U-Net Modeli ile Akciğer Tomografi Görüntülerinin Otomatik Segmentasyonu: Pilot Çalışma

Automated Segmentation of Lung Tomography Images Using the U-Net Model: A Pilot Study

Şinasi Kutay Özen[1], Aslı Sabah[2,3], Yiğit Ali Üncü[4],Mehmet Feyzi Akşahin[5], Cengiz Kurtman[2]

[1]Başkent Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği, Ankara

[2]Ankara Üniversitesi, Tıp Fakültesi, Radyasyon Onkolojisi, Ankara

[3]Denizli Onkomer

[4]Akdeniz Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Biyomedikal Cihaz Teknolojisi Bölümü, Antalya

[5]Gazi Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, Ankara

***Özetçe*— Bu çalışmada, evrişimsel sinir ağlarından biri olan U-Net modeli ile akciğer bilgisayarlı tomografi (BT) görüntülerinin segmentasyonu hedeflenmiştir. Çalışmada, Ankara Üniversitesi Tıp Fakültesi Radyasyon Onkolojisi Bölümünden alınan 30 adet akciğer BT görüntüleri kullanıldı. Görüntülerin 20'i modelin öğrenme aşamasında, 10'u ise test aşamasında kullanıldı. CT görüntüleri 512x512 boyutunda ve 256 kesit içeriyor olup, DICOM formatından NIfTI formatına dönüştürüldü. Öğrenme aşaması için 20 görüntü, çeşitli görüntü çoğaltma yöntemleriyle 100 görüntüye çıkarıldı. Test aşamasında kullanılan 10 görüntünün akciğer yapısı Slicer programı ile segmente edildi. U-Net modeli kullanılarak, test görüntülerindeki toplam 2560 kesit, Slicer segmentasyonlarıyla karşılaştırıldı ve ortalama dice indeksi 96.44±2.62 olarak elde edildi. Sonuçlar, U-Net'in akciğer CT görüntü segmentasyonunda yüksek doğruluk sağladığını göstermektedir.**

Anahtar Kelimeler — U-net; akciğer; evrişimsel sinir ağı; BT görüntü; görüntü segmentasyonu.

***Abstract*—The segmentation of lung computerized tomography (CT) images using the U-Net model, a type of convolutional neural network, was aimed in this study. 30 lung CT images obtained from the Department of Radiation Oncology at Ankara University Faculty of Medicine were utilized. Twenty of these images were used during the training phase of the model, while ten were used during the testing phase. The CT images, with dimensions of 512x512 pixels and containing 256 slices, were converted from DICOM format to NIfTI format. For the training phase, the 20 images were augmented to 100 images using various image augmentation techniques. During the testing phase, the lung structures of the 10 images were segmented using the Slicer program. Using the U-Net model, the total 2560 slices in the test images were compared with the Slicer segmentations, and the average dice index was obtained as 96.44±2.62. The results demonstrate that the U-Net model provides high accuracy in the segmentation of lung CT images.**

Keywords — U-net; lung; convolutional neural networks; CT imaging; style; image segmentation..

I. GİRİŞ

Akciğer kanseri hastalarına; tanı koymak, evrelemek ve tedavi planlamasında non-invaziv yöntemlerden bilgisayarlı tomografi (BT) görüntüleme radyoterapide kritik bir role sahiptir. Gelişen yapay zeka teknolojileri, kantitatif, dozimetrik, teknik ve prognostik amaçlı görüntülerin işlenmesi, radyasyon onkolojisinde iş akışının otomasyonu, optimizasyonu, kullanılan tedavi planlama algoritmalarının doğrulanması ile klinik işleyişin verimini ve tedavi kalitesini arttıracaktır.

Akciğer BT görüntüleme, çeşitli akciğer hastalıklarının teşhisi ve tedavi planlamasında kritik bir rol oynamaktadır. BT iki boyutlu (2B) ve üç boyutlu (3B) görüntülerindeki akciğer yapılarının doğru segmentasyonu, etkili hastalık

karakterizasyonu ve müdahale için gereklidir. Geleneksel manuel segmentasyon yöntemleri emek yoğun ve değişkenlik gösterdiğinden, doğruluğu ve verimliliği artırmak için otomatik tekniklere olan ihtiyaç artmaktadır.

Literatürde, akciğer segmentasyonu için ResUnet mimarisi temelli semantik bir model geliştirilmiş ve test setinde %94,96 Dice katsayısına ulaşılmıştır [1]. U-Net modeli, 140 akciğer görüntüsü kullanılarak eğitilmiş ve Yonsei Üniversitesi Hastanesi veri seti kullanılarak 60 doğrulama setinde ortalama %96,21 Dice katsayısına ulaşmıştır [2]. Başka bir çalışmada, akciğer görüntülerini segmentlere ayırmak için U-Net ve değiştirilmiş U-Net modelleri kullanılmış ve veri seti %80 eğitim, %20 test olarak bölünmüştür [3].

Souza ve diğerleri, akciğer anormallikleri nedeniyle akciğer görüntülerinin otomatik segmentasyonunu gerçekleştiren bir yöntem önermişlerdir. Önerilen yöntem, 138 göğüs röntgeni görüntüsü üzerinde denenmiş ve en yüksek %94 Dice katsayısı elde edilmiştir [4]. Başka bir çalışmada ise 704 görüntü kullanılarak akciğer segmentasyonu yapılmış ve veri seti %80 eğitim, %20 test olarak bölünmüştür [5]. Son yıllarda benzer mimariler ile akciğer segmentasyonu yapılmıştır [6,7].

Derin öğrenme yaklaşımları, özellikle evrişimsel sinir ağları (Convolutional neural netmworks: CNNs), tıbbi görüntü analizinde son yıllarda kullanımı artmış ve görüntü segmentasyonu için ileri düzey araçlar sunmuştur. Bunlar arasında U-Net, biyomedikal görüntü segmentasyonu görevleri için özel olarak tasarlanmış önemli bir mimari olarak öne çıkmaktadır. U-Net'in, global ve lokal özellikleri etkili bir şekilde yakalayan encoder-decoder yapısı ve skip bağlantıları ile karakterize edilen mimarisi, onu karmaşık segmentasyon görevleri için özellikle uygun hale getirmektedir [8].

Son çalışmalarda, U-Net'in tıbbi görüntülerde çeşitli anatomik yapıların segmentasyonunda etkili olduğu gösterilmiştir. Örneğin, U-Net'in akciğer dokuları ve lezyonlarını BT görüntülerinden segmentasyonunda yüksek doğruluk sağladığı gösterilmiştir [9]. Ayrıca, veri artırma teknikleri kullanılarak U-Net'in çeşitli ve gürültülü verilerle başa çıkabilme yeteneği artırılmıştır. Rastgele kırpma, elastik bozulma ve gürültü ekleme gibi veri artırma stratejileri, modelin dayanıklılığını ve genelleştirme yeteneğini iyileştirdiği gösterilmiştir [10].

Geliştirilmiş U-Net ağı, kodlayıcı olarak Efficientnet-b4 ve kod çözücü göğüs röntgeni görüntülerinde yüksek hassasiyetli akciğer segmentasyonu elde edilmiştir [11]. 3B U-net derin öğrenme modeli, göğüs BT görüntülerinde akciğer nodülünün tespiti için hem dahili hem de harici doğrulamada yüksek performans gösterildi [12]. Hibrit derin öğrenme modeli, geniş aralıktaki görüntü özelliklerine sahip akciğer nodülleri için radyologlarınkine benzer segmentasyon doğruluğu elde edilmiştir [13]. Bir diğer çalışmada ResBCDU-Net derin sinir ağı mimarisi, akciğer BT görüntü segmentasyonunda % 97,31'lik bir zar katsayısı indeksine ulaşılmıştır [14]. Derin CNN'ye sahip bir U-Net mimarisi kullanan bir çalışmada derin öğrenme yöntemi, yaygın interstisyel akciğer hastalığında akciğer segmentasyonu için geleneksel yöntemlere kıyasla önemli ölçüde daha iyi segmentasyon performansı göstermiştir [15] ve son yıllarda benzer çalışmalar U-Net ile yapılmıştır [16-19].

Bu ilerlemelere rağmen, belirli tıbbi uygulamalar için segmentasyon modellerinin optimize edilmesinde zorluklar devam etmektedir. Bu çalışma, U-Net mimarisini akciğer BT görüntülerine uygulayarak ve performansını nicel metrikler kullanarak değerlendirerek bu zorlukları ele almayı amaçlamaktadır. Hem görüntü artırma tekniklerini hem de U-Net modelini kullanarak, bu araştırma tıbbi görüntüleme alanında otomatik segmentasyon sistemlerini geliştirmeye yönelik mevcut çabalara katkıda bulunmayı hedeflemektedir.

II. YÖNTEMLER

Bu çalışmada, Ankara Üniversitesi Tıp Fakültesi Radyasyon Onkolojisi Bölümünde 2010-2023 yılları arasında akciğer kanseri tedavisi görmüş 30 hastanın GE marka Discovery Model BT ile elde edilen retrospektif görüntüleri kullanıldı. Her bir görüntü 512x512 piksel boyutunda olup, 256 kesit içermektedir. Görüntüler, etik kurul izni ile DICOM formatında alınmış ve ardından metafile çıkarılarak NIfTI formatına dönüştürülmüştür.

Evrişimsel bir ağ yapısına sahip bir derin öğrenme modeli olan U-Net modeli özellikle biyomedikal görüntülerin segmentasyonunda son yıllarda önemli bir araç olarak kullanılmaktadır. Bu çalışmada, akciğer BT görüntülerinden akciğer segmentasyonu yapmak için MATLAB programı ile, U-Net modeli kullanılmıştır.

Çalışmada veri hazırlığı ve çoğaltma yapılmış eğitim verisi olarak toplam 30 akciğer BT görüntüsünden 20'si modelin öğrenme aşamasında kullanılmıştır. Bu 20 görüntü, veri artırma yöntemleri ile çoğaltılmıştır. Görüntü çoğaltma işlemi, her bir BT görüntüsüne rastgele kırpma, elastik bozulma, Gauss gürültüsü, döndürme ve tuz-biber gürültüsü eklenerek gerçekleştirilmiştir. Bu işlemler sonucunda, her bir görüntüden 5 farklı varyasyon üretilmiş ve toplamda 100 görüntü elde edilmiştir. Segmentasyon aşaması test aşamasında kullanılacak 10 akciğer BT görüntüsündeki akciğer yapıları, Slicer yazılımı kullanılarak segmentasyon işlemi yapılmıştır.

Kullanılan U-Net modelinin, iki ana bileşenden oluşan bir mimariye sahiptir. Bunlar kodlayıcı (encoder) ve kod çözücü (decoder) bölümleridir.

Kodlayıcı Bölümü

Kodlayıcı, görüntüdeki bağlamı ve özellikleri yakalamak amacıyla kullanılan daraltma (downsampling) yolunu içerir. Bu aşama, giriş görüntüsünden yüksek düzeydeki özellikleri çıkararak daha kompakt ve soyut bir temsil oluşturur. Yapı olarak daraltma yolunda, evrişim katmanları ve maksimum havuzlama (max pooling) işlemleri kullanılarak görüntüdeki ayrıntılar giderek daha soyut bir biçime dönüştürülür. Bu, modelin önemli özellikleri öğrenmesini ve bağlamı anlamasını sağlar.

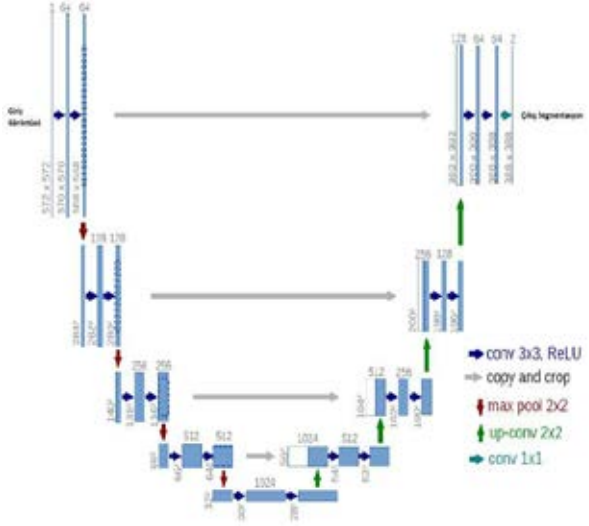
Kod Çözücü Bölümü

Fonksiyon olarak kod çözücü, kodlayıcı tarafından öğrenilen soyut özellikleri kullanarak görüntünün her bir pikselinin hassas bir şekilde segmentasyonunu sağlar. Bu bölüm, segmentasyon sonuçlarının yüksek çözünürlükte olmasını sağlar. Yapı olarak kod çözücü, simetrik olarak tasarlanmış olup, transpoze konvolüsyonlar (dekonvolüsyonlar) kullanarak görüntünün

çözünürlüğünü geri kazandırılır. Bu sayede, kodlayıcıda elde edilen detaylar yeniden yapılandırılarak yüksek kaliteli segmentasyon sonuçları elde edilir [20].

Mimari Özellikler

U-Net'in yapısı, basit ve genişletilebilir olmasının yanı sıra, yüksek kaliteli segmentasyon sonuçları üretmeye uygun olarak tasarlanmıştır. Model, yalnızca evrişim katmanları içerir ve bu da onu hesaplama açısından verimli kılar (Şekil 1).



Şekil. 1. U-Net mimarisi [20]

Uçtan uca tam evrişimsel yapı olarak U-Net, uçtan uca tam evrişimsel bir mimaridir. Bu özellik, modelin tüm işlem aşamalarında evrişimsel katmanları kullanarak doğrudan girişten çıktıya bilgi akışını sağladığı için bu modelin segmentasyon görevleri için giriş görüntülerini işleyerek her bir pikseli belirli bir sınıfa atayan çıktı üreterek 100 çoğaltılmış eğitim görüntüsü ile eğitilmiştir.

Performans Kriteri

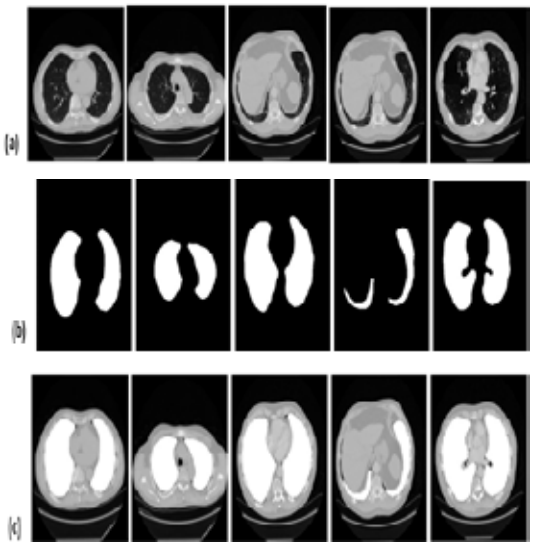
Çalışmadaki performans ölçümünde ise test aşamasında kullanılan 10 görüntüdeki toplam 2560 kesit, Slicer ile elde edilen segmentasyon sonuçları ile karşılaştırılmıştır. Bu işlem için yüksek Dice katsayı kullanılmıştır. Yüksek Dice katsayısı, modelin doğru segmentasyon yaptığına işaret eder. Bu yöntem, iki veri kümesi arasındaki benzerliği ölçen istatistiksel bir araçtır.

$$Dice = \frac{2\,x\,DP}{(2\,x\,DP)+YN+YP} \quad (1)$$

Bu formülde DP, doğru pozitif, DN, doğru negatif, YN, yanlış negatif ve YP, yanlış pozitif ifade eder [21].

III. SONUÇLAR

Bu çalışmada, U-Net derin öğrenme modelinin akciğer BT görüntülerinin segmentasyonundaki etkinliği değerlendirilmiştir. Eğitim aşamasında kullanılan 20 akciğer BT görüntüsü, çeşitli veri artırma yöntemleriyle çoğaltılarak toplamda 100 görüntü elde edilmiştir. Bu görüntüler, U-Net modelinin öğrenme sürecinde kullanılmıştır.

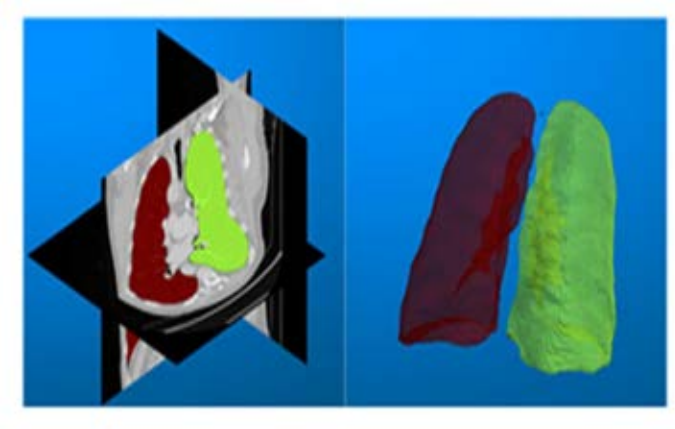


Şekil. 2. Akciğer BT segmentasyonu, a) örnek akciğer BT görüntüleri, b) örnek akciğer BT maske görüntüleri c) örnek akciğer BT segmente görüntüleri

Test aşamasında kullanılan 10 akciğer BT görüntüsü, Slicer programı ile segmentasyon işlemi yapılmış ve bu segmentasyonlar, U-Net modelinin tahmin sonuçları ile karşılaştırılmıştır. Örnek 5 farklı akciğer BT görüntüleri, maske görüntüleri ve segmente görüntüleri Şekil 2'de gösterilmiştir. Toplam 2560 kesitte yapılan karşılaştırmada, Dice indeksi kullanılarak segmentasyon sonuçlarının doğruluğu ölçülmüştür.

Sonuçlar, U-Net modelinin akciğer BT görüntülerindeki segmentasyon başarısını yüksek bir doğrulukla sağladığını göstermektedir. Ortalama Dice indeksi değeri 96.44±2.62 olarak hesaplanmıştır. Bu yüksek Dice indeksi değeri, U-Net modelinin akciğer yapılarının segmentasyonunda yüksek doğruluk ve güvenilirlik sağladığını ortaya koymaktadır.

U-Net modelinin segmentasyon esnasında sağ ve sol akciğeri tespit etmesi de modele öğretilmiştir. Model sağ ve sol akciğeri 100% doğrulukla bulmuştur. Elde edilen bölütlenmiş görüntülerin BT içerisindeki gösterimi ve 3B hali Şekil 3'de gösterilmiştir.



Şekil. 3. Örnek sağ ve sol akciğer tespit görüntüsü

Elde edilen bulgular, U-Net modelinin tıbbi görüntü segmentasyonunda etkili bir araç olduğunu ve akciğer BT görüntülerinin otomatik segmentasyonunda başarılı bir performans sergilediğini göstermektedir. Bu sonuçlar, akciğer hastalıklarının tanı ve tedavi süreçlerinde otomatik segmentasyon sistemlerinin kullanımının artırılabileceğini ve bu alandaki çalışmalara katkıda bulunabileceğini vurgulamaktadır. İlerleyen çalışmalarda daha fazla BT görüntüleri kullanılarak daha yüksek segmentasyon başarısı hedeflenmektedir.

KAYNAKLAR

[1] Mique, E. and Malicdem, A., "Deep residual u-net based lung image segmentation for lung disease detection", *IOP Conf. Ser.: Mater. Sci. Eng., Vol 803, 2020, p 012004.*

[2] Heo, S. J., Kim, Y., Yun, S., Lim, S. S., Kim, J., Nam, C. M., Park, E. C., Jung, I. and Yoon, J.H., "Deep learning algorithms with demographic information help to detect tuberculosis in chest radiographs in annual workers health examination data*", Int. J. Environ. Res. Public Health*, 16, 2-9, 2019.

[3] Rahman, T., Khandakar, A., Kadir, M. A., Islam, K. R., Islam, K. F., Mazhar, R., Hamid, T., Islam, M. T., Kashem, S., Mahbub, Z. B., Ayari, M. A. and Chowdhury, M. E. H., "Reliable tuberculosis detection using chest x-ray with deep learning, segmentation and visualization", *IEEE Access., Vol. 8, 2020, p 191586-191601.*

[4] Souza, J. C., Banderia Diniz, J. O., Ferreira, J. L., França da Silva, G. L., Corrêa Silva, A. and de Paiva, A. C., "An automatic method for lung segmentation and reconstruction in chest X-ray using deep neural networks", *Comput. Methods Programs Biomed.,* 177, 285-296, 2019.

[5] Gite, S., Mishra, A., Kotecha, K. Enhanced lung image segmentation using deep learning. *Neural Comput. Applic.,* 35, 22839–22853, 2023.

[6] Mothkur, R., & Veerappa, B. N. "Classification Of Lung Cancer Using Lightweight Deep Neural Networks", *Procedia Comput. Sci.*, 218, 1869-1877. 2023.

[7] Prasad, U., Chakravarty, S., & Mahto, G. "Lung cancer detection and classification using deep neural network based on hybrid metaheuristic algorithm", *Soft Comput.*, 1-24, 2023.

[8] Ronneberger, O., Fischer, P., & Brox, T. "U-Net: Convolutional Networks for Biomedical Image Segmentation", Medical Image Computing and Computer-Assisted Intervention (MICCAI), *Vol 9351, 2015, p 234-24.1.*

[9] Çelik, T., Turgut, A., Yılmaz, M. "U-Net'in Akciğer CT Görüntü Segmentasyonundaki Uygulaması: Karşılaştırmalı Bir Çalışma", *J. Med. Imaging*, 8(2), 123-135, 2021.

[10] Shorten, C. and Khoshgoftaar, T.M., "A Survey on Image Data Augmentation for Deep Learning", *J. Big Data*, 6:60, 2019.

[11] Liu, W., Luo, J., Yang, Y. Wang, W., Deng, J., Yu, L., "Automatic lung segmentation in chest X-ray images using improved U-Net", *Sci Rep.,* 12, 8649, 2022.

[12] Suzuki, K., Otsuka, Y., Nomura, Y., Kumamaru, K. K., Kuwatsuru, R., & Aoki, S. "Development and Validation of a Modified Three-Dimensional U-Net Deep-Learning Model for Automated Detection of Lung Nodules on Chest CT Images From the Lung Image Database Consortium and Japanese Datasets", *Acad. Radiol.*, 29, S11–S17, 2022.

[13] Wang, Y., Zhou, C., Chan, H.P., Hadjiiski, L.M., Chughtai, A., Kazerooni, E.A., "Hybrid U-Net-based deep learning model for volume segmentation of lung nodules in CT images", *Medical Phys.*, 49, 7287 – 7302, 2022.

[14] Jalali, Y., Fateh, M., Rezvani, M., Abolghasemi, V., Anisi, M.H., "ResBCDU-Net: A Deep Learning Framework for Lung CT Image Segmentation", *Sensors*, 21(1):268, 2021.

[15] Park, B., Park, H., Lee, S. M., Seo, J. B., Kim, N., "Lung Segmentation on HRCT and Volumetric CT for Diffuse Interstitial Lung Disease Using Deep Convolutional Neural Networks", *J. Digit. Imaging*, 32:6, 1019-1026, 2019.

[16] Khanna, A., Narendra D., Londhe, S., Gupta, Ashish Semwal,A., "A deep Residual U-Net convolutional neural network for automated lung segmentation in computed tomography images." *Biocybernetics Biomed Eng.*, 40:3, 1314-1327, 2020.

[17] Zhang, Z., Wu, C., Coleman, S., Kerr, D., et al. "DENSE-INception U-net for medical image segmentation", *Comput. Methods Programs Biomed.*, 192, 105395, 2020.

[18] Shen, T., Menchita, D., "Lung CT image segmentation algorithm based on improved U-net structure", *2022 IEEE 5th Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC), 5, 2022, p 93-96.*

[19] Chen, K-B., Xuan, Y., Lin, A-J., Guo, S-H., "Lung computed tomography image segmentation based on U-Net network fused with dilated convolution", *Comput. Methods Programs Biomed.*, 207 106170, 2021.

[20] Ronneberger, O., Fischer, P. and Brox, T. "U-net: Convolutional Networks for Biomedical Image Segmentation", *Medical image computing and computer-assisted intervention–MICCAI 2015: 18th international conference, 2015, p 234-241.*

[21] Kong, H., Akakin, H.C., Sarma, S.E., "A generalized laplacian of gaussian filter for blob detection and its applications," *IEEE Trans. Cybern., Vol. 43:6, , 201, p 31719–1733.*