kanalları ile birleştirilir (ing:concatenation). Birleştirme adımından sonra, genişleme yolundaki her basamakta 3×3 ’ lük filtre boyutunda, aktivasyon fonksiyonu ReLU olan 2 adet evrişim katmanı bulunmaktadır. Genişleme yolunda, her yukarı örneklemeden sonra, özellik kanallarının sayısı yarıya iner. Bu sebeple genişleme yolu ile küçülme yolu simetrikdir. Son olarak, 16 adet özellik haritasından bölütleme haritasını çıkarmak için 1×1 ’ lik evrişim kullanılmaktadır. Ağda kullanılan veri sayıları çok az olduğundan dolayı, aşırı uydurmayı engellemek için, evrişim katmanlarından sonra 0.2 oranında iletim sönümü (ing:dropout) işlemi uygulanmıştır. Çalışmamızda oluşturduğumuz U-Net modeline ait mimari yapı ve yapılan tüm işlemler (evrişim, maksimum havuzlama, aşağı ve yukarı örnekleme) Şekil 2’ deki diyagramda ayrıntılı olarak gösterilmiştir. U-Net ağ modelindeki, kodlayıcı ve kod çözücü mimarisinin temel amacı, bilgiyi farklı soyutlama seviyeleriyle birleştirmektir. Kodlayıcı, her bir evrişimli katman tarafından üretilen özellik haritalarının boyutunu, bir havuzlama operatörü ile azaltır. Kodlayıcı ile, düşük çözünürlüklü yüksek seviyeli bilgi haritaları oluşur. Bu haritalar, görüntüdeki nesnelere ilgili detaylı özellikler içerir, bu özellikler nesnelere tanımlamak için yetelidir fakat ayrıntılı bilgiler kaybolur. Yukarı örnekleme ile oluşturulan yüksek çözünürlüklü, düşük seviyeli özellik haritaları, kodlayıcı tarafından üretilen bilgi katmanları ile birleştirilir ve nesnelere ilgili ayrıntılı bilgiler



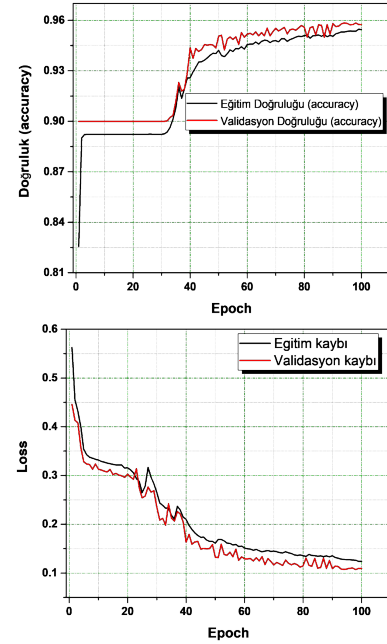
Şekil 2: Retina damarı ve hücre çekirdeği bölütlemesi için oluşturulan u-net ağının boyut azaltma ve boyut artırma aşamalarını gösteren modeli

kurtarılmış olur. Yapılan deneysel çalışmalarda Google colab alt yapısı kullanılmıştır. U-Net evrimsel sinir ağı modelinin oluşturulması için keras-tensorflow (version 2.4.1, python version = 3.7) kütüphanesi kullanılmıştır. U-Net ağ mimarisi için ağın katmanları, Şekil 2’ de görüldüğü gibi, ilk adımda 16 özellik haritası ile oluşturulmuş ve dört aşağı örnekleme ve her örneklemede özellik haritası sayısı 2 katına çıkarılarak ilerletilmiştir. Oluşturulan U-Net ağının özellikleri (**Optimizasyon: Adam, epoch:cell veri seti= 40, retina veri seti= 100, loss:binary crossentropy, değerlendirme metriği: accuracy, öğrenme oranı (learning rate)= 0.001**) olarak belirlenmiştir. Ağın eğitimi aşamasında verinin %10’ u validasyon olarak ayrılmıştır ve her bir iterasyondaki yığın büyüklüğü (ing:batch size) 4 olarak belirlenmiştir.

III. SONUÇLAR VE TARTIŞMA


Bu çalışmada derin öğrenme yaklaşımı ile, medikal görüntülerden oluşan iki ayrı veri setindeki görüntülerin otomatik bölütlenmesi sağlanmıştır. İlk veri setinde bulunan retina kan damarlarının bölütlenmesi için 20 adet eğitim verisi ile U-Net ağı eğitilmiş ve eğitilen ağ 20 adet test verisi ile test edilmiş %95.2 doğruluk elde edilmiştir, bu oran eğitilmiş ağın 10 kez test verileri ile test edilmesi ile elde edilen başarımların ortalamasıdır. Şekil 3’ teki grafikte retina kan damarları için eğitilen ağın eğitim ve validasyonu için kayıp (loss) ve doğruluk (accuracy) değişimi görülmektedir. Şekil 4’ te retina kan damarlarının test görüntülerinin U-Net ağı ile otomatik bölütlenmiş çıktıları ve gerçek referansları görülmektedir.

İkinci veri setinde bulunan hücre çekirdeklerinin bölütlenmesi için 670 adet görüntünün %20’ si test ve %80’ i eğitim için rastgele ayrılmıştır. Toplam verinin %20’ si ile



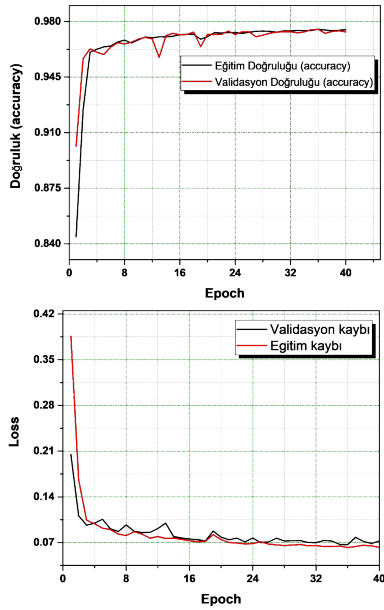
Şekil 3: Retina kan damarı bölütleme sonucu, doğruluk ve kayıp değerlerinin değişimi

yapılan test işlemi sonucunda %97.25 doğruluk elde edilmiştir. Doğruluğun hesaplanmasında, ağ rassal olarak en baştan %80-20 eğitim ve test verisi olarak ayrılmış ve yeniden test doğruluğu hesaplanmıştır, 10 kez yapılan test işleminin sonucunda elde edilen doğruluk değerlerinin ortalaması alınarak genel doğruluk oranı belirlenmiştir. Şekil 5’ te hücre görüntüleri için




Şekil 4: U-Net ağı ile bölütlenmiş retina damar görüntüleri, orijinal retina görüntüleri ve gerçek referans görüntüleri

eğitilen ağı, eğitim ve validasyonu için kayıp ve doğruluk değişimi görülmektedir. Şekil 6' da hücelere ait test görün-



Şekil 5: Hücre bölütleme sonucu, doğruluk (accuracy) ve kayıp (loss) değerlerinin değişimi

tülerinin U-Net ağı tarafından otomatik bölütlenmiş çıktıları ve gerçek referansları görülmektedir. Şekil 6' da ilk sütunda orijinal görüntüler, ortadaki sütunda U-Net ağı ile bölütlenmiş görüntüler, son sütunda ise gerçek referans görüntüleri bulunmaktadır. Bu çalışmada, iki ayrı veri setindeki görüntülerin derin öğrenme yaklaşımı ile otomatik bölütlenmesi sağlanmıştır. Bölütleme için geliştirilen U-Net derin sinir ağı ile her iki veri setinden elde edilen doğruluk değeri %95 in üzerinde hesaplanmıştır. U-Net ağına bu başarıyı, hali hazırda devam



Şekil 6: U-Net ağı ile bölütlenmiş hücre görüntüleri, orijinal görüntüler ve gerçek referans görüntüleri

etmekte olduğumuz fare beyni mikrovaksüler damar ağının üç boyutlu oluşturulması çalışması için bir ön çalışma niteliğinde olup, gelecekte tüm bir fare beyninin damar ağının otomatik segmentasyonu ve mikrovaksüler yapısının oluşturulmasına olumlu yönde katkısı olacağı bu çalışma ile ispatlanmıştır.

KAYNAKLAR

- [1] R. Hollandi, A. Szkalitsy, T. Toth, E. Tasnadi, C. Molnar, B. Mathe, I. Grexa, J. Molnar, A. Balind, M. Gorbe *et al.*, "nucleaizer: a parameter-free deep learning framework for nucleus segmentation using image style transfer," *Cell Systems*, vol. 10, no. 5, pp. 453–458, 2020.
- [2] L. Li, M. Verma, Y. Nakashima, H. Nagahara, and R. Kawasaki, "Iternet: Retinal image segmentation utilizing structural redundancy in vessel networks," in *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, 2020, pp. 3656–3665.
- [3] M. Delgado-Ortet, A. Molina, S. Alférez, J. Rodellar, and A. Merino, "A deep learning approach for segmentation of red blood cell images and malaria detection," *Entropy*, vol. 22, no. 6, p. 657, 2020.
- [4] M. R. K. Mookiah, S. Hogg, T. J. MacGillivray, V. Prathiba, R. Pradeepa, V. Mohan, R. M. Anjana, A. S. Doney, C. N. Palmer, and E. Trucco, "A review of machine learning methods for retinal blood vessel segmentation and artery/vein classification," *Medical Image Analysis*, p. 101905, 2020.
- [5] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," in *International Conference on Medical image computing and computer-assisted intervention*. Springer, 2015, pp. 234–241.
- [6] M. Livne, J. Rieger, O. U. Aydin, A. A. Taha, E. M. Akay, T. Kossen, J. Sobesky, J. D. Kelleher, K. Hildebrand, D. Frey *et al.*, "A u-net deep learning framework for high performance vessel segmentation in patients with cerebrovascular disease," *Frontiers in neuroscience*, vol. 13, p. 97, 2019.
- [7] S. P. Ehsani, H. S. Mousavi, and B. H. Khalaj, "Iterative histogram matching algorithm for chromosome image enhancement based on statistical moments," in *2012 9th IEEE International Symposium on Biomedical Imaging (ISBI)*. IEEE, 2012, pp. 214–217.
- [8] "Retina görüntüleri veri seti," <https://drive.grand-challenge.org/>, en son erişim: 01-03-2021.
- [9] "Hücre veri seti," <https://www.kaggle.com/c/data-science-bowl-2018/data>, en son erişim: 01-03-2021.
- [10] Z. Liu, "Retinal vessel segmentation based on fully convolutional networks," *arXiv preprint arXiv:1911.09915*, 2019.