

**T.C.**  
**İNÖNÜ ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**GÖRÜNTÜDEKİ NESNELERİ ÇEVRELEME YÖNTEMLERİ**

**Sara ALTUN**

**YÜKSEK LİSANS TEZİ**  
**Bilgisayar Mühendisliği Anabilim Dalı**

**AĞUSTOS 2017**

**MALATYA**

**Tezin Bařlıđı:** Görüntüdeki Nesneleri Çevreleme Yöntemleri

**Tezi Hazırlayan:** Sara ALTUN

**Sınav Tarihi:** 02.08.2017

Yukarıda adı geçen tez jürimizce değeriendirilerek Bilimleri Mühendisliđi Ana Bilim Dalında Yüksek Lisans Tezi olarak kabul edilmiştir.

**Sınav Jüri Üyeleri**

**Tez Danışmanı: Doç. Dr. Muhammed Fatih TALU** .....

İnönü Üniversitesi

**Prof. Dr. Ali KARCI** .....

İnönü Üniversitesi

**Doç. Dr. Mehmet KARAKÖSE** .....

Fırat Üniversitesi

**Prof. Dr. Halil İbrahim ADIGÜZEL**

Enstitü Müdürü

## **ONUR SÖZÜ**

Yüksek Lisans Tezi olarak sunduđum “Görüntüdeki Nesnelere Çevreleme Yöntemleri” başlıklı bu çalışmanın bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığını ve yararlandığım bütün kaynakların, hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuđunu belirtir, bunu onurumla doğrularım.

SARA ALTUN

# ÖZET

Yüksek Lisans Tezi

## GÖRÜNTÜDEKİ NESNELERİ ÇEVRELEME YÖNTEMLERİ

Sara ALTUN

İnönü Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

50+x sayfa

2017

Danışman: Doç. Dr. M. Fatih TALU

Bu tez çalışmasında, literatürde aktif çevreleme yöntemleri (active contour models-ACMs) olarak adlandırılan ve görüntüdeki herhangi bir nesnenin çevrelenmesini sağlayan yöntemler incelenmiştir.

Bölütleme işleminde görüntü içerisindeki homojen renk dağılımı sergileyen pikseller gruplanmaktadır. ACM'ler, görüntü işleme alanındaki bölütleme konu başlığı altında incelenmektedir. ACM'deki temel amaç, ön plan nesnesi ile arka plan bölgesini birbirinden ayıran **sınır hattının** keşfedilmesidir. Literatürdeki ACM'ler incelendiğinde kenar tabanlı ve alan tabanlı olmak üzere iki sınıfa ayrıldığı görülmektedir.

Alan tabanlı ACM'ler, "*ön plan nesnesi görüntünün orta kısmında olur*" fikrine dayanmaktadır. Kenar tabanlı yöntemler, orijinal görüntü fonksiyonunun sürekli bir yaklaşımını kullanmıştır. Kenar tabanlı ACM'ler, nihai çevrelemeye ulaşmak için görüntü gradyanına dayalı kenar algılama yöntemi kullanmıştır.

Alan tabanlı yöntemlerin doğruluk ve performans açısından kenar tabanlı yöntemlerden iyi olduğu bilinmektedir. Bu nedenle tez çalışmasında alan tabanlı yöntemlere odaklanılmıştır.

Alan tabanlı yöntemlerden kısaca bahsetmek gerekirse; Mumford-Shah yönteminin geliştirilmiş bir versiyonu olan C-V yöntemi, gradyan kullanımına ihtiyaç duymadan ön plan nesnesini çevreleyen sınır hattını tespit edebilmektedir.

SBGFRLS yöntemi, görüntüdeki nesnelere kaplayacak bir maskeyi sürekli güncelleyerek ön plan nesnesini arka plandan ayırmaya çalışmaktadır.

ORACM, SBGFRLS yönteminin geliştirilmiş bir versiyonudur. ORACM parametre gerektirmeyen ve daha az zaman gerektiren, alan tabanlı ACM'dir.

Bulanık enerji tabanlı aktif çevreleme yöntemi (FACM), yukarıda bahsedilen klasik yöntemlerden farklı olarak aktif sınır hatlarını tespit etmek için bulanık mantık teorisini kullanmaktadır. FACM, global ve lokal görüntü bilgisini birlikte kullanmaktadır.

Tez kapsamında FACM yöntemi detaylı bir şekilde incelenmektedir.

Bu tez çalışmasında alan tabanlı ACM'lerin uygulamaları Matlab kullanılarak gerçekleştirilmiştir. Farklı yapılara sahip gerçek görüntüler kullanılarak test edilen yöntemlerin üstünlük ve eksiklikleri kapsamlı bir şekilde irdelenmiştir. Sonuç olarak, FACM ve ORACM yöntemlerinin aktif sınır hattını doğru bir şekilde keşfettiği ve birbirine yakın sonuçlar ürettiği görülmüştür.

**ANAHTAR KELİMELER:** Aktif Çevreleme Yöntemleri, C-V, ORACM, SBGFRLS ve FACM

# **ABSTRACT**

Master Thesis

## **SURROUNDS METHODS OF IMAGE OBJECTS**

Sara ALTUN

İnonu University

Graduate School of Natural and Applied Sciences

Department of Computer Engineering

50+x pages

2017

Advisor: Asst. Prof. Dr. M. Fatih TALU

In this thesis study, methods which are called active contour models (ACMs) in the literature and which enable any objects in the image to be surrounded are investigated.

In the segmentation process, groups of pixels exhibiting a homogeneous color distribution in the image are grouped. ACMs are studied under the topic of segmentation in the region of image processing. The main purpose of the ACM is to discover the boundary line that separates the foreground object from the background area. When the ACMs in the literature are examined, it is seen that there are two classifications, edge-based and region-based.

Area based ACMs are based on the idea that "the foreground object is in the middle of the view". Edge-based methods use a continuous approach to the original image function. Edge-based ACMs use image gradient-based edge detection to achieve the ultimate perimeter.

Region-based methods are based on edge-based methods are better known. For this reason, the focus is on region-based methods in the thesis study.

To mention briefly region based methods; The C-V method, an improved version of the Mumford-Shah model, can detect the boundary line surrounding the foreground object without the need for gradient use.

The SBFRLS method continuously updates a mask to cover the objects in the image, thereby trying to separate the foreground object from the background.

ORACM is an enhanced version of the SBFRLS method. ORACM is a region-based ACM that does not require parameters and requires less time.

Fuzzy energy based active containment method (FACM) uses fuzzy logic theory to detect active boundary lines, unlike the conventional methods mentioned above. FACM uses global and local image information together.

In the thesis, the FACM method is examined in detail.

In this thesis study, region based ACM applications were performed using Matlab. The advantages and disadvantages of the methods tested using real images with different constructions have been extensively discussed. As a result, it has been found that FACM and ORACM methods accurately detect the active boundary line and produce close results.

**KEYWORDS:** Active Contour Model, C-V, SBFRLS, ORACM, FACM

## TEŐEKKÜR

Tez konumun Őekillenmesinde ve alıŐmalarım boyunca gsterdiĐi anlayıŐ ve ilgi iin, verdiĐi her trl destek ve katkıları iin danıŐman hocam Sayın Do. Dr. M. Fatih TALU' ya;

Her zaman destekim olduĐunu hissettiĐim, alıŐma disiplinini ğrendiĐim Sayın Prof. Dr. Ali KARCI' ya;

Blm baŐkanımız Sayın Do. Dr. Celaleddin YEROĐLU'na ve tm blm alıŐanlarına;

Tez yazarken desteklerini esirgemeyen Seda GRSUL, Eda SEZEN, Mahdi Hatami VARJOVI, ArŐ. Grv. Nazmiye ELİK, ArŐ. Grv. AyŐe POLAT ve ArŐ. Grv. Hacer GRKAN, ArŐ. Grv. Esra KARADENİZ ve ArŐ. Grv. Zeynep UMUR'a;

Ailemizin emektarları olan ve desteklerini hibir zaman esirgemeyen anneme ve babama;

Benim kk asistanlarım olarak adlandırdıĐım kardeŐlerime,

Manevi olarak desteklerini esirgemeyen ok deĐerli dostlarıma,

TEŐEKKÜR EDERİM.



## İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	iii
TEŞEKKÜR.....	v
ŞEKİLLER LİSTESİ.....	vii
ÇİZELGELER VE TABLOLAR.....	viii
SİMGELER VE KISALTMALAR.....	ix
1. GİRİŞ.....	1
2. KURAMSAL TEMELLER.....	4
2.1. AKTİF ÇEVRELEME YÖNTEMLERİ.....	4
2.1.1. Kenar Tabanlı ACM'ler.....	5
2.1.2. Alan Tabanlı ACM'ler.....	9
2.1.3. Diğer ACM'ler.....	15
3. MATERYAL VE METOTLAR.....	17
3.1. FACM.....	17
3.1.1. Önerilen Yöntem.....	18
3.1.2. Sözde Kod Seviye Küme Fonksiyonu.....	20
3.1.3. Nümerik Yaklaşım.....	22
3.1.4. Hesapsal Karmaşıklık.....	25
3.2. C-V YÖNTEM.....	25
3.3. SBGFRLS.....	27
3.4. ORACM.....	29
4. UYGULAMA.....	30
5. SONUÇ VE ÖNERİLER.....	46
KAYNAKÇA.....	47
EKLER.....	51
EK-1. ÖZGEÇMİŞ.....	51

## ŞEKİLLER LİSTESİ

Şekil 2.1 Aktif Kontur Modelleri.....	4
Şekil 2.2. Mumford-Shah Yöntemi.....	12
Şekil 3.1. FACM Algoritmik Akış Diyagramı .....	17
Şekil 3.2. (a) İyonosfer(Heaviside) fonksiyon (b) Dirac fonksiyon. ....	26
Şekil 3.3. SBGFRLS Görüntü Üzerinde Bir İterasyon.....	28
Şekil 3.4. ORACM Görüntü Üzerinde Bir İterasyon.....	29
Şekil 4.1. FACM'nin Çalışma Biçimi .....	31
Şekil 4.2. (a) Orijinal Görüntü (b) Üyelik Derecesi Matrisinin İlk Durumu (c) Üyelik Derecesi Matrisinin Bir İterasyon Sonraki Durumu (d) Üyelik Derecesi Matrisinin Son Durumu .....	32
Şekil 4.3. ACM'yi Başlatma.....	32
Şekil 4.4. (a) ORACM1 (b) ORACM2 (c) SBGFRLS (d) C-V (e) FACM.....	33
Şekil 4.5. (a) ORACM1 (b) ORACM2 (c) SBGFRLS (d) C-V (e) FACM.....	34
Şekil 4.6. (a) ORACM1 (b) ORACM2 (c) SBGFRLS (d) C-V (e) FACM.....	35
Şekil 4.7. (a) ORACM1 (b) ORACM2 (c) SBGFRLS (d) C-V (e) FACM.....	36
Şekil 4.8. (a) ORACM1 (b) ORACM2 (c) SBGFRLS (d) C-V (e) FACM.....	37
Şekil 4.9. (a) ORACM1 (b) ORACM2 (c) SBGFRLS (d) C-V (e) FACM.....	38
Şekil 4.10. (a) ORACM1 (b) ORACM2 (c) SBGFRLS (d) C-V (e) FACM.....	39
Şekil 4.11. (a) ORACM1 (b) ORACM2 (c) SBGFRLS (d) C-V (e) FACM.....	40
Şekil 4.12. (a) ORACM1 (b) ORACM2 (c) SBGFRLS (d) C-V (e) FACM.....	41
Şekil 4.13. (a) ORACM1 (b) ORACM2 (c) SBGFRLS (d) C-V (e) FACM.....	42
Şekil 4.14. (a) ORACM1 (b) ORACM2 (c) SBGFRLS (d) C-V (e) FACM.....	43
Şekil 4.15. FACM'nin Görüntü Üzerindeki Değişimi.....	44

## ÇİZELGELER VE TABLOLAR

<b>Çizelge 4.1.</b> ACM'lere Göre Süre ve İterasyon Sonuçları .....	45
---	----

## **SİMGELER VE KISALTMALAR**

ACMs	Active Contour Models
ACM	Active Contour Model
C-V	Chan ve Vese Model
GAC	Geodesic Active Contour
FACM	Fuzzy Energy Based Active Contour Model
PDE	Partial Differential Equation(Kısmi Diferansiyel Denklemler)
ROI	Region Of Interest
SBGFRLS	The Formulation Of Selective Binary And Gaussian Filtering Regularized Level Set Model
SPF	Signed Pressure Force Function

## 1. GİRİŞ

Görüntü işleme, insan gözünün algılayabildiği bir görüntünün sanal ortama aktarıldıktan sonra sayısallaştırma gibi çeşitli işlemlere tabi tutularak bulunan sonucun çıkışa iletilmesini sağlayan bir çalışma alanıdır[1]. Bölütleme, sahip olunan ham verinin belirli işlemlerden geçirilerek görüntünün kendi içerisinde sınıflandırılma biçimi olarak tanımlanan görüntü işleme yöntemidir. Görüntü bölütlemedeki amaç, sahip olunan görüntü veri kümesini ya da nesnelere; gruplara, sınıflara ya da kümelerle ayırmaktır [2, 5]. Görüntü bölütleme, analiz sonuçlarının performansını ölçmede, kalitesini değerlendirmede önemlidir ve görüntü işleme uygulamalarında en zorlayıcı aşamalardan biridir [6]. Bir bölütleme tekniğinin bölütleme seviyesi, belirli görüntünün türüne ve sorunun özelliklerine göre kararlaştırılmıştır [7]. Görüntü bölütleme çoğu biyomedikal görüntü analizi için önemli bir aşama olarak ele alınmıştır [8-10].

Mevcut bölütleme yöntemlerinden olan ACM tezde ayrıntılı olarak incelenmiştir. ACM, bazı kısıtlamalar altında görüntünün nesne çevrelemesine doğru gelişecek şekilde bir başlangıç sınır hattının deformasyonuna dayanır. ACM, son on yılda başta görüntü bölütleme ve hareket takibi olmak üzere bir dizi uygulama için oldukça popüler hale gelmiştir.

ACM'ler kenar tabanlı ve alan tabanlı olmak üzere iki kısımda incelenmiştir. Alan tabanlı ACM'ler görüntüdeki nesneyi çevrelerken küresel enerji minimizasyonu nedeniyle ilk sınır hattının belirlenmesinde herhangi bir kısıtlama yapmaz. Sınır hattı önceden belirlendiği için bağımsız bölütleme yöntemi sunmuştur. Kenar tabanlı ACM'lerin dezavantajı görüntünün gradyanına bağlı olmasıdır.

Alan tabanlı ACM'ler, "*ön plan nesnesi görüntünün orta kısmında olur*" fikrine dayandığından orta bölgeyi kapsayan bir sınır hattıyla algoritmaya başlar ve bu sınır hattını iteratif bir şekilde güncelleyerek nihai sınır hattını keşfeder. Güncelleme işlemi yöntemlere göre farklılık arz etmektedir. Temel olarak nihai sınır hattının keşfinde, ön ve arka plan piksellerin kapladığı alana değerlendirildiği için alan tabanlı olarak isimlendirilmişlerdir.

Kenar tabanlı ACM'ler, görüntü gradyanına dayalı kenar algılama yöntemi kullanmıştır. Sabit terim nedeniyle, kenar tabanlı ACM'lerin her biri içte veya dışta tek bir yöne doğru sınır hattı geliştirmiştir.

Tez çalışmasında alan tabanlı yöntemler detaylı olarak incelediğinden bu bölümde kısaca değinilmiştir.

Birçok yöntem kenar bilgisini kullanırken; Chan ve Vese tarafından önerilen "Kenarları Olmayan Aktif Konturlar" yöntemi, alan tabanlı bir bilgi kullanır. Bu yöntemde ön plan nesnesini çevreleyecek sınır hattının içindeki ve dışındaki bölgeler homojen renk dağılımına sahip kabul edilir.

SBGFRLS yöntemi, Gauss filtresi kullanır. Gauss filtresi seviye belirleme fonksiyonunu düzgün hale getirebilir ve gelişimi daha kararlı yapabilir. SBGFRLS yöntemi genel ve sağlamdır. Görüntüyle aynı boyutta olan bu maske üzerinde ön plan nesnesine ait pikseller pozitif, kalan pikseller negatif olarak etiketlenmektedir. Negatif ve pozitif etiketler iteratif bir şekilde güncellenerek ön plan nesnesinin tespiti yapılmaktadır. Yöntemin en önemli dezavantajı aktif sınır hattının hızlı deforme olmasıdır.

Alana tabanlı yöntemlerden olan ORACM, ortalama 5 kat hızlı çalışmaktadır ve giriş görüntüsüne bağlı ön parametreye ihtiyaç duymamaktadır.

FACM, ön plan nesnesini çevrelerken sınır hattını geliştirme prensibine dayanmaktadır. FACM, yerel ve global enerji terimini birleştirilerek homojen olmayan durumlarda gürültüye, bulanık sınır hatlarına ya da kesikli köşelere sahip görüntülerde daha iyi sonuç vermektedir.

Tez kapsamında FACM yöntemi detaylı bir şekilde incelenmektedir.

Bu tez çalışmasında alan tabanlı ACM'lerin uygulamaları Matlab kullanılarak gerçekleştirilmiştir. Farklı yapılarla sahip gerçek görüntüler kullanılarak test edilen yöntemlerin üstünlük ve eksiklikleri kapsamlı bir şekilde irdelenmiştir. Sonuç olarak, FACM ve ORACM yöntemlerinin aktif sınır hattını doğru bir şekilde keşfettiği ve birbirine yakın sonuçlar ürettiği görülmüştür.

Tezde, alan tabanlı ACM'lerden üç klasik ve bir bulanık olmak üzere dört farklı nesne çevreleme yöntemi incelenmiştir.

Tezin organizasyonu şu şekilde planlanmıştır:

Bölüm 2'de görüntü bölütleme ve bulanık mantık ile ilgili temel kuramsal bilgiler verilmektedir. Tez çalışmasının temelinde görüntü işleme olduğundan görüntü işleme ile başlar. FACM'nin temeli görüntü bölütlemedir. Bahsedilen yöntem görüntü bölütleme yöntemlerinden olan ACM'dir. Görüntü bölütleme anlatıldıktan sonra ACM'ler kapsamlı bir şekilde anlatılmıştır.

Bölüm 3'te literatürdeki mevcut ACM'ler (C-V, SBGFRLS, ORACM ve FACM) ifade edilmektedir.

Bölüm 3'te materyal ve yöntemlere değinilmiştir. Bu bölümde çalışılan ACM'lere (C-V, SBGFRLS, ORACM ve FACM) açıklayıcı biçimde yer verilmiştir.

Bölüm 4'te MATLAB yazılımı üzerinde çalıştırılan görüntü sonuçları gösterilmiştir.

Bölüm 5'te yapılan uygulamalar karşılaştırılmıştır. Görüntü hassaslığına ve performansa göre sonuca ulaşılmıştır.

## 2. KURAMSAL TEMELLER

### 2.1. AKTİF ÇEVRELEME YÖNTEMLERİ

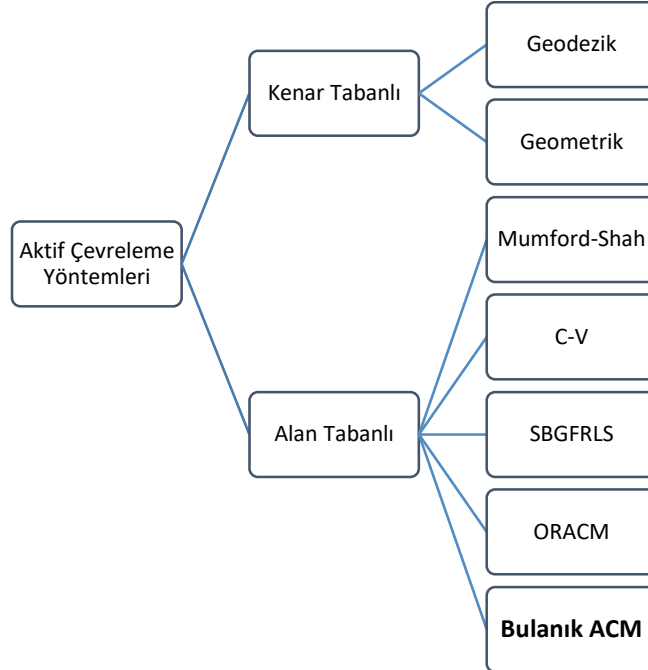
ACM'ler; görüntü bölütleme [11], nesne algılama ve izleme [12, 13], özellik çıkarımı [14], görüntü kaydetme [15] yöntemlerinde başarılı bir şekilde uygulanmıştır. ACM'ler, çeşitli nesne etkilerine ve hareketlerine uyan deforme olabilen sınır hatlarının kullanımına dayanır. Bu yöntem, kapalı parametrik sınır hattı üretme yeteneğine sahiptir [16].

Bununla birlikte, bazı dezavantajları vardır:

- i. Bölütleme sonuçları, sınır hattının pozisyonuna bağlıdır,
- ii. Verilen görüntünün sahip olduğu gürültüyle kolayca bozulur.

Bu tür dezavantajların üstesinden gelmek için ACM'lere dayanan çeşitli yaklaşımlar geliştirilmiştir [17 - 21].

Şekil 2.1' de aktif çevreleme yöntemleri gösterilmiştir.



Şekil 2.1 Aktif Kontur Modelleri



Klasik ACM'den geliştirilmiş diğer yöntemler literatürde başlatılmıştır [20,21,13]. Bu ACM'ler, kenar ve alan tabanlı aktif çevreleme yöntemleri olmak üzere nesne çevreleme durumunu geliştiren iki kısımda incelenmiştir [22].

### 2.1.1. Kenar Tabanlı ACM'ler

Kenar tabanlı yöntemler, görüntüdeki nesne çevrelemeleri boyunca doğru sınır hattına ulaşmak için görüntü gradyanını kullanmıştır. Klasik ACM'lerden geometrik ACM ve geodezik ACM, "kenar-tabanlı" yöntemler olarak bilinir. Çünkü bu yöntemler amaçlanan nesnelerin çevrelemeleri üzerindeki sınır hatlarının gelişimini durdurmak için kenar-tabanlı fonksiyonları kullanmıştır. Aynı zamanda kenar tabanlı ACM'ler görüntüdeki nesne çevrelemesini yaparken kenarlar nesne gradyanının tersine eşit olur. Bu yüzden, bu yöntemler zayıf ya da net olmayan sınır hatlı görüntülerde iyi çalışmaz.

Sabit terim nedeniyle, görüntüdeki sınır hattı ya içte ya da dışta olmak üzere tek bir yöne doğru gelişmiştir. İlk sınır hattı ROI (Region of Interest)'nin iç veya dış kısmına tamamen yerleştirilmiştir. Aynı zamanda görüntüdeki nesneye ait olan en iyi çevrelemeyi bulmak için görüntünün bir iterasyon önceki bilgisi gereklidir. Ayrıca kenar tabanlı ACM'lerde, paralel yöntem kullanıldığından kenar tabanlı bölütleme yöntemlerinin birkaç dezavantajına sahiptir. Bu dezavantajlardan birincisi, hem kenar tabanlı bölütlemeler hem de kenar tabanlı ACM'ler görüntü gradyan işlemine bağlıdır. Kenar tabanlı ACM'ler, bulanık sınır hatlarını atlayabilir ve yerel minimale duyarlıdırlar.

Kenar tabanlı ACM'lere aşağıda kısaca değinilmiştir:

**Geometrik ACM:** Bu yöntem, Caselles ve arkadaşları tarafından görüntünün sınır hattı (eğri) değişimine dayanan geometrik bir ACM olarak önerilmiştir [17]. Sınır hattı normal kuvvet yönünde gelişmiştir ve kenar tabanlı fonksiyon kullanılarak görüntüdeki nesneye uygun sınır hattına ulaştığında çevrelemeyi tamamlar.

Ortalama eğri hareketine dayanan geometrik ACM, aşağıdaki formülde verilmiştir [19]:

$$\frac{\partial \phi(x,y)}{\partial t} = |\nabla \phi(x,y)|(\varepsilon \kappa(\phi(x,y)) + \nu) \quad (2.1)$$

$(\varepsilon \kappa(\phi(x,y)) + \nu)$  daima pozitif kalsın diye seçilen  $\nu$  sabiti, düzeltme terimidir. Bu sabit, eğri sıfır ya da negatif olduğunda sınır hattını görüntüdeki nesnelere çevresine doğru iten bir kuvvet olarak yorumlanabilir. Ayrıca,  $\nu > 0$  sınır hattı içindeki alan üzerinde sınırdır ve yayılma hızını artırır.

Burada  $\kappa$ , aşağıdaki verilen seviye seti fonksiyonunun ortalama eğriliğini gösterir:

$$k(\phi(x,y)) = \text{div} \left( \frac{\nabla \phi}{\|\nabla \phi\|} \right) \quad (2.2)$$

$$k(\phi(x,y)) = \frac{\phi_{xx}\phi_y^2 - 2\phi_x\phi_y\phi_{xy} + \phi_{yy}\phi_x^2}{(\phi_x^2 + \phi_y^2)^{3/2}} \quad (2.3)$$

Burada  $\phi_x$  ve  $\phi_{xx}$ ,  $\phi(x,y)$ 'nin  $x$ 'e göre sırasıyla birinci ve ikinci türevini; aynı şekilde  $\phi_y$  ve  $\phi_{yy}$ ,  $\phi(x,y)$ 'nin  $y$ 'e göre sırasıyla birinci ve ikinci türevini göstermektedir. Sınır hattının rolü, iç enerji teriminin klasik ACM'de yaptığı gibi görüntüdeki nesne çevrelemelerinin düzenliliğini kontrol etmektir.  $\varepsilon$ , sınır hattı değişiminin düzenliliği ve sağlamlığı arasındaki dengeyi kontrol etmektir.

Geometrik ACM'de, hız fonksiyonuna durdurma fonksiyonu eklenirse:

$$\frac{\partial \phi(x,y)}{\partial t} = g(I(x,y))(\varepsilon \kappa(\phi(x,y)) + \nu)|\nabla \phi(x,y)| \quad (2.4)$$

Burada  $g(I(x, y))$ , durdurma fonksiyonu yani görüntü gradyanının azalan fonksiyonu ve bir pozitiflik belirtir. Durdurma fonksiyonuna basit bir örnek şu şekilde verilmiştir:

$$g(I(x, y)) = \frac{1}{1+|∇I(x,y)|} \quad (2.5)$$

Çevrelemeler,  $g(I(x, y))(v + \epsilon\kappa(\phi(x, y)))$ 'nin hızıyla normal yönde hareket eder ve  $g(\cdot)$ 'nin kaybolduğu sınır hattında durur. Eğrilik terimi  $\kappa$ , görüntüdeki nesne çevrelemelerinin düzenliliğini korurken;  $v$  sabit terimi, kapalı alanı en aza indirerek sınır hattı değişimini hızlandırır ve nihai sonuçta durur [19].

Geometrik ACM, [23]'de seviye belirleme yöntemleri kullanılarak uygulanmıştır. Bu yöntem, nesnelere ve arka plan arasında zayıf kontrasta sahip görüntüler için iyi çalışmaz. Bu tür problemlerin üstesinden gelebilmek için geodezik ACM önerilmiştir [19]. Geometrik ACM, bir çeşit geodezik ACM'dir [19, 20].

**Geodezik ACM ( GAC ):** En popüler kenar tabanlı yöntemlerden biri olan ve arzulanan nesnelere çevrelemeleri üzerinde sınır hattını durdurmak için görüntü gradyanını kullanan yöntem GAC yöntemidir [24]. Bu yöntem, görüntüde nesne çevrelemeleri üzerindeki sınır hatlarını durdurmak için kenar durdurma fonksiyonu (ESF-edge stopping function) gradyanını kullanmıştır [25]. GAC, enerji fonksiyonelliğini minimize etmek için eşdeğer olmayı sağlayan Riemannian uzayında minimum uzaklık eğrisini bulan problemde elde edilmiştir [12].

GAC yönteminde, aşağıdaki seviye seti formülü kullanılmıştır [19]:

$\Omega \subset R^2$  görüntü domaini olmak üzere,  $I: \Omega \rightarrow R$  giriş görüntüsü ve  $C$  kapanan sınır hattıdır. GAC yöntem, aşağıdaki enerji fonksiyonunu minimize ederek formüle edilmiştir [25]:

$$E^{GAC}(C(q)) = \int_0^1 g(|\nabla I(C(q))|) |C'(q)| dq, \quad (2.6)$$

$g$ , azalan fonksiyondur.

$$g(|\nabla I|) = \frac{1}{1+|\nabla G_\sigma * I|^2}, \quad (2.7)$$

$\nabla G_\sigma * I$ , standart sapması  $\sigma$  olan Gauss çekirdeği ile  $I$  görüntüsünü evriştirilmesini gösterir.

Değişken hesabı ile Eşitlik (2.6)'dan Euler-Langrange eşitliği aşağıdaki gibi elde edilmiştir:

$$C_t = g(|\nabla I|)k\vec{N} - (\nabla g \cdot \vec{N})\vec{N}, \quad (2.8)$$

$k$ , görüntüdeki nesne çevrelemesinin sınır hattıdır ve  $N$  sınır hattı için iç doğru normaldir.

$C$ , sınır hattı sıfır seviyesine ayarlanmıştır, yani  $C = \{x \in \Omega | \phi(x) = 0\}$ . Aşağıdaki seviye kümesi formülasyonu elde edilmiştir:

$$\frac{\partial \phi}{\partial t} = g \operatorname{div} \left( \frac{\nabla \phi}{|\nabla \phi|} \right) |\nabla \phi| + \nabla g \cdot \nabla \phi, \quad (2.9)$$

GAC yöntemi, görüntüdeki nesne çevrelemesini durdurmak için kenar fonksiyonu  $g$ 'ye bağlı olduğundan yöntem gradyan tarafından tanımlanan kenarlarla nesnelere algılayabilir.

### 2.1.2. Alan Tabanlı ACM'ler

Alan tabanlı ACM'ler yoğunluk, renk ve yapı özelliği gibi alan bilgisi kullanarak başlatılmıştır [26, 27]. Genellikle alan tabanlı yöntemler sadece sınır hattını geliştirmede değil aynı zamanda iç ve dış çevreleme görüntü istatistiğinden görüntü bilgilendirmede kullanılmıştır.

Bu çevreleme yöntemi sınır hattının içi veya dışı olmak üzere iki alt kümeye aittir. Bu yöntemde, görüntüdeki nesneyi çevrelemek için kullanılan başlangıç sınır hattı yerel enerji minimizasyonu yerine küresel enerji minimizasyonuna bağlı olduğundan görüntüde herhangi bir yere yerleşebilir. Bu nedenle, kenar tabanlı ACM'lerden daha az bilgi gereklidir. Ayrıyeten görüntüde başlangıç sınır hattının yerleştirilmesinde herhangi bir kısıtlama yoktur. Yani alan tabanlı ACM'ler, başlangıç sınır hattının konumuna bakılmaksızın iç çevrelemeleri tespit edebilmektedir. Önceden tanımlanmış başlangıç sınır hatlarının kullanılması, bağımsız bölütleme yöntemi sunmuştur. Kenar tabanlı ACM'lerden daha az yerel minime veya gürültüye duyarlıdırlar.

Alan tabanlı ACM'lerden birkaçına aşağıda kısaca değinilmiştir:

**Mumford-Shah Yöntemi:** David Mumford ve Jayant Shah, verilen bir başlangıç görüntüsünün optimal parçalı-düzgün veya parçalı-sabit denklemlerini hesaplamaya izin veren bir enerji küçültme problemini formüle etmişlerdir. Mumford ve Shah, bölütleme görevlerini gerçekleştirmek için enerji fonksiyonlarında görüntü yoğunluğu kullanmayı önermiştir [28].

Bu yöntemde görüntünün küresel bilgileri, görüntüyü bölütlemek için durdurma ölçütü olarak kullanılmıştır [29]. En iyi görüntü bölütleme sonucunu elde edebilmek için görüntüdeki tüm bilgileri kullanmıştır. Bu yöntemde, giriş görüntüsü düzenli çevrelemelerle parçalı düzenli fonksiyonlar tarafından tahmin edilen temel yaklaşım olarak görülmüştür [28].

Verilen başlangıç görüntüsü  $g$ 'nin,  $u$  optimal parçalı-düzgün veya parçalı-sabit denklemlerini hesaplamaya yarayan bir enerji minimizasyon problemi oluşturmuştur [30].

$\Omega \subset R^d$  görüntü domaini tanımlanmıştır ( $d = 1$  ise bir aralıktır,  $d = 2$  ise düzlemde bir üçgendir ).  $\Omega$ 'nin sınırlanmış, bağlı ve açık olduğu farzedilmiştir.  $g: \Omega \rightarrow R$  gri seviyeli bir görüntü olsun ( bir boyutluda bir sinyal, iki boyutluda düzlemsel bir görüntü, üç boyutluda hacimsel bir görüntü).  $g$  ,  $\Omega$  içerisinde sınırlandırılmış bir fonksiyon farz edildiği için herhangi bir özelliğini kaybetmez ve doğaldır (  $g \in L^\infty(\Omega)$  ).

[28]'de görüntü analizinde ve bilgisayar görmesinde bölütleme işlemi ayrışma hesaplamayı içermektedir:

$$\Omega = \Omega_1 \cup \Omega_2 \cup \dots \cup \Omega_n \cup K$$

$g$  görüntüsünün domaini yani,

- (a)  $g$  görüntüsü, her bir  $\Omega_i$  içinde düzgün veya yavaş yavaş değişir.
- (b)  $g$  görüntüsü, farklı  $\Omega_i$  ve  $K$  sınırı arasında çoğunlukla kesikli ve / veya hızlı bir şekilde değişir.

Sonraki aşamada  $\Omega_i$ ,  $\Omega$  domaininin her biri parçalı düzgün sınırlarla birbirine bağlı açık alt kümeleri olacaktır (  $\Omega_i$ 'nin sınırlarının birleşimi  $\Omega$  içerisinde olduğu için) ve  $K$  kapalı bir küme olacaktır, bu yüzden;

$$\Omega = \Omega_1 \cup \Omega_2 \cup \dots \cup \Omega_n \cup K, \quad K = \Omega \cap (\partial\Omega_1 \cup \dots \cup \partial\Omega_n)$$

Görüntü bölütlemesi için arasında  $E$  enerji fonksiyonu minimize edilmiştir [30] :

$$E(u, K) = \mu^2 \int_{\Omega} (u - g)^2 dx + \int_{\Omega \setminus K} |\nabla u|^2 dx + \nu |K|, \quad (2.10)$$

Burada,  $u: \Omega \rightarrow R^d$  de bir sabittir ve her  $\Omega_i$  içerisinde türevlenebilir (veya  $u \in H^1(\Omega_i)$ ) ve  $K$  boyunca kesikli olabilir.  $|K|$ , hiper yüzey  $K$ 'nin toplam yüzey ölçüsüdür ( $d = 1$  ise sayma,  $d = 2$  ise uzunluk,  $d = 3$  ise alan ölçüsü). Sonrasında,  $\mathcal{H}^{d-1}(K)$  tarafından  $|K|$  tanımlanmıştır.  $d - 1$ ,  $R^d$ 'de Hausdorff ölçümünün boyutudur.

Eşitlik (2.11)'deki bu üç terimden herhangi biri bırakılarak  $\inf E = 0$  olma durumları:  $u = 0$ ,  $K = \emptyset$  ilk şartı sağlamadığında;  $u = g$ ,  $K = \emptyset$  aldığı anda ikinci şartı sağlamadığında; örnek verilecek olursa  $g$  görüntüsünün tüm piksellerinin sınırını sağlamak için  $K$  ayrık durumunda her bir  $\Omega_i$  bir piksel olmakta ve  $u$ , her piksel üzerinde  $g$ 'nin ortalama değeridir. Bu üç terimin varlığı,  $u$  ve optimal çift  $(u, K)$  için önemli çözümlere yol açar, bu durum  $g$ 'nin sadeleştirilmesini sağlayan güncel görüntü  $g$ 'nin zahirisi olarak görülebilir.

$u$  parçalı sabit fonksiyonları içerisinde  $E$  sınırlandırılırsa önemli bir özel durum elde edilmiştir; yani,  $u$ , her bir  $\Omega_i$  açık kümesi üzerinde  $c_i$  sabitidir.  $E$ ,  $\mu^{-2}$  ile çarpılırsa;

$$\mu^{-2}E(u, K) = \sum_i \int_{\Omega_i} (g - c_i)^2 dx + v_0 |K|, \quad (2.11)$$

$v_0 = v / \mu^2$ 'dir.  $c_i$  değişkenlerinde bunun en aza indirgendiği rahatlıkla gözlemlenmiştir:


$$c_i = \text{mean}_{\Omega_i}(g) = \frac{\int_{\Omega_i} g(x) dx}{|\Omega_i|}, \quad (2.12)$$

$|\Omega_i|$ ,  $\Omega_i$ 'nin Lebesgue ölçümünü belirtir (yani  $d = 2$  ise alan,  $d = 3$  ise hacim). Tekrar indirgenecek olursa;

$$E_0K = \sum_i \int_{\Omega_i} (g - \text{mean}_{\Omega_i}(g))^2 dx + v_0|K| \quad (2.13)$$

$\mu \rightarrow 0$ 'a giderken  $E$ 'nin limit fonksiyonu olarak  $E_0$ 'ı yorumlamak mümkündür [28].

Şekil 2.1'de bu yöntemin nasıl çalıştığı gösterilmiştir.



Şekil 2.2. Mumford-Shah Yöntemi

Bu alan tabanlı ACM, seviye belirleme yöntemi [31] ile enerji fonksiyonunun minimizasyonu sağlanarak Chan ve Vese tarafından daha çok popüler yapılp ve geliştirilmiştir [32].

**C-V (Chan-Vese) ACM:** Chan ve Vese, Mumford-Shah yönteminden esinlenerek alan tabanlı enerji fonksiyonuna dayanan ACM önermiştir[32]. Bu yöntemde görüntüdeki nesnenin çevrenemesinin içindeki ve dışındaki iki bölge homojen kabul edilmiştir. Sonrasında enerji fonksiyonellikleri ortalama ayırma [20], histogram bölünmesi [33] ve Bayesian yöntem [34] gibi birkaç örnek diğer yoğunluk ilişkisi üzerinde tanımlanan Chan-Vese uzantılı birçok çalışma geliştirilmiştir [33-36].



Bu yöntemde, küresel görüntü istatistik bilgileri enerji fonksiyonunda kullanılmıştır. Bu enerji fonksiyonu, seviye seti formulasyonuna dönüştürülmüştür. Bu yöntem, diğer alan tabanlı yöntemlerin yanı sıra zayıf sınır hattı olan görüntülerle ilgilenmiştir. Buna ek olarak, "kenar tabanlı" yöntemle kıyasla sınır hatları başlangıç pozisyonuna daha az duyarlı olduğu gözlemlenmiştir[37].

Bu yöntemde amaç, biri algılanan nesnelere ve diğeri arka planı temsil eden iki bölge içinde verilen görüntünün belirli parçalarını aramaktır [29]. Görüntüdeki nesnenin nihai çevrelenmesi, sınır hattının gelişimini sonlandırmak için kenar fonksiyonuna bağlı sonuç bulmaz. Bu yöntemde, görüntüde sınır hattının yeri çok iyi tespit edildiği için gürültülü olsa bile ilk görüntüyü yumuşatmaya gerek yoktur. Sınır hattının gradyan tarafından veya çok düzgün çevrelemelerle tanımlanmasına gerek yoktur. Tek bir başlangıç sınır hattı ile başlayan bu yöntem, iç çevrelemeleri otomatik olarak algılayabilir ve nesnelere tespit etmek için nesnelere etrafından başlamak zorunda değildir. Bu yöntemle ilgili kapsamlı bilgiye Bölüm 3'te yer verilmiştir.

**Bulanık Enerji Tabanlı ACM (FACM):** Son zamanlarda hem bulanık mantık teorisini hem de C-V yöntemini hesaba katarak, Krinidis ve Chatsiz alan tabanlı ACM olan FACM'yi önermiştir [35]. Bu yöntem, nesnelere çevrelemelerini gradyan tarafından tanımlanmasına gereksinim duymadan düzgün şekillerle hatta kesikli sınır hatlarıyla ele alabilir.

Bulanık mantık veri kümelemede kullanılan yoğunluğa sahip olan bir araçtır, fakat ACM değildir. Genellikle bulanık metotlar, daha doğru ve sağlam veri kümeleme sağlar. Bu yüzden bulanık enerji-tabanlı minimizasyon yöntemini içeren ACM ile birleştirilebilir. Enerjinin bulanıklılığı "zayıf" yerel minimumu yansıtmak için güçlü yeteneklerle dengeli bir teknik sağlar. Dahası, sözde seviye küme fonksiyonlarının terimleri ile yöntemi formüle edilebilir.

Bu yöntem, global görüntü bilgisini kullanan diğer alan tabanlı ACM'ler gibi sınır hattının başlangıç pozisyonunda kaba, kesikli ve bulanık sınır hattı bulunan görüntülerle çalışabilme yeteneğine sahiptir. Bu yöntem, görüntüyü parçalı sürekli

yoğunluklu iki bölgeye yaklaştırma varsayımına bağlı olarak çalışır. Bu yüzden yoğunluk homojensizliği olan görüntülerle çalışıldığında, bu varsayım gereksinimleri karşılamaz [38]. Görüntüdeki nesnenin sınır hattı dışında ya da içinde her bir pikselin üyelik fonksiyonu derecesini enerji fonksiyonelliği ile birleştirmiştir. Bu yöntem, Euler-Langrange eşitliğini çözmek yerine sınır hattını doğrudan hesaplar. Böylece görüntüdeki istenen nesne çevrelemelerini kavrar. Shyu ve arkadaşları [38] ise bu gibi sorunları çözüme ulaştırmak için yerel bulanık enerjinin görüntüdeki yoğunluk homojensizliğini incelemiştir.

FACM'nin enerji fonksiyonunda  $\Omega \subset \mathcal{R}^2$  görüntü domaini olmak üzere,  $I: \Omega \rightarrow \mathcal{R}$  gri seviyeli görüntü için tanımlanmıştır.  $\Omega$  görüntü domaininde  $C$  sınır hattı tanımlanmıştır.  $C$  sınır hattı tarafından  $\text{ıç}(C)$  ve  $\text{dış}(C)$  olarak iki bölgeye ayrılan bölütlenmiş  $I$  görüntüsü olduğu farzedilmiştir. Krinidis ve Chatsiz, FACM'yi aşağıdaki gibi tanımlamıştır [35]:

$$F(C, c_1, c_2, u) = \mu|C| + \lambda_1 \int_{\Omega} [u(x)]^m |I(x) - c_1|^2 dx + \lambda_2 \int_{\Omega} [1 - u(x)]^m |I(x) - c_2|^2 dx \quad (2.14)$$

Burada  $\mu \geq 0$ ;  $\lambda_1, \lambda_2 > 0$  sabit parametrelerdir;  $c_1$  ve  $c_2$   $\text{ıç}(C)$  ve  $\text{dış}(C)$ 'nin tahmini görüntü yoğunlukları olan iki sabittir;  $|C|$ ,  $C$  sınır hattının uzunluğudur;  $u(x)$ ,  $C$  sınır hattının iç kısmındaki  $I(x)$ 'in üyelik derecesidir;  $m$  ise her bulanık üye üzerindeki ağırlıklandırılmış eksponansiyelidir, diğer bir deyişle  $m$  bulanıklılık derecesidir (bulanık üyelik derecesi  $u(x) \in [0,1]$  olduğu unutulmamalıdır).

$F(C, c_1, c_2, u)$  enerji fonksiyonu üzerindeki minimizasyon ve uzunluk terimi ihmal edilirse, iki sabit olan  $c_1, c_2$  ve değişken  $u(x)$ 'i sabitlerini aşağıdaki şekilde hesaplamak basit olur:

$$c_1 = \frac{\int_{\Omega} [u(x)]^m I(x) dx}{\int_{\Omega} [u(x)]^m dx} \quad (2.15)$$

$$c_2 = \frac{\int_{\Omega} [1 - u(x)]^m I(x) dx}{\int_{\Omega} [1 - u(x)]^m dx}$$

$$u(x) = \frac{1}{1 + \left( \frac{\lambda_1(u(x) - c_1^2)}{\lambda_2(I(x) - c_2^2)} \right)^{\frac{1}{m-1}}} \quad (2.16)$$

Enerji fonksiyonelliğini minimize etmede  $c_1$  ve  $c_2$  optimal sabitleri, iç ve dış aktif sınır hattı değişimi anlamına gelen yoğunluk olduğu açıktır. Yani yöntem, görüntü iki homojen bölgenin birleşimi olduğu varsayımına dayanır.

Klasik ACM'ler ile karşılaştırıldığında FACM, görüntüde yerel minimale sıkışmamak için sınır hatlarına izin verme ve bölütleme problemlerini hızlı kapsamaması gibi bazı avantajlara sahiptir [35]. Ancak arka plandaki karmaşıklığın varlığında ve nesne tıkanması olan görüntüler için tanımlanan durum pek de tatmin edici sonuçlar vermez.

### 2.1.3. Diğer ACM'ler

Alan tabanlı ACM'lerin avantajlarından dolayı sonradan geliştirilen ACM'lerin çoğu alan tabanlıdır.

Sınır hattının değişim yönünü kontrol edebilen alan tabanlı işaretli basınç gücü (SPF-signed pressure force) fonksiyonu [39] inşa etmek için iç ve dış sınır hatlarının istatistiksel bilgisini kullanılmıştır.

Zhang ve arkadaşları yeni bir yöntem olan SBGFRLS seviye belirleme yöntemi önermiştir [25]. Yöntem, SPF'nin hesaplanmaktan uzak durduğu ve yeniden başlatıldığı geleneksel seviye belirleme yöntemlerini geliştirmiştir. Bu yöntem, ilk önce seviye belirleme fonksiyonunun hatalarının ikili olan seçici adım kullanmıştır ve sonrasında düzenli hale getirmek için bir Gauss filtresi kullanmıştır. Gauss Filtresi seviye belirleme fonksiyonunu düzgün hale getirebilir ve gelişimi daha kararlı

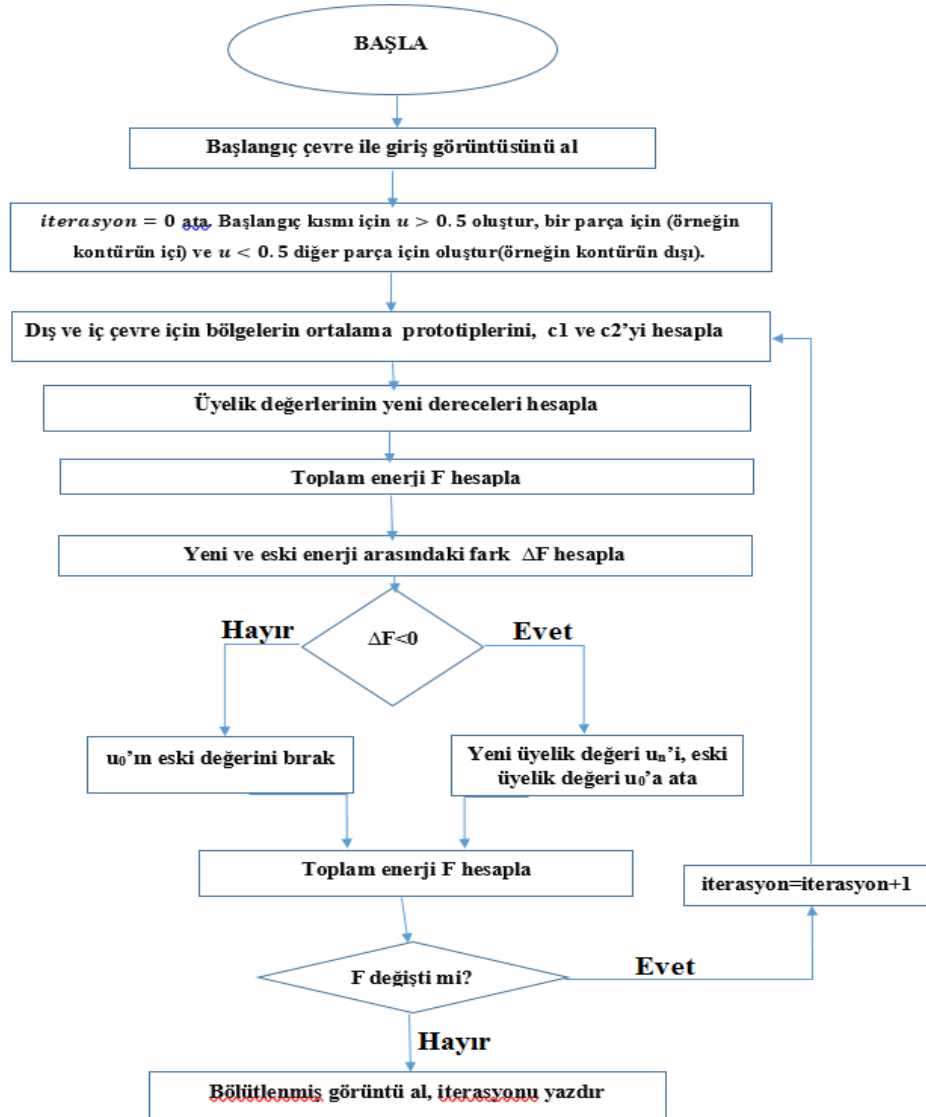
yapabilir. SBGFRLS yöntemi genel ve sağlamdır. Bu yöntem GAC yöntemi [19, 17], C-V yöntemi [40] gibi klasik ACM'lere uygulanabilmektedir. Ayrıca, hesaplama karmaşıklığı analizleri SBGFRLS yönteminin geleneksel seviyeden daha verimli olduğunu göstermiştir. SBGFRLS ile önerilen yöntem yalnızca arzulanan nesnelere değil, aynı zamanda doğru bir şekilde iç ve dış çevrelemelerle tüm nesnelere çıkaran selektif yerel veya küresel bölütleme özelliği vardır. Bu yöneme Bölüm 3'te ayrıntılı biçimde yer verilmiştir.

M.F. Talu tarafından önerilen alan tabanlı yöntemlerden biri olan ORACM; geleneksel ACM'lere kıyasla bölütleme doğruluğunu değiştirmeden, parametre gerektirmeyen ve daha az zaman gerektiren alan tabanlı ACM'dir [41]. Bu yöntem, her yinelemede bir blok eşikleme işlemi gerçekleştirmiştir. Bu eşikleme süreci katı çevrelemeler ve birçok küçük parçacık üretir, nesneye ait değildir. Bu küçük parçacıkları çıkarmak, pürüzsüz ve düzgün nesne çevrelemesi elde etmek için, açma ve kapama morfolojik işlemleri sırasıyla uygulanmıştır [41]. SBGFRLS'ye benzer şekilde ORACM, başlatma adımında kullanıcı tanımlı bir aktif sınır hattı kullanmıştır ve ardından bu sınır hattı görüntüdeki nihai nesne çevrelenmesini bulmak için sürekli güncelleştirilmiştir [41]. Bu yöntemin ayrıntılı açıklamasına Bölüm 3'te yer verilmiştir.

### 3. MATERYAL VE METOTLAR

#### 3.1. FACM

FACM, bir önceki bölümde bahsedildiği gibi alan tabanlı ACM'dir. Bu bölümde önerilen yöntemin açıklaması yapılmıştır. Özellikle önerilen algoritma yüksek yoğunluk homojensizliği içeren görüntü bulanıklaştırma, gürültüyü bölütleyebilir. Bu yöntemi daha iyi anlayabilmek için Şekil 3.1' de akış diyagramı verilmiştir.



Şekil 3.1. FACM Algoritmik Akış Diyagramı

### 3.1.1. Önerilen Yöntem

Bu bölümde hem global hem de lokal bilgi alan bulanık enerji tabanlı bir fonksiyon önerilmiştir.

$I(x):\Omega \rightarrow R^d$  verilen vektörün görüntü değeridir. Burada  $\Omega \subset R^2$  görüntü domainidir ve  $d \geq 1$ :  $I(x)$  vektörünün boyutudur. Özellikle  $d = 1$  gri seviye görüntüler için;  $d = 3$  renkli görüntüler içindir.  $\Omega$  görüntü domaininde kapanan  $C$  sınır hattı olarak tanımlanmıştır.  $\Omega$  iki bölgeye ayrılmıştır.  $\Omega_1 = iç(C)$ ;  $\Omega_2 = dış(C)$ .  $I(x)$  fonksiyonu verildiğinde önerilen enerji fonksiyonunun genel şekli  $\Omega$  görüntü domaini üzerinde iki bölge olarak yaklaşmıştır.

$$\begin{aligned} F(C, c_1, c_2, u) = & \mu L(C) + \lambda_1 \beta \int_{\Omega} [u(X)]^m \|I(X) - c_1\|^2 dX \\ & + \lambda_2 \beta \int_{\Omega} [1 - u(X)]^m \|I(X) - c_2\|^2 dY \\ & + \lambda_1 (1 - \beta) \int_{\Omega} [u(X)]^m \left[ \int_{\Omega} W_{XY} [1 - u(Y)]^m \|I(Y) - c_1\|^2 dY \right] dX \\ & + \lambda_2 (1 - \beta) \int_{\Omega} [1 - u(X)]^m \left[ \int_{\Omega} W_{XY} [u(Y)]^m \|I(Y) - c_2\|^2 dY \right] dX \end{aligned} \quad (3.1)$$

FACM için Eşitlik (3.1)'de verilen enerji fonksiyonunun değişkenleri şu şekilde tanımlanmıştır:

Burada  $c_1, c_2 \in R^d$  ( $C$ 'ye bağımlı) nispeten  $C$  sınır hattının içi ve dışı için bölgelerin ortalama prototipidir.  $u(x)$ , üyelik fonksiyonudur.  $(u(x) \in [0,1]) \rightarrow C$ 'nin iç tarafına ait olan  $X$  pikselinin üyelik derecesidir.  $m > 1$ , her bir üyelik değerinin "bulanıklılığını" kontrol eden ağırlıklı örneğidir.  $I(Y)$ ,  $X$  pikselinin komşuluğundaki  $Y$ . pikselin ağırlığıdır.  $W_{xy}$ ,  $X$  pikselinin lokal(yerel) komşuluğundaki  $Y$ . pikselin ağırlığıdır.  $\lambda_1 > 0$  ve  $\lambda_2 > 0$  iki sabit değeri vardır.  $0 \leq \beta \leq 1$  hem global hem de lokal enerjinin etkisini kontrol etmek için bir sabittir.  $\mu \geq 0$ , sınır hattının uzunluk parametresidir ve kullanıcı tarafından seçilebilir. Yapay olgu olmaksızın kısaca karşılaştırılmıştır[42]. Bu parametre bazı görüntüler için önemli değildir. Ancak

gürültülü görüntü olduğunda, uzunluk parametreleri kullanışlı olabilir [35, 43, 44]. Burada  $W_{XY}$ , ağırlığı hem lokal uzaysal çevrelemeye hem de lokal gri/renk çevrelemeye bağlıdır.  $X \in \Omega$  pikselinin herbiri için lokal uzaysal çevreleme merkezi pikselden uzaysal uzaklıklarla komşuluğunun uzantısını söndürmeyi yansıtır ve;

$$W_{XY}^{SC} = \frac{1}{1+d_{XY}} \quad (SC: \text{spatial constraint}) \quad (3.2)$$

$d_{XY} = ||X - Y||$ ,  $Y \in \eta X$ , burada  $\eta X$ (yerel pencerede)  $X$ 'in uzaysal komşuluğudur. Merkezi piksellerden onların uzaklığına göre değişebilir.

Yerel gri/renkli çevreleme:

$$W_{XY}^{FC} = \exp \left\{ \frac{-||I(X)-I(Y)||^2}{\sum_{Y \in \eta X} ||I(X)-I(Y)||^2} \right\} \quad (3.3)$$

Burada,  $I(X)$ , uzaysal lokal penceredeki  $X$  merkezi pikselinin gri/renkli değeridir.  $I(Y)$ , aynı penceredeki  $Y$ . değer(pikselin) gri/renkli değeridir.  $\eta X$ ,  $X$  pikselinin komşuluğundadır. Gösterici merkezi pikseli çevreleyen yerel yoğunluğun bir fonksiyonudur ve onun değeri bu yerel pencerenin gri/renkli değerli homojenlik derecesini yansıtır.  $\eta X$  değeri küçük olduğu zaman yerel pencere daha homojendir.  $W_{XY}^{FC}$ , bir görüntü üzerindeki piksellerin farklı gri/renkli değerleriyle değişebilir ve bu yüzden yoğun renkli değerler içerisinde söndürülen(azaltılan) uzantıyı yansıtmaktadır. Eşitlik (3.3)'te  $X$  merkezi pikselinin  $Y$ . komşuluğunun  $I(Y)$  yoğunluk değeri  $I(X)$ 'e yakın olduğunu göstermektedir.  $W_{xy}$ , hem lokal uzaysal çevrelemeye hem de gri/renkli çevrelemeye dayanmaktadır ve;

$$W_{XY} = W_{XY}^{SC} * W_{XY}^{FC} \quad (3.4)$$

şeklinde tanımlanmıştır. Enerji fonksiyonu ( Eşitlik (3.1) ) nispeten  $C$  sınır hattı kesinlikle nesnenin çevrelemelerinde olduğunda ve  $c_1$  ve  $c_2$ ,  $C$ 'nin iç ve dış iki bölge

içerisinde verilen görüntüye optimal olarak yaklaştığında minimize edilebilmektedir. Tam nesne çevrelemesini tanımlamak için  $X \in \Omega$  olan tüm pikseller üzerinde Eşitlik (3.1)'de verilen önerilen enerji fonksiyonunu minimize eden bir  $C$  sınır hattı bulmak zorundadır. Ek olarak bazen yumuşatılmış  $C$  sınır hattı önerilen enerji fonksiyonu için düşünülmüştür. Ayrıca önerilen enerji fonksiyonu için bazen  $C$  sınır hattını yumuşatmak için  $C$  sınır hattının  $L(C)$  uzunluğunda bir ceza (penalty) terimi düşünülmüştür.  $C_0$ , görüntüdeki nesnenin optimal çıkarılmış çevrelemelerini kapsar, o yüzden  $C = C_0$  olduğunda Eşitlik (3.1)'de verilen enerji fonksiyonu minimize edilebilir.

$$C_0 = \operatorname{argmin} F(C, c_1, c_2, u) \quad (3.5)$$

Buradan sınır hattı başlangıcı  $C_0$ (nesnenin çevrelemeleri) bölütleme probleminin çözümü olduğu aşikârdır.

### 3.1.2. Sözde Kod Seviye Küme Fonksiyonu

Bu bölümde [35] ve [45]'de ilgili olarak önerilen bulanık enerji fonksiyonu sözde kod seviye küme fonksiyonu kullanarak formülleştirilmiştir.

Sınır hattı  $C \subset \Omega$ , Lipshitz benzerlik fonksiyonu  $u: \Omega \rightarrow R$  'nin sözde sıfırıncı seviye kümesi tarafından imalı olarak sunulmuştur, ki o;

$$\begin{cases} C = \{X \subset \Omega : u(X) = 0.5\} \\ \text{inside}(C) = \{X \in \Omega : u(X) > 0.5\} \\ \text{outside}(C) = \{X \in \Omega : u(X) < 0.5\} \end{cases} \quad (3.6)$$

şeklindedir.



Burada düzenlenen ya da Eşitlik (3.1)'de verilen önerilen enerji fonksiyonunu  $F(C, c_1, c_2, u)$ 'da  $L(C) = \int_{\Omega} |\nabla H(u(X) - 0.5)| dx$ ,  $H(s)$  iyonosfer (heaviside) fonksiyonudur. Eşitlik (3.1)'deki enerji fonksiyonunu tekrardan yazılacak olursa;

$$\begin{aligned}
F(C, c_1, c_2, u) = & \mu \int_{\Omega} |\nabla H(u(X) - 0.5)| dX + \lambda_1 \beta \int_{\Omega} [u(X)]^m \|I(X) - c_1\|^2 dY \\
& + \lambda_2 \beta \int_{\Omega} [1 - u(X)]^m \|I(X) - c_2\|^2 dX \\
& + \lambda_1 (1 - \beta) \int_{\Omega} [u(X)]^m \left[ \int_{\Omega} W_{xy} [1 - u(Y)]^m \|I(Y) - c_1\|^2 dY \right] dX \\
& + \lambda_2 (1 - \beta) \int_{\Omega} [1 - u(X)]^m \left[ \int_{\Omega} W_{xy} [u(Y)]^m \|I(Y) - c_2\|^2 dY \right] dX
\end{aligned} \tag{3.7}$$

şeklinde olmaktadır.

Önerilen enerji fonksiyonu minimize edildiği zaman  $C$  sınır hattının iç kısmına konumlanmış pikselleri için  $u$ 'nun değeri, dış kısmına konumlanmış çevreleme değerinden farklıdır. Ancak  $C$  sınır hattının iç tarafında konumlanmış pikseller kendi aralarında benzer değerlere sahiptir. Bu  $C$  sınır hattının dış tarafında konumlanmış pikseller için de aynıdır. Diğer bir deyişle  $u$  üyelik değeri, iç ve dış çevreleme için farklı değerler almaktadır fakat kendi aralarında benzer değerler almaktadır.

$u$  üyelik değeri sabit tutulmuştur ve Eşitlik (3.7) deki  $F(C, c_1, c_2, u)$  enerji fonksiyonu minimize edilerek  $c_1$  ve  $c_2$  değeri nispi olarak Eşitlik (3.8) ve Eşitlik (3.9)'da verilen şekilde bulunmuştur:

$$\int_{\Omega} [u(X)]^m \|I(X) - c_1\|^2 dX = 0 \Rightarrow c_1 = \frac{\int_{\Omega} [u(X)]^m I(X) dX}{\int_{\Omega} [u(X)]^m dX} \tag{3.8}$$

$$\int_{\Omega} [1 - u(X)]^m \|I(X) - c_2\|^2 dX = 0 \Rightarrow c_2 = \frac{\int_{\Omega} [1-u(X)]^m I(X) dx}{\int_{\Omega} [1-u(X)]^m dx} \quad (3.9)$$

Tekrar  $c_1$  ve  $c_2$  sabit tutulmuştur ve Eşitlik (3.7)'de verilen enerji fonksiyonu  $F(C, c_1, c_2, u)$  minimize edilerek  $u(X)$ 'e indirgenmiştir;

$$\begin{aligned} F(C, c_1, c_2, u) = & \lambda_1 \beta m [u(X)]^{m-1} \|I(X) - c_1\|^2 - \lambda_2 \beta m [1 - u(X)]^{m-1} \|I(X) - c_2\|^2 \\ & + \lambda_1 (1 - \beta) m [u(X)]^{m-1} \left[ \int_{\Omega} W_{xy} [1 - u(Y)]^m \|I(Y) - c_1\|^2 dY \right] \\ & - \lambda_2 (1 - \beta) m [1 - u(X)]^{m-1} \left[ \int_{\Omega} W_{xy} [u(Y)]^m \|I(Y) - c_2\|^2 dY \right] = 0 \end{aligned}$$

$$\Rightarrow u(X)$$

$$\begin{aligned} &= \frac{1}{\left( \frac{\lambda_1 \left\{ \beta \|I(X) - c_1\|^2 + (1 - \beta) \int_{\Omega} W_{xy} [1 - u(Y)]^m \|I(Y) - c_1\|^2 dY \right\}}{\lambda_2 \left\{ \beta \|I(X) - c_2\|^2 + (1 - \beta) \int_{\Omega} W_{xy} [u(Y)]^m \|I(Y) - c_2\|^2 dY \right\}} \right)^{1/(m-1)}} \end{aligned} \quad (3.10)$$

Kısacası genel yapısını kaybetmeden Eşitlik (3.10) minimizasyonu üzerinde uzunluk terimi (örn:  $\mu = 0$ ) ihmal edilerek formülizasyon hesaplanmıştır.

### 3.1.3. Nümerik Yaklaşım

Verilen görüntünün  $P \in \Omega$  pikseli için  $P$  pikselinin yoğunluk değeri  $I_0$ 'dır.  $I_0$  için üyeliğin karşılık gelen değeri  $u_0$ 'dır. Farz edilir ki; Eşitlik (3.10) kullanılarak hesaplanan  $P$  pikselinin üyelik derecesi yeni bir  $u_n$  değeri ile değiştirilmiştir. Sonrasında  $\Delta F$ ,  $P$  pikselinin üyelik derecesi değiştiğinde eski ve yeni enerji arasındaki fark olmaktadır. bu durumda,  $\Delta F$  şu formülasyonu takip ederek hesaplanmıştır:

$$\begin{aligned}
\Delta F &= \lambda_1 \beta S_1 \alpha_1 \|I_o - c_1\|^2 + \lambda_2 \beta S_2 \alpha_2 \|I_o - c_2\|^2 - 2\lambda_1(1 - \beta) S_1 \|I_o - c_1\|^2 b_1 \\
&+ \lambda_1(1 - \beta) g_1 [\|c_1 + S_1(\|I_o - c_1\|)\|^2 - \|c_1\|^2] \\
&+ \lambda_1(1 - \beta)(u_n^m - u_o^m) \left\{ \sum_{\Omega} W_{oY} [1 - u(Y)]^m \|I(Y) - c_1 - S_1(\|I_o - c_1\|)\|^2 \right\} \\
&+ \lambda_1(1 - \beta)(u_n^m - u_o^m) \left\{ \sum_{\Omega} W_{oY} [1 - u(Y)]^m \|I_o - c_1\|^2 [1 - S_1]^2 \right\} \\
&- 2\lambda_2(1 - \beta) S_2 \|I_o - c_2\|^2 b_2 + \lambda_2(1 - \beta) g_2 [\|c_2 + S_2(\|I_o - c_2\|)\|^2 - \|c_2\|^2] \\
&+ \lambda_2(1 - \beta)[(1 - u_n)^m - (1 - u_o)^m] \left\{ \sum_{\Omega} W_{oY} [u(Y)]^m \|I(Y) - c_2 - S_2(\|I_o - c_2\|)\|^2 \right\} \\
&+ \lambda_2(1 - \beta)[(1 - u_n)^m - (1 - u_o)^m] \left\{ \sum_{\Omega} W_{oY} [u(Y)]^m \|I_o - c_2\|^2 [1 - S_2]^2 \right\},
\end{aligned} \tag{3.11}$$

Burada;

$$\begin{aligned}
\alpha_1 &= \sum_{\Omega} u(X)^m, \\
\alpha_2 &= \sum_{\Omega} [1 - u(X)]^m, \\
S_1 &= \frac{u_n^m - u_o^m}{\sum_{\Omega} u(X)^m + u_n^m - u_o^m} \\
S_2 &= \frac{(1 - u_n)^m - (1 - u_o)^m}{\sum_{\Omega} [1 - u(X)]^m + (1 - u_n)^m - (1 - u_o)^m}
\end{aligned}$$

$$b_1 = \sum_{\Omega} u(X)^m \left\{ \sum_{\Omega} W_{XY} [1 - u(Y)]^m I(Y) \right\}$$

$$b_2 = \sum_{\Omega} [1 - u(X)]^m \left\{ \sum_{\Omega} W_{XY} [u(Y)]^m I(Y) \right\}$$

$$g_1 = \sum_{\Omega} u(X)^m \left\{ \sum_{\Omega} W_{XY} [1 - u(Y)]^m \right\}$$

$$g_2 = \sum_{\Omega} [1 - u(X)]^m \left\{ \sum_{\Omega} W_{XY} [u(Y)]^m \right\}$$

şeklindedir.

Kısaca bulanık enerji fonksiyonu tarafından değerlendirilen ACM'nin önerilen algoritması:

**Algoritma 1.** Görüntü bölütleme için dayanıklı global ve lokal FACM.

1. Başlangıç kısmı için bir parça için  $u > 0.5$  oluştur (örneğin sınır hattının içi) , ve diğer parça için  $u < 0.5$  oluştur (örneğin sınır hattının dışı).
2. Eşitlik (3.8) ve (3.9)'da kullanılan  $c_1$  ve  $c_2$ 'yi hesapla.
3. Farz edilir ki mevcut  $P$  pikselinin yoğunluk değeri  $I_o$ 'dır ve  $u_o$  onun üyelik değerinin derecesidir. O zaman  $u_n$  üyelik değerinin yeni derecesi mevcut piksel için Eşitlik (3.10) kullanılarak hesaplanmıştır. Yeni ve eski enerji arasındaki fark  $\Delta F$ , Eşitlik (3.11) kullanılarak hesaplanmıştır. Eğer  $\Delta F < 0$  ise o zaman  $u_o, u_n$  yer değiştirilir, değilse  $u_o$ 'ın eski değeri tutulmaktadır.
4. Tüm görüntü için toplam enerji  $F$ 'yi hesaplamak için Jacobi iterasyonu kullanarak adım 3'ü tekrarla.
5. Hala toplam enerji  $F$  değişmezse adım 2-4 ü tekrarla.

### 3.1.4. Hesapsal Karmaşıklık

$M \times N$  boyutlu görüntü verilmiş olduğu varsayılmıştır.  $W$  düşünülen komşuluğun boyu olsun ve  $T$  kümeleme için gereken iterasyonların toplam sayısı olmak üzere algoritma için gereken toplam zaman:

$$f_t = O(M * N * T * W)$$

Böyle deneylerde  $W$  sabittir, bu yüzden;

$$f_t = O(M * N * T) \quad (3.12)$$

## 3.2. C-V YÖNTEM

Mumford-Shah bölütleme tekniklerini temel alan C-V yönteminin seviye belirleme formülasyonu, domain  $\varphi$ 'deki belirli bir görüntü için, aşağıdaki duruma göre hareket etmektedir:


$$\begin{cases} C = \{x \in \varphi : \emptyset(x) = 0\} \\ i\check{c}(C) = \{x \in \varphi : \emptyset(x) > 0\} \\ dı\check{s}(C) = \{x \in \varphi : \emptyset(x) < 0\} \end{cases} \quad (3.13)$$

Burada  $\emptyset(x)$  seviye kümesini belirtmekte ve  $C$  görüntüdeki aktif sınır hattını göstermektedir. Sıfır seviyesi ( $\emptyset(x) = 0$ ) değerini güncellenebilmesi için, C-V yöntemi, aşağıda verilen ilgili varyasyon düzeyi formülünü hesaplamıştır:

$$\frac{\partial \emptyset}{\partial t} = \delta(\emptyset) \left[ \mu \nabla \left( \frac{\nabla \emptyset}{|\nabla \emptyset|} \right) - \nu - \lambda_1 (I - c_1)^2 + \lambda_2 (I - c_2)^2 \right] \quad (3.14)$$

Burada  $\mu$ , seviye kümesinin pürüzsüzlüğünü kontrol etmektedir;  $\nu$ , yayılma hızını arttırmaktadır;  $\lambda_1$  ve  $\lambda_2$ , çevreleme içindeki ve dışındaki resim verilerine dayalı kuvveti kontrol eden sabit parametreler olarak tanımlanmaktadır.  $\nabla$ , gradyan

operatörüdür.  $H(\emptyset)$  ve  $\delta(\emptyset)$  Heaviside fonksiyonu ve Dirac fonksiyonu olarak Şekil 3.1’de sırasıyla gösterilmiştir [41].



**Şekil 3.2.** (a) İyonosfer(Heaviside) fonksiyon (b) Dirac fonksiyon.

$c_1$  ve  $c_2$  sırasıyla çevrelemesin içindeki ve dışındaki ortalama yoğunlukları olan iki sabit aşağıdaki gibi hesaplanmıştır:

$$c_1(\emptyset) = \frac{\int^I(x) \cdot H(\emptyset) dx}{\int^H(\emptyset) dx} \quad (3.15)$$

$$c_2(\emptyset) = \frac{\int^I(x) \cdot (1 - H(\emptyset)) dx}{\int^H(1 - H(\emptyset)) dx}$$

C-V yöntemi iki önemli dezavantaja sahiptir. İlk olarak, yüksek hesaplama gideri eğiliminde olan sınır hattı yaklaşımı  $\nabla\emptyset$  'ı hesaplamaya ihtiyaç duymaktadır. İkincisi, yalnızca küresel bölütleme özelliği taşır ve bu özellik istenen nesneyi uygun bir başlangıç çevrelemesi ile bölütleyebilmektedir. Görüntüdeki nesnenin içinde başlangıçtaki sınır hattını ayarlayarak iç çevrelemeyi çıkaramaz ve tüm nesnelere bölütlemeye başarısız olur.

### 3.3. SBFRLS

SBGFRLS'de sınır hattı kullanıcı tanımlı olarak başlatma adımında belirlenmektedir ve daha sonra aşağıdaki gibi tanımlanan alan tabanlı bir işaretli basınç fonksiyonu (SPF) ile sürekli güncellenen bir başka bölgeye dayalı yöntem olarak bilinmektedir.

$$spf(I(x, y)) = \frac{I(x, y) - \frac{c_1 + c_2}{2}}{\max(|I(x, y) - \frac{c_1 + c_2}{2}|)} \quad (3.16)$$

Burada  $c_1$  ve  $c_2$ , C-V yönteminde yazıldığı gibi hesaplanmaktadır.  $c_1$  ve  $c_2$  hesaplamasında C-V yönteminin aksine SBFRLS yöntemi, bir Heaviside işlevini yalnızca  $eps = 0$  ile kullanmaktadır. SPF fonksiyonu, ilgi alanı içindeki ve dışındaki basınç kuvvetinin işaretlerini modüle etmektedir. Böylece sınır hattı görüntüdeki nesnenin dışındayken küçülmektedir veya görüntüdeki nesnenin içinde olduğunda genişlemektedir.


Buna ek olarak SBFRLS, aşağıdaki şekilde verilen ilgili varyasyon düzeyi formülasyonunu kullanmıştır:

$$\frac{\partial \phi}{\partial t} = spf(I(x)) \cdot \alpha \cdot |\nabla \phi| \quad (3.17)$$

Burada  $\alpha$  sabittir ve seviye küme güncellemesinin hızını kontrol etmektedir. SBFRLS'nin en büyük dezavantajı olayın sonuca büyük etkisi olmasına rağmen başlangıç sınır hattının görüntüye göre ayarlanması gerekmektedir. Bu durum SBFRLS'yi farklı görüntülerde zorlaştırmıştır ve gerçek zamanlı video görüntülerinde nihai çevreleme sonucuna ulaşmayı imkansız hale getirmiştir. Diğer dezavantajı yavaş olmasıdır.  $|\nabla \phi|$  seviye seti fonksiyonunun gradyanını belirtmektedir ve aşağıdaki formülle hesaplanmıştır:

$$\nabla g = \sqrt{\phi_x^2 + \phi_y^2} \text{ } \left. \vphantom{\sqrt{\phi_x^2 + \phi_y^2}} \right\} \text{ gradyan} \quad (3.18)$$

Seviye seti formulasyonunda  $|\nabla\phi|$  kullanarak görüntüdeki nesne çevrelemesinde SPF fonksiyonunun sonucunu yayar. Bu durumda seviye setinin çevrelemesi yalnızca güncellenmiştir, bu da yavaşlamaya neden olmuştur. Daha iyi anlaşılabilmesi için SBGFRLS'nin bir iterasyonu Şekil 3.3'te gösterilmiştir [41].



Şekil 3.3. SBGFRLS Görüntü Üzerinde Bir İterasyon




### 3.4. ORACM

SBGFRLS'ye benzer şekilde ORACM de başlatma adımında kullanıcı tanımlı etkin sınır hattı kullanmıştır ve daha sonra bu sınır hattını sürekli güncelleştirmiştir. ORACM, basit ve etkili bir seviye kümesi güncelleme formülünü aşağıdaki gibi kullanmıştır:

$$\frac{\partial \phi}{\partial x} = H(\text{spf}(I(x)))\phi(x)$$

Burada  $H(\cdot)$  grafikli şekilde gösterilen heaviside fonksiyonudur. Şekil 3.4'te bir iterasyon için çalışma mantığı gösterilmiştir [41]:




Şekil 3.4. ORACM Görüntü Üzerinde Bir İterasyon

#### 4. UYGULAMA

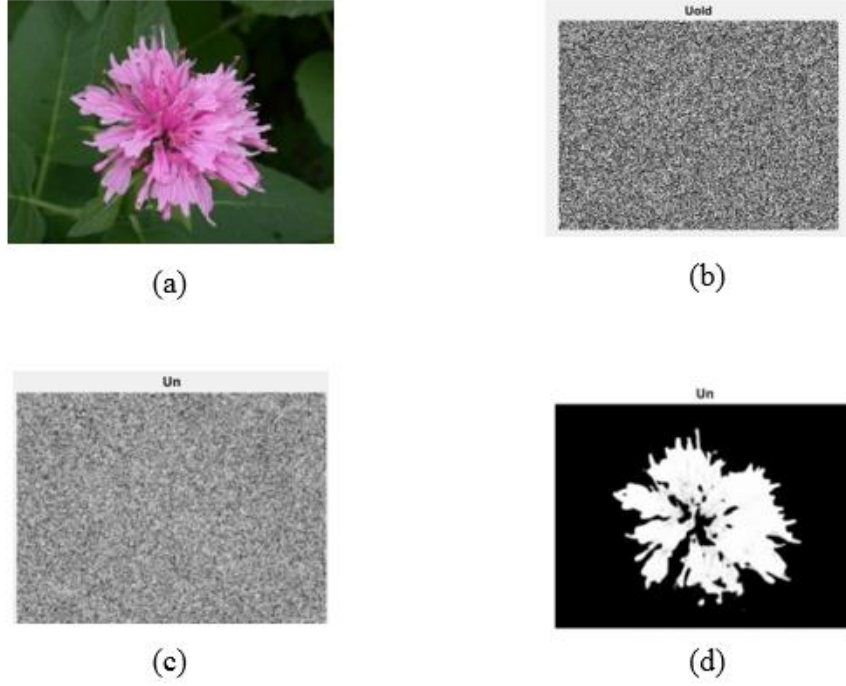
Bu bölümde alan tabanlı ACM'lerden olan C-V yöntemi, SBFRLS yöntemi, ORACM ve önerilen FACM karşılaştırılmıştır. Uygulama MSI marka bilgisayarda Windows 10 işletim sistemi üzerinde Matlab yazılımı kullanılarak 13 görüntü üzerinde uygulanmıştır.

FACM, Bölüm 3'de gösterilen formülde  $u$  üyelik derecesi  $[0,1]$  aralığında değişmektedir. FACM'yi daha iyi anlayabilmek için bulanık mantığın ve görüntü işleminin temellerini bilmeye ihtiyaç duyulmaktadır. İlk kez 1965 yılında Lotfi A. Zadeh tarafından önerilen bulanık mantık, günümüzde birçok konuda uygulama alanı bulmuştur. Bulanık mantığın uygulama alanlarından birisi de kümelemedir. Keskin kümeler 0 yada 1 değeri ile işlev görürler. Bulanık kümeler ise  $[0,1]$  aralığında değişken değerlere sahiptir. Lotfi A. Zadeh her şeyin bir bulanıklık değeri olduğunu ve hiçbir şeyin kesin değerinin olmadığını vurgulamıştır. Üyelik derecesi  $u$  olarak adlandırılır ve bu değer bahsedilen gibi net olmayan  $[0,1]$  arasında değişen değerdir. Yaptığımız uygulamada görüntüde üyelik dereceleri toplamı klasik kümelerde de olduğu gibi 1'e eşittir.

FACM'nin görüntü üzerinde çalışma biçimi Şekil 4.1'de gösterilmiştir:



Şekil 4.1. FACM'nin Çalışma Biçimi




**Şekil 4.2.** (a) Orijinal Görüntü (b) Üyelik Derecesi Matrisinin İlk Durumu (c) Üyelik Derecesi Matrisinin Bir İterasyon Sonraki Durumu (d) Üyelik Derecesi Matrisinin Son Durumu

Başlangıç sınır hattı, Şekil 4.3'te gösterilmiştir. Bu başlangıç sınır hattı, tüm yöntemler için uygulanmıştır.




**Şekil 4.3.** ACM'yi Başlatma

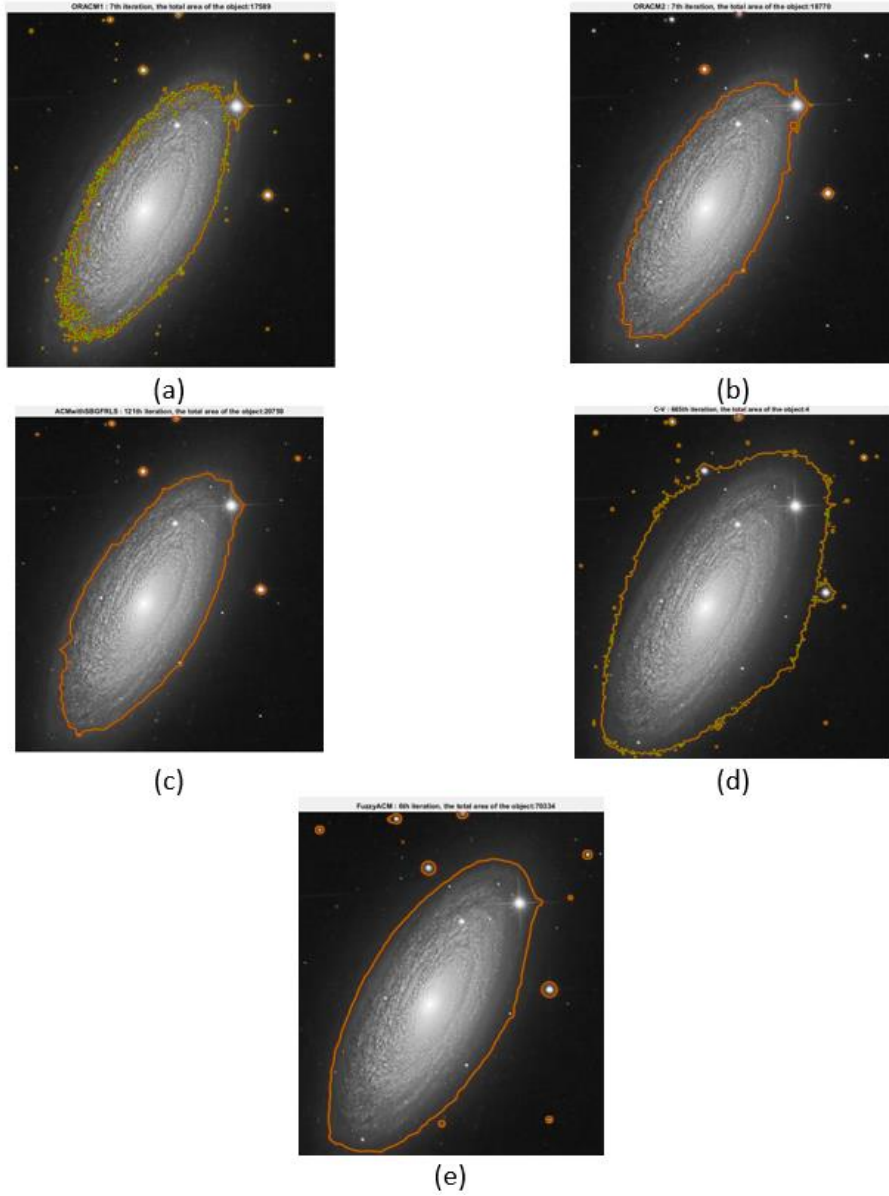
Şekil 4.4 ve Şekil 4.14 arasında uygulanan görüntüler üzerindeki ACM'lerin sonuçları karşılaştırılmıştır.




Şekil 4.4. (a) ORACM1 (b) ORACM2 (c) SBGFRLS (d) C-V (e) FACM



Şekil 4.5. (a) ORACM1 (b) ORACM2 (c) SBFGRFS (d) C-V (e) FACM




Şekil 4.6. (a) ORACM1 (b) ORACM2 (c) SBGFRLS (d) C-V (e) FACM




**Şekil 4.7.** (a) ORACM1 (b) ORACM2 (c) SBGFRLS (d) C-V (e) FACM






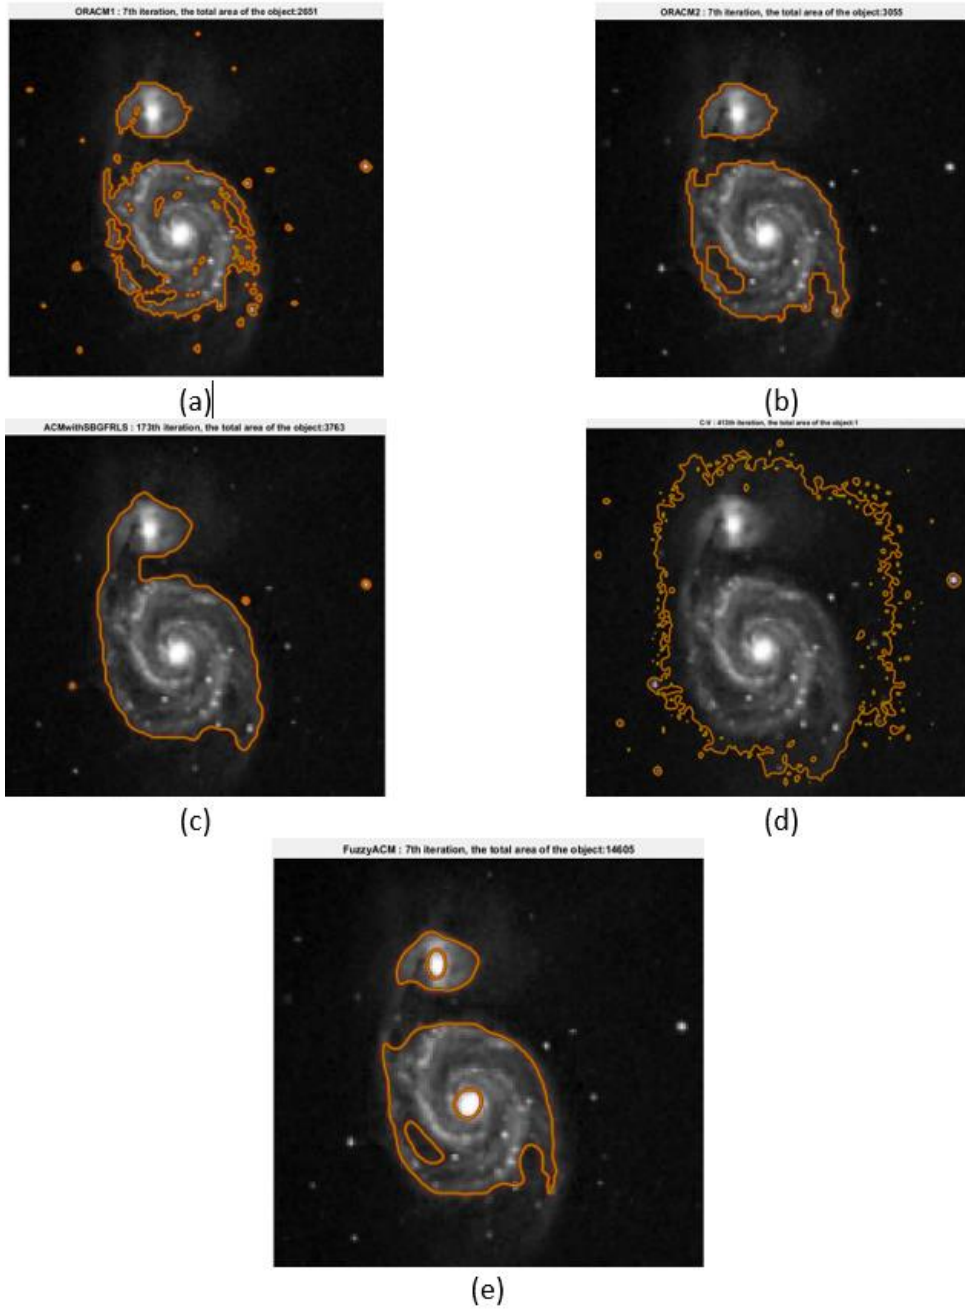
Şekil 4.8. (a) ORACM1 (b) ORACM2 (c) SBGFRLS (d) C-V (e) FACM




Şekil 4.9. (a) ORACM1 (b) ORACM2 (c) SBFRLS (d) C-V (e) FACM




Şekil 4.10. (a) ORACM1 (b) ORACM2 (c) SBFGRFS (d) C-V (e) FACM




Şekil 4.11. (a) ORACM1 (b) ORACM2 (c) SBFGRS (d) C-V (e) FuzzyACM



Şekil 4.12. (a) ORACM1 (b) ORACM2 (c) SBGFRLS (d) C-V (e) FACM




Şekil 4.13. (a) ORACM1 (b) ORACM2 (c) SBFRLS (d) C-V (e) FACM



Şekil 4.14. (a) ORACM1 (b) ORACM2 (c) SBFRLS (d) C-V (e) FACM

Şekil 4.15'te, FACM'nin bir görüntü üzerinde 9 ile 14 iterasyon arasındaki değişimi gösterilmiştir.



Şekil 4.15. FACM'nin Görüntü Üzerindeki Değişimi



Çizelge 4.1’ de kullanılan ACM’lerin performans ve iterasyon bakımından sonuçlarına yer verilmiştir.

**Çizelge 4.1.** ACM’lere Göre Süre ve İterasyon Sonuçları

Görüntü	Özellikler	Boyut	ORACM1		ORACM2		SBGERLS		C-V		FUZZY ACM	
			Süre(sn)	İterasyon	Süre(sn)	İterasyon	Süre(sn)	İterasyon	Süre(sn)	İterasyon	Süre(sn)	İterasyon
Görüntü 1	96x96	114x101	0,117212	2	0,113526	2	0,333413	7	2,842474	55	13,2	5
Görüntü 2	96x96	114x101	0,274005	5	0,176445	3	0,516317	11	1,252217	22	12,02	10
Görüntü 3	72x72	319x127	0,482132	7	0,517858	7	10,38624	122	14,90391	151	50	8
Görüntü 4	72x72	88x104	0,251655	4	0,184328	3	1,693851	32	12,63048	151	5,9618	5
Görüntü 5	96x96	400x320	0,689046	5	0,769312	6	44,06085	269	178,2538	641	9,8754	10
Görüntü 6	72x72	272x297	0,73145	7	0,710015	7	14,15632	121	166,9359	665	15,7	6
Görüntü 7	96x96	200x227	0,729579	7	0,407698	5	5,218473	64	15,44183	141	22,3642	6
Görüntü 8	72x72	88x104	0,217965	4	0,312703	5	0,937738	19	0,995571	19	6,38	6
Görüntü 9	96x96	136x132	0,24645	4	0,186726	3	1,069857	21	11,94857	147	10,6873	6
Görüntü 10	96x96	146x134	0,410007	7	0,428923	7	12,98545	173	62,16796	413	11,3335	7
Görüntü 11	72x72	108x130	0,206751	3	0,18866	3	1,803083	33	5,405693	82	8,3114	7
Görüntü 12	72x72	95x93	0,132442	2	0,347299	6	0,79454	17	1,151778	22	35,2114	37
Görüntü 13	72x72	667x500	2,494524	6	1,996283	7	100,0639	285	98,44027	227	360,3569	14

## 5. SONUÇ VE ÖNERİLER

Bölütleme sonucu incelendiğinde, Şekil 4.5 hariç diğer şekillerde FACM, C-V ve SBGFRLS yöntemlerine göre daha iyi sonuç vermiştir. Önerilen yöntem, Şekil 4.4'te verilen hem keskin sınır hatlı hem de gürültülü görüntüde bölütleme olarak iyi bir sonuç verse de tam sonuca ulaşamamıştır. Şekil 4.9, Şekil 4.10, Şekil 4.13'te net olmayan görüntülerde de aynı sonuçlar elde edilmiştir. FACM, Şekil 4.11'de tüm yöntemlere oranla daha iyi çalışır. Şekil 4.12, görüntü belirli bir şekle sahip olduğundan tüm yöntemler hemen hemen aynı çalışmıştır. FACM, ORACM1 yöntemine göre iyi performans gösterememiş; genellikle ORACM2 yöntemiyle aynı sonuçlara sahip olmuştur. Bölüm 4'te edilen sonuçlara bakıldığında hem net olmayan görüntüler için hem net olan görüntülerde iyi bir bölütleme sonucuyla karşılaşılmıştır. Bölütleme olarak ORACM2 yöntemiyle neredeyse aynı sonuca sahiptir. Genel olarak FACM, ORACM1 yöntemi hariç diğer yöntemlerden daha iyi bölütleme sonucuna sahiptir.

İterasyon açısından incelendiğinde; FACM'nin C-V ve SBGFRLS yöntemlerinden çok daha iyi çalıştığı gözlemlenmiştir. Bu yöntem, ORACM2 yöntemiyle yakın sonuçlara sahiptir.

Performans olarak bakıldığında boyutu büyük olan görüntülerde SBGFRLS yöntemi doğru bir şekilde çalışmaz. Önerilen yöntem, C-V ve SBGFRLS yöntemlerine oranla çok daha iyi çalışmıştır. Fakat ORACM yöntemlerine göre iyi bir performans sergilememiştir.

Çizelge 4.1'de görüntülerin çözünürlüklerine ve boyutuna göre inceleme yapılmıştır. Görüntü 1 ve 2'nin boyutu ve çözünürlükleri aynıdır. Görüntü 2, Görüntü 1'in gürültü eklenmiş şeklidir. Gürültü bulunan Görüntü 2'de performans ve iterasyon daha yavaştır. Piksel sayısı arttıkça C-V ve SBGFRLS yöntemlerinin çevrelemesi nesne çevrelemelerine oturtma yeteneği azalır. Bu yüzden iterasyon sayısı artar. Diğer yöntemler için bu durum söz konusu değildir.

Önerilen yöntemde, Matlab yazılım ortamında matrissel çalışma yapıldığından performansı yavaş olduğu düşünülmektedir. Bunun yerine vektörel çalışma önerilmiştir.

## KAYNAKÇA

- [1] Ebru Karabatak, *Nötrozofi Yaklaşımı İle Renkli Görüntü Bölütleme*, Yüksek Lisans Tezi, Fırat Üniversitesi Türkiye, Şubat 2010.
- [2] Z. Chi, H. Yan ve P. T., *Fuzzy Algorithms: with application to image processing and pattern recognition*, World Scientific Publishing Co. Pte.Ltd., 1996.
- [3] R. C. Gonzalez ve R. E. Woods, *Digital Image Processing*, Adison Wesley Publishing Company, 2008, 77-102.
- [4] E. E. Kerre ve M. Nachtgeael, *Fuzzy Techniques in Image Processing*, Physica-Verlag Heidelberg,Almanya, 2000.
- [5] G. J. Awcock ve R. Thomas, *Applied Image Processing*, McGraw-Hill, Inc., 1996.
- [6] H. D. Cheng, X. H. Jiang, Y. Sun ve J. L. Wang, "Color image segmentation: advances and prospects" , in *Pattern Recognition*, 2001, p. 34.
- [7] R. Dass, Priyanka and S. Devi, *Image Segmentation Techniques*, **IJECT**, 3:1 (2012).
- [8] D. L. Pham, C. Y. Xu ve Prince J. L., *Current methods in medical image segmentation*, **Annu Rev Biomed Eng**, (2000), 315-+,.
- [9] I. Njeh, I. Ben Ayed ve A. Ben Hamida, "A Distribution-Matching Approach to Mri Brain Tumor Segmentation" in 2012 9th Ieee International Symposium on Biomedical Imaging (Isbi), 2012, p.1707-1710
- [10] R. Cardenes, R. de Luis-Garcia ve M. Bach-Cuadra, *A multidimensional segmentation evaluation for medical image data*, **Comput Meth Prog Bio**, (2009) ,96, 2, 108-24
- [11] T. N. A. Nguyen, J. Cai, J. Zhang and J. & Zheng, *Robust interactive image segmentation using convex active contours*, **IEEE Transactions on Image Processing**,21: 8 (2012) 3734-3743.
- [12] M. Kass, A. Witkin and D. Terzopoulos, *Snakes: Active contour models*, *International journal of computer vision*,1:4 (1988) 321-331.
- [13] D. Paragios and R. Deriche, *Geodesic active contours and level sets for the detection and tracking of moving objects*, **IEEE Trans. Pattern Anal. Mach.**

**Intell**, 22 :3 (2010) 266–280.

- [14] S. Gunn, *Dual active contour models for image feature extraction*, Doktora tezi, Southampton Üniversitesi, 1994.
- [15] H. M. B. S. & M. S. K. Li, *A contour-based approach to multisensor image registration*, **IEEE transactions on image processing**, 4:3, (1995) 320-334.
- [16] D. Cremers, M. Rousson and R. Deriche, *A review of statistical approaches to level set segmentation: integrating color, texture, motion and shape* **International journal of computer vision**, 72:2 (2007) 195-215.
- [17] V. Caselles, F. Catté, T. Coll and F. Dibos, *A geometric model for active contours in image processing*, **Numerische mathematic**, 66:1 (1993) 1-31.
- [18] R. Malladi, J. Sethian ve B. Vemuri, *Shape modeling with front propagation: a level set approach*, **IEEE Trans. Pattern Anal. Mach. Intell**, 17:2 (1995) 158-175.
- [19] V. Caselles, R. Kimmel and G. Sapiro, *Geodesic active contours*, **International journal of computer vision**, 22:1 (1997) 61-79.
- [20] A. Yezzi, S. Kichenassamy, A. Kumar, P. Olver and A. Tannenbaum, *A geometric snake model for segmentation of medical imagery*, **IEEE Trans. Med. Imaging**, 16:2 (1997) 199– 209.
- [21] Cohen, L.; Kimmel, R., *Global minimum for active contour models: A minimal path approach*, **Int. J. Comput. Vis.**, 24:1 (1997) 57–78.
- [22] D. Baswaraj, A. Govardhan and P. Premchand, *Active contours and image segmentation: The current state of the art.*, **Global Journal of Computer Science and Technology**, (2012) p. 11-F.
- [23] A. Mishra, Y. Aloimonos, L. F. Cheong ve A. Kassim, *Active visual segmentation*, **IEEE Transactions on Pattern Analysis and Machine Intelligence**, (2012) 639-653.
- [24] L. D. Cohen, *On active contour models and balloons*, **CVGIP: Image understanding**, 53:2 (1991) 211-218.
- [25] K. Zhang, L. Zhang, H. Song and Z. W., *Active contour with selective local or global segmentation: A new formulation and level set method*, **Image and Vision Computing**, 28 (2009) 668-676.

- [26] W. X. Kang, Q. Q. Yang and R. P. Liang, "The comparative research on image segmentation algorithms," In Education Technology and Computer Science, 2009. ETCS'09 First International Workshop on Vol. 2, 2009, p. 703-707.
- [27] H. Zhang, J. E. Fritts ve S. A. Goldman, *Image segmentation evaluation: A survey of unsupervised methods*, **Computer Vision and Image Understanding**, 110:2 (2008) 260-280.
- [28] D. Mumford and J. Shah, *Optimal approximations by piecewise smooth functions and associated variational problems*, **Communications on pure and applied mathematics**,42:5 (1989) 577-685.
- [29] X. Jiang, R. Zhang ve S. Nie, *Image segmentation based on PDEs model: A survey* **Bioinformatics and Biomedical Engineering, 2009. ICBBE 2009. 3rd International Conference on**, 2009.
- [30] L. Bar, T. F. Chan, C. Ginmo, M. Jung, N. Kiryati, R. Mohieddine, N. Sochen ve L. Vese, *Mumford and shah model and its applications to image segmentation and image restoration*, Handbook of mathematical methods in imaging, Springer, New York, 2011, p. 1095-1157.
- [31] J. A. Sethian, *Level set methods and fast marching methods: evolving interfaces in computational geometry, fluid mechanics, computer vision, and materials science*, **Cambridge university press**, no. 3, 1999.
- [32] T. Chan ve L. Vese, *A multiphase level set framework for image segmentation using the mumford and shah model*, **Tech. Rep. 0125, Computational Applied Math Group, UCLA**, (2001) 32.
- [33] O. Michailovich, Y. Rathi and A. Tannenbaum, *Image segmentation using active contours driven by the Bhattacharyya gradient flow*, **IEEE Trans. Image Process**, 15 (2007) 2787–2810.
- [34] M. Rousson and R. Deriche, *A variational framework for active and adaptive segmentation of vector valued images*, **Proceedings of the IEEE Workshop on Motion and Video Computing**, (2002) 56–62.
- [35] S. Krinidis and V. Chatzis, *Fuzzy energy-based active contour*, **IEEE Trans. Image Process**, 18 (2009) 2747–2755.
- [36] A. Yezzi, A. Tsai and A. Willsky, *A fully global approach to image segmentation via coupled curve evolution equations*, **J. Vis. Commun. Image Represent**, 13 (2002) 195–216.

- [37] A. Mondal, G. Susmita ve G. Ashish, *Robust global and local fuzzy energy based active contour for image*, **Applied Soft Computing**, 47 (2016) 191–215
- [38] K. Shyu, V. Pham, T. Tran ve L. P.L., *Global and local energy based active contours for image segmentation*, **Nonlinear Dyn.** 67:15 (2012) 59–1578.
- [39] C. Xu, L. Pham ve L. Prince, *Image Segmentation Using Deformable Models*, **Medical Image Processing and Analysis**, 2 (2000) .
- [40] T. Chan and L. Vese, *Active contours without edges*, **IEEE Trans. Image Process**, 10:2 (2001) 266–277.
- [41] M.F. Talu, *ORACM: Online region-based active contour model*, **Expert Systems with Applications**, (2013) 6233-6240.
- [42] T. T. Tran, V. T. Pham ve K. K. Shyu, *Image segmentation using fuzzy energy-based active contour with shape prior*, **Journal of Visual Communication and Image Representation**, 25:7 (2014) 1732-1745.

## **EKLER**

### **EK-1. ÖZGEÇMİŞ**

**Ad Soyad** : Sara ALTUN

**Doğum Yeri ve Tarihi** : Malatya - 12.06.1991

**Adres** : İnönü Üniversitesi Mühendislik Fakültesi  
Bilgisayar Mühendisliği Bölümü

**E-Posta** : [sara.altun@inonu.edu.tr](mailto:sara.altun@inonu.edu.tr)  
[sara.altun35@gmail.com](mailto:sara.altun35@gmail.com)

**Lisans** : İnönü Üniversitesi (2009-2013)

#### Mesleki Deneyim

Araştırma Görevlisi : Bayburt Üniversitesi Mühendislik Fakültesi, 2014-2016

Araştırma Görevlisi : İnönü Üniversitesi Mühendislik Fakültesi, 2016-....

## **TEZDEN TÜRETİLEN YAYINLAR/SUNUMLAR**

Uluslararası Bilimsel Toplantılarda Sunulan Bildiriler

**Altun S.**, TALU M.F. “Bulanık ve Klasik Yöntemlerin Kümeleme Yeteneklerinin İncelenmesi”, International Artificial Intelligence Data Processing Symposium. Malatya, 2016.