

Beyin MR Görüntüleri için Süperpiksel Yöntemlerinin Bölütleme Performansı Analizi Segmentation Performance Analysis of Superpixel Methods for Brain MR Images

Fadime ÖZEREN

Biyomedikal Cihaz Teknolojisi Programı
İstanbul Gedik Üniversitesi
İstanbul, Türkiye
fadime.ozeren@gedik.edu.tr

Ufuk ÖZKAYA

Elektrik-Elektronik Mühendisliği Bölümü
Süleyman Demirel Üniversitesi
Isparta, Türkiye
ufukozkaya@sdu.edu.tr

Özetçe— Manyetik rezonans görüntüleme ile büyük miktarda veri üretilmektedir ve bu verilerin manuel olarak işlenmesi yüksek hesaplama karmaşıklığına neden olmaktadır. Yüksek hesaplama karmaşıklığını çözebilmek için bilgisayarlı görü sistemlerinde yaygın olarak kullanılan gruplama işlemi önerilmektedir. Bu gruplama işlemi süperpiksel olarak adlandırılmaktadır. Süperpikseller, özellikle imge ve video bölütleme uygulamalarında kullanılan; bir imgeye veya videoya ait renk, yoğunluk ve doku özellikleri benzerlik gösteren piksellerden oluşan görsel yapılardır. BrainWeb veri kümesinden alınan beyin MR görüntüleri üzerinde çalışılmıştır. Literatürde yaygın olarak kullanılan ve yüksek başarıya sahip olan 3 süperpiksel algoritmasının performansları karşılaştırılmıştır. Süperpiksel algoritmalarının başarılarını test edebilmek için görüntülere ait kesin referans verilerinden yararlanılmıştır. Süperpiksel algoritmalarının oluşturduğu sınırlar ile kesin referans arasında başarı metrikleri hesaplanmıştır.

Anahtar Kelimeler — Süperpiksel, İmge bölütleme, Beyin MR görüntüleri.

Abstract— Magnetic resonance imaging produces large amounts of data, and the manual processing of these data results in high computational complexity. In order to solve the high computational complexity, the grouping process which is commonly used in computer vision systems is recommended. This grouping process is called superpixel. Superpixels, used especially in image and video segmentation applications, are the visual structures composed of pixels having same color, intensity and texture behavior. Brain MR images from BrainWeb data set were studied. The performances of 3 superpixel algorithms which are widely used in the literature and have high success are compared. In order to test the success of superpixel algorithms, precise reference data of the images were used. Success metrics were calculated between the boundaries created by the superpixel algorithms and the exact reference.

Keywords — Superpixel, Image segmentation, Brain MR images.

I. GİRİŞ

Manyetik rezonans görüntüleme(MRI), büyük miktarlarda veri ürettiği için manuel inceleme ile yorumlanması oldukça zordur. Beyin MR verilerinden klinik bilgilerinin çıkarılarak

hekimlere daha iyi bilgi sunabilen bilgisayar tabanlı araçların geliştirilmesi desteklenmektedir. Geliştirilen araçlar sayesinde yüksek çözünürlüklü görüntüler oluşturulmaktadır. Yüksek çözünürlüklü görüntülerin oluşması ile de yüksek hesaplama karmaşıklığı oluşmaktadır. Yüksek hesaplama karmaşıklığı problemi gruplama işlemi yapılarak çözülebilmektedir. Bu gruplama işlemi bilgisayarlı görü sistemlerinde süperpiksel olarak adlandırılır.

Süperpiksel renk, doku ve yoğunluk gibi özelliklerinin benzerliği ile piksel gruplarından oluşmasına ve bir imgeyi veya bir videoyu daha az veri ile ifade etmeye olanak sağlamaktadır. Görüntü işleme uygulamalarında süperpiksellerin tercih edilmesinin sebebi işlem yükünü ve işlem süresini oldukça azaltmasıdır. Örneğin bir imgeyi işlerken imgedeki her bir piksel ile işlem yapmak oldukça maliyetlidir. Fakat bir imgedeki binlerce pikselden yüzlerce süperpiksele dönüştürülerek işlem yükünün ve süresinin ne kadar düştüğünün fark edilebilir şekilde gözlenmesi mümkündür. Bu yüzden süperpiksel imge işleme uygulamalarında sıklıkla kullanılmaktadır. Bu uygulamalara nesne tanıma[1], vücut modeli tahmini[2], görsel izleme[3] olarak örnek verilebilir.

Literatür incelendiğinde süperpiksel uygulamaları, medikal görüntüler üzerinde çalışmalar yapıldığını göstermektedir. Süperpikseller kullanılarak MR analizinin karmaşıklığını azaltma işlemi gerçekleştirilmiştir[4]. Bu çalışmada IBSR veri seti kullanılarak düşük seviye beyin MR analiz görevlerinde süperpiksellerin ve süperpiksellerin faydası araştırılmıştır. Beyin MR görüntülerinde süperpiksellerin doğruluğunu sınırlara bağlılık ve yoğunluk ölçüsüne göre basit doğrusal yinelenmeli kümeleme algoritması(SLIC) kullanılarak değerlendirilmiştir. Beyin MR görüntüsünde SLIC algoritmasının performans değerlendirmesi beyin beyaz madde, boz madde ve omurilik sıvısı dikkate alınarak yapılmıştır. Bir başka çalışma olarak retina kan damarlarını bölütlere ayırmak için Minimum Yayılma Süperpiksel Ağacı(MSST) dedektörü önerilmiştir [5]. Retinadaki damarların tespiti için MSST algoritmasında SLIC algoritmasına doku ve geometrik yapı parametresi de eklenerek süperpiksel ayırma işlemi ile kan damarlarının tespiti

gerçekleştirilmiştir. Çalışmada DRIVE, STARE ve NIVE veri kümesi olmak üzere üç veri kümesi üzerinde çalışılmıştır. Alzheimer hastası ve sağlıklı birey sınıflandırması yapılabilmesi için beyin MR görüntüsünden yararlanılmıştır [6]. Burada sınıflandırma yapabilmek için beyin anatomik bölgesi olan boz madde ve beyaz maddenin birleştirilmesiyle hasta ve sağlıklı birey arasında eşleştirme yapılarak sınıflandırma gerçekleştirilmiştir.

Bu çalışmada anatomik bölgelerden oluşan beyin MR görüntüleri üzerinde çalışılmıştır. Beyin MR görüntülerinin anatomik bölgelerinin sınırlarının doğru bir şekilde bulunması ile hastalık tespiti yapılmaktadır. Yüksek çözünürlükteki görüntülerin anatomik bölgelerinin bulunabilmesi için literatürde yaygın olarak kullanılan basit doğrusal yinelemeli kümeleme algoritması (SLIC), doğrusal spektral kümeleme algoritması (LSC) ve düzenliliği korunmuş süperpiksel algoritması (RPS) olmak üzere üç farklı süperpiksel algoritması ile çalışılmıştır. Süperpiksel algoritmalarının performanslarını değerlendirmek için literatürdeki bölütlemede kullanılan performans metriklerinden yararlanılmış olup sonuçlar karşılaştırılmıştır.

Takip eden bölümlerde sırasıyla süperpiksel algoritmaları, uygulama örnekleri ve elde edilen sonuçlar sunulacaktır. Son kısımda ise sonuçlar tartışılacaktır.

II. SÜPERPİKSEL ALGORİTMALARI

Literatürde yaygın olarak kullanılan süperpiksel algoritmaları farklı kullanım alanlarına sahip olduğu için tek başlık altında toplamak mümkün değildir. Genel olarak kümeleme tabanlı, graf tabanlı, kontur tabanlı, yol tabanlı olarak sınıflandırılmaktadır. Bu çalışmada SLIC [7] ve LSC [8] kümeleme tabanlı ve RPS [9] yol tabanlı algoritmaları ile çalışılmıştır. Literatürde kullanılan bu algoritmaların uygulama açısından kolay olmasından dolayı SLIC algoritması seçilmiştir. LSC algoritması, SLIC algoritmasının geliştirilmiş bir versiyonu olduğu için ve daha iyi sonuçlar verebileceği düşünüldüğü için tercih edilmiştir. RPS algoritması ise yol tabanlı bir algoritma olduğu ve şekilsel düzenliliği ön planda tuttuğu için beyin MR görüntüleri üzerindeki performansının değerlendirilmesi için seçilmiştir.

A. Doğrusal Spektral Kümeleme Algoritması


Doğrusal spektral kümeleme (LSC) olarak adlandırılan ve düşük hesaplama maliyetleri ile hem yüksek sınır uyumu hem de görsel olarak kompaktlığa sahip süperpikselle üretebilen bir süperpiksel algoritmasıdır. İmgenin pikselleri arasında hem alan yakınlığı hem de renk benzerliği ölçen mesafe metriği kullanılarak SLIC ve normalize kesme tabanlı algoritmasına uyarlanmıştır. Normalize kesme çalışmasında olduğu gibi direkt olarak öz tabanlı algoritma kullanmak yerine piksel değerleri yüksek boyutlu öznitelik uzayına haritalandırılmıştır. Bu özellik ağırlıklandırılmasıyla, ağırlıklandırılmış k-ortalamlar (kmeans) ile normalleştirilmiş kesimlerin amaç fonksiyonları aynı optimum noktaları temsil etmektedir. Böylece önerilen öznitelik uzayında k-ortalamlar kümeleme algoritması yinelemeli olarak uygulanarak normalize kesme algoritmasının maliyet fonksiyonu optimize edilmektedir. (Şekil 1(a))

B. Düzenliliği Korunmuş Süperpiksel Algoritması

Düzenliliği korunmuş süperpiksel (RPS) algoritmasında süperpiksel yapılarının düzenli olması amaçlanmaktadır. Düzenli süperpiksel kavramı, piksellerden oluşan bölgelerin birbirleriyle uyumlu olması ve piksellerin yapı, homojenlik, mekânsal topolojisinin korunması olarak iki kriterde incelenmektedir. Algoritma üç adımdan oluşmaktadır. İlk adım bağlantı noktalarının bulunmasıdır. Giriş imgesinde noktaların bulunabilmesi için kenar genlik haritasına ihtiyaç duyulmaktadır. Çalışmada kenar genlik haritası olarak gPB haritası kullanılmaktadır. İkinci adım ise bağlantı noktalarının sınır haritasının maksimal genliğine göre optimal pozisyona göre hareket ettirilmesidir. Algoritmanın son adımı ise bağlantı noktalarının en kısa yol probleminden yararlanılarak dikey ve yatay olarak birleştirilmesidir. Oluşan süperpikselle izgara benzeri yapılarda oluşmaktadır. (Şekil 1(b))

C. Basit Doğrusal Yinelemeli Kümeleme Algoritması

Kümeleme tabanlı süperpiksel algoritmaları arasında en çok kullanılan algoritmaların başında basit doğrusal yinelemeli kümeleme algoritması (SLIC) gelmektedir. Bu algoritma hem gri seviyeli imgelere hem de renkli imgelere uygulanabilmektedir. SLIC başlangıç kümelerinin oluşturulması ve gradyan bilgisine bağlı olarak oluşturulan bu kümelerin yinelemeli güncellenmesine mantığına dayanmaktadır. Kümeleme tabanlı süperpiksel algoritmalarının ortak özelliği olan başlangıç kümeleri için merkez noktaları 3x3 komşuluğundaki noktalar arasındaki en küçük gradyan bilgisine göre belirlenmektedir. Başlangıç kümelerinin merkezleri l, a, b renk bilgileri ve x, y konum bilgilerini içeren beş boyutlu piksel vektörü ile temsil edilmektedir. Daha sonra imgeye ait tüm piksellerin hangi süperpikselle ait olduğu atanır. Bu atama işlemi temel olarak k-ortalamlar kümeleme algoritmasının mantığına dayanmaktadır. Burada her bir süperpikselle merkez noktası ile imgeye ait piksellerin arasındaki mesafeye bakılarak o pikselin en yakın olduğu süperpiksel belirlenir. Mesafe hem renk bilgilerini hem de konum bilgilerini içeren bir Öklid mesafesidir. Bir pikselin etiketine mesafe değeri en küçük olan süperpikselle etiket değeri atanır. Atama gerçekleştirildikten sonra her bir süperpiksel merkezi, süperpiksel içerisindeki piksellerin ortalaması alınarak güncellenmektedir. Bu güncelleme işlemi hata değerinin belirlenen eşik değerinize yinelenmektedir. (Şekil 1(c))



Şekil 1. Algoritmaların 300 süperpiksel gösterimi
(a)LSC, (b)RPS, (c)SLIC

III. UYGULAMA VE SONUÇLAR

A. Veri Kümesi

Beyin MR görüntülerinde süperpiksel algoritmalarının performansını değerlendirebilmek için BrainWeb veri kümesi kullanılmıştır [10]. BrainWeb veri kümesi beyin MR


görüntülerinden oluşan veri kümesi MS lezyon beyin veri kümesi ve yirmi normal anatomik modellerden oluşmaktadır. Şekil 2'de verilen 5 beyin MR görüntüsü üzerinde çalışılmıştır.



Şekil 2. Orijinal imge gösterimi

B. Performans Metrikleri

Süperpiksel algoritmalarının başarısını değerlendirebilmek için görüntüye ait kesin referans verilerine ihtiyaç duyulmaktadır. BrainWeb'de verilen beyin MR görüntülerinin veri kümesi için kesin referans bilgisi anatomik düzeyde olup 20 görüntüyle sınırlıdır. Bu veri kümesindeki kesin referans değerlerinin sınır bilgileri ve etiket bilgileri oluşturulmuştur. Böylece süperpiksel algoritmalarının başarı metriklerini değerlendirebilmek için kesin referans değerleri oluşturulmuştur. Şekil 3'te bir beyin MR görüntüsünün anatomik bölgeleri, anatomik bölgelere ait sınır bilgileri ve etiketli bölgeleri gösterilmektedir. İlk satır kafatası kısmını, ikinci satır kas doku, üçüncü satır beyaz madde, dördüncü satır boz madde ve beşinci satır ise omurilik sıvısını temsil etmektedir. Sütun bazında incelendiğinde ilk sütun anatomik bölgeyi, ikinci sütun sınır bilgilerini ve üçüncü sütun etiketli bölgeleri içermektedir.



Şekil 3. MR görüntülerinin anatomik bölümlerinin sınırları ve etiket bilgilerinin gösterimi

1) Erişilebilir Bölütleme Doğruluğu (EBD)

Bir görüntüde oluşturulan her bir süperpikselin etiketi ile kesin referansın etiketinin örtüşme alanını hesaplar. Denklem (1)'de süperpiksel $S = \{S_1, S_2, \dots, S_j\}$, kesin referans $G = \{G_1, G_2, \dots, G_i\}$ ile gösterilmektedir. N toplam piksel

sayısıdır. Erişilebilir bölütleme doğruluğunun değeri [0,1] arasındadır. Süperpiksel sayısı arttıkça erişilebilir bölütleme doğruluğu da artmaktadır.

$$EBD(S, G) = \frac{1}{N} \sum_{S_j \in S} \max_{G_i} \{|S_j \cap G_i|\} \quad (1)$$

$$S_j \cap G_i = \{x \in S_j \mid x \in G_i\}$$

2) Sınır Örtüşmesi (SÖ)

Süperpiksel sınırları ile kesin referansın oluşturduğu sınırların birbirine yakınlık derecesinin ifadesidir. En ideal durum her iki bölütleme sonucunda sınırlarının örtüşmesidir. p kesin referansın oluşturduğu bölütlerin sınır piksellerinin, q ise süperpiksellerin oluşturduğu sınır pikselleridir. $dist_{xy}$, sınırlar arasında öklit mesafesi hesaplanmaktadır ve \mathcal{E} değeri 2 olarak seçilmiştir. SÖ değeri [0,1] arasında olup 1'e yakınlığı süperpiksel algoritmasının başarısını göstermektedir.

$$SÖ_G(S) = \frac{\sum_{p \in \delta G} \phi(\min_{q \in \delta S} dist_{xy}(p, q) < \mathcal{E})}{\delta G} \quad (2)$$

3) Açıklık Değişimi (AD)

Süperpiksellerden kaynaklanan renk bozukluk seviyesini ölçmektedir. Burada, N süperpiksel sayısını göstermekte ve μ_k her bir süperpikselin piksel yoğunluğunun değerlerinin ortalamasını ifade etmektedir. μ değeri ise tüm imgenin ortalama değeridir. x_i imgedeki her bir pikselin yoğunluğunu ifade etmektedir. AD değerinin yüksek olması süperpiksellerin oluşturduğu piksel gruplarının homojenliğini göstermektedir.


$$AD = \frac{\sum_{k=1}^N (\mu_k - \mu)^2}{\sum_{i \in I} (x_i - \mu)^2} \quad (3)$$

4) Eksik Bölütleme Hatası (EBH)

Kesin referans bölgeleri ile süperpiksel bölgeleri arasında sızıntı bölgeleri ölçer yani örtüşmeyen bölgeleri hesaplar. Süperpiksel $S = \{S_1, S_2, \dots, S_j\}$, kesin referans $G = \{G_1, G_2, \dots, G_i\}$ ile gösterilmektedir. N imgedeki toplam piksel sayısıdır. Eksik Bölütleme hatası değeri [0,1] aralığındadır ve hata değerinin 0'a yakın olması istenilmektedir.

$$EBH(S, G) = \frac{1}{N} \sum_{G_i \in G} \sum_{S_j \cap G_i \neq \emptyset} \min\{|S_j \cap G_i|, |S_j - G_i|\} \quad (4)$$


Şekil 4'te LSC, RPS ve SLIC süperpiksel algoritmalarının performans metriklerinin ortalama değerleri verilmiştir. Burada 100, 300 ve 500 süperpiksel sayısı için sonuçlar elde edilmiştir.



Şekil 4. Süperpiksel algoritmalarının performans metriklerinin karşılaştırılması

Grafikler incelendiğinde sırasıyla en iyi performansı LSC, SLIC ve RPS sergilemiştir. EBD, AD ve SÖ performans metriklerinin süperpiksel sayısının artmasıyla doğru bir orantı oluşurken, performans metriği ile ters bir orantı oluşturmaktadır. RPS algoritmasının diğer algoritmalara göre kötü bir sonuç değeri oluşturmasının nedeni algoritmanın temelinde düzenliliğe dayanmasıdır. LSC algoritmasının süperpiksel sayısının artmasına bağlı olarak metrik değerlerinin iyileştiği gözlenmektedir. Ancak çok büyük bir değişiklik görülmemektedir. Bu sonuçlar ile LSC algoritmasının performansı süperpiksel sayısı daha küçük olduğunda da anatomik bölgelerin sınırlarını bulma konusunda başarılı olduğunu göstermektedir.

görüntüleri üzerinde çalışılmasının nedeni, MR görüntülerinin işlenmesi sırasında meydana gelen yüksek hesaplama karmaşıklığını indirmektedir. Literatürde yaygın bir şekilde kullanılan LSC, SLIC ve RPS algoritmaları ile çalışılmıştır. Bu algoritmaların performansı değerlendirilirken literatürdeki çalışmalarda bulunan beyaz madde, boz madde ve omurilik sıvısı olan anatomik bölgelerinin yanı sıra bu çalışmada ek olarak kafatası, kas doku, yağ doku gibi anatomik bölgelerle de karşılaştırılarak değerlendirilme yapılmıştır. Bu çalışma yapılırken bu anatomik bölgelerin ortalama değerleri ile değerlendirilmiştir. İncelenen performans metrikleri ışığında süperpiksel algoritmalarının anatomik sınırları en iyi LSC algoritması vermiştir. Bunun sebebi SLIC algoritmasına ek olarak öznelik uzayının genişletilmesiyle oluşmasıdır. RPS algoritması şekilsel düzenliliği incelediği için anatomik bölgelerin sınırlarını bulma konusunda zayıf kalmıştır.



(a) (b) (c)

Şekil 5. MR görüntülerindeki süperpiksel algoritmalarının gösterimi
(a)LSC, (b)RPS, (c)SLIC

Şekil 5'te ilk satır 100 süperpiksel, ikinci satır 500 süperpiksel sonuçlarını göstermektedir. Algoritmalar süperpiksel sayısı ile değerlendirildiğinde anatomik bölgeleri bulunmasında başarısı doğru orantılı olarak artmaktadır. Şekil 4'te verilen performans metrikleri sonucu ile Şekil 5'te verilen görsel sonuçların birbiriyle paralel olduğu gözle görülür bir sonuç sunmaktadır. Anatomik bölgelerin sınırlarını yakalayan en iyi algoritma LSC algoritmasıdır.

IV. TARTIŞMA

Bu çalışmada beyin MR görüntüleri üzerinde süperpiksel algoritmalarının performansı değerlendirilmiştir. Beyin MR

KAYNAKLAR

- [1] Li, Z., Wu, X. M., & Chang, S. F. (2012, June). Segmentation using superpixels: A bipartite graph partitioning approach. In 2012 IEEE Conference on Computer Vision and Pattern Recognition (pp. 789-796). IEEE.
- [2] Mori, G. (2005, October). Guiding model search using segmentation. In Tenth IEEE International Conference on Computer Vision (ICCV'05) Volume 1 (Vol. 2, pp. 1417-1423). IEEE.
- [3] Yang, F., Lu, H., & Yang, M. H. (2014). Robust superpixel tracking. IEEE Transactions on Image Processing, 23(4), 1639-1651.
- [4] Verma, N., Cowperthwaite, M. C., & Markey, M. K. (2013, July). Superpixels in brain MR image analysis. In 2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) (pp. 1077-1080). IEEE.
- [5] Sheng, B., Li, P., Mo, S., Li, H., Hou, X., Wu, Q., ... & Feng, D. D. (2018). Retinal vessel segmentation using minimum spanning superpixel tree detector. IEEE transactions on cybernetics, 49(7), 2707-2719.
- [6] Fuse, H., Oishi, K., Maikusa, N., Fukami, T., & Japanese Alzheimer's Disease Neuroimaging Initiative. (2018, December). Detection of Alzheimer's Disease with Shape Analysis of MRI Images. In 2018 Joint 10th International Conference on Soft Computing and Intelligent Systems (SCIS) and 19th International Symposium on Advanced Intelligent Systems (ISIS) (pp. 1031-1034). IEEE.
- [7] Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P., & Süsstrunk, S. (2012). SLIC superpixels compared to state-of-the-art superpixel methods. IEEE transactions on pattern analysis and machine intelligence, 34(11), 2274-2282.
- [8] Chen, J., Li, Z., & Huang, B. (2017). Linear spectral clustering superpixel. IEEE Transactions on Image Processing, 26(7), 3317-3330.
- [9] Fu, H., Cao, X., Tang, D., Han, Y., & Xu, D. (2014). Regularity preserved superpixels and supervoxels. IEEE Transactions on Multimedia, 16(4), 1165-1175.
- [10] Online <https://brainweb.bic.mni.mcgill.ca/>