

Gauss Filtreleri Kullanılarak Geliştirilen Bölge Temelli Yeni Bir Aktif Kontur Yöntemi

A New Region-Based Active Contour Method Developed Using Gauss Filters

Kazım HANBAY¹ 

¹Inönü Üniversitesi, Yazılım Mühendisliği Bölümü, Malatya, Türkiye
(kazimhanbay@gmail.com)

Received: Dec.19, 2021

Accepted: Feb.1, 2022

Published: Jun.06, 2022

Özetçe— Aktif kontur yöntemleri görüntü bölütlemeye sıklıkla kullanılmaktadır. Bu yöntemler kenar temelli ve bölge temelli yöntemler olarak ikiye ayrılabilir. Yöntemlerin her ikisi de nesne sınırlarını elde etmek için ham görüntü verisini kullanmaktadır. Önerilen yöntemler başlangıç kontur konumu, parametre bağımlılığı, gürültü duyarlılığı ve düzensiz görüntü yoğunlukları gibi bazı zorlu problemlere sahiptir. Bu çalışmada, orijinal ACM with SBGFRLS yönteminin α parametresinin otomatik olarak hesaplanmasını sağlayan yeni bir yaklaşım geliştirilmiştir. Bu parametre giriş görüntüsünün gauss türev filtreleri kullanılarak otomatik olarak hesaplanmıştır. Hesaplanan parametre düzey küme fonksiyonunda iteratif olarak kullanılmıştır. Deneysel sonuçlar, iyileştirilmiş ACM with SBGFRLS yönteminin daha yüksek bölütleme doğrulukları sağladığını göstermektedir.

Anahtar Kelimeler : Aktif kontur, Bölütleme, Medikal görüntü.

Abstract— Active contour methods are often used in image segmentation. These methods can be divided into edge-based and region-based methods. Both methods use generally raw image data to obtain objects boundaries. The proposed methods have some challenging problems such as the initial contour position, parameter dependency, noise sensitivity and irregular image intensities. In this paper, a new approach has been developed that provides automatic calculation of the α parameter of the original ACM with SBGFRLS method. This parameter is calculated automatically using the gaussian derivative filters of the input image. The calculated parameter is used iteratively in the level set function. The experimental results show that the improved ACM with SBGFRLS method provides higher segmentation accuracies.

Keywords : Active contour, Segmentation, Medical image.

1. Giriş

Aktif kontur modelleri, son yıllarda farklı bilgisayarlı görme medikal görüntüleme ve görüntü inceleme/analiz etme uygulamalarında kullanılarak uygun çözümler sağlamaktadırlar. Temel olarak bakıldığında, aktif kontur modelleri görüntü bölütleme işlemini genellikle bir eğri gelişim şeması kullanarak gerçekleştirirler. Bu şema ile görüntü verisine dayalı olarak hesaplanan enerji fonksiyonları ile birlikte kontur temsil yöntemleri de kullanılarak obje sınırları türetilmektedir.

İlk aktif kontur modeli parametrik bir yöntem olup, kullandığı enerji fonksiyonu ile nesne sınırlarını etkili bir şekilde tespit etmektedir. Bu yöntemden sonra literatürde çok sayıda aktif kontur yöntemi geliştirilerek hızlı ve yüksek doğrulukta kenar bulan yöntemler geliştirilmiştir. Geliştirilen yöntemler görüntü bilgisine göre temelde kenar temelli aktif kontur yöntemleri ve bölge temelli aktif kontur yöntemleri olmak üzere iki ana sınıfta incelenebilir (Iqbal, Niaz, Memon, Asim, & Choi, 2020). Kenar temelli yöntemlerde gradyan gibi kenar bilgileri kullanılmaktadır. Bu yöntemler nesnenin kenarlarına bağlı olarak aktif konturu ilerleterek nesnenin kenarlarını tespit etmeye çalışmaktadır. Ayrıca geometrik

modeller (Caselles, Catté, Coll, & Dibos, 1993; Caselles, Kimmel, & Sapiro, 1997) ve kenar anizotropi özellikleri kullanan yöntemlerde vardır (Melonakos, Pichon, Angenent, & Tannenbaum, 2008). Güncel kenar temelli bir yöntemde çoklu lokal istatistiksel bilgiler kullanılarak gürültülü görüntülerde bölütleme yapabilen kenar temelli aktif kontur yöntemi geliştirilmiştir (Liu, Liu, & Xing, 2019).

Kenar temelli yöntemler genelde net görünen ve ayırt ediciliği belirgin olan görüntülerde etkili sonuçlar elde etmişlerdir. Ancak kenar bölgelerinin gradyanını olumsuz etkileyen gürültü gibi durumlardan olumsuz etkilenebilmektedirler. Bu durumlarla baş edebilmek için bölge temelli çalışan aktif kontur yöntemleri geliştirilmiştir (Arrieta et al., 2017; Y. Chen, Yue, Xu, & Fujita, 2017; Niu et al., 2017). Bu yöntemler genellikle bölgesel tanımlama operatörleri kullanarak kontur eğrisinin değerlendirilmesinde istatistiksel bilgi sağlamaktadırlar. Chan ve Vese tarafından geliştirilen CV modeli önemli bir bölge temelli aktif kontur yöntemidir (Chan & Vese, 2001). Bu yöntem literatürde oldukça ilgi çekmekle birlikte çalışma hızı ve yoğunluk düzensizliği durumlarındaki zayıflığı nedeniyle eleştirilmiştir. C-V yönteminin performansını iyileştirmek için farklı çalışmalar yapılmıştır. Karmaşık arka plan içeren görüntülerde daha iyi aktif kontur elde etmek için geliştirilen bir yöntemde geodezik bilgisini de kullanan bir CV yöntemi geliştirilmiştir (L. Chen, Zhou, Wang, & Yang, 2006). ACM with SBGFRLS olarak adlandırılan diğer bir çalışmada ise ikilik bir fonksiyon ile başlatılabilen ve böylece daha etkili işaretli uzaklık fonksiyonu inşa edebilen bölge temelli bir bölütleme yöntemi geliştirilmiştir (Zhang, Zhang, Song, & Zhou, 2010). Bu yöntem farklı görüntülerde iyi sonuç vermekle birlikte, yöntemin performansı önemli ölçüde düzey küme fonksiyonundaki α parametresine bağlıdır. Sabit sayı olan bu parametrenin farklı görüntülerde farklı tamsayı değerlere ayarlanması gerekmektedir. Bu durum yöntemi parametre bağımlı bir yöntem haline getirmektedir. Yine görüntülerdeki nesnelerin iç kısımlarında bulunan önemli bölgelerin bölütlenmesinde bu yöntem istenen sonuçları verememektedir.

Bu çalışmada literatürdeki ACM with SBGFRLS yönteminin performansını iyileştirmek için bu yönteme önemli bir iyileştirme yapılarak yeni bir aktif kontur yöntemi geliştirilmiştir. ACM with SBGFRLS yönteminin başarısını önemli ölçüde etkileyen α parametresi ele alınan görüntüye göre otomatik hesaplanan bir yapıya kavuşturulmuştur. Bu parametrenin hesaplanmasında Gauss fonksiyonu kullanılarak tasarlanan türev hesaplamasından faydalanılmıştır. Giriş görüntüsünün birinci merteye yatay ve dikey yönlerdeki türevlerinin büyüklük (magnitude) bilgisi kullanılarak α parametresi hesaplanmış ve düzey küme fonksiyonunda kullanılmıştır. Böylece nesnenin etrafındaki aktif kontur enerjisi hızlı şekilde minimize edilerek optimal kenar bölgeleri hesaplanmıştır. Böylece yöntemin parametre bağımlı yapısı iyileştirilerek uygun daha doğru nesne bölütlemesi yapılabilmektedir.

Çalışma şu şekilde organize edilmiştir: Bölüm 2’de literatürdeki ACM with SBGFRLS yöntemi kısaca tanımlanarak bu yönteme yapılan iyileştirme sonucu elde edilen yeni aktif kontur metodolojisi anlatılmıştır. Mevcut ACM with SBGFRLS yönteminin düzey küme fonksiyonunu geliştirmek için α parametresinin otomatik hesaplanmasına dayanan Gauss türevleri temelli yeni yaklaşıma ait detaylara yer verilmiştir. Bölüm 3’te önerilen yeni yöntemin literatürdeki yöntemlerle yapılan karşılaştırmalı deneysel sonuçlarına yer verilmiştir. Bölüm 4’te ise elde edilen genel sonuçlara ve bazı çıkarımlara değinilmiştir.

2. Gauss Türev Filtreleri İle İyileştirilen ACM with SBGFRLS Yöntemi

Bu bölümde öncelikle mevcut ACM with SBGFRLS yöntemi kısaca tanımlanmıştır. Daha sonra önerilen Gauss türev filtreleri temelli türev büyüklüğü bilgisinin kullanılmasıyla ACM with SBGFRLS yönteminin düzey küme fonksiyonundaki α parametresinin nasıl adaptif şekilde belirlendiği açıklanmıştır.

2.1. ACM with SBGFRLS Yöntemi

ACM with SBGFRLS yönteminde temel olarak iki matematiksel ifade mevcuttur (Zhang, Zhang, et al., 2010). Bunlardan ilki işaretli basınç kuvveti (signed pressure force (SPF)) fonksiyonudur. SPF fonksiyonu $[-1,1]$ aralığında değerlere sahiptir. Bu fonksiyon aktif kontur eğrisinin iç ve dış basınç kuvvetlerinin işaretlerini modüle eder. Yani kenarları bulunmak istenen nesnenin kenar bölgeleri boyunca aktif konturu optimize etmeye çalışır. SPF fonksiyonu aşağıdaki gibi ifade edilir:

$$spf(I(x)) = \frac{I(x) - \frac{c_1 + c_2}{2}}{\max\left(|I(x) - \frac{c_1 + c_2}{2}|\right)} \quad (1)$$

Burada c_1 ve c_2 iki sabit olup kontur eğrisinin iç ve dış taraflarındaki ortalama yoğunlukları ifade etmektedirler. $I(x)$ ise giriş görüntüsüdür. SPF fonksiyonunun işareti kontur eğrisinin iteratif ilerleyişini önemli ölçüde etkilemektedir. Bu yüzden ACM with SBGFRLS yöntemi düzey küme fonksiyonu içerisinde SPF fonksiyonunu kullanmaktadır. ACM with SBGFRLS yönteminin düzey küme fonksiyonu aşağıdaki şekilde ifade edilmektedir:

$$\frac{\partial \phi}{\partial t} = spf(I(x))\alpha|\nabla\phi|, x \in \Omega \quad (2)$$

Denklem (2) de $|\nabla\phi|$ ifadesi düzey küme fonksiyonunun gradyanını göstermektedir. Bu hesaplama aktif kontur hesaplamasının her iterasyonunda yapılmaktadır. Bu yöntemin performansını etkileyen en önemli parametrelerden birisi ise α parametresidir. Bu parametre orijinal yöntemde pozitif bir sayı olarak giriş görüntüsüne göre genelde 5, 10, 20 ve 25 gibi değerler almıştır (Zhang, Zhang, et al., 2010). Bir görüntüde iyi sonuç veren bir α sayısı başka bir görüntüde istenen sonucu vermemektedir.

2.2. Önerilen Gauss Türev Temelli ACM with SBGFRLS Yöntemi

ACM with SBGFRLS yönteminin çalışma sistemi incelendiğinde, bölütleme sonuçlarının aktif bir şekilde α parametresine bağlı olduğu görülmektedir. Her iterasyonda hesaplanan türevsel değerlendirme sonuçları bu parametre ile çarpılarak aktif konturun işareti ve konumu güncellenmektedir. Yapılan değerlendirmelerde iteratif türev bilgisinin kenar bölgelerindeki değişim yanıtını zayıflatmayacak bir α parametresinin belirlenmesine ihtiyaç olduğu gözlemlenmiştir. Böylece ACM with SBGFRLS yönteminin kararlı çalışması sağlanmakla birlikte parametre bağımlı yapısının iyileştirilebileceği anlaşılmıştır. Bu noktadan hareketle, giriş görüntüsünün türev yanıtlarının güçlü şekilde hesaplanmasında etkin çözümler sunan Gauss fonksiyonu temelli birinci türev bilgisi hesaplanmıştır. Görüntünün yatay ve dikey birinci türevlerinden elde edilen büyüklük bilgisi α parametresinin hesaplanmasında kullanılmıştır. Türev hesaplaması aktif kontur değerlendirmesinin iteratif olarak yapıldığı adımın öncesinde yapılarak yöntemin zaman maliyetinin artmaması sağlanmıştır.

İki boyutlu Gaussian türev filtreleri Gauss fonksiyonunun yatay ve dikey yönlerde birinci türevlerinin hesaplanması ve bu türevlerin filtre olarak tasarlanması ile inşa edilen filtrelerdir. Yatay ve dikey Gaussian türev filtreleri ile $I(x)$ giriş görüntüsünün yatay ve dikey yönlerde türevleri hesaplanır. Temel Gauss fonksiyonu aşağıdaki gibidir:

$$G(x, y) = e^{-\frac{(x^2+y^2)}{\sigma^2}} \quad (3)$$

Gauss fonksiyonunun iki boyutlu yatay ve dikey birinci türev filtreleri fonksiyonun aşağıdaki bir boyutlu birinci türevleri kullanılarak tasarlanır:

$$f_1 = \frac{-2t}{\sigma^2} e^{-\frac{t^2}{\sigma^2}} \quad (4)$$

$$f_2 = e^{-\frac{t^2}{\sigma^2}} \quad (5)$$

Tablo 1’de 1 boyutlu Gaussian yatay ve dikey birinci türev filtreleri kullanılarak iki boyutlu Gaussian türev filtrelerinin nasıl tasarlandığı görülmektedir.

Tablo 1. İki boyutlu Gaussian türev filtrelerinin üretim adımları.

Temel filtreler	Yatay yönde	Dikey yönde
G_x	f_1	f_2
G_y	f_2	f_1

Tablo 1’de verilen türev filtreleri ile giriş görüntüsünün birinci mertebeye yatay ve dikey türevleri aşağıdaki gibi elde edilir:

$$I_x = I * G_x \quad (6)$$

$$I_y = I * G_y \quad (7)$$

Burada I_x ve I_y sırasıyla görüntünün birinci mertebeye yatay ve dikey türevleridir. Önerilen yeni yöntemde giriş görüntüsünün yatay ve dikey türevlerinin büyüklük bilgisi hesaplanmıştır. Büyüklük bilgisi matrisinin en büyük elemanı hesaplanarak ACM with SBGFRLS yönteminin düzey küme fonksiyonundaki α parametresinin değeri olarak kullanılmıştır. Türev büyüklükleri aşağıdaki gibi hesaplanmıştır:

$$Mag = \sqrt{(I_x)^2 + (I_y)^2} \quad (8)$$

Yapılan analizlerde hesaplanan büyüklük bilgisindeki en büyük sayının α parametresi olarak kullanılmasının birçok görüntüde arzu edilen nesne sınırlarını elde etmede iyi sonuçlar verdiği görülmüştür. Bu nedenle bölütlenecek her görüntünün türevleri hesaplanarak elde edilen büyüklük bilgisinin en büyük elemanı aşağıdaki gibi hesaplanarak uygun α parametresi elde edilmiştir:

$$\alpha = \max(\max(Mag)) \quad (9)$$

Önerilen yöntemin temel işlem adımları şu şekildedir:


- 1) Düzey küme fonksiyonu ϕ başlatılır.
- 2) Görüntünün I_x ve I_y türevleri hesaplanır.
- 3) Denklem (9) ile α parametresi hesaplanır.
- 4) $c_1(\phi)$ ve $c_2(\phi)$ katsayıları hesaplanır (Zhang, Zhang, et al., 2010).
- 5) Düzey küme fonksiyonu Denklem (2) kullanılarak değerlendirilir.
- 6) Gaussian filtre ile düzey küme fonksiyonu düzenlenir.
- 7) Düzey küme fonksiyonunun optimal değere ulaşım ulaşmadığı değerlendirilir.

3. Deneysel Sonuçlar

Geliştirilen yöntem Matlab 2018 ortamında Intel i7 dizüstü bilgisayarda uygulanmıştır. Orijinal ACM with SBGFRLS yönteminde olduğu gibi, $\rho = 1$, $\varepsilon = 1$, $\sigma = 1$, $K = 5$ ve zaman adım katsayısı $\Delta t = 1$ olarak alınmıştır (Zhang, Zhang, et al., 2010). Önerilen yöntemde Gaussian türev filtresi için kullanılan sigma parametresi ise 3 olarak alınmıştır.


Geliştirilen yöntem bazı medikal görüntülerin bölütlenmesinde test edilmiştir. Önerilen yöntem ilk olarak orijinal ACM with SBGFRLS yöntemi ile karşılaştırılarak bu yönteme yapılan iyileştirmenin etkileri gözlemlenmiştir. İkinci yöntem ise LIF yöntemi olarak adlandırılan ve aktif kontur enerjisinin bölgesel olarak ele alınıp hesaplandığı bir bölütleme yöntemidir (Zhang, Song, & Zhang, 2010). Kullanılan yöntemler optimal parametreleri ile test edilmiştir. LIF yöntemi birçok parametre içermektedir. LIF yöntemi için, bu çalışmada iterasyon sayısı 300, diğer parametreler ise görüntü bazında en iyi sonuçları verecek şekilde manuel olarak seçilmiştir. Yöntemlerin sonuçları görsel değerlendirme ve çalışma zamanları açısından kıyaslanmıştır. Ayrıca bölütleme doğruluğunun metrik olarak ölçülmesi de önemlidir. Bu nedenle literatürde sıklıkla kullanılan ve Figure of Merit (FOM) olarak bilinen yöntem kullanılmıştır (Abdou & Pratt, 1979). Bu yöntemde FOM değeri 1 ise, geliştirilen yöntemin gerçek bölütleme ile aynı bölütleme sonucunu elde ettiği anlaşılmaktadır. FOM sonuçlarının karşılaştırıldığı ilgili tablolarda en iyi FOM değeri elde eden yönteme ait sonuç koyu font olarak belirtilmiştir.

Ele alınan ilk görüntü kardiyak MRI görüntüsüdür. LIF yöntemi hem bölütleme sonuçları hem de çalışma hızı açısından en kötü sonuçları üretmiştir. Kardiyak görüntüsündeki bölge sınırlarını doğru ve pürüzsüz şekilde bulamamıştır. Önerilen Gaussian temelli ACM with SBGFRLS yöntemi bölge sınırlarını hemen hemen tam olarak ve pürüzsüz şekilde bölütleyebilmiştir. Orijinal ACM with SBGFRLS yöntemi ise kardiyak görüntüsündeki iç bölgeleri birbirinden ayıramayarak daha düşük bir bölütleme doğruluğu elde edebilmiştir.




Şekil 1. Kardiyak MRI için yöntemlerin bölütleme sonuçları

Ele alınan ikinci görüntü bilgisayarlı tomografi (BT) ile elde edilen karaciğer görüntüsüdür. Bir önceki uygulamaya benzer şekilde LIF yöntemi aşırı bölütleme yapmıştır. Ancak organın iç ve dış konturlarını bulabilmiştir. Bununla birlikte yüksek iterasyon sayısına ve hesaplama maliyetine sahiptir. Orijinal ACM with SBGFRLS yöntemi ise organın iç bölgesindeki önemli konturları bulamamıştır. Sadece dış sınırları bulabilmiştir. Bu yöntemle yapılan Gaussian türev temelli iyileştirme sayesinde, yöntemin organın iç bölge sınırlarını düzgün ve hızlı bir şekilde bulması sağlanmıştır. Burada α parametresinin otomatik olarak hesaplanıp düzey küme fonksiyonuna sunulmasının etkileri gözlemlenmiştir. Böylece fonksiyonun nesnenin iç ve dış kontur bölgeleri arasında hızlı yakınsama yapması sağlanmıştır. Şekil 2’de karaciğer BT görüntüsüne ait bölütleme sonuçları görülmektedir.



Şekil 2. Karaciğer BT görüntüsü için yöntemlerin bölütleme sonuçları

Yapılan son uygulama günlük bir görüntü üzerinde gerçekleştirilmiştir. Böylece yöntemlerin medikal görüntü dışındaki farklı görüntülerdeki performansı incelenmiştir. Renkli giriş görüntüsü gri seviyeye dönüştürülmüştür. Şekil 3’te bölütleme sonuçları görülmektedir. LIF yöntemi diğer görüntülerde olduğu gibi aşırı bölütleme yapmıştır. Parmak sınırlarını kısmen doğru bulmakla birlikte arka plan bölgesini gereksiz ve yanlış bir biçimde bölütlemeye çalışmıştır. Orijinal ACM with SBGFRLS yöntemi ise parmak sınırlarını önerilen yeni versiyonuna yakın bir şekilde bulmuştur. Ancak orijinal ACM with SBGFRLS yöntemi kısmen arka planda istenmeyen bölütlemeler yapmıştır. Ancak önerilen yeni ACM with SBGFRLS yöntemi parmaktaki halkanın iç sınırlarını ve halkanın iç kısmındaki parmak sınırlarını da doğru şekilde bulmuştur.



Şekil 3. Günlük görüntü için yöntemlerin bölütleme sonuçları

Tablo 2’de Şekil 1, Şekil 2 ve Şekil 3’te verilen yöntemlerin bölütleme sonuçlarına ait iterasyon sayıları, çalışma zamanları ve FOM metrik sonuçları verilmiştir. En iyi sonuçlar koyu font olarak belirtilmiştir. Sonuçlardan görüleceği üzere, en iyi sonuç her üç parametre açısından da önerilen yönteme aittir. Özellikle önerilen yeni yaklaşımın orijinal ACM with SBGFRLS yönteminin çalışma zamanını ve iterasyon sayısını azalttığı görülmektedir. Bununla birlikte çalışma doğruluğuna da önemli katkılar sunulmuştur.

Tablo 2. Ele alınan yöntemlerin iterasyon sayıları, çalışma süreleri ve FOM metrik sonuçları

	LIF Yöntemi			Orijinal ACM with SBGFRLS Yöntemi			Önerilen Gaussian temelli ACM with SBGFRLS Yöntemi		
	İterasyon sayısı	Süre	FOM	İterasyon sayısı	Süre	FOM	İterasyon sayısı	Süre	FOM
Şekil 1	300	15.646	0.413	54	2.155	0.584	15	0.617	0.636
Şekil 2	300	38.978	0.425	180	10.42	0.214	38	1.893	0.683
Şekil 3	300	54.946	0.195	127	8.957	0.695	41	2.467	0.843

3. Sonuçlar

Bu çalışmada güçlü bir aktif kontur yöntemi olan ACM with SBGFRLS yöntemine Gaussian türev filtreleri temelli bir yaklaşım kazandırılması amaçlanmıştır. Önerilen yaklaşım ile ACM with SBGFRLS yönteminin düzey küme fonksiyonunda aktif şekilde kullanılan α parametresinin yol açtığı yavaş çalışma ve bazı görüntülerde yanlış bölütleme sonuçları üretme gibi durumların önüne geçilmeye çalışılmıştır. Orijinal ACM with SBGFRLS yönteminde görüntülere göre manuel olarak seçilmek zorunda olunan bu parametrenin giriş görüntüsüne göre adaptif şekilde otomatik hesaplanması sağlanmıştır. Bu amaç doğrultusunda giriş görüntüsünün Gaussian filtreleri ile birinci mertbe türevlerinin büyüklüğü kullanılarak α parametresi otomatik olarak hesaplanmıştır. Bu parametre iteratif şekilde yöntemin düzey küme fonksiyonunda kullanılmıştır.

Geliştirilen yaklaşım ile orijinal ACM with SBGFRLS yönteminin hem yavaş çalışmasının hem de bazı görüntülerde yanlış bölütleme sonuçları vermesinin önüne geçilmiştir. Giriş görüntüsünün bir defaya mahsus hesaplanan yatay ve dikey yön türevleri, düzey küme fonksiyonunun iteratif güncellenmesinin yapıldığı iterasyon bloğu içerisinde hesaplanmamıştır. Böylece algoritma karmaşıklığı engellenmiştir. Gaussian türev filtreleri ile gürültüden arındırılmış bir α parametresi hesaplanmıştır. Bu parametre düzey küme fonksiyonunun nesnenin iç ve dış kontur noktalarını değerlendirip optimal sınırlara daha hızlı yakınsamasına katkı sunmuştur. Ayrıca kullanıcının giriş görüntüsüne bağımlı olarak bir sabit α parametresi belirleme zorunluluğu ortadan kaldırılmıştır.

Gelecekte yapılacak çalışmalar ile güçlendirilen ACM with SBGFRLS yöntemine hız kazandırılması ve daha pürüzsüz obje sınırları elde etme yeteneğine katkılar sunulması planlanmaktadır. Yine yöntemin kullandığı diğer bazı sabit parametrelerin tıpkı α parametresinde olduğu gibi adaptif seçilebildiği yöntemler geliştirilmesi düşünülmektedir.

Kaynaklar

- Abdou, I. E., & Pratt, W. K. (1979). Quantitative design and evaluation of enhancement/thresholding edge detectors. *Proceedings of the IEEE*, 67(5), 753–763.
- Arrieta, C., Uribe, S., Sing-Long, C., Hurtado, D., Andia, M., Irarrazaval, P., & Tejos, C. (2017). Simultaneous left and right ventricle segmentation using topology preserving level sets. *Biomedical Signal Processing and Control*, 33, 88–95.
- Caselles, V., Catté, F., Coll, T., & Dibos, F. (1993). A geometric model for active contours in image processing. *Numerische Mathematik*, 66(1), 1–31.

- Caselles, V., Kimmel, R., & Sapiro, G. (1997). Geodesic Active Contours. *International Journal of Computer Vision*, 22(1), 61–79.
- Chan, T. F., & Vese, L. A. (2001). Active contours without edges. *IEEE Transactions on Image Processing*, 10(2), 266–277.
- Chen, L., Zhou, Y., Wang, Y., & Yang, J. (2006). GACV: Geodesic-Aided C–V method. *Pattern Recognition*, 39(7), 1391–1395.
- Chen, Y., Yue, X., Xu, R. Y. Da, & Fujita, H. (2017). Region scalable active contour model with global constraint. *Knowledge-Based Systems*, 120, 57–73.
- Iqbal, E., Niaz, A., Memon, A. A., Asim, U., & Choi, K. N. (2020). Saliency-Driven Active Contour Model for Image Segmentation. *IEEE Access*.
- Liu, C., Liu, W., & Xing, W. (2019). A weighted edge-based level set method based on multi-local statistical information for noisy image segmentation. *Journal of Visual Communication and Image Representation*, 59, 89–107.
- Melonakos, J., Pichon, E., Angenent, S., & Tannenbaum, A. (2008). Finsler active contours. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 30(3), 412–423.
- Niu, S., Chen, Q., de Sisternes, L., Ji, Z., Zhou, Z., & Rubin, D. L. (2017). Robust noise region-based active contour model via local similarity factor for image segmentation. *Pattern Recognition*, 61, 104–119.
- Zhang, K., Song, H., & Zhang, L. (2010). Active contours driven by local image fitting energy. *Pattern Recognition*, 43(4), 1199–1206.
- Zhang, K., Zhang, L., Song, H., & Zhou, W. (2010). Active contours with selective local or global segmentation: A new formulation and level set method. *Image and Vision Computing*, 28(4), 668–676.