

# Kalp Duvarlarının Adaboost ve Düzey Kümesi ile Bulunması

## Locating Cardiac Walls with Adaboost and Level Sets

Ayşe Betül Oktay ve Yusuf Sinan Akgül

GYTE Bilgisayarla Görme Laboratuvarı, <http://vision.gyte.edu.tr/>

Bilgisayar Mühendisliği

Gebze Yüksek Teknoloji Enstitüsü

Gebze, Kocaeli

{oktay,akgul}@bilmuh.gyte.edu.tr

### Özetçe

*Ekokardiyogramlardan endokardiyum ve epikardiyumun önsel bilgi kullanmadan geleneksel bölütleme yöntemleriyle bulunması zordur. Bu çalışmada, yerel ve küresel önsel bilgiyi Adaboost ve düzey kümesi metodu ile ekleyerek kalp duvarlarını bulma metodu sunulmaktadır. Küresel önsel bilgi, sisteme belirli aralıklarla uzman çevritleri etkisi altındaki düzey kümesinin yeniden başlatılması ile dahil edilmektedir. İmge ve zaman bilgisi içeren ve 2 ve 3 boyutlu Haar filtrelerle çıkartılan yerel önsel bilgi Adaboost ile öğrenilmektedir. Sistem ekokardiyogramlar üzerinde test edilmiş ve sonuçlar başarılı bulunmuştur.*

### Abstract

*Locating the endocardium and epicardium in the echocardiograms is very hard with conventional segmentation methods in the lack of prior information. This paper presents a cardiac wall locating technique by introducing local and global priors through Adaboost and level sets. The global prior is incorporated into the system by regularly re-initializing the level set surface under the influence of the expert detected contours. The local priors with image and temporal information, extracted with 2D and 3D Haar filters, are learned through Adaboost. The system is validated on the echocardiograms and the results are found promising.*

### 1. Giriş

Ekokardiyografi cerrahi işlem gerektirmeyen, ucuz ve taşınabilir bir medikal uygulama olup kalp atışı analizinde ve hastalıkların belirlenmesinde kullanılmaktadır. İç ve dış kalp duvarlarının (endokardiyum ve epikardiyum) ekokardiyogramlar kullanılarak bölütlenmesi kalp fonksiyonları ve kalp duvarının boyutu ve kalınlığı, kalp karıncık ve kulakçıklarının hacmi ve ejeksiyon fraksiyonu (kan pompalama kapasitesi) gibi önemli bilgiler vermektedir. Klinik uygulamalarda kalp duvarları uzmanlar tarafından manuel olarak belirlenmektedir. Manuel belirleme işlemi uzmana bağlıdır ve uzmanların bölütlemeleri arasında bile büyük değişimler olmaktadır (Şekil 1). Ayrıca bu işlem çok zaman almaktadır ve verimli değildir. Bu yüzden kalp duvarının otomatik bölütlenmesi, kalp ölçümlerinin daha doğru yapılması ve hızlandırılması açısından önemlidir.

Yılanlar ve düzey kümesi gibi klasik bölütleme teknikleri kalp duvarı bulunmasında başarılı olamamaktadır. Bu yüzden, regülarizasyon stratejilerine düzgünlük, devamlılık, şekil gibi önsel bilgilerin eklenmesi ile [1,2,3] bölütleme işlemi daha başarılı bir şekilde yapılabilmektedir. Fakat geometrik özellikler, zaman, uzaklık gibi imgeye bağlı olan ve olmayan farklı bilgilerin beraber aynı anda bölütleme işlemine dahil edilmesi zordur.


Bu çalışmada, yerel ve küresel önseller kullanarak Adaboost ve düzey kümesi metodu ile iç ve dış kalp duvarını bölütleyen yeni bir yaklaşım sunulmaktadır. Yerel özellikler Haar filtrelerle çıkartıldıktan sonra Adaboost ile öğrenilmekte ve Adaboost algoritmasının çıktısı düzey kümesi metodunda kullanılmaktadır [4]. Küresel önseller, bölütleme işlemine geometrik bilgi katan klasik şekil önsellerini içermektedir. Bu çalışmadaki küresel önsel ekleme tekniği, düzey kümesi optimizasyonundaki gelişen yüzeyin sıfırıncı düzeyi ve uzman çevritlerinin birbirleri ile etkileşimi fikrine dayanmaktadır [5]. Yerel önseller, hareket bilgisini ve çevritleri sadece yerel olarak ifade eden zorunlulukları bölütleme işlemine eklemektedir. Mesela geometrik şekil, referans noktasına uzaklık gibi yerel olarak ifade edilen çevrit özellikleri yerel önsel kapsamına girmektedir.

Farklı özellikler çıkartıldıktan sonra, öğrenme ve test için Adaboost algoritması [6] kullanılmıştır. Literatürde Adaboost karmaşık yapılarda şekil, doku vs. öğrenmek için sıkça kullanılmaktadır. Mesela fetal yapının bulunması [7], damarların kenarlarının bulunması [8] ve MR görüntülerden kalp duvarlarının bulunup izlenmesinde [9] başarılı bir şekilde kullanılmıştır.

Önerilen yöntem, gerçek ekokardiyogramlar üzerinde test edilmiştir. Kalp merkezinden uzaklık kullanılan yerel özelliklerden bir tanesidir. Diğer yerel özellikler, çeşitli 2 ve 3 boyutlu Haar filtrelerle kutupsal düzleme çevrilmiş ekokardiyogramlardan çıkartılmıştır. 3 boyutlu filtreler, komşu görüntülerdeki hareket bilgisini, 2 boyutlu filtreler de imge bilgisini çıkartmaktadır.

Geliştirilen sistemin birçok avantajı vardır. İlk olarak, kalp duvarlarındaki hareket bilgisi 3 boyutlu Haar tipi filtreler ile bölütleme işlemine dahil edilmiştir ve ayrı bir 3 boyutlu model oluşturmaya gerek kalmamıştır. Bu ekokardiyografide önemli bir avantajdır, çünkü kalp duvarının belli bölümleri sadece hareket bilgisiyle görülebilir ve kalp duvarları için 3 boyutlu hareket modeli tanımlamak zordur. İkinci olarak, kalp duvarı açısı ve ultrason dalgası arasındaki ilişki Adaboost ile

çözümlemiş ve ayrı bir hesaplama yapmaya gerek bırakmamıştır. Üçüncü olarak, yerel önsel bilgi için görüntülerden elde edilen başka özellikler de kullanılabilir ve görüntü ile alakası olmayan yerel özellikler de (duvardaki komşu noktaların ilişkisi gibi) kolaylıkla sisteme entegre edilebilir. Son olarak, epikardiyum ve endokardiyumun ayrı ayrı öğrenilmesi düzey kümesi metoduyla rahat bir şekilde herhangi bir karışıklık olmadan kullanılabilir.



Şekil 1: İlk imge bir ekokardiyogramı, diğer imgeler ise bu ekokardiyogramın 4 farklı uzman tarafından manuel işaretlenmiş iç ve dış kalp duvarlarını göstermektedir.

## 2. Yerel Önseller ve Adaboost

Bölütlenen objenin farklı bölümleri farklı karakteristiğe sahip ise, bölütleme işlemine yerel önseller dahil etmek gerekmektedir. Geliştirilen sistemde kullanılan yerel önseller, yerel olarak ifade edilebilen kalp duvarı özelliklerini belirtmektedir.

Yerel özellikleri daha iyi tanımlayabilmek ve görüntülerdeki yön bilgisi farkını gidermek için, ekokardiyogramlar ilk olarak kalp merkezi kutupsal merkez olacak şekilde kutupsal koordinat sistemine çevrilmektedir. Böylelikle ekokardiyogramlar arasındaki öteleme farkı en aza indirilmekte ve yer bilgisi de yerel özellik olarak kullanılabilir.

Ekokardiyogramlar çok gürültülü olduğundan ve yan taraflarda duvarlar belirgin olmadığından dolayı, uzmanlar kalp duvarlarını çizmek için kalp döngüsündeki görüntüleri film şeklinde izlemekte ve komşu görüntüler kalp duvarlarını çizmede yardımcı olmaktadır. Literatürde kalp hareketini modelleyen teknikler [10] olmasına rağmen, bu çalışmada 2 ve 3 boyutlu Haar filtreler kullanılarak, sistemi çok karmaşık hale getirmeden hareket bilgisi de eklenmiştir.

Sistemde kullanılan bazı Haar filtreler Şekil 2'de gösterilmiştir. 2 boyutlu filtreler sistol ve diastoldeki imge bilgisini çıkartırken, 3 boyutlu filtreler hem görüntü hem de hareket bilgisini çıkartmaktadır. Sistol ve diastol esnasında kalp en küçük ve büyük halini aldığından dolayı, komşu görüntülerdeki kalp duvarı hareket etmektedir; fakat kaç piksel hareket ettiği bilinmemektedir. Bu hareketi öğrenebilmek için, 3 boyutlu komşu filtrelerin 1'den  $n$ 'ye kadar piksel aşağı/yukarı kaydırılmış hali de farklı bir şekilde kullanılmıştır. Filtreler, komşu görüntüler için 1'den  $n$ 'ye kadar farklı büyüklüklerde sistol için aşağı, diastol için ise

yukarı kaydırılırlar. Bu filtrelerin doğrudan değerlerini kullanmak yerine, en büyük değeri veren filtrenin sonucu kullanılmıştır. Bu işlem sisteme doğrusal olmayan bir şekilde veri girişi sağlamış ve hareket bilgisinin daha iyi öğrenilmesine neden olmuştur.

Filtreler, çeşitli boyutlarda ve Şekil 2'deki görüntülerinin gri düzeyde tersi alınmış şekilde de uygulanmıştır. Filtreler, görüntü özelliklerini iyi bir şekilde tanımlarlar ve integral imgeler [11] kullanılarak kolay ve hızlıca hesaplanırlar.

Ayrıca kutupsal sistemdeki her bir açı aralığı, kalp iç ve dış duvarı ve kalp fazı (sistol ya da diastol) için ayrı ayrı çıkarılan özellikler Adaboost ile yine ayrı öğrenilmektedir. Geliştirilen sistemde herbiri 10 derece olan, 36 tane açı aralığı kullanılmıştır.

### 2.1. Adaboost ile Öğrenme ve Değerlendirme

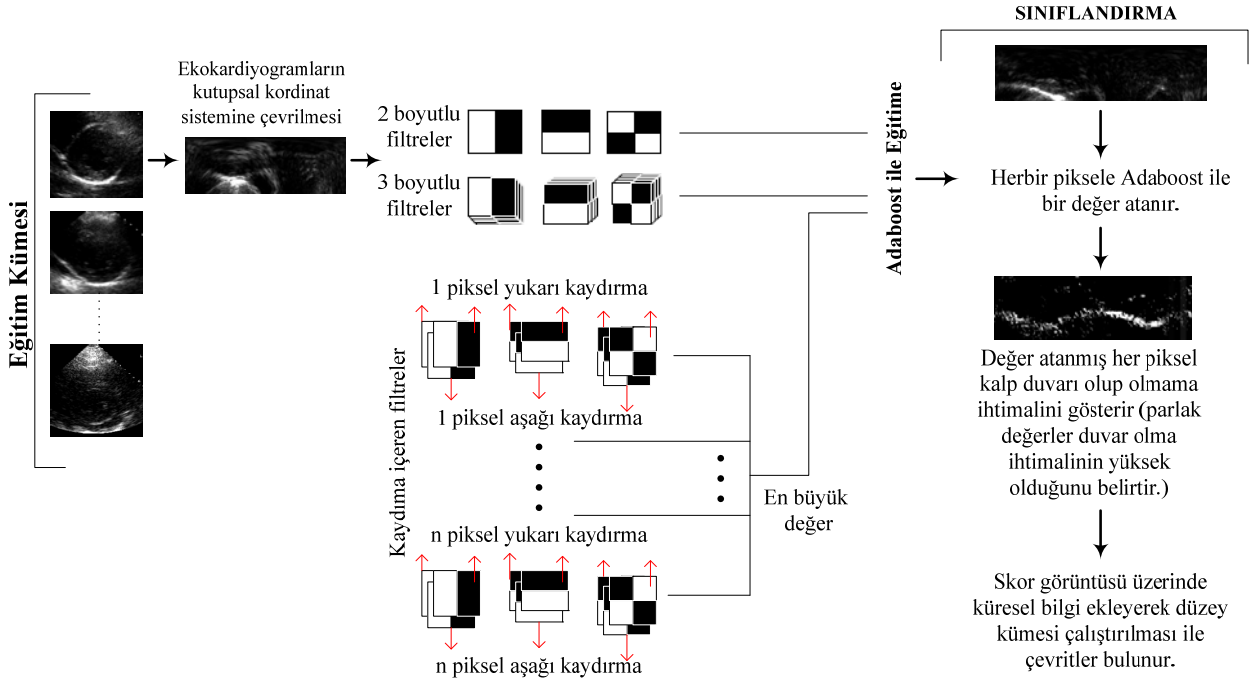
Bu çalışmada, Adaboost ile ekokardiyogramlardan çıkarılan yerel özellikler öğrenilmiş ve değerlendirilmiştir. Adaboost, zayıf sınıflayıcıları  $h_t$  belirleyip, onları birleştirerek güçlü bir sınıflayıcı  $H(x)$  oluşturma fikrine dayanmaktadır. Klasik Adaboost algoritmasındaki gibi her bir piksel için kalp duvarı ya da değil ( $H(x) > 0$  ise 1; değilse -1) gibi bir sınıflandırma yapmak yerine, doğrudan  $H(x)$  değerleri kullanılmıştır.

Ekokardiyogramlardaki örnekler,  $c_i = \{1, -1\}$  kalp duvarı ya da değil sınıflarını göstermek üzere  $\{x_i, c_i\}$  olsun. Adaboost zayıf sınıflayıcıları  $h_t$  kullanır ve sınıflandırmanın doğruluğu ile ters orantılı olarak  $\alpha$  ağırlıklarını sınıflayıcılara atar. Daha sonra bu zayıf sınıflayıcılardan ( $T$  tane) aşağıdaki şekilde güçlü sınıflayıcıyı oluşturur:

$$H(x) = \sum_{t=1}^T \alpha_t h_t(x), \quad (1)$$

Öğrenme işlemi için, kutupsal koordinatlara dönüştürülmüş her ekokardiyografik görüntü, 10 derecelik 36 tane açı aralığına bölünmüştür. Bir önceki bölümde anlatılan şekilde özellikler Haar filtrelerle çıkarılmış ve  $H(x)$  sınıflayıcısı Adaboost ile öğrenilmiştir. Bir açı aralığındaki öğrenme için, sadece o aralıktaki pikseller kullanılmıştır. Daha önceden çizilmiş olan uzman çevritleri pozitif örnek, diğer piksellerin %10'u ise negatif örnek olarak sisteme dahil edilmiştir.

Çalışma zamanında ekokardiyogramlar kutupsal koordinatlara çevrilir ve filtrelerle özellikler çıkartılır. Her bir pikselin skor değeri elde edilir. Yüksek değerler kalp duvarı olma ihtimalinin daha fazla olduğunu gösterir. Her bir piksele Denklem 1 ile bir skor değeri verilir ve bu şekilde endokardiyum ve epikardiyum için  $I^{epi}$  ve  $I^{endo}$  olarak adlandırılan ve değerlerden oluşan iki görüntü elde edilir. Bu görüntüler kartezyen koordinat sistemine çevrilir. Oluşturulan görüntüler düzey kümesinde fonksiyonunda kullanılmaktadır.



Şekil 2: Geliştirilen sistemin çalışma süreci.

### 3. Küresel Önseller

Düzyüz kümesi metodu nesnelerin şekillerini bir üst boyuttaki yüzeyin sıfıncı düzeyine gömme felsefesine dayanmaktadır. Yüzey görüntü ve yüzey özelliklerine göre gelişir ve sonuç olarak sıfıncı düzey bölütlenecek nesnenin çevritini içerir.

Geometrik bilgi içeren küresel şekil önsel bilgi, gelişen yüzeyin tekrar başlatılması esnasında önceden belirlenen uzman kalp çevritleri sayesinde dahil edilmektedir. Yerel önseller bir önceki bölümde anlatıldığı üzere, Haar tipi filtrelerle öğrenilmekte ve Adaboost her bir piksele kalp duvarı olup olmama durumuna binaen bir değer vermektedir. Düzyüz kümesi işte bu değerlerden oluşan görüntü üzerinde çalışmakta ve kalp duvarlarını içine küresel bilgi de katarak bölütlemektedir.

Kalp duvarı bölütleme işlemi için  $c_1(t)$  ve  $c_2(t)$ ,  $R^2$  düzlemi üzerinde zamana ( $t$ ) göre gelişen iki kapalı çevrit olsun.  $c_1(t)$  iç duvarı,  $c_2(t)$  ise dış duvarı bölütlemek amacıyla kullanılmaktadır.  $C$ ,  $c_1(0)$  ve  $c_2(0)$  üzerindeki noktalar kümesi,  $\Phi$  de işaretli uzaklık fonksiyonu olsun.  $x$ 'e pozisyon vektörü ve  $d$ 'ye  $x$ 'ten  $C$ 'ye olan Öklid uzaklık dersek  $\Phi$  aşağıdaki şekilde tanımlanmıştır:

$$\Phi(x) = \begin{cases} 0, & x \in C, \\ -d(x), & x \text{ } c_1 \text{'in dışında, } c_2 \text{'nin içindeyse,} \\ d(x), & \text{diğer.} \end{cases} \quad (2)$$

İlk olarak  $c_1$  endokardiyumun içinde,  $c_2$  ise epikardiyumun dışında olacak şekilde  $\Phi$  yüzeyi Denklem 2 ile oluşturulur. Yüzeyin üzerinde gelişeceği görüntü, Adaboost ile skor verilmiş  $I^{epi}$  ve  $I^{endo}$  görüntülerini kullanarak aşağıdaki gibi oluşturulur:

$$I(x) = \begin{cases} \frac{1}{1 + I^{endo}(x)}, & x \text{ } c_1 \text{'e yakınsa,} \\ \frac{1}{1 + I^{epi}(x)}, & x \text{ } c_2 \text{'ye yakınsa.} \end{cases} \quad (3)$$

Ayrıntılı düzyüz kümesi formülizasyonu için [12]'ye bakınız. Sistem gelişmekte olan bir düzyüz kümesi yüzeyinin sıfıncı düzeyindeki çevrite en benzer olan uzman çevritini belirli aralıklarla seçer ve bu seçilen çevriti sıfıncı düzyüz koyarak Denklem 2 ile yeni bir yüzey oluşturur. Oluşan yeni yüzey görüntünün üzerinde gelişmeye devam eder ve böylelikle küresel önsel olarak kullanılan şekil bilgisi bölütleme işlemine katılmış olur [5]. Sistemin genel çalışma düzeni Şekil 2'de gösterilmiştir.

### 4. Sonuçlar

Geliştirilen sistem gerçek ekokardiyogramlar üzerinde test edilmiştir. Veri kümesi, çeşitli kişilerden alınmış bir kalp döngüsünü sistol ve diastol dahil olmak üzere gösteren ultrason görüntülerinden oluşmaktadır. Herbir sistol ve diastoldeki kalp duvarı 4 farklı uzman tarafından manuel olarak işaretlenmiştir ve herbir duvar 100 nokta ile ifade edilmektedir.


Öğrenme kümesinde, sistol için 4 farklı uzman tarafından işaretlenmiş 15 görüntü ve 3 boyutlu filtreler için sistole ve diastole komşu 4 görüntü kullanılmıştır. Sistole ve diastole görüntüleri ayrı ayrı öğrenilip sınıflandırılmıştır. Herbir piksel için 1081 tane özellik çıkartılmıştır. Ayrıca küresel önseli dahil ederken uzmanlar tarafından çizilmiş 8 kalp çevriti kullanılmıştır.

Sistem 12 sistol ve diastol görüntü üzerinde test edilmiştir. Test sonuçlarını değerlendirmek için bir uzman tarafından çizilmiş çevritler kullanılmış ve bu uzmanın

çizdiği çevrit ile bizim sistemimizin bulduğu çevrit arasındaki Chamfer uzaklığı hesaplanmıştır. Tablo 1’de 12 tane test imgesinin uzmanla bizim sistemimizin ortalama epikardiyum ve endokardiyum uzaklığı gösterilmiştir (Haar Filtreler + Lineer olmayan Adaboost + Küresel bilgi). Ayrıca, düzey kümesi metodu küresel bilginin eklenmesi (Düzye Kümesi + Küresel bilgi) ile Adaboost skor imgesi üzerinde değil de, direk ekokardiyogramlar üzerinde çalıştırılmıştır. Bu şekilde yerel bilginin sisteme etkisinin gösterilmesi amaçlanmıştır. Tablo 1’de görüldüğü üzere sistem Haar filtrelerle lokal bilgi kullanıldığı zaman uzmana daha yakın sonuç vermektedir. Sisteme lineer olmayan bir şekilde hareket bilgisini ekleyen kaydırmalı filtrelerin etkisinin belirlenmesi amacıyla da bir deney yapılmıştır. Kaydırmalı filtrelerin en büyük değer verenini almak yerine, hepsini kullanarak bölütleme (Haar Filtreler + Lineer Adaboost + Küresel bilgi) yapılmış ve sonucunun uzman konturuna lineer olmayan sistemden daha uzak olduğu görülmüştür.

Tablo 1: Uzmanlar arasındaki ve otomatik bulunan çevritler arasındaki ortalama uzaklıklar

	Ortalama Chamfer Uzaklığı
Düzye Kümesi + Küresel bilgi	4.59
Haar Filtreler + Lineer Adaboost + Küresel bilgi	4.13
Haar Filtreler + Lineer olmayan Adaboost + Küresel bilgi	3.96



Şekil 3: İlk satırda diastol, ikinci satırda sistol imge gösterilmiştir. İlk kolon orjinal imgeyi, ikinci kolon sistemin bulduğu çevriti, son kolonda uzmanın çizdiği çevriti (beyaz) ve sistemin bulduğu çevriti (kırmızı) belirtmektedir.

Şekil 3’te bizim sistemimizin bulduğu epikardiyum ve endokardiyum çevritleri ve uzmanın çizdiği çevritler test kümesindeki aynı kişinin sistol ve diastol görüntüleri için gösterilmiştir. Gözle değerlendirildiği zaman, sistemimizin bulduğu otomatik sonuçların uzman sonuçlarına benzediği görülmektedir. Rakamsal sonuçların da ümit verici olduğu fakat geliştirilmesi gerektiği gözlemlenmiştir.

## 5. Kaynakça

- [1] Mignotte, M., Meunier, J., “A multiscale optimization approach for the dynamic contour-based boundary detection issue”, *Comput. Med. Imag. Graph.*, (3) (2001) 265\_275.
- [2] Chen, Y., Tagare, H. D., Thiruvankadam, S., Huang, F., Wilson, D., Gopinath, K. S., Briggs, R.W., Geiser, E. A., “Using prior shapes in geometric active contours in a variational framework”, *Int. J. Comput. Vision* 50 (3) 2002 315\_328.
- [3] Chen, Y., Huang, F., Tagare, H. D. and Rao, M., “A coupled minimization problem for medical image segmentation with priors”, *Int. J. Comput. Vision*, 71(3):259-272, 2007.
- [4] Oktay, A. B., Akgul, Y. S., “Echocardiographic contour extraction with local and küresel priors through boosting and level sets”, in *Proc. of the IEEE Work. on Math. Methods in Biomed. Imag. Analysis*, 2009, pp. 46-51.
- [5] Oktay, A. B., Akgul, Y. S., “A novel level set based echocardiographic contour extraction method with prior knowledge”, in *British Mach.Vis. Conf.*, 2008.
- [6] Freund Y. and Schapire, R.E., “A decision-theoretic generalization of on-line learning and an application to boosting”, *Int. J. of Comput. and Sys. Sciences*, 55(1):119-139, 1997.
- [7] Carneiro, G., Georgescu, B., Good, S., Comaniciu, D., “Detection and measurement of fetal anatomies from ultrasound images using a constrained probabilistic boosting tree”, *IEEE Trans. Med. Imaging*, (9) 1342\_1355.
- [8] Pujol, O., Rosales, M., Radeva, P., Nofrerias-fernandez, E., “Intravascular ultrasound images vessel characterization using Adaboost”, *Func. Imag. Model. of the Heart: LNCS*, 2003, pp. 242\_251.
- [9] Qian, Z., Metaxas, D. N., Axel, L., “Boosting and nonparametric based tracking of tagged mri cardiac boundaries”, in: *Int. Soc. Conf. Series Med. Image Comput. Comput-Assist. Intervention*, 2006, pp. 636\_644.
- [10] Noble, J., and Boukerroui, D., “Ultrasound image segmentation: A survey”, *IEEE Trans. Med. Imaging*, 25(8):987-1010, August 2006.
- [11] Crow F. C., “Summed-area tables for texture mapping”, In *Proc. of Conf. Comp. Grap. and Inter. Tech.*, pp. 207-212, New York, NY, USA, 1984.
- [12] Li, C., Xu, C., Gui, C., and Fox, M. D., “Level set evolution without re-initialization: A new variational formulation”, In *IEEE Conf. Comput. Vis. Pattern Recognit.*, volume 1, pages 430-436 vol. 1, 2005.