

YEREL İKİLİ ÖRÜNTÜ (LBP) VE ÖNSEL ŞEKİL BİLGİSİ TABANLI BİR DESEN BÖLÜTLEME METODU

A LOCAL BINARY PATTERNS AND SHAPE PRIORS BASED TEXTURE SEGMENTATION METHOD

Erkin Tekeli, Müjdat Çetin, Aytül Erçil

Mühendislik ve Doğa Bilimleri Fakültesi

Sabancı Üniversitesi, İstanbul

erkintekeli@su.sabanciuniv.edu,

mcetin@sabanciuniv.edu,

aytulercil@sabanciuniv.edu

Özetçe

Bu çalışmada, yerel ikili örüntü (LBP) ve aktif konturlar kullanarak şekil ve veriye dayalı desen bölütleme metodu sunuyoruz. Desen yapılı imgeleri desen yapısından arındırmak için yeni LBP tabanlı yeni bir filtreden geçiriyoruz. "Filtrelenmiş" ortamda, orijinal imgedeki her desen yapılı bölge özgün bir yeşinlik dağılımı gösteriyor. Bu ortamda bölütleme problemini Bayes çatısı altında bir eniyileme problemi olarak ele alıyoruz. Kullandığımız maliyet fonksiyonu veri terimi ve bölütlenecek nesnelerin şekil bilgilerini beraberinde getiren bir önsel şekil terimi içermektedir. Optimizasyon problemini düzey kümeleri tabanlı aktif konturlar kullanarak çözüyoruz. Sentetik ve gerçek desenli zorlu imgelerdeki test sonuçlarımız çalışmamızın etkinliğini ve bunun yanı sıra kapatılma ve kayıp veri problemlerindeki gürbüzlüğü ortaya koymaktadır.

Abstract

We propose a shape and data driven texture segmentation method using local binary patterns (LBP) and active contours. In particular, we pass textured images through a new LBP-based filter, which produces non-textured images. In this "filtered" domain each textured region of the original image exhibits a characteristic intensity distribution. In this domain we pose the segmentation problem as an optimization problem in a Bayesian framework. The cost functional contains a data-driven term, as well as a term that brings in information about the shapes of the objects to be segmented. We solve the optimization problem using level set-based active contours. Our experimental results on synthetic and real textures demonstrate the effectiveness of our approach in segmenting challenging textures as well as its robustness to missing data and occlusions.¹

1. Giriş

İmge işlemede temel bir adım olan imge bölütleme, bir imgedeki tektürel bölgelerin yalıtılması veya bölgeler arasındaki sınırların bulunması olarak tanımlanabilir. İmge bölütleme farklı perspektiflerden yaklaşmış bir problem

olmasına rağmen hala zorluğunu korumaktadır. Bu perspektiflerden biri, bizim de çalışmamızda kullandığımız, aktif kontur yaklaşımıdır [1, 2, 5, 6, 7, 8]. Çeşitli imge bölütleme problemlerinde piksel değerlerinin, rengin, piksel değerlerinin istatistiksel dağılımlarının ortalaması veya değişirliğinin ve kenar bilgisinin ayırt edici rol oynayamadığı durumlar vardır. Bu tür senaryolarda desen, bölütleme problemini çözmede iyi bir öznitelik olabilir. İmge işlemede desenin önemli rol oynadığı birçok uygulama alanı vardır. Bunlardan bazıları biyomedikal imge analizi, endüstriyel denetim, uydu imgelerinin analizi, imge veritabanlarından içerik tabanlı geri kazanım, doküman analizi, biyometrik kimlik doğrulama, bilgisayar grafikleri ve animasyonu için desen sentezi ve imge kodlamadır. İmge bölütleme problemlerinde deseni etkin biçimde hesaba katma gereği bölütleme probleminin çözümünü daha uğraştırıcı hale getirir.

Son yıllarda şekil bilgisini bölütleme problemlerinde kullanmaya ilgi artmaktadır. Şekil bilgisi prensipte bölütleme işlemini daha etkin kılsa da pratikte beraberinde getirdiği çeşitli zorluklar vardır.

Bu çalışmamızda amacımız, mevcut başarılı aktif kontur ve şekile dayalı bölütleme metotlarını birleştirerek, desen bölütleme problemlerinde kullanmaktır. Bu çalışmada ilk katkımız olarak desen bölütleme problemini; yeşinlik değerlerine dayalı imge bölütleme problemine indirgeyen LBP tabanlı bir desen filtresi geliştirdik. Desen filtremiz filtrelenmiş imgede mevcut imge bölütleme tekniklerini kullanabilme olanağını sağlamaktadır. İkinci katkımız ise parametrik olmayan yoğunluk kestirimi tabanlı önsel şekil bilgisini desen bölütleme problemlerinde kullanmaktır.

LBP, merkez ve komşu piksel değerleri arasında sıralı ikili karşılaştırmalara dayalı, ayrımsama gücü yüksek bir desen analizi tekniğidir [4]. Desen yapılı imgeleri desen yapısından arındırmak amacıyla LBP kullanarak bir desen filtresi tasarladık. Desen yapılı imgeleri filtremizden geçirerek yapısal olarak birbirinden bağımsız piksel değerlerine sahip ve piksel yeşinlik dağılımları açısından birbirinden ayırt edilebilen bölgelerden oluşan filtrelenmiş yeni bir imge oluşturuyoruz. Daha sonra filtrelenmiş imgede enerji denkleminiz için piksel değerleri ve bölge etiketleri arasındaki karşılıklı bilgi miktarını en büyüyen eden bir veri terimi oluşturuyoruz. Ayrıca şekil uzayında Parzen yoğunluk kestirimi ile bir şekil dağılımı kestirimi yaparak parametrik olmayan önsel şekil bilgisini oluşturuyoruz. Daha sonra veri ve

¹Bu çalışma Avrupa Komisyonu'nun FP6-2004-ACC-SSA-2 ve MIRG-CT-2006-041919 sayılı projeleri kapsamında desteklenmiştir




Figure 1- LBP değerinin hesaplanmasının grafiksel ifadesi. Eşikleme işleminden sonra sol üst köşedeki ikili sayı ilk basamak kabul edilerek saat yönü sırasıyla 8-bitlik LBP kodu oluşturuluyor. Daha sonra bu kodun onlu sistemdeki değerini hesaplayarak merkez pikselimizin LBP değerini buluyoruz.




Figure 2- a) Desenli yapılu uçak resmi b) Filtreleme sonucu

şekil terimlerimizi Bayes çatısı altında birleştiriyoruz. Enerji fonksiyonunu aktif çevritler kullanarak en küçükleyip bölütleme sonucuna ulaşıyoruz. Yöntemimizin sentetik ve gerçek desenli imgelerdeki etkin ve gürbüz sonuçlarını deneysel sonuçları kısmında sunuyoruz.

2. Yerel İkili Örüntü Kullanarak Şekil ve Veriye Dayalı Desen Bölütleme

2.1. LBP'ye Dayalı Desen Filtreleme

LBP yerel uzamsal yapıyı betimlemede kullanılan parametrik olmayan bir operatördür. LBP ayırısama gücü yüksek desen analizi tekniği olarak ilk [4]'te önerildi. LBP bir merkez pikselin komşu piksel değerleri ile arasındaki sıralı ikili karşılaştırmalardan oluşur. LBP operatörü bir imgedeki her pikseli, kendisini çevreleyen 3x3'lük komşuluk bölgesindeki komşu piksellerini merkez piksel değerine göre eşikleyerek etiketler. Eğer komşu pikselin değeri merkez pikselden büyükse veya eşitse komşu piksel 1, küçükse 0 değerini alır. Böylece bir komşuluk bölgesi için 8-bitlik bir LBP kodu oluşturulmuş olur. Bu kodun onluk sistemdeki değeri ise merkez pikseli çevreleyen 3x3'lük bölgedeki yerel yapıyı ifade eder (şekil 1). LBP'nin matematiksel ifadesi aşağıdaki gibidir:

$$LBP(x) = \sum_{i=1}^8 s(G(x_i) - G(x)) 2^{i-1} \quad (1)$$

$$s(t) = \begin{cases} 1, & t \geq 0 \\ 0, & t < 0 \end{cases} \quad (2)$$

burada x merkez pikselin konumu, x_i i indislisi komşu pikselin konumunu ve $G(.)$ piksel yeğlilik değerini ifade etmektedir. Bu yordamı uygulayarak piksel yeğlilik değerleri 0 ile 255 değerleri arasında değişen LBP imgemizi oluşturuyoruz. Her LBP değeri farklı bir örüntüyü ifade etmektedir. LBP imgemizin histogramı ise bir desenin içinde 256 farklı örüntünün her birine ne kadar sıklıkla rastlandığını

göstermektedir. LBP'nin farklı gösterimleri de vardır. Örneğin; 2 piksel uzaklık komşuluklu 8-bit ikili gösterim, 2 piksel uzaklık komşuluklu 16-bit ikili gösterim ve 3 piksel uzaklık komşuluklu 24-bit ikili gösterimi gibi. Şekil 1, 1 piksel uzaklık komşuluklu 8-bit ikili gösterimi ifade etmektedir. 2 piksel uzaklık komşuluklu 8-bit ikili gösteriminde 2 piksel uzaklıktaki gri seviye değerleri tam olarak bir piksel konumunun merkezine düşmezse yeğlilik değeri aradeğerleme kullanılarak kestirilir.

İdeal durumlarda desen filtrelerinden beklenen, piksel yeğlilik değerleri açısından bağımsız özdeşçe dağılıma sahip tektürel bölgeler oluşturmalarıdır. Fakat uygulamada desen filtreleri tamamen bu duruma uygun sonuçlara ulaşamazlar. Yine de amaç desen filtresi kullanarak, desen bölütleme problemini piksel yeğlilik değeri tabanlı imge bölütleme probleminde indirgemektir. Bu amaçla desen yapıları desensel yapıdan arındırıp yeğlilik değerleri dağılımları ile birbirinden ayrılabilen bölgelere sahip imgeler oluşturabilmek için bir LBP tabanlı desen filtresi öneriyoruz. Filtremizi bölütlemek istediğimiz bölgeden bir yama olarak eğitiyoruz. Eğitim evremiz aslında bölütlemek istediğimiz bölgeden bir şablon olarak bölgenin desensel yapısı hakkında bilgi edinmekten ibarettir. Eğitim imgemizden LBP uzayında yeni bir imge oluşturmak için 1. ve 2. denklemleri kullanarak x konumu her piksel ve yeğlilik değeri için bir LBP değeri oluşturuyoruz. Daha sonra LBP uzayındaki imgenin histogramını hesaplıyoruz.

Ayrık rastgele değişken olan LBP değerleri 8-bitlik ikili kodların onluk sistemdeki karşılığı olduğu için LBP histogramını sürekli rasgele değişkenlerden oluşmuş bir histogram olarak düşünemeyiz. LBP histogramları sele numaraları ile bir desenin özgün yapısını ifade ederler. Örneğin imge uzayında bir imgenin histogramını oluşturduğumuzda 116. seleye en yakın sele değerleri 115 ve 117'dir. Fakat LBP uzayında 116, (01110100)₂ ikili sayısının onluk sistemdeki karşılığı olduğu için yapısal açıdan 116'ya en yakın sele değerleri ikili sistemdeki karşılığından 1 bit farklılık gösteren sayılardır (Ör: 117, 118, 124, 244). Daha sonra test imgemizi (örneğin şekil 2(a)) filtremizden geçiriyoruz. İlk olarak LBP uzayındaki görüntüsünü oluşturuyoruz. Daha sonra her piksel için kendisi merkez piksel olacak şekilde 17x17'lik pencereler oluşturuyoruz. Her pencerenin histogramını eğitim imgemizin histogramı ile L_1 uzaklık metriği kullanarak karşılaştırıyoruz. İki histogram arasındaki L_1 uzaklık metriğinin matematiksel ifadesi aşağıdaki gibidir:

$$\|H_{\text{eğitim}} - H_{\text{test}}\|_1 = \sum_{i=1}^n |H_{\text{eğitim}}[i] - H_{\text{test}}[i]| \quad (3)$$

$H_{\text{eğitim}}$ ve H_{test} eğitim ve test imgelerinin histogramlarını ifade etmektedir. n ise histogramların sele sayılarını ifade etmektedir. Daha sonra her pencerenin $L_1(H_{\text{eğitim}}, H_{\text{test}})$ uzaklık değerlerini piksel yeğlilik değeri olarak merkez piksellere atıyoruz.

$$G(x) = \|H_{\text{eğitim}} - H_{\text{test}}\|_1 \quad (4)$$

Bu işlemi LBP uzayındaki test imgemizin her pikseli için uygulayarak filtrelenmiş imgemizi elde ediyoruz. Eğer pencerenin içindeki desen eğitim imgemizdeki desene benziyorsa o pencerenin merkez pikseli filtrelenmiş imgede düşük yeşinlik değerine sahip oluyor. Eğer eğitim imgesinden farklı bir desen ise yüksek yeşinlik değerine sahip oluyor. Şekil 2(a)'daki desen yapılı imge için L_1 uzaklık değerlerinden oluşmuş filtreleme sonucu şekil 2(b)'de görebilirsiniz.

LBP uzayındaki her piksel değeri, kendi etrafındaki yapısal özellikleri ifade ettiği için, bu uzayda pencereler kullanarak karşılaştırma yapmamız bize pencereler içindeki her pikselin yapısal özelliklerini hesaba katma olanağı vermektedir. Bundan dolayı piksel değerlerine atadığımız L_1 uzaklık değeri desen yapımız hakkında hesaba kattığımız güçlü bilginin sonucudur. Bu durum desen filtremizi gürbüz bir filtre yapmaktadır. Bununla birlikte pencereleme işlemi filtreleme sırasında bölgelerin sınırlarında yumuşatmaya neden olmaktadır. Pencereleme sırasında bir pencere iki farklı bölge tarafından paylaşıldığında sınırlarda yumuşatma meydana gelmektedir. Yumuşatma desensel yapıdan arınmak için iyi bir etkidir ancak sınırlarda sınırlarda yumuşatma etkisine neden olmaktadır. Yine de pencereleme işleminin filtremize kattığı gürbüzlük yumuşatma etkisinden çok daha önemli bir unsurdur. Ayrıca yumuşatma etkisinin birçok yaklaşım ile minimize edilmesi mümkündür. Örneğin sınırlarda daha küçük pencere ölçüleri kullanılabilir. Pencereleme ölçüleri sınırlardaki pencerelerin içindeki tektürelliğe göre küçültülebilir. Pencereleme içindeki entropi bir tektürelilik kriteri olarak alınabilir.

2.2. Enerji Fonksiyonu

Çalışmamızda filtrelenmiş imge uzayında bölütleme problemini bir en iyileme problemi olarak ele alıyoruz. Veri terimimizi ve önsel şekil bilgisi terimimizi Bayes çatısı altında birleştiren bir enerji denklemi (4) kullanıyoruz.

$$E(C) = -\log p(\text{data} | C) - \log p_C(C) \quad (4)$$

Denklemimizdeki veri ve önsel şekil bilgisi terimlerinin seçimini sıradaki alt bölümlerde anlatıyoruz.

2.2.1. Veri Terimi

Filtreleme işlemi ile desen bölütleme problemini yeşinlik değerlerine dayalı imge bölütleme problemine indirgedik. Filtrelenmiş imgede karşılıklı bilgi miktarına dayalı bir veri terimi oluşturuyoruz [2]. Bununla birlikte kullandığımız veri terimi haricinde başka veri terimleri kullanmamız da mümkün. Desen filtremiz; özellikle birörnek desenli imgelerde; piksel yeşinlik dağılımları açısından kolayca birbirinden ayrılabilen bölgelerden oluşmuş başarılı filtreleme sonuçları verdiği için ortalama ve değişinti gibi daha basit öznitelikler kullanan mevcut imge bölütleme yöntemleri kullanmamız da mümkün [1]. Fakat birörnek olmayan zorlu desenlerde kullanılan desen filtresi temiz filtreleme sonucu vermesi mümkün olmayabilir. Filtreniz gürbütlü filtreleme sonucu verdiği zaman diğer veri terimlerini kullanmak tatmin edici bölütleme sonuçları vermez. Çalışmamızda birçok veri terimi denedik ve tatmin edici bölütleme sonuçlarına ulaştık ancak çözümü genelleştirmek için farklı tipteki yeşinlik dağılımlarında kullanılabilen parametrik olmayan karşılıklı bilgi miktarına

dayalı veri terimini kullandık [2]. Bunun ışığında bölütleme problemini piksel yeşinlik değerleri ile bölge etiketleri arasındaki karşılıklı bilgi miktarının en üst düzeye çıkarılması olarak ele aldık. Kullandığımız veri terimi aşağıdaki gibidir:

$$-|\Omega| \hat{I}(G(X); L_C(X)) \quad (5)$$

$\hat{I}(\cdot)$ yeşinlik değerleri ($G(x)$) ve ikili etiketler ($L_C(X)$) arası kestirilmiş karşılıklı bilgi miktarını ifade etmektedir. $|\Omega|$ imge alanını ve X ise piksel indisini ifade etmektedir.

2.2.2. Önsel Şekil Bilgisi Terimi

Kayıp veri, örtme veya düşük kalite promlerine haiz imgelerdeki bölütleme problemlerinde önsel şekil bilgisi bölütlemeyi iyileştirebilir. Şekil terimi için [3]'teki parametrik olmayan önsel şekil bilgisi yaklaşımı kullandık. Rasgele seçilmiş bir şekil için olabilirliğin değerlendirilebileceği, şekil uzayında Parzen yoğunluk kestirimi kullanarak bir parametrik olmayan önsel şekil dağılımı oluşturuyoruz. Yoğunluk kestirimimiz aşağıdaki gibidir:

$$\hat{p}_C(\tilde{C}) = \frac{1}{n} \sum_{i=1}^n k(d_C(\tilde{C}, \tilde{C}_i), \sigma) \quad (6)$$

Denklem (6) eğriler uzayında bir Parzen yoğunluk kestirimidir. n eğitim şekillerinin sayısını, \tilde{C} hizalanmış aday eğriyi, \tilde{C}_i ise eğri uzayında hizalanmış eğitim eğrilerini ifade etmektedir. σ Gauss çekirdek ölçüsü, d_C ise eğri uzayında uzaklık metriğini ifade etmektedir. İki tip uzaklık metriği kullandık. Bunlar şablon metrik ve imzalı uzaklık fonksiyonları arası L_2 uzaklığıdır. Şablon metrik şekillerin içi 1 dışı 0 değerlerini almış iki I_1 ve I_2 ikili eşlemi arası L_1 uzaklığı olarak tanımlanabilir:

$$d_T(\tilde{C}, \tilde{C}_i) = \int_{\Omega} \|I_1(x) - I_2(x)\| dx \quad (7)$$

L_2 uzaklığı ise iki imzalanmış uzaklık fonksiyonu arasındaki uzaklık normudur. Desen bölütlemeyi düzey kümeleri kullanarak, denklem (4)'deki enerji denklemimizi bayır inişi metoduyla çözmek suretiyle yapıyoruz. Her döngü adımı sırasında hareket eden eğri eğitim eğrilerinde olduğu gibi hizalanmaktadır.

3. Deneysel Sonuçlar

Denyelerimizde farklı şekiller için doğal ve sentetik desenli imgeler kullandık. Kullandığımız sentetik desenleri Brodatz veritabanından seçtik ve deneylerimizde el ve uçak şekilleri kullandık. Test imgelerimizi piksel yeşinlik değerleri dağılımı açısından ayrılması zor desenlerden seçerek oluşturduk. Şekil uzayımız için 11 farklı uçak ve 6 farklı el şekli kullandık. Şekil uzayımızı oluştururken duruş farklılıklarından doğacak farklılıkları elemek için eğitim şekillerimizi [6]'daki hizalama metoduna göre hizaladık.

3.1 Birörnek Desenlerde Bölütleme Sonuçları:

Şekil 4(a)'da kazak ve paspas desenlerinden alınarak oluşturulmuş iki desenli bölgemiz var. Bu desenler arasındaki kontrast farkı düşük ve birinci dereceden olasılık yoğunluk fonksiyonları benzer bölgelerdir. Bundan dolayı

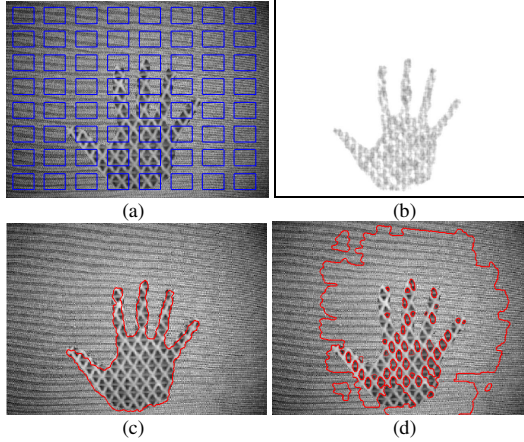


Figure 4- (a) Test imgesi ve eğrinin ilk pozisyonu (b) Filtreleme sonucumuz (c) Bölütleme sonucumuz (d) [2]'deki teknik ile desen filtresi kullanmadan bölütleme sonucu

diğer öznelikleri kullanarak bu bölgeleri birbirinden ayırt etmek zordur. El şekli kullandığımız desenli test imgemizde elde ettiğimiz tatmin edici bölütleme sonucunu şekil 4(d)'de görebilirsiniz.

3.2 Birörnek Olmayan Desenlerde Bölütleme Sonuçları:


Birörnek olmayan desenlerde yapısal olarak analizi zor olan test imgeleri kullandık. Birörnek olmayan desenlerdeki zorluk, diğer desen yapılarına benzer özellikler gösteren birçok deseni ihtiva etmeleridir. Bu sebepten desen analiz metodlarının birörnek olmayan desenleri tanımlama ve diğer desenlerden net olarak ayırt etme konusunda sorunlar gözlenebilir. Bizim desen filtremiz birörnek olmayan desenlerde gürültülü sonuçlar vermesine rağmen karşılıklı bilgi miktarına dayalı veri terimi ve önsel şekil bilgisi terimimiz yardımıyla tatmin edici bölütleme sonuçlarına ulaşıyoruz (Şekil 5).

3.3 Kapatılmış Şekillerde Bölütleme Sonuçları:


Şekil 6(a)'daki desenli imgede uçak şeklinin uç kısmını kapattık. Şekil 6(b)'deki bölütleme sonucunda eğrimiz, uçak nesnesinin kapatılmış kısımlarını eğitim şekillerinden oluşmuş şekil uzayımızdan gelen önsel şekil bilgisinden ve filtrelenmiş imgeden gelen veri bilgisinden yararlanarak kestirim yapmaktadır. Algoritmamızın imgedeki nesnenin kapatılmış kısmına dair önsel bir bilgisi yoktur.

4. Sonuç

Bu çalışmada, yerel ikili örüntü (LBP) ve aktif konturlar kullanarak şekil ve veriye dayalı bir desen bölütleme metodu sunduk. Desen yapıları imgeleri desen yapısından arındırmak için yeni LBP tabanlı yeni bir filtreden geçirdik. "Filtrelenmiş" ortamda, bölütleme problemini Bayes çatısı altında bir eniyileme problemi olarak ele aldık. Maliyet fonksiyonu olarak karşılıklı bilgi miktarına dayalı veri terimi ve bölütlenecek nesnelerin şekil bilgilerini beraberinde getiren bir önsel şekil teriminden oluşan bir maliyet fonksiyonu kullandık. Optimizasyon problemini düzey kümeleri tabanlı aktif konturlar kullanarak çözdük. Sentetik ve gerçek desenli zorlu imgelerdeki test sonuçlarımızla



Şekil 5-(a) Birörnek olmayan desenlerden oluşturulmuş test imgesi (b) Filtreleme sonucumuz (c) Bölütleme sonucumuz (d) [2]'deki teknik ile desen filtresi kullanmadan bölütleme sonucu



Şekil 6- a) Kapatılmış desen yapıları nesne b) Bölütleme sonucumuz

çalışmamızın etkinliğini ve bunun yanı sıra kapatılma ve kayıp veri problemlerindeki gürbüzlüğü gösterdik.

5. Kaynakça

- [1] T. Chan and L. Vese, "Active contours without edges," *IEEE Trans. on ImageProcessing*, 10(2):266–277, February 2001.
- [2] J. Kim, J.W. Fisher, A.Yezzi, Jr., M.Çetin, and A.S. Willsky, "A nonparametric statistical method for image segmentation using information theory and curve evolution." *IEEE Trans. on ImageProcessing*, vol. 14, no. 10, pp. 1486–1502, October 2005.
- [3] J.Kim, M.Çetin, and A.S. Willsky, "Nonparametric shape priors for active contour based image segmentation." *EURASIP European Signal Processing Conference (EUSIPCO)*, September 2005
- [4] T. Ojala, M. Pietikäinen & T. Mäenpää, "Gray scale and rotation invariant texture classification with local binary patterns." *Computer Vision, ECCV Proceedings, Lecture Notes in Computer Science 1842*, Springer, 404–420, 2000
- [5] N.Paragios and R.Deriche, "Geodesic active regions and level set methods for supervised texture segmentation." *Int. J. Computer Vision*, 2002.
- [6] A.Tsai, A.Yezzi, Jr., W.Wells, C.Tempany, D.Tucker, A.Fan, W. E. Grimson, and A.Willsky, "A shape-based approach to the segmentation of medical imagery using level sets." *IEEE Trans. on Medical Imaging*, 22(2):137–154, February 2003.
- [7] G.B. Unal, H. Krim, A. Yezzi, "Information-Theoretic Active Polygons for Unsupervised Texture Segmentation" *International Journal of Computer Vision*, Volume 62, Issue 3 Pages: 199 - 220, ISSN:0920-5691, May 2005
- [8] J.Xie Y.Jiang H.Tsui, "Segmentation of kidney from ultrasound images based on texture and shape priors." *IEEE Transactions on Medical Imaging*, pages: 45- 57 ISSN: 0278-0062, 2005