

FLAIR Sekans MR Görüntüsünde Tümör Sınırlarının Farklı Görüntü Segmentasyon Algoritmaları ile Belirlenmesi

Determination of Tumor Boundaries in FLAIR Sequence MR Image with Different Image Segmentation Algorithms

Muhammet Üsâme Öziç¹, Cansu Güneş¹, Ahmet Avcı¹

¹Biyomedikal Mühendisliği Anabilim Dalı, Necmettin Erbakan Üniversitesi, Konya, Türkiye
{muozic, cansu.gunes, ahmetavci}@erbakan.edu.tr

Özetçe—Tümörler, vücudun birçok farklı bölgesinde meydana gelen istenmeyen doku bozukluklarıdır. Bu bozukluklar, tiplerine göre iyi huylu veya kötü huylu olabilir. Beyin tümörleri nörolojide sıklıkla karşılaşılan beyin dışı yapılardır. Bu yapılar beyinde bulundukları bölgeye göre kişinin fonksiyonel merkezlerini bozarak günlük yaşamı olumsuz bir şekilde etkilemektedir. Radyolojide tümörlü bölgelerin net sınırlarının belirlenmesi tedavi ve tanı için önemli bir parametredir. Bu çalışmada, BRATS veri tabanından alınan FLAIR sekans MR görüntüsünde tümörlü bölgenin segmentasyonu yedi farklı görüntü işleme algoritması ile denlenmiştir. Dice ve jaccard indeksleri kullanılarak algoritmaların segmentasyon performansları belirlenmiştir.

Anahtar Kelimeler—FLAIR; görüntü işleme; MR; segmentasyon; tümör

Abstract—Tumors are undesired tissue disorders that occur in many different parts of the body. These disorders can be either benign or malignant depending on their type. Brain tumors are non-brain structures that are frequently encountered in neurology. These structures negatively affect daily life by disrupting the functional centers of the person with respect to their region in the brain. Determining certain boundaries of tumor areas in radiology is an important parameter for treatment and diagnosis. In this study, segmentation of the tumor region on FLAIR sequence MR image taken from the BRATS database has been tried with seven different image processing algorithms. Segmentation performances of algorithms have been determined by using dice and jaccard indexes.

Keywords—FLAIR; image processing; MR; segmentation; tumor

I. GİRİŞ

Beyin tümörleri, beyin içerisindeki hücrelerin düzensiz çoğalmasından kaynaklı olarak oluşan istenmeyen yapılardır. Hastalık öyküsü, nörolojik muayeneler ve görüntüleme teknikleri ile gerekli teşhisler konulabilir. Genel olarak iyi huylu ve kötü huylu olarak ikiye ayrılırlar. İyi huylu tümörler beyin zarları ve sinirlerden kaynaklı olup tedavileri kolaydır. Kötü huylu tümörler anormal bir şekilde hızlıca büyüyerek sağlıklı beyin hücrelerine doğru yayılır. Bu tümörlerin beyindeki yerleşim, uzunluk ve genişlik ve risk faktörlerine göre tedavileri zorlu süreçlerden geçebilmektedir. Vücudun farklı bölgelerinde meydana gelen kanser hücrelerinden dokular beyne sıçrayarak metastaz yapabilmektedir. [1]. Tümörün boyutsal değişimi, türü ve yerleşimi medikal görüntüleme teknikleri ile izlenebilmektedir. Bilgisayarlı Tomografi, Pozitron Emisyon Tomografi ve Manyetik Rezonans (MR) görüntüleme teknikleri tümör izlemesinde kullanılan tekniklerdir. MR görüntüleme tekniği yumuşak beyin dokularını yüksek çözünürlükte gösterebildiği için bu alanda sıklıkla kullanılmaktadır [2]. MR görüntülerinde tümör büyüklüğü, kapladığı alan, uzunluk ve genişlik gibi birçok morfolometrik özellikler belirlenebilmektedir. Bu ölçüler özellikle nöronavigasyon sistemlerinin kullanıldığı ameliyatlarda cerrahi öncesi planlama ve cerrahi sırası işlemlerde hassas işlemler yapılmasını sağlamaktadır [3]. MR görüntülerinde bazen tümör sınırlarının geçiş intensite dağılımları net bir şekilde seçilemediğinden dolayı manuel çizimler zorlaşmaktadır. Bundan dolayı bilgisayar destekli karar destek sistemleri ve segmentasyon algoritmaları bu işlemlerin yapılabilmesi için pratik bir kullanım sunmaktadır [4]. Bu çalışmada BRATS [5] veri tabanından alınan

FLAIR sekans MR görüntüsü üzerinde yedi farklı segmentasyon algoritması ile tümör sınırlarının net bir şekilde çıkarılabilmesi için denemeler yapılmıştır. Deneme sonuçları altın standart görüntüler ile karşılaştırılmış olup algoritmaların segmentasyon performansları tartışılmıştır.

II. MATERYAL VE METOT


A. Materyal

Materyal olarak Pensilvanya Üniversitesi Perelman School of Medicine tarafından araştırmacılara açık kaynak olarak sunulan BRATS veri tabanından 001 nolu datanın FLAIR sekans 77. kesiti kullanılmıştır. Data içerisinde T1, T2, T1C sekans görüntüleri de bulunmaktadır. Bu sekanslar farklı manyetik rezonans görüntüleme protokolü uygulayarak yumuşak dokuların farklı özelliklerde izlenebilmesini sağlamaktadır. T1 ağırlıklı görüntülerde su ve sıvı içeren dokular koyu, yağ içeren dokular parlak renktedir. T2 ağırlıklı görüntülerde ise su ve sıvılarla dolu dokular parlak, yağ içeren dokular ise koyu renktedir [6]. Bu nedenle tümör oluşumu T2 sekans MR görüntülerde daha iyi gözlenir. Ancak beyin omurilik sıvısı (BOS) da aynı tonda görülür. FLAIR görüntüleri, beyindeki sıvı içeriğinin görünümünün azaltılmasına yardımcı olur. FLAIR'ın görüntüleme işleminde su moleküllerinin sinyali bastırıldığı için, FLAIR, tümör bölgesini BOS'tan ayırmaya yardımcı olur [7]. Bu nedenle tümörün alt bölgelere ayrılmadan tamamının segmente edilmesi ve BOS'tan ayrıştırılabilmesi için FLAIR sekansının kullanılmasına karar verilmiştir. Veri tabanında tümörlü bölgelerin uzman segmentasyonu altın standart olarak verilmektedir. Ancak tümörlü bölgeler 0-background, 1-nekrotik ve non-enhancing tümör bölgesi, 2-peritumoral ödem bölgesi, 4-GD-enhancing tümör olarak etiketlenmiştir. Bu bölgeler farklı renk tonlarında Şekil 1b'de verilmiştir. Bu çalışmada tümörlü bölgeler bir bütün olarak segmente edileceği için altın standart görüntüde etiketli tüm pikseller bir değerine atanmıştır. Şekil 1a'da kullanılan FLAIR sekans MR görüntüsü, Şekil 1b'de altın standart görüntünün alt bölgelerinin farklı tonlarda gösterimi, Şekil 1c'de FLAIR sekans görüntü ile altın standart görüntünün üst üste çakıştırılması, Şekil 1d'de altın standart görüntü içerisindeki farklı piksel ton değerlerinin bir değerine atanmış şekli gösterilmektedir.

B. Segmentasyon Algoritmaları

Segmentasyon işlemi görüntü üzerinde istenen bir nesnenin ortaya çıkarılması ve arka plandan ayrılması işlemidir. Medikal görüntü analizlerinde sıklıkla kullanıldığı gibi görüntü işleme problemlerinde de sıklıkla kullanılmaktadır. Segmentasyon işlemi için birçok görüntü işleme algoritması literatürde sunulmaktadır. Bu algoritmalar görüntüdeki nesnelerin içinde bulunduğu farklı piksel komşuluk durumlarına göre görüntüye matematiksel işlemler

uygulamaktadır. Bu çalışmada K-means, Fuzzy C-means, çoklu otsu eşikleme, watershed, graph cut, split and merge ve active counter yöntemleri ile tümör segmentasyonu yapılmış olup tümör bölütlemesinde performansları değerlendirilmiştir.



Şekil 1. (a) BRATS 001 FLAIR 77. kesiti (b) Farklı etiket değerleri atanmış altın standart segmentasyon görüntüsü (c) Altın standart görüntünün FLAIR görüntü ile çakıştırılması (d) Altın standart görüntüdeki tüm piksel değerlerinin bir değerine atanması.

1) K-Means Algoritması

K-means, kümeler içindeki kareler toplamını en aza indirmek için bir dizi gözlemi bölmeyi amaçlayan bir kümeleme tekniğidir [8].

2) Fuzzy C-Means Algoritması

Fuzzy C-means görüntüyü bölümlere ayırmak için bulanık mantığa dayalı bir kümeleme tekniğidir. Bulanık kümeleme algoritmaları, belirli bir veri kümesinin optimal (bulanık) bir bölümünü kümelere ayırarak belirler [8].

3) Çoklu Otsu Eşikleme

Otsu Eşikleme, görüntüyü ön plan ve arka plan olmak üzere iki bölge sınıfına ayırır. Arka plan ve ön plan bölgeleri ağırlıklı sınıf varyansı kullanılarak seçilir [8]. Çoklu Otsu Eşikleme ise görüntüdeki piksel dağılımlarının küme oluşabilecek varyans değerlerine göre daha fazla bölgeye ayırır.

4) Watershed Yöntemi

Watershed segmentasyonunda görüntü, topografik bir yüzey olarak kabul edilir. Watershed dönüşümü bir görüntüyü tamamen bozar ve her bir pikseli bir bölgeye veya bir havzaya atar. Her bir yerel minimum için, bir havza her bir minimumda en dik iniş yoluna sahip tüm noktaları içerir [9].

5) Graph-Cut Yöntemi

Graph-Cut Algoritması, her bir pikselin ağırlıklı

kenarlarla bağlanmış bir düğüm noktası olduğu görüntünün bir grafiğini oluşturur. Grafik boyunca hareket etmek için tüm kenarları birleştiren bir yol oluşturulur. Bir başlangıç düğümünden bir bitiş düğümüne grafik boyunca hareket etmek için tercih edilen yol, ağırlık toplamının minimum olduğu yoldur. Bu nedenle, yol tercihleri oluşturmak için ağırlıklar ayrı kenarlara atanır. Piksellerin ilişkili olma olasılığı arttıkça ağırlık da artar [10].

6) Split and Merge Yöntemi

Split and Merge yönteminde ilk olarak görüntü bölümlere ayrılır ve homojenlik kriterlerine göre art arda kadrnlara bölünür. İkinci aşamada benzer bölgeler birleştirilerek bölümlere ayrılmış bir görüntü elde edilir. Split algoritması, homojen kriter yerine getirilene kadar, elde edilen bölgelerin her birine tekrar tekrar uygulanır. Merge aşamasında ise bölgelerin birleşimleri homojenlik kriterini karşılıyorsa, bitişik bölge çiftleri karşılaştırılır ve bölgeler birleştirilir [11].

7) Active Counter Yöntemi

Active Counter yöntemi, sınırların ve hareketlerin doğru bir şekilde izlenmesi ile hedef bölgeyi belirlemek amacıyla kuvvetlerin etkisi altında şekil değiştirebilen çevresel doğruları hareket ettirmeye dayanır [12]. Genel olarak bir hedef bölge belirlenir. Bu bölgenin piksel dağılımına göre iterasyonlar uygulanarak, belirlenmiş tohum bölge genişletilip veya küçültülüp sınırlar belirlenmeye çalışılır.

Performans Kriterleri

Segmentasyon algoritmalarının performanslarını değerlendirmek için Dice ve Jaccard indeksleri kullanılmıştır. Bu indeksler sonuç kümesi ile altın standart doğruluk kümesinin ne kadar doğrulukla örtüştüğünün ölçümünü ifade eden metriklerdir [13]. Bölütlenmiş görüntü A ve altın standart görüntü B olmak üzere A ve B'nin örtüştüğü, değeri 1 olan piksellerin toplamı Doğru Pozitif (DP); 1 olan A değerleri ile 0 olan B değerleri toplamı Yanlış Negatif (YN); 0 olan A değerleri ile 1 olan B değerleri toplamı Yanlış Pozitif (YP); A ve B'nin örtüştüğü, değeri 0 olan piksellerin toplamı Doğru Negatif (DN) kabul edilir. Bu değerlerden yola çıkılarak jaccard indeksi Denklem 1'de verildiği gibi, Dice indeksi Denklem 2'de verildiği gibi hesaplanır.

$$Jaccard = \frac{|A \cap B|}{|A \cup B|} = \frac{DP}{YN + YP + DP} \quad (1)$$

$$Dice = 2 \frac{|A \cap B|}{|A| + |B|} = \frac{2 \times DP}{(2 \times DP) + YP + YN} \quad (2)$$

III. BULGULAR VE TARTIŞMA

Yapılan denemeler sonucunda her bir algoritmaya ait Dice ve Jaccard indekslerine göre elde edilen bulgular tablolarda; en iyi çıkan segmentasyon sonuçları görüntü üzerinde; tümörlü bölge, çevre çizimi ve en

küçük dikdörtgene sığan bölgeleri şekiller olarak verilmiştir. Tablo I'de K-means algoritması segmentasyon sonuçları, Şekil 2'de K-means algoritması ile en iyi sonucu veren şekiller, Tablo II'de Fuzzy C-means algoritması segmentasyon sonuçları, Şekil 3'te Fuzzy C-means algoritması ile en iyi sonucu veren şekiller, Tablo III'te Çoklu Otsu eşikleme algoritması segmentasyon sonuçları, Şekil 4'te çoklu otsu eşikleme algoritması ile en iyi sonucu veren şekiller, Tablo IV'te Watershed, Active Counter, Split and Merge, Graph-cut algoritmaları segmentasyon sonuçları, Şekil 5'te Watershed ile en iyi sonucu veren şekiller, Şekil 6'da Graph-cut algoritması ile en iyi sonucu veren şekiller, Şekil 7'de Active Counter algoritması ile en iyi sonucu veren şekiller, Şekil 8'de Split and Merge algoritması ile en iyi sonucu veren şekiller verilmiştir.

Tablo I. K-Means Segmentasyon Sonuçları.


	Küme Sayısı	Jaccard	Dice
K-Means	6	0.8974	0.9459
	8	0.8940	0.9440
	10	0.8896	0.9415
	12	0.8949	0.9445



Şekil 2. K-Means algoritması (küme sayısı=6) ile yapılan tümör segmentasyonu.

Tablo II. Fuzzy C-Means Segmentasyon Sonuçları.


	Küme Sayısı	Jaccard	Dice
Fuzzy C-Means	4	0.8098	0.8949
	3	0.6818	0.8108



Şekil 3. Fuzzy-C means algoritması (küme sayısı=4) ile yapılan tümör segmentasyonu.

Tablo III. Çoklu Otsu Eşikleme Segmentasyon Sonuçları.


	Eşik Sayısı	Küme Sayısı	Jaccard	Dice
Çoklu Otsu Eşikleme	10	11	0.8934	0.9437
	13	14	0.8949	0.9445
	15	16	0.8888	0.9411
	17	18	0.8895	0.9415



Şekil 4. Çoklu Otsu Eşikleme algoritması (küme sayısı=14) ile yapılan tümör segmentasyonu.

Tablo IV. Watershed, Graph Cut, Active Counter, Split and Merge Segmentasyon Sonuçları.

	Jaccard	Dice
Watershed	0.8983	0.9464
Graph Cut	0.8560	0.9224
Active Counter	0.5128	0.6779
Split and Merge	0.6570	0.7930



Şekil 5. Watershed algoritması ile yapılan tümör segmentasyonu.



Şekil 6. Graph-cut algoritması ile yapılan tümör segmentasyonu.



Şekil 7. Active Counter algoritması ile yapılan tümör segmentasyonu.



Şekil 8. Split and Merge algoritması ile yapılan tümör segmentasyonu.

IV. SONUÇLAR

Bu çalışmada, beyin tümörü segmentasyonunda kullanılan görüntü işleme algoritmalarıyla farklı denemeler yapılmıştır. K-means, Fuzzy C-means, çoklu otsu eşikleme, Watershed, Graph cut, Split and Merge ve Active Counter yöntemlerinden tümör segmentasyonu için uygun yöntemler belirlenmeye çalışılmıştır. Yapılan denemeler sonucunda en yüksek çıkan benzerlik indeksi ve algoritma, 0.90 Jaccard benzerlik indeksi ve 0.95 Dice benzerlik indeksi ile Watershed metodu olmuştur. K-means ve Çoklu Otsu eşikleme metotları da diğer yöntemlere göre yüksek sonuçlar vermektedir. Bu segmentasyon algoritmalarının verdiği sınırlar ile tümörlü bölgenin alan, çap, büyüklük, genişlik gibi morfolojik özellikleri belirlenebilir. Gelecek çalışmalarda tümör tespiti için üç boyutlu segmentasyon ve derin öğrenme metotları araştırılacaktır.

KAYNAKÇA

- [1] K. J. Zülch, *Brain tumors: their biology and pathology*. Springer-Verlag, 2013.
- [2] J. R. Fink, M. Muzi, M. Peck, and K. A. J. J. o. N. M. Krohn, "Multimodality brain tumor imaging: MR imaging, PET, and PET/MR imaging," vol. 56, no. 10, pp. 1554-1561, 2015.
- [3] O. Ganslandt, S. Behari, J. Gralla, R. Fahlbusch, and C. J. N. I. Nimsy, "Neuronavigation: concept, techniques and applications," vol. 50, no. 3, p. 244, 2002.
- [4] J. Patel, K. J. A. i. E. Doshi, and E. Engineering, "A study of segmentation methods for detection of tumor in brain MRI," vol. 4, no. 3, pp. 279-284, 2014.
- [5] S. Bakas *et al.*, "Identifying the best machine learning algorithms for brain tumor segmentation, progression assessment, and overall survival prediction in the BRATS challenge," 2018.
- [6] G. Vishnuvarthanan, M. P. Rajasekaran, N. A. Vishnuvarthanan, T. A. Prasath, M. J. I. J. o. I. S. Kannan, and Technology, "Tumor detection in T1, T2, FLAIR and MPR brain images using a combination of optimization and fuzzy clustering improved by seed-based region growing algorithm," vol. 27, no. 1, pp. 33-45, 2017.
- [7] J. Liu *et al.*, "A survey of MRI-based brain tumor segmentation methods," vol. 19, no. 6, pp. 578-595, 2014.
- [8] A. Kaur, "An automatic brain tumor extraction system using different segmentation methods," in *2016 Second International Conference on Computational Intelligence & Communication Technology (CICCT)*, 2016, pp. 187-191: IEEE.
- [9] B. Preim and C. P. Botha, *Visual computing for medicine: theory, algorithms, and applications*. Newnes, 2013.
- [10] O. Veksler, "Star shape prior for graph-cut image segmentation," in *European Conference on Computer Vision*, 2008, pp. 454-467: Springer.
- [11] D. Chaudhuri and A. Agrawal, "Split-and-merge Procedure for Image Segmentation using Bimodality Detection Approach," *Defence Science Journal*, vol. 60, pp. 290-301, 03/27 2010.
- [12] N. Dey, *Classification Techniques for Medical Image Analysis and Computer Aided Diagnosis*. Academic Press, 2019.
- [13] H.-H. Chang, A. H. Zhuang, D. J. Valentino, and W.-C. J. N. Chu, "Performance measure characterization for evaluating neuroimage segmentation algorithms," vol. 47, no. 1, pp. 122-135, 2009.