

Çoklu Beyin Yapılarının Bağlaşık, Parametrik Olmayan Şekil Önbilgisi Kullanılarak Bölütlenmesi

Segmentation of Multiple Brain Structures Using Coupled Nonparametric Shape Priors

M. Gökhan Uzunbaş, Müjdat Çetin, Gözde Ünal ve Aytül Erçil

Mühendislik ve Doğa Bilimleri Fakültesi, Sabancı Üniversitesi, İstanbul, Türkiye

uzunbas@su.sabanciuniv.edu, mcetin@sabanciuniv.edu, gozdeunal@sabanciuniv.edu, aytulercil@sabanciuniv.edu

Özetçe

Bu çalışmada beyne ait tıbbi görüntülerde bulunan birden fazla yapının bölütlenmesi problemini ele alıyoruz. Tıbbi görüntülerde düşük kontrast ve gürültü gibi olumsuz etkilerin varlığında, problemin sadece verilere dayalı çözümü zordur. Bu nedenle anatomik yapıların şekilleri ve şekillerin birbirleriyle etkileşimleriyle ilgili önsel bilgileri de hesaba katan bir yaklaşım öneriyoruz. Bölütleme problemi için istatistiksel bir çerçeve kuruyor ve yapıların birbirleriyle bağlaşık şekil bilgisini önsel olasılık yoğunluk işlevleri ile bu çerçeveye katıyoruz. Bu olasılık yoğunluk işlevlerini eğitim şekillerinden, parametrik olmayan bir yaklaşım ile kestiriyoruz. İmgeden alınan veriler ile şekil bilgisini birleştiren etkin çevritlere dayalı bir bölütleme algoritması geliştiriyoruz. Önerdiğimiz yöntemin, gerçek manyetik rezonans görüntüleri üzerindeki zorlu bölütleme problemlerinde mevcut yöntemlere göre üstünlüklerini gösteriyoruz.

Abstract

We consider the problem of segmenting multiple brain structures in medical images. Due to the low contrast of medical images and the presence of noise, solution of this problem based only on image data, is rather challenging. Motivated by this observation, we propose an approach that incorporates prior information about the shapes of the anatomical structures, as well as about the interaction of neighboring shapes. We construct a statistical framework for the segmentation problem, which captures information about the shapes of coupled anatomical structures through prior probability density functions. We nonparametrically estimate these probability density functions from training shapes. We develop an active contour-based segmentation algorithm that combines image-based data with shape information. We demonstrate the benefits of our approach over existing methods through challenging segmentation scenarios on real magnetic resonance images.

1. Giriş

Gelişen tıbbi görüntü bölütleme teknikleri, görüntülenen dokuların daha doğru ve kesin olarak bölütlenebilmesiyle pek çok hastalığın tedavisini daha kolay ve başarılı kılmıştır. Örneğin; beyindeki korteks altı yapılarda biriken birtakım

kimyasalların analizi ile bazı hastalıkların önceden teşhis ve tedavi edilebileceği düşünülmektedir. Kimyasalların miktarının ya da şekilsel olarak yarattığı bozuklukların analizini bölütleme teknikleri ile güvenli bir şekilde yapmak bizi bu çalışmada teşvik eden unsur olmuştur. Ancak bu yapıların manyetik rezonans (MR) görüntüleri yeterli kontrast ve belirgin şekil kenarı bilgisi içermemektedir. Bu nedenle bu yapıların bölütlenmesi kolay değildir. Buna karşın bu tür durumlarda bölütleme işleminin başarımını arttırmak için şekil önbilgisi kullanımı son zamanlarda çok yaygınlaşmıştır.

Şekil önbilgisini biçim değiştirir modellerle beraber kullanarak bölütleme yapmak, son yıllarda çok yaygınlaşmıştır. En temel şekil önbilgisi olarak eğri uzunluğu kısıtlaması kullanılmıştır. Eğri uzunluğu kısıtlamasındaki temel düşünce; kısa eğrilerin doğru şekle daha yakın olacaktır [1]; ancak bu önbilgi manyetik görüntülerde elde edilen düşük kontrastlı, ayırt etmesi zor yapıların bölütlenebilmesi için yeterli değildir. Birçok uygulamada daha geçerli ve daha üst düzeyli şekil önbilgisi elde edilebilir. Bu tip önbilgilerin bölütleme yöntemleri tarafından etkin biçimde kullanılabilmesi için son yıllarda çaba sarf edilmeye başlanmıştır. Örneğin; [2] ve [3] çalışmalarında temel bileşen analizi yöntemiyle belirli bir veri tabanı kullanarak, bu veritabanındaki şekillerin işaretli uzaklık fonksiyonlarından şekillerin değişkenliği modellenmiştir. Ancak bu yöntemler daha çok şekilsel değişkenliğin az bulunduğu problemlerde uygulanabilmektedir. Ayrıca bu teknikler sadece tekil modeller ve Gauss'a benzer şekilsel yoğunluğun olduğu durumlarda geçerlidir. Özellikle çok kipli şekil yoğunluğu olan problemlerde işlerliğini yitirmektedir. Bu tür problemlerde de çalışacak ve temel bileşen analizi tekniğinin kısıtlamalarını giderecek bir başka yöntem, şekil veri tabanında parametrik olmayan yöntemlerle şekil yoğunluğu hesaplamak ve bu parametrik olmayan şekil önbilgisini kullanmaktır [4], [5].

Parametrik olmayan şekil önbilgisi doğrusal olmayan şekil değişkenliğini yakalamada yeterli görülse de bazı zorlayıcı tıbbi görüntüleme uygulamalarında daha fazla önbilgiye ihtiyaç duyulmaktadır. Pek çok durumda bölütlenmesi istenen yapılar bir ya da daha fazla yapıya komşu durumdadır. Bu ilişkinin, konum ve şekil olarak, yerel geometri açısından yardım sağlayacağı ve yanlış bölütleme sonuçlarını azaltacağı düşünülmektedir. Buradan hareketle, şekil veri tabanlarındaki istatistiksel çoklu şekil bilgisi kullanılarak bağlaşık şekil düzenleri modellenilebilir. Örneğin [6] çalışmasında, farklı şekil sınıfları üzerindeki ikili (karşılıklı) şekilsel değişkenlik, parametrik birleşik şekil önbilgisi ile modellenilemiştir. Benzer bir yaklaşımla, [7] çalışmasında, birden fazla nesnenin birleşik şekil önbilgisi, Bayesçi bir

Bu çalışma Avrupa Topluluğu'nun FP6-2004-ACC-SSA-2 (SPICE), MIRG-CT-2006-041919 ve MTKI-CT-2006-042717 sayılı projeleri ve TÜBİTAK BİDEB yüksek lisans bursu tarafından desteklenmektedir.

çerçevede, aynı imge üzerinde bulunan birden fazla nesnenin bölütlenebilmesi için, kontrastı yüksek, bölütlemesi kolay nesnelere, düşük kontrastlı nesnelere bölütlenmesine yardımcı olacak şekilde modellenmiştir. Bir başka şekilsel bağımlılık modeli, [8] çalışmasında öne sürülmüştür. Bu çalışmada ilişkili yapılar arasındaki uzaklıklar şekil öz niteliği olarak ifade edilmiş ve bu öz niteliğin toplamsal dağılım fonksiyonu önbilgi olarak kullanılmıştır. Nesnelere arasındaki göreceli uzaklıklar kullanılarak etkileşimli bölütleme yapılmıştır.

Bu çalışmada nesnelere arasındaki şekil etkileşimlerini ve bağımlılıklarını kullanmak üzere; parametrik olmayan, bağlaşıklık şekil önbilgisini bölütleme işlemine katan yeni bir yöntem öneriyoruz. Bu yöntemde çoklu şekillerin bilinmeyen şekil dağılımını kestirmek için çoklu değişkenli yoğunluk kestirimi kullanılmıştır. Elde edilen bağlaşıklık şekil önbilgisi ile aynı görüntü üzerinde birden fazla nesne aynı anda bölütlenmiştir. Yeni önbilgi ile nesnelere kendi hallerinde görünen bağlaşıklık kısıtlaması elde edilmiştir. Bu yöntemle zorlu MR görüntü senaryolarında başarılı bölütleme sonuçları elde edilmiştir. Ayrıca var olan çoklu nesne şekil önbilgisine dayalı yöntemlere [6] [7] nazaran, bu yöntem ile parametrik olmayan yoğunluk kestiriminin avantajı kullanılmıştır.

2. Bağlaşıklık Şekil Önbilgisi Tabanlı Bölütleme

Çerçevemizin dayandığı etkin çevrit modeller ile bölütleme işlemi yinelemeli bir algoritma içerir. Bu algoritma bir enerji fonksiyonunu eniyilemek için kullanılır. Bu çalışmada enerji (maliyet) fonksiyonu en büyük sonsal kestirimi (MAP) çerçevesinde aşağıdaki gibi ifade edilmiştir.


$$E(\mathbb{C}) = -\log p(\text{data}|\mathbb{C}) - \log p_{\mathbb{C}}(\mathbb{C}) \quad (1)$$

Bu denklemde \mathbb{C} , değişim gösteren ve m tane nesnenin kenarlarına tutunan eğriler $\mathbb{C} = \{C^1, C^2, \dots, C^m\}$ kümesidir. İlk terim, $\log p(\text{data}|\mathbb{C})$ olabilirlik terimidir ve imgenin kendisinden elde edilebilecek veriye bağlıdır. İkinci terim $\log p_{\mathbb{C}}(\mathbb{C})$ ise birleşik şekil önbilgisidir. Bu çalışmada olabilirlik terimi [9] çalışmasında belirtilen şekilde seçilmiştir. Bu terim birçok çalışmada [3], [5], [6], [7] kullanılan ve bilinen bir terimdir. Bu bildiride sadece bağlaşıklık şekil önbilgisini içeren ikinci terim $\log p_{\mathbb{C}}(\mathbb{C})$ üzerine yoğunlaşmıştır. Bildirimizin teknik katkısı bu terimin farklı yapılar arasındaki etkileşimi modelleyecek şekilde oluşturulmasıdır.

2.1 Birden Fazla Nesnenin Bağlaşıklık Önsel Modeli

Buradaki temel fikir; m tane farklı sınıftan nesnenin bağlaşıklık, parametrik olmayan, şekil önbilgisini $p_{\mathbb{C}}(\mathbb{C})$ oluşturmaktır. N tane eğitim örneğinin olduğunu farz edelim $\{C_1, C_2, \dots, C_N\}$.

Her örnek $C_i = \{C_i^1, C_i^2, \dots, C_i^m\}$ $i = 1, 2, \dots, N$ her biri ayrı nesneye ait m tane şekil örneğinden oluşmaktadır. Eğitim kümesindeki imgelerde duruş farkı bulunmaktadır ve bu farktan doğan değişkenlik hizalama operasyonu ile ortadan kaldırılmaktadır. Hizalama işlemi [3] çalışmasında olduğu gibi yapılmakta ve dört adet benzerlik dönüşüm parametresinin (2 yönde öteleme, ölçekleme ve dönme) hesaplanması ile gerçekleştirilmektedir. Her nesnenin örnek şekilleri kendi aralarında hizalanmaktadır. Böylece hizalanmış örnek kümesi $\tilde{C}_i = \{\tilde{C}_i^1, \tilde{C}_i^2, \dots, \tilde{C}_i^m\}$ $i = 1, 2, \dots, N$ elde edilmektedir. Hizalama işleminden sonra, duruş farkından kaynaklanan değişkenlik ortadan kalkmıştır. Böylece şekiller



Şekil 1- Farklı sekanslarda MR görüntülerden çıkarılmış ve hizalanmış (a) caudate ve (b) putamene ait ikili imgeler.

arasında fark yaratan etken olarak sadece şekilsel değişkenlik kalmıştır. Şekil 1'de 12 farklı MR kesitinden çıkarılmış ve hizalanmış ikili şekiller görülmektedir. Birden fazla nesnenin birleşik önbilgi modelini oluşturmak için, şekillerin gösterimi düzey kümesi yöntemi ile yapılmıştır [10]. Düzey kümesi gösterimleri üzerinden çok değişkenli Parzen yoğunluk kestirimi yöntemi (bkz. [11]) ile nesnelere bilinmeyen birleşik şekil dağılımı kestirilmektedir. "m" tane nesne için genelleştirilebilirliği kaybetmeden, gösterimi basitleştirmek için 2 farklı nesneye ait, birleşik şekil yoğunluk kestirimi aşağıda denklem 2'de gösterilen şekilde yapılmaktadır.

$$p_{\tilde{C}^1, \tilde{C}^2}(\tilde{C}^1, \tilde{C}^2) = \frac{1}{N} \sum_{i=1}^N \prod_{k=1}^{m=2} k(d(\Phi_{\tilde{C}^k}, \Phi_{\tilde{C}_i^k}), \sigma_k) \quad (2)$$

Bu denklemde $k(d(\Phi_{\tilde{C}^k}, \Phi_{\tilde{C}_i^k}), \sigma_k)$, σ_k standart sapmaya sahip Gauss dağılımlı şekilli çekirdektir. $\Phi_{\tilde{C}^k}$, bölütleme işleminde kullanılan eğriye ait işaretli uzaklık fonksiyonudur ve $\Phi_{\tilde{C}_i^k}$ k. nesnenin i. eğitim şekline ait işaretli uzaklık fonksiyonudur. Denklem 2'de görüldüğü üzere, tanımlanan uzaklık metriğine göre birleşik yoğunluk kestirimi için kullanılan çekirdek fonksiyonu, her nesne için, ayrık çekirdeklerin $k(\cdot, \sigma_k)$ çarpımıyla elde edilmektedir. Bu yoğunluk fonksiyonu birçok uzaklık metriği ile kullanılabilir. Bu çalışmada işaretli uzaklık fonksiyonları arasındaki farkı ölçmek için şablon ve Euclid (d_{L_2}) metrikleri kullanılmıştır.

Her k. nesne için çekirdek boyutları σ_k , birini dışarıda bırakmalı en büyük olabilirlik yöntemiyle hesaplanmıştır [12]. Var olan, bağımsız şekil önbilgisi kullanan metotlara nazaran, bu yaklaşımla şekiller arasındaki bağlaşıklıklara dayalı şekil önbilgisi daha kesin ve doğru şekilde elde edilebilmektedir. Bu önemli nokta beyindeki bazı yapıların doğasında bulunan görüngenü ile de örtüşmekte ve bu yapıların bölütlenmesinde birtakım iyileştirmeler sağlayabilmektedir.

2.2. Bağlaşıklık Şekil Önbilgisi için Bayır Akışı

Bu kısımda denklem 2'de gösterilen bağlaşıklık (birleşik) şekil önbilgisinin bayır akışı ifadesinin türetilmesi ve yineleme sürecinde her nesne için en büyük yönde değişiminin hesaplanması anlatılmaktadır.

Denk. 2'de gösterilen ifadenin, logaritması türevlendirilirken kısa gösterim olarak $k(d(\Phi_{\tilde{C}^k}, \Phi_{\tilde{C}_i^k}), \sigma_k)$ için k_{σ_k} kullanılmıştır. Ayrıca $\Phi_{\tilde{C}^k}$ zamanın fonksiyonudur ve $\Phi_{\tilde{C}^k}(t)$ için kısa gösterimdir. Bunlar kullanılarak

$$\frac{d}{dt} \log p_{\tilde{C}^1, \tilde{C}^2}(\tilde{C}^1, \tilde{C}^2) = \frac{\sum_{i=1}^N k'_{\sigma_1} k'_{\sigma_2} + k_{\sigma_1} k'_{\sigma_2}}{N \log p_{\tilde{C}^1, \tilde{C}^2}(\tilde{C}^1, \tilde{C}^2)} \quad (3)$$

elde edilmiştir. Daha sonra her 2 nesnenin hareket halindeki bölütleyici eğrisi için en büyük yöndeki değişimi, Euclid

uzaklık metriği kullanılarak aşağıda denklem 4'teki gibi elde edilmiştir.

$$\frac{\partial \Phi_{\tilde{C}^k}}{\partial t} = \frac{1}{\sigma^2} \sum_{i=1}^N \lambda_i(\tilde{C}^1, \tilde{C}^2) (\Phi_{\tilde{C}^k}(x) - \Phi_{\tilde{C}^k}(x)) \quad (4)$$

$$\text{Burada } \lambda_i(\tilde{C}^1, \tilde{C}^2) = \frac{k_{\sigma_1} k_{\sigma_2}}{N p_{\tilde{C}^1, \tilde{C}^2}(\tilde{C}^1, \tilde{C}^2)} \text{ ve}$$

$\sum_{i=1}^N \lambda_i(\tilde{C}^1, \tilde{C}^2) = 1$ şeklindedir. Son denklemde gösterilen

ifade ile her iki nesneye ait eğriler, bağlaşıklık şekil önbilgisinin yerel en büyüğünü elde edecek yönde hareket edecektir. Buradaki önemli nokta; hareket halindeki eğrinin eğitim şekillerinden hangisine daha yakın ise o eğitim şeklinin daha büyük değerle ağırlıklandırılması ve eğrinin eğitim kümesindeki o şeklin haline daha çok benzemek istemesidir.

Bir başka nokta da ağırlıklandırıcı işlev λ_i 'nin her $(\tilde{C}^1, \tilde{C}^2)$ eğrisine aynı şekilde bağımlı olmasıdır. Buna göre $(\tilde{C}^1, \tilde{C}^2)$ gibi bir eğri çifti verildiğinde, bölütleme süresince eğer \tilde{C}^1 eğrisi kendi eğitim kümesinden birisine yakın olursa, yakın olan eğitim şekli daha büyük ağırlıklandırılır. Diğer, \tilde{C}^2 eğrisi de nesnelere arasındaki doğal bağlaşıklıktan ötürü, kendi eğitim kümesinde birinci eğrinin yakın örneğine karşılık gelen eğitim şeklini daha büyük bir kat sayı ile ağırlıklandırır.

2.3. Yinelemeli Bölütleme Algoritması

Herhangi bir test imgesi verildiğinde imge üzerinde bölütlemek istediğimiz nesne, eğitim kümesinde bulunan örneklerle aynı durumda olma zorunda değildir. Duruş farklarından dolayı hareket halinde olan eğrilerin yoğunluk kestirimi $p_C(\mathbb{C})$ ile eğitim kümesindeki aynı hizaya getirilmiş şekillerin yoğunluk kestirimi $p_{\tilde{C}}(\tilde{\mathbb{C}})$ ilişkilendirilir. Bunu yapmak için şekiller arasında bir dönüşüm matrisi tanımlanır.


$$\tilde{\mathbb{C}} = T[p]\mathbb{C} \quad (5)$$

Buna göre yineleme süresince yukarıda tanımlanan dönüşüm içerisinde m tane nesneye ait eğri için ayrı ayrı benzerlik (iki yönde öteleme, ölçekleme ve dönme) parametreleri $P = p^1, p^2, \dots, p^m$ hesaplanır ve güncellenir. Bu bildiriye yer kısımdan ötürü okuyucuyu duruş güncelleme algoritması için [5] çalışmasına sevk ediyoruz. Son olarak, bölütleme algoritmasının temel adımları aşağıda özetlenmiştir:

1. $t = t_0$ Anına kadar şekil önbilgisi kullanmadan $\mathbb{C} = \{C^1, C^2, \dots, C^m\}$ ler hareket ettirilir.
2. $t = t_0$ Anında her nesnenin hareket eden eğrisi için $P = p^1, p^2, \dots, p^m$ hesaplanır.
3. ($t_0 < \text{yineleme} < \text{son yineleme}$) iken
 - a. $P = p^1, p^2, \dots, p^m$ ler sabitlenir
 - i. $\tilde{\mathbb{C}} = T[p]\mathbb{C}$ hesaplanır
 - ii. $\frac{\partial \Phi_{\tilde{C}^k}}{\partial t}$ hesaplanır.
 - iii. $\mathbb{C} = T^{-1}[p]\tilde{\mathbb{C}}$ ilişkilendirilir
 - b. Her nesnenin hareket eden eğrisi güncellenir.
 - c. Eğriler sabitken $P = p^1, p^2, \dots, p^m$ ler güncellenir.

3. Deneysel Sonuçlar

Bu kısımda beyindeki korteks altı yapılardan kaudat ve putamen için bölütleme sonuçları gösterilmiştir. Öncelikle şekil 1'de gösterilen ikili imgeler üzerine gürültü ekleyerek oluşturulan 2 boyutlu sentetik imgeler üzerinde deneyler yapılmıştır. Bu ikili imgeler gerçek MR görüntülerden manuel olarak çıkarılmıştır. Bu görüntülerle yapılan testlerde, eğitim veri kümesinde dört farklı hastadan alınan on bir kesit kullanılmıştır ve test imgesi eğitim kümesinden bağımsızdır. Sentetik imgelerde düşük kontrastlı putamen ve yüksek kontrastlı caudate kullanılmıştır. Bu senaryoda amaç; birleşik şekil bilgisinin şekiller arasındaki bağlaşıklığa olan etkisine yoğunlaşmaktır. Bu testte putamen üzerinde yeni yöntemle yapılan bölütlemenin başarımı, [5]'de anlatılan, bağımsız şekil önbilgisine bağlı yöntemle yapılabileceğine göre kıyaslanmıştır. Şekil 2'de her iki yöntemle yapılan bölütleme sonucu bir test örneği için gösterilmiştir. Buna göre, bizim önerdiğimiz yöntem bağımsız şekil önbilgisi içeren yöntemle göre daha başarılı olmuştur.



(a) (b) (c)

Şekil 2- Sentetik imgelerde kaudat (mavi eğri) ve putamen (kırmızı eğri) için bölütleme sürecinde (a) önbilgi kullanmadan, (b) bağımsız önbilgi ve (c) bağlaşıklık önbilgi kullanarak elde edilen sonuçlar.

Önerilen yöntemle elde edilen sonuçlar farklı hata ölçüm metodları kullanılarak nicel olarak da gösterilmiştir. Örneğin;

$$FPR = \frac{FP}{FP + TN}$$

$$FNR = \frac{FN}{FN + TP}$$


$$\text{Dice katsayısı: } DC = \frac{2TP}{FP + FN + 2TP} \text{ (bkz. [13]).}$$

Bu denklemlerde kullanılan FP terimi: nesne içinde olarak karar verilen, aslında nesne dışındaki piksellerin sayısını; FN terimi: nesne dışında olarak karar verilen, aslında nesne içinde olan piksellerin sayısını belirtmektedir. TN terimi ise, nesne dışında olarak gösterilen ve nesne dışında olan piksellerin sayısını; TP terimi de nesne içinde olarak karar verilen ve nesne içinde olan piksellerin sayısını temsil etmektedir. Tablo 1'de yapılan 12 deney için elde edilen sonuçların ortalama değerleri gösterilmiştir. Buna göre yöntemimiz FPR, FNR ve (1-DC) ölçümlerine göre daha başarılı olmuştur.

Ortalama $\pm \sigma$	Putamen		
	FPR %	FNR %	(1-DC) %
Bağımsız Önbilgi ile	0.76 \pm 2	13.5 \pm 5.3	16.8 \pm 5.9
Önerilen Önbilgi ile	0.70 \pm 2	13.1 \pm 5.0	13.8 \pm 4.2

Tablo 1. Putamen organı için sentetik imgelerde ortalama başarımlar değerleri.

Daha sonraki deneylerde proton yoğunluğu sekansında MR görüntüleri üzerinde çalışılmıştır. Kaudat ve putamen yapıları



Şekil 3. Kaudat ve putamen için, ön bilgi kullanılmadan (en üst sıra), bağımsız ön bilgi kullanarak (orta sıra) ve önerdiğimiz bağlaşıklık ön bilgi kullanarak (en alt sıra) yapılan bölütlemenin sonuçları.

İçin 11 çift şekilden oluşan eğitim veri kümesi kullanılmıştır. Şekil 3'te en üst satırda şekil ön bilgisi kullanılmadan yapılan bölütleme sürecinde ilk orta ve son adımlar gösterilmiştir. Düşük kontrast nedeniyle başarılı sonuçlar elde edilememiştir. Şekil 3'te orta satırda, her yapı için bağımsız şekil ön bilgisi kullanılarak yapılan bölütleme sonucu [5] gösterilmiştir. Elde edilen sonuçlara göre putamen yapısındaki sızıntılar ve sağ kaudatın sınırlarının yerine tam oturmaması nedeniyle başarımlarımız yetersizdir. En alt satırda ise bizim önerdiğimiz bağlaşıklık şekil ön bilgisi kullanılarak yapılan bölütleme sonuçları gösterilmiştir. Elde edilen sonuçlara göre, putamen ve kaudat arasındaki şekilsel bağlaşıklık, bölütleme başarımlarımızı olumlu biçimde etkilemiştir. Tablo 2'de de gösterildiği üzere, yöntemimiz putamen için çok daha az FPR ve kaudat için çok daha az FNR sağlayarak daha başarılı olmuştur. (1-DC) ölçümüne göre her iki yapı için de yöntemimiz daha iyi performans göstermiştir.

% , % , %	Putamen			Kaudat		
	FPR	FNR	1-DC	FPR	FNR	1-DC
Ön bilgisiz	1.10	5	12	4.2	8	22
Bağımsız	1.08	4	13	0.29	20	17
Önerilen	0.88	4	8	0.35	14	13

Tablo 2. Gerçek MR veri kümesinde ön bilgisiz, bağımsız ön bilgili ve önerilen bağlaşıklık ön bilgi kullanarak elde edilen başarımlar sonuçları.

4. Vargılar

Bu bildiriye birden fazla nesnenin birlikte bölütlenmesi sürecinde, nesnelerin şekil etkileşimleri ile ilgili önsel bilgileri, bölütleme işlemine katabilen bir yöntem öne sürülmüştür. Çok değişkenli Parzen yoğunluk kestirme yöntemiyle, birden fazla nesnenin bilinmeyen şekil ön bilgisi belirlenebilmiştir. Aynı sahne üzerinde, bölütlenmesi kolay, yüksek kontrastlı nesnelere ile bölütlenmesi zor, düşük kontrastlı nesnelere arasında olası bağlaşıklıklar yakalanarak, birden fazla nesnenin aynı anda bölütlenmesi sağlanmıştır.

5. Teşekkür

Yazarlar, parametrik olmayan şekil ön bilgisi elde etme konusunda kod paylaşımı için Junmo Kim'e; faydalı tartışmaları ve gerçek MR görüntüsü sağlama konusunda yardımlarından ötürü Dr. Kutlay Karaman'a teşekkürlerini sunarlar.

6. Kaynakça

- [1] Mumford D. ve Shah J., "Boundary detection by minimizing functionals," IEEE Conference Computer Vision Pattern Recognition, 1985.
- [2] M. Leventon, E. Grimson, ve O. Faugeras, "Statistical shape influence in geodesic active contours," IEEE Conference Computer Vision Pattern Recognition, 2000, s. 316-323.
- [3] A. Yezzi, A. Tsai, W. Wells, C. Tempany, D. Tucker, A. Fan, W.E. Grimson, ve A. Willsky, "A shape-based approach to the segmentation of medical imagery using level sets," IEEE Transactions Medical Imaging, vol. 22, s. 137-154, 2003.
- [4] D. Cremers, S.J. Osher, and S. Soatto, "Kernel density estimation ve intrinsic alignment for shape priors in level set segmentation," Internat. J. Comp. Vision, cilt. 69, no. 3, s. 335-351, 2006.
- [5] J. Kim, M. Cetin, ve A.S. Willsky, "Nonparametric shape priors for active contour-based image segmentation," Signal Processing, cilt. 87, s. 3021 - 3044, 2007.
- [6] A. Tsai, W. Wells, C. Tempany, W.E. Grimson, ve A. Willsky, "Mutual information in coupled multi-shape model for medical image segmentation," Medical Image Analysis, cilt. 8, s. 429-445, 2004.
- [7] J. Yang ve J. Duncan, "Joint prior models of neighboring objects for 3-d image segmentation," IEEE Conference Computer Vision Pattern Recognition, Washington, DC, 2004.
- [8] A. Litvin ve W.C. Karl, "Coupled shape distribution-based segmentation of multiple objects," Information Processing in Medical Imaging, 2005, s. 345-356.
- [9] T. Chan ve L. Vese, "Active contours without edges," IEEE Transactions Image Processing, cilt. 2, s. 266-277, 2001.
- [10] S. Osher ve R. Fedkiw, "Level set methods and dynamic implicit surfaces," Springer, Berlin, 2003.
- [11] D. Erdogmus, R. Jenssen, Y.N. Rao, ve J.C. Principe, "Gaussianization: An efficient multivariate density estimation technique for statistical signal processing," Journal of VLSI Signal Processing, cilt. 45, s. 67-83, 2006.
- [12] B.W. Silverman, "Density estimation for statistics and data analysis," Chapman Hall, Londra, 1986.
- [13] L. Dice, "Measures of the amount of ecologic association between species," Ecology, cilt. 26, s. 297-302, 1945.