



Derin Öğrenmeyle Manyetik Rezonans Prostat İmgelerinin Bölütlenmesi Hakkında Bir İnceleme

A Review about Segmentation of Magnetic Resonance Prostate Images with Deep Learning

Fatih UYSAL ve Fırat HARDALAÇ
Elektrik-Elektronik Mühendisliği Bölümü
Gazi Üniversitesi
Ankara, Türkiye Cumhuriyeti
uysal@gazi.edu.tr, firat@gazi.edu.tr

Mustafa KOÇ
Dahili Tıp Bilimleri Bölümü
Fırat Üniversitesi
Elazığ, Türkiye Cumhuriyeti
mkoc@firat.edu.tr

Özetçe—Derin öğrenme; biyomedikal alanındaki imgeler üzerinde yapılan bölütleme işlemlerinde sıklıkla kullanılmaktadır. Son yıllarda yapılan çalışmalarda, derin öğrenme kullanılarak prostat imgelerinde yapılan bölütleme işlemlerinde, diğer imge bölütleme yöntemlerine kıyasla bir artış olduğu gözlemlenmiştir. Literatüre bakıldığında; özellikle derin öğrenmeyle gerçekleştirilen prostat imgelerinin bölütlenmesi işleminin, prostat kanserinin teşhis ve tedavisi için çok önemli bir adım olduğu görülmektedir. Bu sebeple bu çalışmada; ileride yapılacak olan bölütleme işlemlerine kaynak olması amacıyla; manyetik rezonans (MR) imgeleme cihazlarından elde edilen prostat imgeleri üzerinde derin öğrenmeyle gerçekleştirilen bölütleme işlemleri incelenmiştir.

Anahtar Kelimeler — derin öğrenme; imge bölütleme, prostat kanseri.

Abstract— Deep learning; are often used in segmentation processes on imaged areas of the biomedical field. Recent studies have observed an increase in segmentation in prostate images using deep learning compared to other image segmentation methods. From a literary perspective; especially the segmentation of prostate images, which is carried out with deep learning, appears to be a very important step for the diagnosis and treatment of prostate cancer. For this reason, in this study; in order to be a source of future segmentation operations; we have investigated the segmentation process of the prostate images obtained from magnetic resonance (MR) imaging devices with deep learning.

Keywords — deep learning, image segmentation, prostate cancer.

I. GİRİŞ

Prostat kanseri, erkeklerde en sık görülen kanser türlerinden biridir. Prostat kanserinin görülmemesinde transrektal ultrasonografi (TRUS), bilgisayarlı tomografi (CT) ve MR kullanılabilir. Bunlar içerisinde, derin öğrenmeyle birlikte özellikle MR prostat imgeleri üzerinde bölütleme işlemleri yapılabilmektedir. MR imgeleme tekniklerindeki gelişmeler sayesinde prostat kanserinin saptanmasındaki tanıs

doğruluk artmaktadır. Genel itibarıyla T1 ve T2 ağırlıklı MR imgeleri üzerinde işlemler yapılabilir birlikte; T2 ağırlıklı MR imgeleri anatomiyi çok iyi bir şekilde göstermektedir [1].

Literatüre bakıldığında, prostat kanserinin teşhis ve tedavisinde, özellikle derin öğrenme ile gerçekleştirilen MR prostat imgelerinin bölütlenmesi işleminin çok önemli bir adım olduğu görülmektedir. Bu inceleme çalışmasında; ileride yapılacak olan bölütleme işlemleri için kaynak oluşturması amacıyla, son yıllarda yapılan prostat imgelerinin bölütlenmesi çalışmaları incelenmiş ve şu sonuçlara varılmıştır.

Cho ve arkadaşları; eğitmenli (supervised) ve eğitimsiz (unsupervised) yaklaşımlardan her ikisinin de faydalarından en iyi şekilde yararlanmak için, evrişimsel sinir ağı (ESA) ve topolojik türev (topological derivative, TD) temelli bir bölütleme işlemi gerçekleştirmişlerdir. MR prostat imgeleri üzerinde gerçekleştirdikleri bu çalışmada, ESA temelli bir yöntem geliştirerek prostat bölgesini tespit etmişlerdir. Ardından da TD temelli bölütleme işlemi gerçekleştirerek, ESA temelli yöntemin sonuçlarını iyileştirmeye çalışmışlardır [2].

Zhu ve arkadaşları; farklı hastalardan alınan prostat imgeleri arasındaki büyük şekil ve doku değişimlerinin bölütleme işleminde oluşturdukları problemlerin üstesinden gelmek için, MR prostat imgeleri üzerinde yapılan bölütleme işlemlerinde derinden (deeply) eğitmenli bir ESA modeli önermişlerdir. Ayrıca önerdikleri bu modelle, tam (fully) evrişimler ağı ve bir ESA mimari türü olan U-net modelinin sonuçlarını karşılaştırmışlardır [3].

Cheng ve arkadaşları; MR prostat imgelerinin bölütlenmesi ve yüzey yeniden oluşturma (surface reconstruction) için yeni bir yöntem önermişlerdir. Önerdikleri yöntem; önceden yapılan derin öğrenme temelli yöntemlerden farklı olarak, daha iyi bir bölütleme işlemi sağlamak için bütünsel-iç içe kenar tespitli (holistically-nested edge detector'lı, HED'li) derin öğrenmenin üstünlüklerinden yararlanan bir modeldir. Bu çalışmalarının sonuçları; MR prostat imgelerinin 3 boyutlu ortogonal hacimsel

bölütlemesi için HED'in uygulanmasının, ileride yapılacak olan çalışmalar için çok olumlu olduğunu göstermektedir [4].

Jia ve arkadaşları; MR prostat imgelerini bölütlenmesi için toplu derin (ensemble deep) ESA'ları kullanmışlardır. Önerdikleri yöntemle; geleneksel aktif şekil (active shape) modelini (ASM'yi), olasılıksal ASM'yi ve 3 boyutlu aktif görünüm (active appearance) modelini (3D AAM'i) karşılaştırarak, kendi yöntemlerinin bölütlemede daha yüksek doğruluk oranına sahip olduklarını belirtmişlerdir [5].

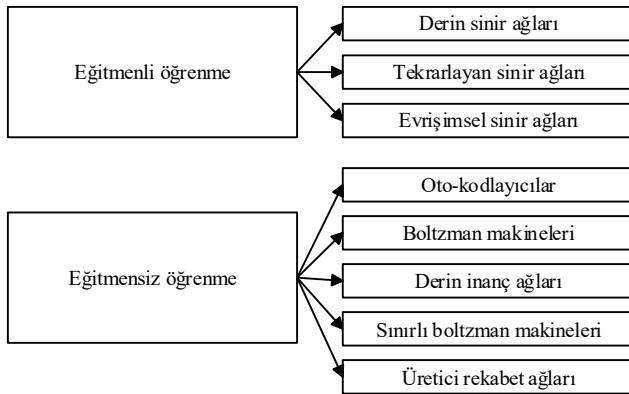
Yan ve arkadaşları; MR prostat imgelerinde otomatik bölütleme için çizge (graph) modelini ve derin ağ'ı kullanmışlardır. Yaptıkları çalışmanın sonucunda; önerdikleri derin ağ ve çizge modelinin, geleneksel prostat bölütleme yöntemlerinden daha iyi bir performans gösterdiğini belirtmişlerdir. Ayrıca; MR prostat imgelerinin, TRUS ve CT'den elde edilen prostat imgeleri ile karşılaştırıldığında, bölütleme işlemi için daha uygun olduğunu belirtmişlerdir [6].

Mun ve arkadaşları ise; yaptıkları çalışmada, ESA'ya dayanan MR prostat imgelerinin bölütlenmesi işlemindeki amaç işlevlerini (objective functions) karşılaştırmışlardır. Bölütleme işlemi için geliştirdikleri temel (baseline) ESA modelinde, amaç işlevlerinden; Hamming uzaklığı, Öklid uzaklığı, Jaccard dizini, Sorensen dizini, kosinüs benzerliği ve çapraz entropiyi kullanarak elde ettikleri sonuçlarını karşılaştırmışlardır. Bu işlemler sonucunda, en iyi bölütleme işlemini, kosinüs benzerliği amaç işlevini kullanarak gerçekleştirdikleri temel ESA modelinde elde etmişlerdir [7].

Bu inceleme çalışmasının devamındaki 2. kısımda; prostat imgelerinin bölütlenmesi işlemlerinde kullanılan derin öğrenme algoritmalarından, yöntem başlığı adı altında bahsedilmiştir. 3. kısımda ise, son yıllarda derin öğrenmeyle gerçekleştirilen prostat imgelerinin bölütlenmesi işlemleri kategorize edilerek incelenmiş ve sonuçlar kısmında açıklanmıştır.

II. YÖNTEM

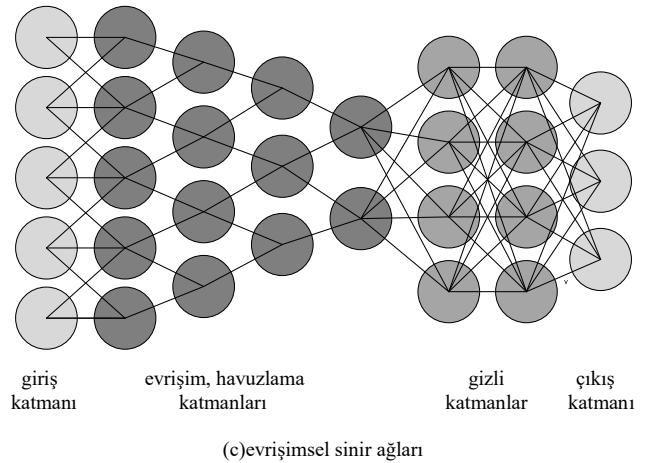
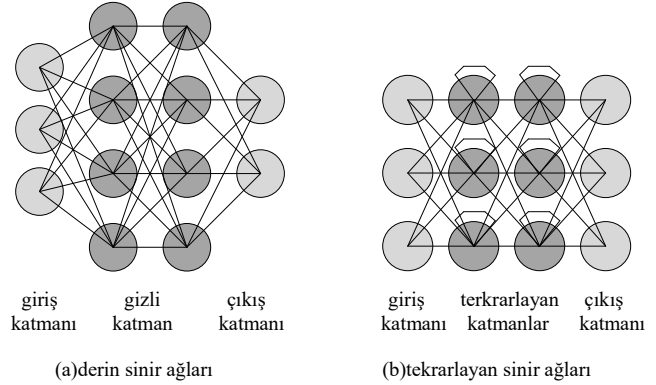
Derin öğrenme; MR prostat imgelerinin bölütlenmesi işlemlerinde sıklıkla kullanılmaktadır ve kendi içerisinde temel olarak 8 farklı algoritmaya ayrılabilir. Eğitimli ve eğitimsiz öğrenme olarak iki farklı öğrenme türüyle kategorize edilen derin öğrenme algoritmaları Şekil 1'de gösterilmiştir.



Şekil 1. Derin öğrenme algoritmaları

Derin öğrenme algoritmalarına Şekil 1'de de gösterildiği gibi; eğitimli öğrenme için, derin sinir ağları (deep neural networks), tekrarlayan sinir ağları (recurrent neural networks) ve ESA'lar; eğitimsiz öğrenme için ise, oto-kodlayıcılar (autoencoders), boltzman makineleri (boltzman machines), derin inanç ağları (deep belief networks), sınırlı boltzman makineleri (restricted boltzman machines) ve üretici rekabet ağları (generative adversarial networks) örnek olarak verilebilir [8].

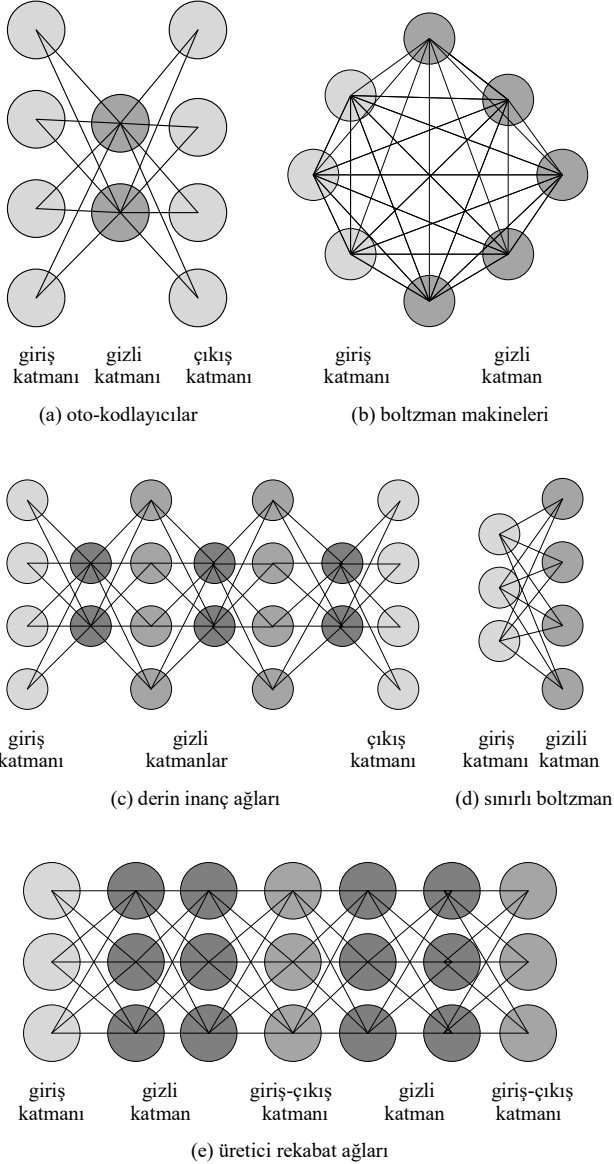
Eğitilmiş öğrenmeli derin öğrenme algoritmalarından; derin sinir ağları, bir katmanın tüm sinir hücrelerinin kendinden sonra gelen katmanın tüm sinir hücrelerine bağlı olduğu birçok gizli katmandan oluşan bir ağıdır [8]; tekrarlayan sinir ağları, birimler arası bağlantıların yönlendirilmiş bir döngüyle sağlandığı bir ağıdır [9]; ESA'lar, yapay sinir ağlarındaki gizli katman sayısının artırılması sonucunda derinleşmiş bir yapıya sahip olan ağıdır [10]. Bu ağların temel yapıları Şekil 2'de gösterilmiştir [8].



Şekil 2. Eğitimli öğrenmeli derin öğrenme ağlarının yapıları

Eğitimsiz öğrenmeli derin öğrenme algoritmalarından; oto-kodlayıcılar, girişinden daha küçük sayıda bir gizli katmandan oluşur; boltzman makineleri, tüm sinir hücrelerini birbirine bağlı olduğu bir ağıdır; sınırlı boltzman makineleri, sadece farklı katmanlardaki sinir hücrelerinin birbirine bağlı olduğu bir ağıdır [8]; derin inanç ağları, sınırlı boltzman makinelerinin yığını olarak tanımlanmaktadır [9]; üretici

rekabet ağları, yapay veri üreten üretken model ile bu verilerin eğitim verilerinin bir parçası olma olasılığını tahmin eden diskriminant modelin birleşiminden oluşur. Bu ağların temel yapıları ise, Şekil 3'te gösterilmiştir [8].



Şekil 3. Eğitimsiz öğrenmeli derin öğrenme ağlarının yapıları

MR prostat imgelerinin bölütlenmesi işlemlerine bakıldığında genel itibarıyla, derin algoritma algoritmalarından eğitimli öğrenme sınıfına giren ESA'ların kullanıldığı görülmektedir. ESA'lar; giriş katmanı, evrişim katmanı, düzleştirilmiş doğrusal birim katmanı, havuzlama katmanı, tam bağlantılı katman, dropout katmanı ve sınıflandırma katmanından oluşur.

III. SONUÇLAR

Özellikle son yıllarda yapılmış olan MR prostat imgelerinin bölütlenmesi işlemleri incelendiğinde; Tablo 1'de gibi kategorize edilmiş bir sonuç elde edilebilir.

TABLO I. MR prostat imge bölütleme çalışmaları

Bölütleme Amacı	Yöntem	Kaynak
Eğitmenli ve eğitimsiz yaklaşımların her ikisinden de faydalanmak	ESA, topolojik türev	Cho ve ark.
Büyük şekil ve doku değişimleri problemlerini gidermek	ESA, U-net	Zhu ve ark.
Daha iyi bir 3 boyutlu ortogonal hacimsel bölütleme sağlamak	HED	Cheng ve ark.
Toplu derin ESA ile ASM ve AAM'i karşılaştırmak	Toplu derin ESA	Jia ve ark.
Geleneksel bölütleme yöntemlerine göre daha iyi bir performans elde etmek	Çizge modeli, derin ağ	Yan ve ark.
Amaç işlevlerini karşılaştırmak	Temel ESA	Mun ve ark.

Yapılan inceleme sonucunda; prostat kanseri teşhis ve tedavisinde çok önemli bir adım olan MR prostat imgelerinin bölütlenmesi işleminde derin öğrenme ile ilişkili yöntem olarak; ESA, topolojik türev, U-net, HED, toplu derin ESA, çizge modeli ve temel ESA'nın kullanıldığı gözlemlenmiştir. Ayrıca bu inceleme çalışması ile birlikte; bölütleme işlemleri için gerekli olan MR prostat imgelerinin açık kaynak veri ile ilgili bilgileri Tablo-2'de belirtilmiştir [11].

TABLO II. Açık kaynak MR prostat imge verileri

Veri ismi	Hasta sayısı	İmge türü	İmge sayısı	İmge boyutu
Prostate-3T	64	T2 ağırlıklı MR	1258	284 MB
Prostatex	346	MR	309251	15,1 GB
Prostate-Diagnosis	92	T1 ve T2 ağırlıklı MR	32537	5,6 GB
Prostate Fused-MRI-Pathology	28	MR	32508	4,4 GB

İleride yapılacak olan MR prostat imgelerinin bölütlenmesi işlemlerinde; kullanılacak ya da geliştirilecek olan derin öğrenme modellerine göre ve/veya kullanılması planlanan imge türüne göre, Tablo-2 de belirtilen açık kaynak verilerinden bir ya da birkaçı kullanılabilir.

KAYNAKLAR

- [1] Gençhellaç, H., Yılmaz, E., "Prostat Görüntüleme", *Türk Radyoloji Seminerleri*, (138-148), 2015.
- [2] Cho, C., Lee, Y. H., Lee, S., "Prostate Detection and Segmentation Based on Convolutional Neural Network and Topological Derivative", *IEEE International Conference on Image Processing*, 2017.



- [3] Zhu, Q., Turkbey, B., Choyke, P. L., Du, B., Yan, P., “Deeply-Supervised CNN for Prostate Segmentation”, *International Joint Conference on Neural Networks*, 2017.
- [4] Cheng, R., Lay, N., Mertan, F., Turkbey, B., Roth, H. R., Lu, L., Gandler, W., McCreedy, E. S., Pohida, T., Choyke, P., McAuliffe, M. J., Summers, R. M., “Deep Learning with Orthogonal Volumetric HED Segmentation and 3D Surface Reconstruction Model of Prostate MRI”, *IEEE 14th International Symposium on Biomedical Imaging*, 2017.
- [5] Jia, H., Xia, Y., Cai, W., Fulham, M., Feng, D. D., “Prostate Segmentation in MR Images using Ensemble Deep Convolutional Neural Networks”, *IEEE 14th International Symposium on Biomedical Imaging*, 2017.
- [6] Yan, K., Li, C., Wang, X., Li, A., Yuan, Y., Feng, D., Khadra, M., Kim, J., “Automatic Prostate Segmentation on MR Images with Deep Network and Graph Model”, *38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2016.
- [7] Mun, J., Jang, W. D., Sung, D. J., Kim, C. S., “Comparison of Objective Functions in CNN-based Prostate Magnetic Resonance Image Segmentation”, *IEEE International Conference on Image Processing*, 2017.
- [8] Meyer, P., Noblet, V., Mazzara, C., Lallement, A., “Survey on deep learning for radiotherapy”, *Computers in Biology and Medicine*, 2018.
- [9] Şeker, A., Diri, B., Balık, H. H., “Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme”, *Gazi Mühendislik Bilimleri Dergisi*, (47-64), 2017.
- [10] İnik, Ö., Ülker, E., “Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri”, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 2017.
- [11] <http://www.cancerimagingarchive.net/>