

BEYNİN MR GÖRÜNTÜLERİNİN WATERSHED ALGORİTMASI YARDIMIYLA BÖLÜTLENMESİ

Mustafa ALÇI

Saime AKDEMİR

Erciyes Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü, 38039, Kayseri

e-posta: saimeakdemir@yahoo.com

ÖZET

Görüntü bölütlemesi (segmentasyonu) işlenmiş görüntü verisinin analizine yol gösteren en önemli basamaklardan biridir. Temel amacı görüntüyü gerçek haliyle güçlü bir korelasyona sahip parçalara bölmektir. Bu makalede görüntü işlemede geniş olarak kullanılan bölütleme hakkında bilgi verilmiş ve MATLAB ortamında beynin manyetik rezonans (MR) görüntüsü incelenmiştir. Bu inceleme Watershed Algoritması kullanılarak gerçekleştirilmiş ve bu algoritmanın patolojik dokuları belirlemede kullanılabileceği gösterilmiştir.

1. GİRİŞ

Bilgisayarlı bölütleme teknikleri son otuz yılda model tanımlama, medikal görüntüleme gibi çeşitli bilimsel alanlarda uygulanmaya başlanmıştır [1]. Medikal alandaki kullanımına örnek olarak, MR görüntülerinde ayrı nöral yapıların üç boyutlu görüntülenmesi ile çeşitli klinik uygulamaları sağlayan görüntü analizi gösterilmektedir. Bölütlemeye asıl amaç gerçek görüntüden güçlü korelasyona sahip parçalar elde etmektir. Bölütlemeyi gerçekleştirmek için domenin özel bilgilerini kullanan işlem basamaklarıyla işbirliğinin sağlanması gereklidir. Görüntüdeki veri yetersizliği temel bölütleme problemlerinden biridir. Bu çalışmanın organizasyonu şu şekildedir: 2. bölümde bölütleme metotları, 3. bölümde bölütleme teknikleri, 4. bölümde bölütleme algoritmaları verilmiştir. Son bölümde ise yapılan çalışmanın sonuçları verilmektedir.

2. BÖLÜTLEME METOTLARI

Bu bölümde verilen bölütleme metotları dört grupta incelenmektedir. Bunlar: Eşikleme (thresholding) bölütlemesi, kenar çıkarım (edge detection) bölütlemesi, bölge çıkarım (region detection) bölütlemesi ve yüzey (surface) bölütlemesidir.

2.1 Eşikleme Bölütlemesi

Gri seviye eşiklemesi en temel bölütleme işlemidir. Uygulanması pahalı olmayan bir eşiklemedir ve yaygın olarak kullanılmaktadır. Birçok obje veya görüntü bölgelerinin, yüzeylerinin yansıma veya ışık soğurma (absorbtion) sabitiyle karakterize edildiği göz önüne alınarak eşiklemenin genel ifadesi;

$$\begin{aligned} G(i,j) &= 1 & f(i,j) \geq T \text{ için} \\ G(i,j) &= 0 & f(i,j) < T \text{ için} \end{aligned} \quad (1)$$

ile verilmektedir. Burada:

T =Eşik

$G(i,j)=1$ Objenin görüntü elemanları

$G(i,j)=0$ Arka planın görüntü elemanlarıdır.

Eğer görüntüdeki objeler temassız ve gri seviyeleri açıkça arka planın gri seviyesinden farklı ise eşikleme uygun bir bölütleme metodudur. Doğru eşik seçimi başarılı bir görüntü bölütlemesi için gereklidir. Bu seçim etkileşimli veya çeşitli eşik tanımlama algoritmalarıyla yapılır. Tüm görüntü için tek bir eşik kullanımı nadiren yapılır ki buna global eşikleme denir. Basit görüntülerde bile objeler ve arka plan gri seviye çeşitlilikleri vardır. Bu çeşitlilik düzgün olmayan (non-uniform) ışığa, düzgün olmayan giriş devre parametreleri veya birtakım diğer faktörlere bağlı olabilmektedir. Bölütleme eşik değeri bölgesel görüntü karakteristiklerinin bir fonksiyonu olarak görüntü üzerinde değiştiğinde, değişken eşikler kullanılarak bu durumlara çözüm üretilir. Bu bölütleme de adaptif bölütleme olarak adlandırılır [5].

Görüntünün tamamı için tanımlanan global eşik f :

$$T = T(f) \quad (2)$$

şeklinde ve yerel eşikler;

$$T = T(f,fc) \quad (3)$$

şeklindeBurada fc tanımlanan eşikdeki görüntü parçasıdır. Bu noktadaki seçimlerden biri, f

görüntüsünü f_c alt görüntülerine bölmek ve her bir alt görüntüdeki bağımsız eşiği tanımlamaktır. Eğer bir eşik, bazı alt görüntülerde tanımlanamaz ise komşu alt görüntülerde tanımlanan eşiklerce kutuplandırılabilir. Her bir alt görüntü daha sonra bölgesel eşiğe bağlantılı olarak işlenir.

Denklem (1) de gösterildiği gibi temel eşiklemenin çok sayıda varyasyonu vardır. D kümesi kullanılarak gerçekleştirilen başka bir eşikleme ise;

$$\begin{aligned} G(i,j) &= 1 \quad f(i,j) \in D \\ G(i,j) & \end{aligned} \quad (4)$$

şeklinde tanımlanmaktadır. Bu eşikleme, örneğin mikroskobik kan hücre bölütlemesinde; arka planın parlak-hücre özünün koyu olduğu sitoplazmayı gösteren kısmi gri seviye aralığını göstermede kullanılabilir. Bu eşikleme tanımlaması bir sınır dedektörü olarak; koyu objelerin parlak bir arka planda oldukları ve bu objelerle arka plan arasındaki bazı gri seviyelerin yalnızca obje sınırında olduğu kabul edilerek kullanılabilir.

D_i 'lerin ayrı ayrı gri seviyelerinin tanımlandığı eşikleme ise;

$$\begin{aligned} G(i,j) &= 1 \quad f(i,j) \in D1 \\ &= 2 \quad f(i,j) \in D2 \\ &= 3 \quad f(i,j) \in D3 \\ & \dots \\ &= n \quad f(i,j) \in Dn \\ &= 0 \quad \text{diğerleri} \end{aligned} \quad (5)$$

şeklinde verilebilir.

2.1.1 Optimal Eşikleme

Bu metot, optimal eşikleme olarak adlandırılan farklı bir yaklaşımı gösteren normal dağılımlı iki ya da daha fazla yoğunluğun ağırlıklı toplamlarını kullanan bir görüntü histogramı yaklaşımına dayanmaktadır. Eşik minimum bölütleme hatasını veren iki ya da daha fazla normal dağılımın maksimumları arasında minimuma uygun gri seviye yaklaşıklığı olarak ayarlanır. Bu metottaki zor olan kısım kesinlik olmayan normal dağılım parametrelerinin tahminidir. Bu zorluklar optimal bir eşiğin objeler ve arka plan arasında maksimum gri seviye varyansı olarak aranmasıyla aşılabılır. Bu yaklaşım bir eşikten daha fazlasına ihtiyaç olsa bile uygulanabilir.


2.1.2 Çoklu-Spektral Eşikleme

Bir çok pratik bölütleme problemi bir spektral bandın içerdiğinden daha fazla bilgiye ihtiyaç duyar. Renk görüntüleri bilgilerin üç spektral bandla kodlandığı doğal bir örnektir ki, bu bandlar kırmızı, mavi ve yeşildir. Bir bölütleme yaklaşımı her bir spektral band

içerisinde bağımsızdır ve tek bir bölüte görüntü içerisine birleştirilir [4].

Eşikleme Uygulaması

Bu çalışmada eşikleme işlemi uygulamak için MATLAB ortamında beyin MR görüntüsü kullanılmıştır. Şekil-1(a) incelenecek olan MR dokusunu, (b) eşikleme sonucu görüntüdeki küçük yapıları, (c) eşikleme sonucu görüntüdeki büyük yapıları, (d) ise gerçekleştirilen MR görüntü bölütlemesini göstermektedir.



(a)



(b)



(c)



(d)

Şekil-1(a) Beyin MR görüntüsü, (b) Küçük yapılar, (c) Büyük yapılar, (d) Eşiklenerek bölütlenen görüntüsü.

2.2 Kenar Çıkarım Bölütlemesi

Kenar çıkarım bölütlemesi, görüntüdeki kenarlar hakkında bilgiye bağlı metotların yaygın bir kısmını simgeler. En eski bölütleme yaklaşımlarından biri olmasına rağmen geniş bir kullanım alanı bulunmaktadır. Kenar çıkarım bölütlemesi, kenar çıkarma operatörleri tarafından bir görüntüde bulunan kenarlara bağlıdır ki bu kenarlar gri seviye, renk gibi düzensizliklerin görüntü yerleşimlerini işaretler. Kenar çıkarım bölütlemesinin en büyük problemi görüntü gürültüsüdür.

2.3 Bölge Çıkarım Bölütlemesi

Bu bölütleme metotlarının amacı, bölgeler arasındaki sınırları bularak bölümleri tanımlamaktır. Sınırları bularak bölge tanımlamak kolaydır. Ancak belirtilmesi gereken nokta, kenar sezme ve bölge genişletme metotlarındaki bölütleme sonuçlarının tamamen aynı olmamasıdır. Bölge genişletme teknikleri genelde kenar sezmenin zor olduğu gürültülü görüntülerde iyi sonuç verir. Buna karşın, homojenlik bölgelerde önemli bir özelliktir ve bölge genişletmede temel bölütleme kriteri olarak kullanılmaktadır. Homojenlik kriteri gri seviye, renk, şekil gibi özelliklere bağlı olmaktadır.

2.4 Yüzey Bölütlemesi

Bu bölütleme metodu, üç boyutlu hacim bilgisi ele alınarak üç boyutlu uzayda obje sınırlarını gösteren yüzeylerin tanımlanması esasına dayanır. Bu metot yardımıyla MR, röntgen, ultrasound veya diğer tomografik sistemlerden alınan medikal görüntü verisinin bölütlenmesi gerçekleştirilir [4]. Örneğin, beynin sağ ve sol yarım kürelerinin üç boyutlu bölütlenmesinde bu teknik kullanılmakta ve korteks yüzeyi görüntülenmektedir.

3. BÖLÜTLEME TEKNİKLERİ

Bu bölümde incelenen bölütleme teknikleri bölge genişletme ve sınır algılama teknikleridir.

3.1 Bölge Genişletme Teknikleri

Temel olarak satır-sütun uzayında çalışan tekniklerdir. Bu tekniklerden bazıları yereldir. Yani görüntünün küçük bir bölgesinden tümüne doğru gider. Bazıları ise tüm görüntü üzerinde çalışır. Bir homojenlik testi tanımlanır. Görüntü eşit büyüklükte parçalara bölünür. Her bir parça için homojenlik değeri hesaplanır. Eğer bir bölge homojen ise komşu bölgelerle birleştirilmeye çalışılır, değilse bölünür. Homojenlik testi genellikle uygulamaya göre değişir. Bu test ile cisim içinde aynı, dışında ise farklı özellikler bulunmaya çalışılır.


3.2 Sınır Algılama Teknikleri

Genelde temel metotların çoğu tüm bölütleme tekniklerine uygulanabilmektedir. Çeşitli bölütleme teknikleri iki kriter kullanılarak sınıflandırılabilir: Çalışma prensibi ve etkileşim (interaktivite) seviyesi. Çalışma prensibi; sınır tanıma tekniği, bölge tanıma tekniği ve istatistiksel teknik olarak sınıflandırılabilir. Etkileşim seviyesi ise manuel, yarı otomatik ve otomatik olarak sınıflandırılabilir. Farklı teknikler bir araya getirilebilir. Bu nedenle doğru sınıflandırmayı yapmak çok zor olmaktadır. Manuel ve otomatik tekniklerin her ikisi de bir takım avantaj ve dezavantajlara sahiptirler. Otomatik metotlar gürültüye ve birtakım hatalara neden olan istenmeyen durumlara duyarlıdır. Fakat sonuçlar yüksek çözünürlüğe sahiptir. Manuel ve yarı otomatik metotlar gürültüye duyarlı değildirler, fakat operatörün sonucun doğruluğunu etkilemesi nedeniyle çözünürlükleri genellikle düşüktür. Farklı bölütleme algoritmalarının karşılaştırılması, hesaplanması gereken çeşitli parametrelerden dolayı çok zordur. Çeşitli istatistiksel yaklaşımlar farklı algoritmaların verimi, avantajı ve sınırlamaları açısından önerilmeye devam edilmektedir [3].

4. BÖLÜTLEME ALGORİTMALARI

Görüntü bölütleme algoritmaları, görüntü içerisindeki objeleri ayırt etmek için objenin kendisindeki homojenliği veya obje sınırlarındaki karşıtlığı (kontrast) araştırma düşüncelerini temel alır. Birçok görüntü bölütleme algoritması bu iki temel yaklaşımın değişik uzantısı ve birleşimidir [3].

Bu çalışmada MATLAB ortamında birbirine temas eden dokuları bölütlemeye kullanılan Watershed Algoritması beynin MR görüntülerine uygulanmıştır. Öncelikle beynin farklı kesitlerini gösteren dilimleri alınmış ve bunlar sagittal düzlemde gösterilmiştir. Şekil-2(a) yatay olarak alınmış beyin kesitlerini göstermektedir. Şekil-2(b) de bu görüntü dizininden alınan dilimlerden birinin sagittal düzlemde görüntüsü elde edilmiştir. Şekil-2(c) de ise en son olarak kesitin Watershed Algoritması uygulanarak bölütlenmiş hali elde edilmiş ve gösterilmiştir. Böylece yoğunlukları farklı olan dokular uygulanan algoritma ile sınırları belirlenerek bölütlenmiştir. Dokular birbirlerinden farklı renkli gösterimlerle ayrılmıştır. Bundan sonra, görüntüde tümör gibi patolojik bir olgunun varlığı durumunda algoritma incelenmiştir. Bu durumu incelemek için alınan kesit için de aynı işlemler tekrarlanmış, görüntüde açığa çıkmayan yapıları görüntülemek için görüntü terslendirilmiş ve en son olarak görüntünün Watershed Algoritması ile bölütlenmiş hali elde edilmiştir. Şekil-3(a) da patolojik bir dokuyu içeren MR kesiti görülmektedir. Şekil-3(b) de görüntünün tersi alınmış ve Şekil-3(c) de ise Watershed Algoritması yardımıyla MR görüntüsündeki patolojik dokunun başarıyla bölütlendiği belirlenmiştir.



(a)




(b)



(c)

Şekil-2 (a) Beynin yatay MR kesitleri,
(b) Sagittal düzlemde MR kesiti,
(c) Watershed Algoritması uygulanmış kesit



(a)



(b)



(c)

Şekil-3 Beynin; (a) MR görüntüsü, (b) kestirilen görüntüsünün tersi, (c) Watershed Algoritması sonucu

5. SONUÇ

Bu çalışmada bölütleme hakkında bilgi verilmiş, bölütleme teknikleri ve algoritmaları açıklanmıştır. Algoritmalar içerisinde birbirine temas eden dokuları ayrılmasında daha etkili olan Watershed Algoritması MATLAB ortamında kullanılmıştır. Yapılan çalışmaların ilkinde eşikleme kullanılarak beynin MR görüntüsü bölütlenmiştir. Daha sonra ise Watershed Algoritmasının beynin MR görüntülerindeki sonucu irdelenmiştir. Kesit kesit görüntüleme yapan MR Tekniğinde, kullanılan algoritma ile bölütlenmesi sonucu patolojik dokunun belirlenmesinin mümkün olduğu gösterilmiştir.

KAYNAKLAR

- [1] Heikonen T., Dastidar P., Frey H., Eskola H. Applications of MR Image Segmentation, INTERNATIONAL JOURNAL OF BIOELECTROMAGNETISM, Vol. , Number 1, 1999.
- [2] Alonge F., Ardizzone E., Pirrone R., Neural Classification of Multiple Sclerosis Lesions in MR Images
- [3] Heionen, T., Dastidar, P., Laarne, P., Segmentation of T1 MR scans for Reconstruction of Head Models. COMPUTER METHODS and PROGRAMS in BIOMEDICINE 54, p .173-181
- [4] Jhonston B., Atkins S., Mackiewich B., Segmentation of multiple sclerosis lesions in intensity corrected multispectral MRI, IEEE TRANSACTIONS ON MEDICAL IMAGING,15(2):154-169,1996
- [5] Wilson, J.A. Noble Adaptive Segmentation of MRI Data D.L.