

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**OTOMATİK TOHUMLANDIRMALI BÖLGE BÜYÜTME METODUYLA
RENKLİ GÖRÜNTÜLERDE BÖLGE VE KENAR TESPİTİ**

YÜKSEK LİSANS TEZİ

Elektrik-Elektronik Müh. Seniha KETENCİ

**HAZİRAN 2011
TRABZON**

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**OTOMATİK TOHUMLANDIRMALI BÖLGE BÜYÜTME METODUYLA RENKLİ
GÖRÜNTÜLERDE BÖLGE VE KENAR TESPİTİ**

Elektrik-Elektronik Müh. Seniha KETENCİ

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"ELEKTRONİK YÜKSEK MÜHENDİSİ"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

Tezin Enstitüye Verildiği Tarih : 24.05.2011
Tezin Savunma Tarihi : 09.06.2011

Tez Danışmanı : Doç. Dr. Ali GANGAL

Trabzon 2011

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü

Elektrik-Elektronik Anabilim Dalında

Seniha KETENCİ tarafından hazırlanan

**OTOMATİK TOHUMLANDIRMALI BÖLGE BÜYÜTME METODUYLA
RENKLİ GÖRÜNTÜLERDE BÖLGE VE KENAR TESPİTİ**

**başlıklı bu çalışma, Enstitü Yönetim Kurulunun 24 / 05 / 2011 gün ve 1406 sayılı
kararıyla oluşturulan jüri tarafından 09 / 06 / 2011 tarihinde yapılan sınavda**

YÜKSEK LİSANS TEZİ

olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Prof. Dr. Temel KAYIKÇIOĞLU

Üye : Doç. Dr. Ali GANGAL

Üye : Doç. Dr. Cemal KÖSE

Prof. Dr. Sadettin KORKMAZ

Enstitü Müdürü

ÖNSÖZ

Bu tez, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı, Elektronik Mühendisliği Yüksek Lisans Programı'nda hazırlanmıştır. Bu çalışmada, RGB görüntüleri bölütlenerek bölge ve kenar tespiti yapılmaya çalışılmıştır. Ayrıca, bu amaç doğrultusunda bir bilgisayar programı hazırlanmıştır.

Yüksek lisans tez danışmanlığımı üstlenen değerli hocam Doç. Dr. Ali GANGAL'a, çalışmalarım esnasında moral verme ve motive etme konusunda bana destek veren aileme teşekkür etmeyi bir borç bilirim.

Seniha KETENCİ

Trabzon 2011

TEZ BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “ Otomatik Tohumlandırılmalı Bölge Büyütme Metoduyla Renkli Görüntülerde Bölge ve Kenar Tespiti ” başlıklı bu çalışmayı baştan sona kadar danışmanım Doç Dr. Ali GANGAL‘ın sorumluluğunda tamamladığımı, verileri kendim topladığımı, analizleri ilgili laboratuvarlarda yaptığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 09/06/2011

Seniha KETENCİ

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ BEYANNAMESİ	IV
İÇİNDEKİLER.....	V
ÖZET.....	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ.....	IX
SEMBOLLER DİZİNİ.....	XI
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Görüntü Bölütleme	1
1.3. Bölütleme Teknikleri.....	3
1.3.1. Piksel Tabanlı Teknikler	4
1.3.1.1. Eşikleme Metodu.....	4
1.3.1.1.1. Temel Global Eşikleme	5
1.3.1.1.2. Otsu Metodu	5
1.3.1.2. Kümeleme Metodu	9
1.3.1.2.1. K- Ortalama Algoritması.....	10
1.3.2. Sınır Tabanlı Teknikler	11
1.3.2.1. Gradyan Operatörleri.....	11
1.3.2.1.1. Roberts Operatörü	13
1.3.2.1.2. Prewitt Operatörü	13
1.3.2.1.3. Sobel Operatörü.....	14
1.3.2.2. Laplasyen Operatörü	15
1.3.2.3. Canny Kenar Detektörü.....	16
1.3.3. Bölge Tabanlı Teknikler.....	17
1.3.3.1. Bölge Büyütme Metodu	17
1.3.3.2. Bölge Bölme ve Birleştirme Metodu	18
1.3.4. Çizge Tabanlı Teknikler	19
1.3.4.1. Ağaç/Çizge Tabanlı Metot	19

1.3.4.2.	Çizge Bölme Metodu.....	20
1.3.5.	Model Tabanlı Teknikler.....	20
1.3.6.	Yapay Sinir Ağ Tabanlı Teknikler	20
1.3.7.	Melez Teknikler	20
2.	YAPILAN ÇALIŞMALAR VE BULGULAR	21
2.1.	Giriş.....	21
2.2.	Otomatik Tohumlandırılmalı Bölge Büyütme.....	21
2.2.1.	RGB Renk Uzayından YC_bC_r Renk Uzayına Dönüşüm	22
2.2.2.	Otomatik Tohum Seçimi	24
2.2.3.	Tohumlandırılmalı Bölge Büyütme.....	40
2.2.4.	Bölge Birleştirme	45
3.	İRDELEME VE SONUÇLAR.....	55
4.	ÖNERİLER	59
5.	KAYNAKLAR.....	60
ÖZGEÇMİŞ		

Yüksek Lisans

ÖZET

OTOMATİK TOHUMLANDIRMALI BÖLGE BÜYÜTME METODUYLA RENKLİ
GÖRÜNTÜLERDE BÖLGE VE KENAR TESPİTİ

Seniha KETENCİ

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Ali GANGAL
2010, 61 Sayfa

Teknolojinin farklı alanlarında büyük bir öneme sahip görüntüden, doğru analizle istenilen bilgi elde edilebilir. Görüntü bölütleme, görüntüden veri eldesinde kullanılacak doğru bir tercihtir. Bu sebeptendir ki; bölütleme, görüntü işleme alanında yer alan önemli araştırma konularından biridir.

Bu tezde farklı özellikteki görüntüler kullanılarak renkli imge bölütlemesi gerçekleştirilmiştir. Renkli görüntü bölütlemesi için otomatik tohumlandırılmalı bölge büyütme yöntemi kullanılmıştır. Tohum piksel adaylarından tohumları seçen eşik değeri, görüntü kenar piksellerinin ortalama öklid uzaklığıyla ilişkilendirilmiştir. Dinamik hale getirilen bu eşik değeri parametresiyle tohum seçimi iyileştirilmiştir. Dolayısıyla daha iyi bölütlemeyle daha doğru bölge ve kenar tespiti gerçekleştirilmiştir.

Anahtar Kelimeler: Renkli Görüntülerde Bölütleme, Otomatik Tohumlandırılmalı bölge büyütme, Kenar belirleme, Bölütleme Teknikleri.

Master Thesis

SUMMARY

AREA AND EDGE DETECTION FOR COLOR IMAGES VIA AUTOMATED SEEDED
REGION GROWING METHOD

Seniha KETENCİ

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical and Electronics Engineering Graduate Program

Supervisor: Assoc. Prof. Ali GANGAL
2010, 61 Pages

Required information can be obtained from digital image which has an important application in technology. Image segmentation is suitable process to get data from color image. Because of this, segmentation is crucial subject in image processing.

In this thesis, color image segmentation is performed to different images with automated seeded region growing algorithm. Threshold value with which seed pixels are selected among seed pixel candidates is related to relative Euclidean distance of image edges. The threshold value changed dynamically makes selection of seed pixels be more effective. Thus, automated seeded region growing algorithm with dynamic threshold value determines to more correct areas and edges of color image.

Key Words: Segmentation for Color Images, Automated Seeded Region Growing, Edge Detection, Segmentation Techniques.

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1.1. İmge	2
Şekil 1.2. Bölütlenmiş görüntü	2
Şekil 1.3. İki farklı gösterimle 3x3 boyutlu görüntü parçası	12
Şekil 1.4. Roberts Operatörü için maskeler.....	13
Şekil 1.5. Prewitt Operatörü için maskeler.....	14
Şekil 1.6. Sobel Operatörü için maskeler.....	14
Şekil 1.7. Pozitif merkezli Laplasyan maskesi	15
Şekil 1.8. Negatif merkezli Laplasyan maskesi	15
Şekil 1.9. Bölümlenmiş görüntü ve ilgili dörtlü ağaç.....	19
Şekil 2.1. Otomatik tohumlandırılmalı bölge büyütme algoritması	21
Şekil 2.2. 4 renkli test görüntüsü	23
Şekil 2.3 Test görüntü R, G, B ve Y, C_b, C_r bileşenleri	23
Şekil 2.4. a pikselinin 4- komşuluğu ve 8-komşuluğu	24
Şekil 2.5. Gauss maskesi ve Sobel operatörü.....	28
Şekil 2.6. (a) Hh benzerlik matrisi, (b) Hh benzerlik matrisinin 3-boyutlu gösterimi.....	30
Şekil 2.7. (a) Tohum piksel adaylarının öklid uzaklıkları, (b) Tohum piksel adaylarının öklid uzaklık matrisinin 3-boyutlu gösterimi.....	31
Şekil 2.8. Test görüntüsü için tohum pikselleri.....	32
Şekil 2.9. İncelenecek görüntü çeşitleri.....	32
Şekil 2.10. (a) NT görüntü, (b) Kenarları belirlenmiş NT görüntü.....	33
Şekil 2.11. (a) NÇA görüntü, (b) Kenarları belirlenmiş NÇA görüntü.....	33
Şekil 2.12. (a) NÇF görüntü, (b) Kenarları belirlenmiş NÇF görüntü.....	34
Şekil 2.13. (a) BT görüntü, (b) Kenarları belirlenmiş BT görüntü	34
Şekil 2.14. (a) BÇA görüntü, (b) Kenarları belirlenmiş BÇA görüntü.....	34
Şekil 2.15. (a) BÇF görüntü, (b) Kenarları belirlenmiş BÇF görüntü.....	35
Şekil 2.16. NT için tohumlandırılmış görüntüler	36
Şekil 2.17. NÇA için tohumlandırılmış görüntüler	37
Şekil 2.18. NÇF için tohumlandırılmış görüntüler	38
Şekil 2.19. BT için tohumlandırılmış görüntüler.....	38

Şekil 2.20.	BÇA için tohumlandırılmış görüntüler.....	39
Şekil 2.21.	BÇF için tohumlandırılmış görüntüler	40
Şekil 2.22.	Tohumlandırılmalı bölge büyütme, (a) Tohum ve komşu pikseller, (b) Sınıflandırılacak pikselin belirlenmesi, (c) Yeni piksellerin Q kümesine dahil edilmesi.....	41
Şekil 2.23.	(a) NT imge, (c) Sınıflandırma bittikten sonra bölgeler	42
Şekil 2.24.	(a) NÇA imge, (c) Sınıflandırma bittikten sonra bölgeler.....	42
Şekil 2.25.	(a) NÇF imge, (c) Sınıflandırma bittikten sonra bölgeler	43
Şekil 2.26.	(a) BT imge, (c) Sınıflandırma bittikten sonra bölgeler	43
Şekil 2.27.	(a) BÇA imge, (c) Sınıflandırma bittikten sonra bölgeler.....	44
Şekil 2.28.	(a) BÇF imge, (c) Sınıflandırma bittikten sonra bölgeler.....	44
Şekil 2.29.	(a) NT için öklid uzaklığına göre bölge birleştirmeden önce bölgeler, (b) NT için öklid uzaklığına göre bölge birleştirmeden sonra bölgeler	45
Şekil 2.30.	(a) NÇA için öklid uzaklığına göre bölge birleştirmeden önce bölgeler, (b) NÇA için öklid uzaklığına göre bölge birleştirmeden sonra bölgeler	46
Şekil 2.31.	(a) NÇF için öklid uzaklığına göre bölge birleştirmeden önce bölgeler (b) NÇF için öklid uzaklığına göre bölge birleştirmeden sonra bölgeler.....	47
Şekil 2.32.	(a) BT için öklid uzaklığına göre bölge birleştirmeden önce bölgeler (b) BT için öklid uzaklığına göre bölge birleştirmeden sonra bölgeler.....	47
Şekil 2.33.	(a) BÇA için öklid uzaklığına göre bölge birleştirmeden önce bölgeler (b) BÇA için öklid uzaklığına göre bölge birleştirmeden sonra bölgeler.....	48
Şekil 2.34.	(a) BÇF için öklid uzaklığına göre bölge birleştirmeden önce bölgeler (b) BÇF için öklid uzaklığına göre bölge birleştirmeden sonra bölgeler.....	49
Şekil 2.35.	NT için bölge boyutuna göre bölge birleştirme, (a) Bölgeler, (b)Kenarlar	50
Şekil 2.36.	NÇA için bölge boyutuna göre bölge birleştirme, (a) Bölgeler, (b)Kenarlar...	51
Şekil 2.37.	NÇF için bölge boyutuna göre bölge birleştirme, (a) Bölgeler, (b)Kenarlar ...	52
Şekil 2.38.	BT için bölge boyutuna göre bölge birleştirme, (a) Bölgeler, (b)Kenarlar.....	52
Şekil 2.39.	BÇA için bölge boyutuna göre bölge birleştirme, (a) Bölgeler, (b)Kenarlar ...	53
Şekil 2.40.	BÇF için bölge boyutuna göre bölge birleştirme, (a) Bölgeler, (b)Kenarlar ...	54
Şekil 2.41.	(a) NT görüntüyü $T_{eşik1} = 0.05$ [5] ile bölütleme, (b) NT görüntüyü dinamikleştirilmiş $T_{eşik1} = 0.0329$ ile bölütleme	55
Şekil 2.42.	(a) NÇA görüntüyü $T_{eşik1} = 0.05$ [5] ile bölütleme, (b) NÇA görüntüyü dinamikleştirilmiş $T_{eşik1} = 0.0243$ ile bölütleme	56
Şekil 2.43.	(a) NÇF görüntüyü $T_{eşik1} = 0.05$ [5] ile bölütleme, (b) NÇF görüntüyü dinamikleştirilmiş $T_{eşik1} = 0.0883$ ile bölütleme	56
Şekil 2.44.	(a) BT görüntüyü $T_{eşik1} = 0.05$ [5] ile bölütleme, (b) BT görüntüyü dinamikleştirilmiş $T_{eşik1} = 0.0817$ ile bölütleme.....	57
Şekil 2.45.	(a) BÇA görüntüyü $T_{eşik1} = 0.05$ [5] ile bölütleme, (b) BÇA görüntüyü dinamikleştirilmiş $T_{eşik1} = 0.0566$ ile bölütleme	57
Şekil 2.46.	(a) BÇF görüntüyü $T_{eşik1} = 0.05$ [5] ile bölütleme, (b) BÇF görüntüyü dinamikleştirilmiş $T_{eşik1} = 0.0589$ ile bölütleme	58

SEMBOLLER DİZİNİ

$B\check{C}A$:	Bulanık, aynı cisimden çokça içeren görüntü
$B\check{C}F$:	Bulanık, birden çok farklı cisim içeren görüntü
BT	:	Bulanık, tek cisimli görüntü
$N\check{C}A$:	Net, aynı cisimden çokça içeren görüntü
$N\check{C}F$:	Net, birden çok farklı cisim içeren görüntü
NT	:	Net, tek cisimli görüntü
c	:	Küme merkezi
C	:	Görüntü sınıfları
C_b	:	Referans değer ile mavi renk arasındaki fark
C_r	:	Referans değer ile kırmızı renk arasındaki fark
$\overline{C_r}$:	3x3 maskedeki piksellerin C_r bileşenlerinin ortalama değeri
$\overline{C_b}$:	3x3 maskedeki piksellerin C_b bileşenlerinin ortalama değeri
d	:	Öklid uzaklığı
d_{ort}	:	Kenar pikselleri için ortalama öklid uzaklığı
f	:	İki boyutlu görüntü
F	:	Bölütleme alt kümelerinin toplamı
G	:	Piksel gurupları
G_x	:	x yönündeki gradyan bileşeni
G_y	:	y yönündeki gradyan bileşeni
H	:	Piksel benzerliği
J	:	Performans indeksi
K	:	Başlangıç küme merkez sayısı
L	:	Gri seviye düzeyi
M	:	Sınıf sayısı
N	:	Toplam piksel sayısı
p	:	Gri seviye olasılığı
P	:	Mantıksal hüküm hesaplayıcısı
R	:	Giriş görüntü bölgeleri toplamı
RGB	:	Kırmızı, yeşil, mavi bileşenlerinden oluşmuş renk modeli

S	:	Bölütleme alt kümeleri
Q	:	Sınıflandırılmamış komşu piksel kümesi
t	:	Otsu metodu eşik değeri
T	:	Temel global eşik değeri
T_{esik}	:	Bölge büyüme eşik değeri
$T_{eşik1}$:	Tohum seçme eşik değeri
$T_{eşik2}$:	Bölge birleştirme eşik değeri
u_r	:	Sınıfların ortalama değer toplamı
u	:	Sınıf ortalama değeri
U	:	Renk
V	:	Doyum
w	:	Sınıfların olasılık dağılımı
x	:	Görüntü koordinatı
Y	:	Işıklılık
\bar{Y}	:	3x3 maskedeki piksellerin Y bileşenlerinin ortalama değeri
y	:	Görüntü koordinatı
z_{tohum}	:	Tohum pikseli
Z	:	Gradyan büyüklüğü
z	:	Görüntüyü oluşturan herhangi bir pikselin değeri
ΔT	:	Eşik değerleri arasındaki fark
σ^2	:	Sınıfın varyans değeri
σ_B^2	:	Sınıf içi varyans
σ_W^2	:	Sınıflar arası varyans
σ_T^2	:	Toplam varyans
∇^2	:	Laplasyen operatörü
∇	:	Gradyan operatörü
θ	:	Gradyan yönü

1. GENEL BİLGİLER

1.1. Giriş

Görüntü bölütleme, bir imgedeki aynı özellikteki bölgelerin çıkarılması veya bölgeler arasındaki sınırların bulunması olarak tanımlanır. Görüntü analizinin önemli bir basamağı olarak kabul gören bu süreç, imgeyi anlamlı bileşenlere veya nesnelere ayırır.

Bölütleme, görüntü işleme alanında halen araştırılmakta olan bir konudur ve pek çok uygulaması mevcuttur. Görüntü bölütleme ürün kalite denetimi, tıbbi hastalık teşhisi, uydu görüntülerinin işlenmesi, MR (manyetik rezonans) görüntü analizi, trafikte çalıntı araçların tespiti ve görsel-yönlendirimli otonom robotların kontrolü gibi uygulamalarda ara işlem olarak kullanılır [1,2].

1.2. Görüntü Bölütleme

Renk, parlaklık ve doku gibi imge niteliklerinin türdeşliğine göre imgeyi farklı bölgelere ayırma işlemine *görüntü bölütleme* denir.

Bölütleme işlemi başarıyla gerçekleştirilmiş bir görüntü için aşağıdaki eşitliklerden söz edilebilir [3]:

$$\bigcup_{i=0}^n S_i = F \quad (1.1)$$

$$S_i \cap S_j = \emptyset, (i \neq j) \quad (1.2)$$

(S_1, S_2, \dots, S_n) alanları bölütleme altkümeleri olarak adlandırılır. F kümesi bu alanların birleşimi olarak tanımlanan görüntüdür. Daha açık bir deyişle, F kümesi birbirinden farklı ve kesişimleri boş küme olan (S_1, S_2, \dots, S_n) görüntü alanlarının toplamıdır.

Bölütleme işleminin başarısını lojik olarak ifade edersek [3];

*Tüm S_i alanlar için $P(S_i) = \text{doğru}$.

* S_i ve S_j komşu ve $(i \neq j)$ iken $P(S_i \cup S_j) = \text{yanlış}$ olmalıdır.

$P()$ mantıksal hüküm hesaplayıcısı olarak adlandırılır. Bir grup piksel için benzerlik üzerinden tanımlanır. Mantıksal hüküm hesaplayıcısının çıkışı, giriş değişkenine göre 1(*doğru*) veya 0(*yanlış*) değerlerinden birini alır.

Doğru gruplanmış bütün alanlar için mantıksal hüküm hesaplayıcısının sonucu doğrudur. Herhangi iki alanın kesişimi için ise sonuç yanlıştır.

Varılacak olan sonuç şudur ki: doğru belirlenmiş bölütleme alt kümeleri için kesişimden söz edilemez.

Görüntü bölütleme bütünüyle insan yapısının görüş algısıyla ilgilidir. İnsanların görme duyuları, onlara çaba harcamadan çevrelerindeki farklı objeleri ve onların hareketlerini algıma, onları tanımlama olanağı verir. Karışık bir süreç olmasına rağmen insanın görsel algı sistemi bunu doğal bir aktivite olarak kolaylıkla yapar. Performansı insanın görsel algı sistemiyle kıyaslandığında yapay algoritmalar için ne yazık ki bu o kadar kolay değildir [4].



Şekil 1.1. İmge



Şekil 1.2. Bölütlenmiş görüntü

Görüntü bölütleme kavramı ilk gri seviyeli görüntüler için kullanılmış ve uygulanmıştır. Son yıllarda da ise renkli görüntü bölütleme için var olan gri seviyeli görüntü bölütleme yöntemleri modifiye edilmiş ya da yeni yöntemler geliştirilmiştir.

Görüntü bölütleme için tek ve standart bir yaklaşım yapılamamaktadır. Görüntüde farklı türdeki görüntü parçaları(sahneleri), tanımlamalarla belirlenen bölütleri

oluşturmaktadır. İmgeden bu kısımları özütleyebilecek birçok farklı yol vardır. Uygun bölütleme tekniği seçimi görüntünün tipine bağlıdır [5].

Görüntü bölütlemeye ilgili yakın zamanda yapılan çalışmalar şöyledir; tohumlandırılmalı bölge büyütme düşüncesi ilk Adams Bischof ve Leanne Bischof tarafından 1994 yılında ortaya kondu. Önerdikleri tohumlandırılmalı bölge büyütme (TBB) yönteminde nesnelere, bölge ve renk homojenitesine göre bölütlendi [6]. Chantal Revol ve Michel Jourlin algoritmayı daha işe yarar nesne öznitelikleri ve büyütme-birleştirme kriteri ile 1997'de modifiye etti [7]. Fakat incelenmiş olan nokta ve bölgelerin sırasına bağımlı olması algoritmalarının yeterli olmadığını gösterdi. S.Y. Wan ve E.H. William 2003'te geliştirdikleri simetrik bir fonksiyonla piksel işlem sırasına bağımlılık sorununu çözen simetrik bölge büyütme metodunu geliştirdi [8]. Bir yıl sonra L. Zhi ve Y. Jie tohumlandırılmalı bölge büyütme (TBB)'yi piksel düzeyinden bölge düzeyine genişleten, hızlı tohumlu bölge birleştirme yaklaşımını yaptı [9]. 2005 yılında Yue Feng, Hui Fang, ve Jianmin Jiang tarafından doku bütünlüğüne dayanarak başlangıç tohum piksellerini seçen, otomatik tohumlamayla bölge büyütme yöntemi geliştirildi [10]. F.Y. Shih ve S. Cheng renkli imge bölütlemesi için RGB renk uzayından YCbCr renk uzayına dönüştüren, 8-bağlantılı komşuluklarıyla ilişkili olarak hesaplanan maksimum öklit uzaklığına ve renk benzerliğine göre aday başlangıç tohum piksellerini otomatik belirleyen otomatik tohumlandırılmalı bölge büyütme metodunu (OTBB) geliştirdi [5].

1.3. Bölütleme Teknikleri

İmge türüne ve uygulamanın çeşidine göre bölütleme tekniğinin uygunluğu değişir. Henüz bütün görüntülere uygulanabilen ve iyi sonuçlar veren standart bir teknik gerçekleştirilememiştir [5]. Geliştirilmiş görüntü bölütleme teknikleri şu başlıklar altında toplanabilir;

- 1) Piksel Tabanlı Teknikler
- 2) Sınır Tabanlı Teknikler
- 3) Bölge Tabanlı Teknikler
- 4) Grafik Tabanlı Teknikler
- 5) Model Tabanlı Teknikler
- 6) Yapay Sinir Ağı Tabanlı Teknikler
- 7) Melez Teknikler

1.3.1. Piksel Tabanlı Teknikler

Piksel-tabanlı teknikler uzamsal değerler üzerinden işlem görür. Bunun yanı sıra renk, parlaklık gibi özellikleri de işleme katar.

Hem piksel niteliklerinin hem de uzamsal koordinatların değerlendirilmesi bu tekniğe avantajın yanında dezavantaj da sağlar. Algoritmanın basitleşmesi bir avantajken, uzamsal kısıtlamanın olmayışıyla görüntünün gürültüye duyarlı hale gelmesi ise bir dezavantajdır [4].

Piksel-tabanlı teknikler genel başlığı altında iki metot vardır:

1. Eşikleme metodu
2. Kümeleme metodu

1.3.1.1. Eşikleme Metodu

Bilinen en basit ve en eski tekniktir. Bölütlemeye yaygın olarak kullanılır [4]. Eşikleme metodunda görüntünün histogramı incelenir. Histogram vadi ve tepelerden oluşur. Bölge sayısı histogramdaki tepe sayısı kadar veya vadi sayısının bir eksiği kadardır [11].

$$\text{Bölge sayısı} = \text{Histogramdaki Tepe sayısı} \quad (1.3)$$

$$\text{Bölge sayısı} = \text{Histogramdaki Vadi sayısı} - 1 \quad (1.4)$$

Örneğin, bir görüntüde gri seviye düzeyleri birbirinden çok farklı bir objeyle arka plan varsa, histogram muhtemelen derin vadili iki tepedir. Bu durumda vadinin en dibi eşik değeri olarak seçilir. Eşik değerinin yukarısındaki ve aşağısındaki değerler farklı iki bölge olarak gruplandırılır. Bu iki seviyeli eşikleme olarak adlandırılır. Bölgeleri belirleyen eşik seviyesi iki veya daha fazla olursa da çoklu eşikleme olarak adlandırılır [4].

Eşikleme metodunda en önemli problem eşik değerinin veya değerlerinin doğru olarak belirlenmesidir. Bunun için temel global eşikleme, otsu metodu gibi metotlar kullanılır [12].

1.3.1.1.1. Temel Global Eşikleme

Temel global eşikleme iki seviyeli bir eşiklemedir. Arka plan ve bir objeden oluşmuş sadece bir eşik değerinden söz edilen görüntüler için kullanılır. Bu eşik değerine göre obje arka plandan özütlenir [12].

Temel global eşik değeri, histogramın görsel incelemesinden deneme yanılmayla diğer bir deyişle sezgisel olarak bulunur. Eşik değeri otomatik olarak şu algoritmayla elde edilir [12]:

1. Histograma bakılarak vadiden bir eşik yani T değeri seçilir.
2. Bu T değerine göre pikseller G_1 ve G_2 olmak üzere iki grupta sınıflandırılır. Görüntü piksel değeri $> T$ ise G_1 bölgesine ve görüntü pikselin değeri $\leq T$ ise G_2 bölgesine dâhil edilir.
3. G_1 ve G_2 bölgelerinin ortalama değerleri μ_1 ve μ_2 değerleri hesaplanır.
4. Yeni eşik değeri, T aşağıdaki gibi hesaplanır:

$$T = \frac{1}{2}(\mu_1 + \mu_2) \quad (1.5)$$

5. Seçilen T ile hesaplanan T arasındaki fark önceden belirlenen ΔT sabitinin değerinden küçük olana kadar 2. adımdan 4. adıma işlem basamakları iterasyonla yinelenir.

ΔT sabitinin değeri yinelemenin hızını belirler. Bu sabit ne kadar iyi seçilirse T değeri o kadar hızlı belirlenir. Algoritma sonlandığında global eşik değeri belirlenmiş olur [12].

1.3.1.1.2. Otsu Metodu

İmge eşiklemede eşik değerinin veya değerlerinin doğru belirlenmesi için en iyi yöntemlerden birini Otsu önermiştir. Bu sebepten yöntem Otsu metodu olarak bilinir. Hem iki seviyeli eşiklemede hem de çok seviyeli eşiklemede kullanılır [13].

İki seviyeli eşikleme için Otsu metodu aşağıdaki işlem basamaklarından sonra hesaplanan sınıf içi varyans ve sınıflar arası varyansa bakarak bir eşik değeri belirlenir [13]:

Bir görüntüdeki toplam piksel sayısı, N 'dir.

$$N = n_0 + n_1 + \dots + n_{L-1} \quad (1.6)$$

Görüntü $[0, 1, \dots, L-1]$ aralığında L tane gri seviyeyle gösterilmiştir. Eşitlik (1.6)'da i seviyesine sahip piksel sayısı, n_i cinsinden toplam piksel sayısı N 'nin ifadesi verilmiştir.

$$p_i = n_i/N, p_i \geq 0, \sum_{i=0}^{L-1} p_i = 1 \quad (1.7)$$

(1.7) eşitliğinden i . gri seviyesinin olasılığı olan p_i hesaplanmıştır.

İki seviyeli eşikleme metodunda görüntü, eşik değeri t olmak üzere gri seviyeleri $[0, 1, \dots, t]$ aralığında olanlar bir sınıf (C_1 sınıfı), $[t+1, \dots, L-1]$ aralığında olanlar başka bir sınıf (C_2 sınıfı) olmak üzere iki sınıfa ayrılır. Bu iki sınıfın olasılık dağılımı w_1, w_2 'dir.

$$w_1 = P_r(C_1) = \sum_{i=0}^t p_i \quad (1.8)$$

$$w_2 = P_r(C_2) = \sum_{i=t+1}^{L-1} p_i \quad (1.9)$$

u_1 , C_1 sınıfının ortalama değeri ve u_2 , C_2 sınıfının ortalama değeridir.

$$u_1 = \sum_{i=0}^t i p_i / w_1 \quad (1.10)$$

$$u_2 = \sum_{i=t+1}^{L-1} i p_i / w_2 \quad (1.11)$$

$$u_T = w_1 u_2 + w_2 u_2 \quad (1.12)$$

Toplam ortalama u_T eşitlik (1.12) 'den hesaplanır.

$$\sigma_1^2 = \sum_{i=0}^t (i - u_1)^2 p_i / w_1 \quad (1.13)$$

$$\sigma_2^2 = \sum_{i=t+1}^{L-1} (i - u_2)^2 p_i / w_2 \quad (1.14)$$

Sınıfların varyansları sırasıyla σ_1^2 ve σ_2^2 eşitlik (1.13) ve eşitlik (1.14)'den hesaplanır.

$$\sigma_W^2 = \sum_{k=1}^M w_k \sigma_k^2 \quad (1.15)$$

Sınıf içi varyans, σ_B^2 eşitlik (1.15)'den hesaplanır.

$$\sigma_B^2 = w_1 (u_1 - u_T)^2 + w_2 (u_2 - u_T)^2 \quad (1.16)$$

Sınıflar arası varyans, σ_W^2 eşitlik (1.16)'den hesaplanır.

$$\sigma_T^2 = \sigma_W^2 + \sigma_B^2 \quad (1.17)$$

Toplam varyans eşitlik (1.17)'den hesaplanır.

Otsu metodu en uygun eşik değerini sınıf içi varyansın minimum olduğu maksimum sınıf-arası varyans değeri ile seçer. Sınıf içi varyans ve sınıflar arası varyansın toplamı olan toplam varyans farklı kısımlar için sabittir [13].

$$t = \arg \left\{ \max_{0 \leq t \leq L-1} \left\{ \sigma_B^2(t) \right\} \right\} = \arg \left\{ \min_{0 \leq t \leq L-1} \left\{ \sigma_W^2(t) \right\} \right\} \quad (1.18)$$

Eşitlik (1.18)'ten anlaşıldığı gibi sınıf içi maksimum varyansa sahip gri seviye yeni optimum eşik değeri olarak belirlenir.

Otsu metodu çok-seviyeli eşiklemeye genişletilebilir [13]. $\{C_1, C_2, \dots, C_M\}$ sınıfları göstermek üzere M tane sınıfın varlığında $\{t_1, t_2, \dots, t_{M-1}\}$ yani M-1 tane eşik değerinden söz edilebilir.

$$w_j = P_r(C_j) = \sum_{i=t_{j-1}+1}^{t_j} p_i \quad (1.19)$$

w_j , j.sınıfın olasılık dağılımını gösterir ve $j=1, 2, \dots, M$ 'dir.

$$u_j = \sum_{i=t_{j-1}+1}^{t_j} i p_i / w_j \quad (1.20)$$

u_j , j. sınıfının ortalama değeridir.

$$u_T = \sum_{j=1}^M w_j u_j \quad (1.21)$$

Toplam ortalama u_T eşitlik (1.21) 'den yararlanılarak elde edilir.

$$\sigma_j^2 = \sum_{i=t_{j-1}+1}^{t_j} (i - u_j)^2 p_i / w_j \quad (1.22)$$

j. sınıfın varyansı, σ_j^2 eşitlik (1.22)'den hesaplanır.

$$\sigma_W^2 = \sum_{j=1}^M w_j \sigma_j^2 \quad (1.23)$$

Sınıf içi varyans, σ_B eşitlik (1.23)'ten hesaplanır.

$$\sigma_B^2 = \sum_{j=1}^M w_j (u_j - u_T)^2 \quad (1.24)$$

Sınıflar arası, σ_W varyans eşitlik (1.24)'den hesaplanır.

$$\sigma_T^2 = \sigma_W^2 + \sigma_B^2 \quad (1.25)$$

Toplam varyans eşitlik (1.25)'ten hesaplanır.

Sınıf içi varyansın minimum olduğu sınıflar arası varyansın ise maksimum olduğu seviyeler optimum eşik değerleri olarak seçilir [13].

$$\begin{aligned} \{t_1, t_2, \dots, t_{M-1}\} &= \arg \left\{ \max_{0 \leq t \leq L-1} \left\{ \sigma_B^2(t_1, t_2, \dots, t_{M-1}) \right\} \right\} \\ &= \arg \left\{ \min_{0 \leq t \leq L-1} \left\{ \sigma_W^2(t_1, t_2, \dots, t_{M-1}) \right\} \right\} \end{aligned} \quad (1.26)$$

1.3.1.2. Kümeleme Metodu

Kümeleme piksel-tabanlı diğer bir tekniktir. Bölütlemeye geniş ölçüde kullanılır. Genel anlamda kümeleme, bir veri kümesinin sahip olduğu özelliklere göre kategorilendirilmesidir. Kümeleme yönteminde veriler sınıflandırılır. Böylece gereksiz veri incelenmesi ve tekrar ortadan kalkar. İmgenin renk, boyut, şekil gibi özelliklerine bakılarak verilerin hangi sınıfa dahil edileceği belirlenir. Başarılı bir kümeleme işleminde sınıflar arasındaki benzerlik minimum, sınıf içi benzerlik maksimumdur [14].

1.3.1.2.1. K- Ortalama Algoritması

Kümeleri belirlemek için K-ortalama algoritması kullanılır. K- ortalama algoritması performans içerik minimizasyonuna bağlıdır. Performans indeks minimizasyonu, bir küme grubunda bütün noktaların küme merkezine olan uzaklığın karelerinin toplamı olarak tanımlanır [4].

K-ortalama algoritması dört adımdan oluşur [4]:

Adım 1. $c_1(1), c_2(1), \dots, c_K(1)$ olmak üzere K tane başlangıç küme merkezi seçilir.

$c_1(1)$, 1. iterasyon boyunca 1. küme merkezinin renk, boyut, şekil gibi özelliklerinden biridir.

Adım 2. t . iterasyon sonunda her bir a pikseli K tane kümeden birine atanır.

$j=1,2,\dots,K$ olmak üzere $C_j(t)$, t . iterasyon sonunda $c_j(1)$ merkezli kümeye dahil edilen piksel grubunu gösterir. K tane küme $C_1(t), C_2(t), \dots, C_K(t)$ ile ifade edilir.

$\forall i,j=1, 2, \dots, K$ ve $i \neq j$ olmak üzere $\| a - c_j(t) \| \leq \| a - c_i(t) \|$ şartını sağlıyorsa a pikseli $C_j(t)$ ye dahil edilir.

Adım 3. Adım 2'den elde edilen sonuçlara göre $j=1,2,\dots,K$ olmak üzere $C_j(t)$ kümesindeki bütün noktaların yeni küme merkezine olan karesel uzaklık toplamı minimum olacak şekilde yeni küme merkezi $c_j(t + 1)$ hesaplanır. Diğer bir deyişle performans indeksi J minimum olacak şekilde yeni merkez $c_j(t + 1)$ elde edilir.

$$J_j = \sum_{a \in C_j(k)} \| a - c_j(t+1) \|^2, \quad j = 1,2,\dots, K \quad (1.27)$$

$$c_j(t+1) = \frac{1}{N_j} \sum_{a \in C_j(k)} a, \quad j = 1,2,\dots, K \quad (1.28)$$

N_j , $C_j(t)$ sınıfına dahil piksellerin sayısı olmak üzere performans indeksi, J eşitlik (1.27) 'den ve yeni küme merkez, $c_j(t + 1)$ eşitlik (1.28)' den hesaplanır.

Adım 4. Eğer $c_j(t + 1) = c_j(t)$ ise yani t . iterasyon sonunda hesaplanmış küme merkezleri ile bir sonraki iterasyonda hesaplanan küme merkezleri aynı ise işlem sonlandırılır. Aksi takdirde Adım 2'ye gidilerek sürece devam edilir.

K-ortalama algoritmasında kritik nokta başlangıç küme merkezlerinin belirlenmesidir. Başlangıç noktalarının doğruluğu algoritmanın hızını etkilediği için önemlidir. K adet başlangıç küme merkezi histogramdan yararlanılarak histogramın en baskın tepe noktalarından belirlenir [4].

1.3.2. Sınır Tabanlı Teknikler

Sınır tabanlı teknikler bölütlemeye kullanılan temel tekniklerdendir [15].

Bir imgede bir doğrultu boyunca gidildiğinde parlaklık ve renk değerinin değiştiği gözlenir. Ani değişimlerin olduğu noktalarda kenarlardan söz edilebilir. Diğer bir deyişle görüntü yoğunluğundaki keskin değişimler sınırları temsil eder [15].

Sınır-tabanlı tekniklerde özellikle gürültülü görüntülerde doğru olmayan sınırlar kenar olarak belirlenmesi ve kırık (kesik) sınırların varlığında yanlış sonuçların elde edilmesi olasıdır [1, 16]. Bunun birlikte sınır tabanlı teknikler, bilgisayar görmeye obje tanıma algoritmalarını görüntü işleme uygulamalarıyla birleştirme kolaylığı sağlar [15].

Sınır tabanlı tekniklerde birçok kenar belirleme operatörü kullanılabilir. Bunlardan bir kaçısı aşağıda açıklanmıştır. Sınır tabanlı tekniklerde doğruluk ve basitlik bakımından tercih edilen Canny detektörüdür [15].

1.3.2.1. Gradyan Operatörleri

Gradyan görüntünün 1. dereceden türevi ve yoğunluk seviyesindeki değişim ölçütüdür. Gradyan değeri aynı zamanda görüntünün ne kadar hızlı ya da yavaş değiştiğini gösteren bir büyüklüktür. Kenarın varlığını, hesaplanan gradyan büyüklüğünün belirli bir eşik değerinden daha büyük olup olmaması belirler [12].

$$\nabla f = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (1.29)$$

(x, y) konumundaki iki boyutlu bir f(x, y) görüntüsünün vektör olarak tanımlanan gradyanı (1.29) eşitliğinde verilmiştir.

$$\nabla f = \text{mag} (\nabla f) = G[f(x,y)] = [G_x^2 + G_y^2]^{1/2} \quad (1.30)$$

$$\nabla f = G[f(x,y)] \approx |G_x| + |G_y| \quad (1.31)$$

Gradyan büyüklüğü ∇f vektörünün genliğidir ve yapılan bir yaklaşımla eşitlik(1.31)'deki gibi formüle edilir.

Gradyan operatörü kısmi türev yardımıyla gri seviye yoğunluk değişimlerini hesaplar. Bu değişimler bir doğrultuya ve yöne sahiptir. Gradyan vektörünün yönü, $\theta(x, y)$ ile gösterilir ve önemli bir niceliktir. (x,y) noktasında ∇f vektörünün x eksenine göre ölçülen açısıdır.

$$\theta(x, y) = \tan^{-1} \left(\frac{G_y}{G_x} \right) \quad (1.32)$$

$f(i-1, j-1)$	$f(i-1, j)$	$f(i-1, j+1)$
$f(i, j-1)$	$f(i, j)$	$f(i, j+1)$
$f(i+1, j-1)$	$f(i+1, j)$	$f(i+1, j+1)$

z_1	z_2	z_3
z_4	z_5	z_6
z_7	z_8	z_9

Şekil 1.3. İki farklı gösterimle 3x3 boyutlu görüntü parçası

Şekil 1.3'te görüldüğü gibi iki boyutlu görüntünün x doğrultusundaki gradyanı ve y doğrultusundaki gradyanı aşağıdaki gibidir.

$$G_x = f(i+1, j) - f(i, j) \quad (1.33)$$

$$G_y = f(i, j+1) - f(i, j) \quad (1.34)$$

Sınır belirlemede kullanılan Robert operatörü, Sobel operatörü, Prewitt operatörü, Canny operatörü gradyan operatörüdür. Bunlar basit ve etkilidir [12].

Sınır-tabanlı teknikler, görüntüyle yukarıda belirtilen gradyan maskelerini katlamaya sokarak geçiş noktalarını diğer bir deyişle kenarları belirler [2].

1.3.2.1.1. Roberts Operatörü

Roberts operatörünün x, y doğrultularındaki gradyan vektörleri ve gradyan büyüklüğü şöyledir:

$$G_x = (z_9 - z_5), \quad G_y = (z_8 - z_6) \quad (1.35)$$

$$G[f(x, y)] \approx |G_x| + |G_y| = |z_9 - z_5| + |z_8 - z_6| \quad (1.36)$$

-1	0	0	-1
0	1	1	0
G_x		G_y	

Şekil 1.4. Roberts Operatörü için maskeler

Maske boyutları 2x2'lik olduğu için maske merkezi yoktur. Bu sebepten dolayı işlevsizdirler.

1.3.2.1.2. Prewitt Operatörü

Prewitt operatörünün x, y doğrultularındaki gradyan vektörleri ve gradyan büyüklüğü şöyledir:

$$G_x = (z_3 + z_6 + z_9) - (z_1 + z_4 + z_7), \quad G_y = (z_7 + z_8 + z_9) - (z_1 + z_2 + z_3) \quad (1.37)$$

$$G[f(x, y)] = |(z_3 + z_6 + z_9) - (z_1 + z_4 + z_7)| + |(z_7 + z_8 + z_9) - (z_1 + z_2 + z_3)| \quad (1.38)$$

-1	0	1
-1	0	1
-1	0	1

G_x

-1	-1	-1
0	0	0
1	1	1

G_y

Şekil 1.5. Prewitt Operatörü için maskeler

1.3.2.1.3. Sobel Operatörü

Sobel operatörünün x, y doğrultularındaki gradyan vektörleri ve gradyan büyüklüğü şöyledir:

$$G_x = (z_3 + 2z_6 + z_9) - (z_1 + 2z_4 + z_7), \quad G_y = (z_7 + 2z_8 + z_9) - (z_1 + 2z_2 + z_3) \quad (1.39)$$

$$G[f(x, y)] = |(z_3 + 2z_6 + z_9) - (z_1 + 2z_4 + z_7)| + |(z_7 + 2z_8 + z_9) - (z_1 + 2z_2 + z_3)| \quad (1.40)$$

-1	0	1
-2	0	2
-1	0	1

G_x

-1	-2	-1
0	0	0
1	2	1

G_y

Şekil 1.6. Sobel Operatörü için maskeler

1.3.2.2. Laplasyen Operatörü

Görüntüde ani geçiş noktalarını belirlemek için kullanılır. İki boyutlu bir görüntünün, $f(x,y)$ 'nin ikinci türevi olarak tanımlanır.

$$\nabla^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2} \quad (1.41)$$

$$\nabla^2 f = 4 z_5 - (z_2 + z_4 + z_6 + z_8) \quad \text{veya} \quad \nabla^2 f = 8 z_5 - (z_1 + z_2 + z_3 + z_4 + z_6 + z_7 + z_8 + z_9) \quad (1.42)$$

Pozitif merkezli laplasyen operatörü eşitlik (1.42) ' de verilmiştir.

0	-1	0
-1	4	-1
0	-1	0

-1	-1	-1
-1	8	-1
-1	-1	-1

Şekil 1.7. Pozitif merkezli Laplasyan maskesi

$$\nabla^2 f = (z_2 + z_4 + z_6 + z_8) - 4 z_5 \quad \text{veya} \quad \nabla^2 f = (z_1 + z_2 + z_3 + z_4 + z_6 + z_7 + z_8 + z_9) - 8 z_5 \quad (1.43)$$

Negatif merkezli laplasyen operatörü eşitlik (1.43) ' te verilmiştir.

0	1	0
1	-4	1
0	1	0

1	1	1
1	-8	1
1	1	1

Şekil 1.8. Negatif merkezli Laplasyan maskesi

Laplasyen orijinal formuyla yetkin olmadığı için gauss fonksiyonuyla kombine edilerek kullanılır. Orijinal şekliyle Laplasyen operatörünün kenar belirlemede kullanılmama sebepleri şöyledir [12]:

- 2. derece türev olan laplasyen kabul edilemez derecede gürültüye duyarlıdır.
- Laplasyen büyüklüğü görüntüde istenmeyen çift kenar etkisi yaratır. Bu da bölütlemeyi karmaşık hale getirir.
- Son olarak, Laplasyan kenar doğrultusunu belirleyemez.

Gradyan operatöründe doğrultudan söz edilebilirken laplasyenda söz edilemez.

1.3.2.3. Canny Kenar Detektörü

Gürültüler yüksek frekanslarda ortaya çıkar. Alçak geçiren filtre yardımıyla görüntü gürültüden kurtarılır. Fakat görüntü bulanıklaştığı için kenar belirleme işlemi zorlaşır. Kenar belirleme operatörlerinde kenar bulma duyarlılığı arttıkça gürültüye olan duyarlılık artar. Canny kenar detektörü, hem gürültüye karşı dayanıklılığın artırılmasını hem de noktaların doğru tespit edilmesini sağlar. Bunu gausyan filtresi yardımıyla gerçekleştirir. [17].

Canny kenar detektörü üç hedefi amaçlar.

- Düşük hata oranı
- Kenar noktalarının yerini doğru belirleme
- Doğru her sınır için yalnızca bir nokta belirleme

Gerçek kenar çevresindeki lokal maksimumlar, birden çok kenarın belirlenmesine sebep olabilir. Buna rağmen Canny kenar detektörü yalnızca tek kenar belirlemelidir [17].

Altı adımdan oluşan Canny kenar belirleme algoritması aşağıda verilmiştir:

1. Gürültülü görüntü gausyan filtresi ile filtrelenir.
2. Elde edilen görüntünün gradyan büyüklüğü hesaplanır.
3. Kenarların açısı hesaplanır.
4. Kenarların yönü belirlenir.
5. Lokal maksimumlar bastırılır.
6. Eşiklemeyle kenarlar tespit edilir.

1.3.3. Bölge Tabanlı Teknikler

Bölge-tabanlı metotlar, sınır-tabanlı metotların eksik kaldığı noktaları tamamlar niteliktedir. Bölge tabanlı metotlarda amaç seçilen homojenlik kriterine göre, aynı ya da benzer pikselleri gruplandırıp bölgelere ayırmaktır [3].

Bölge-tabanlı tekniklerle bölütlenmiş bir görüntü için aşağıdaki tanımlama ve tespitler yapılabilir [12]:

$$(a) \bigcup_{i=1}^n R_i = R \quad i=1, 2, \dots, n \quad (1.44)$$

$$(b) R_i \text{ ilgili bölge, } i=1, 2, \dots, n$$

$$(c) \text{ Bütün } i, j \text{ ve } (i \neq j) \text{ değerleri için } R_i \cap R_j = \emptyset \quad (1.45)$$

$$(d) P(R_i) \text{ 'nin sonucu } \textit{doğru}$$

$$(e) (i \neq j) \text{ için } P(R_i \cup R_j) \text{ 'nin sonucu } \textit{yanlış}$$

R , giriş görüntüsünü oluşturan bütün bölgeleri göstermektedir ve n tane alt bölgenin, R_1, R_2, \dots, R_n 'in toplamına eşittir. Bu bölgelerin kesişimlerinin bulunmamaktadır.

(a) maddesi, bölütlemenin tamamlandığını ve her pikselin bir bölgeye ait olduğunu gösterir. (b) maddesi, bir bölgedeki bütün noktalar öncesinde belirlenmiş bir kriterine göre birbirleriyle ilişkili olması gerektiğini gerektirir. (c) maddesi, farklı bölgelerin kesişimlerinin bulunmaması gerektiğini gösterir. (d) maddesi, bölütlenmiş bir bölgedeki piksellerin taşınması gereken özelliği yansıtmaktadır. Örneğin, R_i bölgesindeki tüm pikseller aynı gri seviyesine sahipse $P(R_i)$ *doğru*'dur. Son olarak, (e) maddesi R_i ve R_j bölgelerinin farklı P operatörü duyarlılığında olması gerektiğini gösterir [12].

1.3.3.1. Bölge Büyütme Metodu

Kavram olarak bölge büyütme ön tanımlı benzerlik kriterine göre geniş bölgeleri alt bölgelere veya piksellere gruplandırma işlemidir [12].

Benzerlik kriteri seçimi görüntüden elde edilebilen data çeşidine bağlıdır. Benzerlik kriterleri aşağıdaki özelliklerin homojenitesine bakılarak belirlenir [11]:

- Ortalama yoğunluk
- Varyans

- Renk
- Doku
- Hareket
- Şekil
- Boyut

Aynı benzerlik kriterini sağlayan piksellerin oluşturduğu gruba *bölge* denir. Basit yaklaşımla, seçilen bir grup tohum pikseliyle işe başlanır. Tohum pikselleri komşu piksellerle kıyaslanır ve aynı özelliğe sahip olup olmadığına bakılır [12]. Tohum pikseliyle aynı özelliğe sahipse o piksel tohum pikseliyle aynı bölgede yer alır.

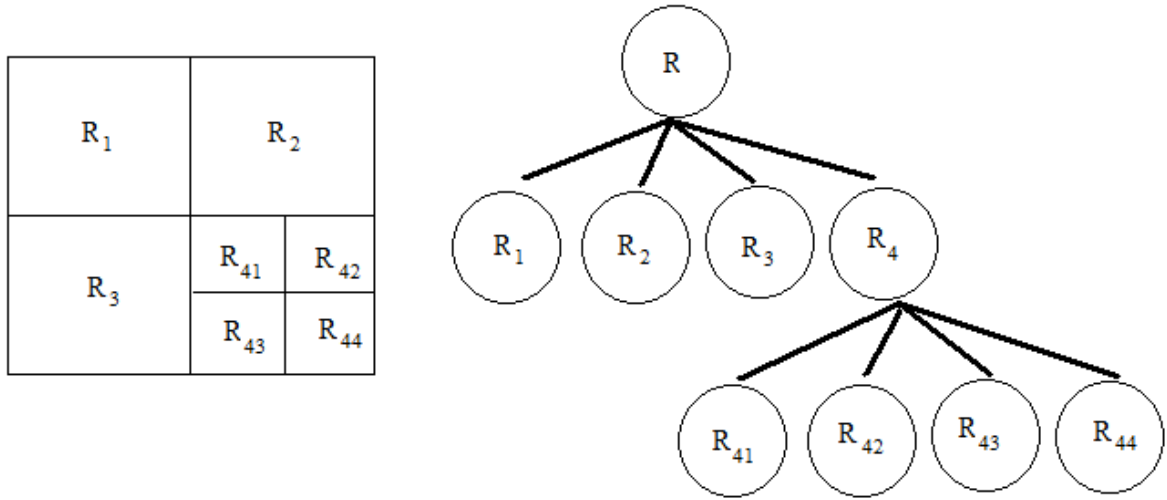
Bölge büyütme metodunda benzerlik kriterine göre bir eşik değeri seçilir. Eşik değeri görüntü bilgisinden çıkarılır. Tohum pikselinin komşu pikselleriyle arasındaki farka bakılır. Fark değeri bu eşik değerinin altında bir değere sahip pikseller tohum pikseliyle aynı bölgeye dahil edilir [18].

$$|z - z_{tohum}| < T_{esik} \quad (1.46)$$

Bölge büyütme metodunda kritik nokta tohum noktalarını ve eşik değerinin uygun seçilmesidir.

1.3.3.2. Bölge Bölme ve Birleştirme Metodu

Bölge bölme ve birleştirme metodu, tek bir büyük bölge olan görüntüyü önceden belirlenen benzerlik kriterine göre parçalar ve küçük bölgelere ayrılır. Daha sonra elde edilen küçük bölgeleri benzerlik ve yoğunluğa bakarak birleştirir [12].



Şekil 1.9. Bölümlenmiş görüntü ve ilgili dörtlü ağaç

Bölge bölme ve birleştirme yöntemi basitçe aşağıdaki adımları takip eder [12]:

1. $P(R_i) = \text{yanlış}$ olan her R_i bölgesi dörde bölünür.
2. $P(R_j \cup R_k) = \text{doğru}$ olan her R_j ve R_k komşu bölgeler birleştirilir.
3. Birleştirme veya bölme gerçekleşmeyinceye kadar işlem devam ettirilir.

1.3.4. Çizge Tabanlı Teknikler

Çizge tabanlı tekniklerden iki metot: Ağaç/Çizge tabanlı metot ve Çizge bölme metodu aşağıda açıklanmıştır.

1.3.4.1. Ağaç/Çizge Tabanlı Metot

Ağaç/Çizge tabanlı bölütleme metodunda çıkış görüntüsü bir grup farklı bölütleme sonucunun mutabakatına dayanır [19]. Bir piksel için lokal homojenite komşu piksellerin her çiftinden hesaplanan istatistikle belirlenir. Bu istatistik, komşu piksellerin her çifti için eş-oluşum olasılığı hesaplanarak elde edilir. Böylece yerel seviyede global bilgi elde edilmiş olur [15]. Bölütleme bu olasılık üzerinden gerçekleştirilir.

1.3.4.2. Çizge Bölme Metodu

Bu metotta bölütlenecek görüntü ağırlıklandırılmış yönsüz çizge (grafik) olarak modellenir. Her bir piksel çizgede bir boğum noktasıdır ve her piksel çifti arasında bir ayrıt vardır. Ayrıt ağırlığı pikseller arasındaki benzerlikle ölçülür ve bölütleme çizgi ağırlıklarını minimize edilmesiyle gerçekleştirilir [15].

1.3.5. Model Tabanlı Teknikler

Objeler geometrik olarak tekrarlanan bir biçime sahiptir. Model tabanlı yaklaşımda objelerin bu yapılarından yararlanır ve objenin şekil değişimini açıklayan olasılıksal model belirlenir [15].

Bu tekniklerle obje bölütlenirse imge kısıtlamalara maruz kalacaktır. İmge bölütlemesini kısıtlayan sebepler aşağıda belirtildiği gibidir [15]:

- Objenin genel duruşunu belirlemek için eğitim örneklerinin kaydı.
- Kaydedilen örnek varyasyonların olasılıksal gösterimi.
- Model ile görüntü arasındaki istatistiksel girişim.

1.3.6. Yapay Sinir Ağ Tabanlı Teknikler

Yapay sinir ağ tabanlı tekniklerde görüntünün küçük bölgeleri sinir ağı kullanılarak incelenir. Karar verme mekanizması, bu bölgeleri sinir ağı tarafından bilinen bir kategoriye göre işaretler [15].

1.3.7. Melez Teknikler

Melez teknikler daha iyi bir bölütleme yapabilmek için iki ya da daha fazla tekniğin birleştirilmesiyle elde edilmiş tekniklerdir. Bölge-tabanlı tekniklerle sınır tabanlı tekniklerin kombinasyonu melez tekniklere örnek gösterilebilir [5].

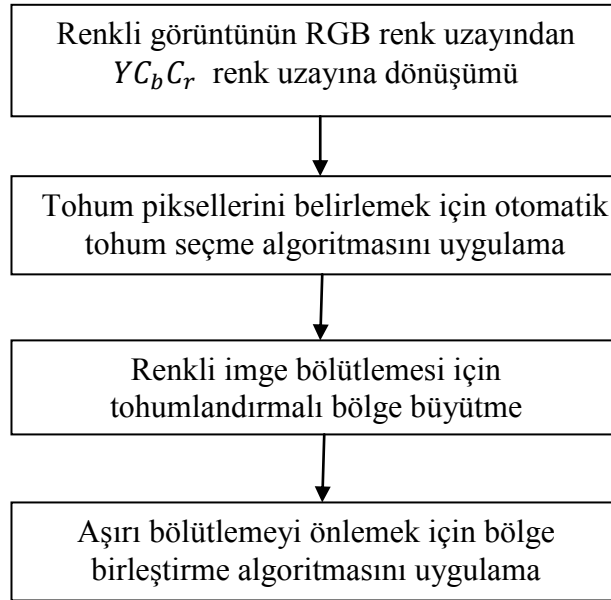
2. YAPILAN ÇALIŞMALAR, BULGULAR

2.1. Giriş

Yapılan çalışmada renkli görüntüler bölütlenerek bölgelere ayrılmış ve görüntü kenarları tespit edilmiştir. Kullanılan otomatik tohumlandırılmalı bölge büyütme metodunda Shih[5] tarafından bir sabit olarak belirlenmiş, tohum piksel adaylarını tohum olarak seçen eşik değeri, görüntüden elde edilen bilgiyle dinamik hale getirilmiştir. Bunun sonucunda kenarların daha iyi tespit edilip bölgelerin daha düzgün çıkarıldığı gözlemlenmiştir.

2.2. Otomatik Tohumlandırılmalı Bölge Büyütme

Otomatik tohumlandırılmalı bölge büyütme yöntemi, bölge büyütme metodu ile kümelemenin kombinasyonu ile gerçekleştirilmiş melez bir tekniktir. Renkli görüntülerde bölütleme için kullanılır ve algoritma basamakları aşağıdaki gibidir [5].



Şekil 2.1. Otomatik tohumlandırılmalı bölge büyütme algoritması

Şekil 2.1’de görüldüğü üzere görüntüye önce renk uzay dönüşümü yapılmıştır. Ardından tohum pikselleri belirlenerek bölge büyüme gerçekleştirilmiştir. Son olarak da aşırı bölütlemeyi önlemek için bölge birleştirme uygulanmıştır.

2.2.1. RGB Renk Uzayından YC_bC_r Renk Uzayına Dönüşüm

Algoritmanın ilk basamağı Şekil 2.1.’de görüldüğü gibi RGB uzayındaki görüntünün YC_bC_r uzayına taşınmasıdır.

RGB renk modelinin üç bileşeni vardır. Bunlar R (*red*, kırmızı), G (*green*, yeşil), B (*blue*, mavi)’ dir. Her renk, gösterimde bu üç bileşenle ifade edilir.

YC_bC_r renk modeli YUV renk uzayının kaydırılmış versiyonudur. Y ışıklılığı, U rengi, V doyumu, C_b bir referans değeri ile mavi arasındaki farkı ve C_r bir referans değeri ile kırmızı arasındaki farkı ifade etmektedir

RGB uzayı renklerin gösterimi için en uygun model olmasına karşın imge bölütlemesi ve analizi için tercih edilmez. Bunun sebebi R, G ve B bileşenleri arasındaki ilişkinin kuvvetli olmasıdır. Buna ek olarak simetrik olmayan RGB renk uzayının renk noktaları arasındaki uzaklığın düzgün bir skalada algısal farkla temsil edilememesidir [5].

Sonuç olarak görüntü işleme ve görüntü analizi yapabilmek için görüntü RGB ‘den diğer modellere dönüştürülmüştür. YC_bC_r renk uzayının tercih edilmesinin sebepleri şunlardır [5];

- * MPEG ve JPEG gibi video sıkıştırma standartlarında YC_bC_r renk uzayının kullanılması,

- * İnsan algısındaki renk farkları bu uzayda öklid uzaklığıyla direk olarak ifade edilebilmesi,

- * Yoğunluk ve doygunluk bileşenlerinin kolaylıkla ve birbirinden bağımsız kontrol edilebilmesidir.

RGB uzayından YC_bC_r uzayına dönüşüm formülü eşitlik (2.1)’de verilmiştir.


$$\begin{bmatrix} Y \\ C_b \\ C_r \end{bmatrix} = \begin{bmatrix} 65.481 & 128.553 & 24.966 \\ -39.797 & -74.203 & 112 \\ 112 & -93.786 & -18.214 \end{bmatrix} X \begin{bmatrix} R \\ G \\ B \end{bmatrix} + \begin{bmatrix} 16 \\ 128 \\ 128 \end{bmatrix} \quad (2.1)$$

[0, 1] aralığındaki R, G ve B bileşenlerinden dönüşüm sonucunda Y, C_b ve C_r bileşenleri elde edilmiştir. Dönüşüm sonucunda Y bileşeninin aralığı [16 235], C_b ve C_r bileşen aralıklarının ise [16 240] olduğu görülmüştür.



Şekil 2.2. 4 renkli test görüntüsü

Şekil 2.2.'de 10x10 boyutundaki; kırmızı, yeşil, mavi, beyaz olmak üzere 4 renkten oluşmuş test görüntüsü ele alınarak ayrıntılı bir inceleme yapılmıştır.



Şekil 2.3. Test görüntü R, G, B ve Y, C_b, C_r bileşenleri

Test imgesinin R, G, B ve Y, C_b, C_r bileşenleri şekil 2.3 'te görüldüğü gibidir. Görüntünün 1. ve 4. parçası R bileşenini, 2. ve 4. parçası G bileşenini, 3. ve 4. parçası B bileşenini içermektedir. Görüntünün 4. parçasında beyaz renk R, G ve B ile elde edilmiştir.

RGB uzayında parlaklık bileşeni renk bileşenlerine dağılmışken; YC_bC_r uzayında parlaklık, Y bileşeniyle renk tonundan ve doyumundan ayrı olarak ifade edilir. Renk farkları YC_bC_r uzayında öklid uzaklığıyla direkt olarak ifade edilebilir. Öklid uzaklığı algoritmada kullanılacak olan önemli bir parametre olduğundan renk farklarının öklid uzaklığıyla direkt bağdaştırılabilmesi bu uzayın tercih edilmesindeki en önemli etkidir.

2.2.2. Otomatik Tohum Seçimi


Otomatik tohumlandırılmalı bölge büyütme algoritmasının ikinci adımıdır. Görüntünün RGB'den YC_bC_r 'ye dönüşümü tamamlandıktan sonra tohum piksellerinin belirlenmesi gerekir. Piksellerin tohum pikseli olarak seçilmesi önemli bir süreçtir. Tohumlar ne kadar iyi belirlenirse başarı o kadar artmaktadır.

Otomatik tohum seçiminde dikkat edilmesi gereken üç husus vardır [5]:

- Tohum pikselleri 8-komşuluğundaki piksellerle yüksek benzerlikte olmalıdır.
- Her ayrı bölgeye en az bir tohum pikseli düşmelidir.
- Farklı bölgelerin tohum pikselleri birbirinin 8-komşuluğunda bulunmamalıdır.

Diğer bir deyişle farklı bölge tohumları birbiriyle bağlantısız olmalıdır.

Tohum piksellerini belirlemek için ilk olarak her bir pikselin benzerlik değerini hesaplamak gerekir. Bu benzerlik değeri, pikselinin 8-komşuluğundaki piksellerden elde edilen standart sapmayla ilgilidir.



Şekil 2.4. a pikselinin 4- komşuluğu ve 8-komşuluğu

Şekil 2.4'deki 3x3'lük görüntü parçasında a pikselinin çevresinde ve a pikseliyle bağlantılı 4 adet ve 8 adet komşu piksel görülmektedir. Bu piksellere a pikselinin 4-komşuluğu diğerine ise 8-komşuluğu denir.

Renkli görüntüdeki her pikselin, ilgili piksel 3x3'lük pencerenin merkezinde kalacak şekilde, üç bileşenin ortalama değeri eşitlik (2.2), eşitlik (2.3) ve eşitlik (2.4)'den hesaplanmıştır..

\bar{Y} , \bar{C}_b ve \bar{C}_r pencere içerisindeki piksellerin Y , C_b ve C_r bileşenlerinin ortalama değerleridir. Y_i , C_{bi} , C_{ri} ise görüntüdeki 3x3 boyutundaki maskedeki piksellerin Y , C_b ve C_r değerleridir.

$$\bar{Y} = \frac{1}{9} \sum_{j=1}^9 (Y_j) \quad (2.2)$$

$$\bar{C}_b = \frac{1}{9} \sum_{j=1}^9 (C_{bj}) \quad (2.3)$$

$$\bar{C}_r = \frac{1}{9} \sum_{j=1}^9 (C_{rj}) \quad (2.4)$$

Görüntüde bir pikselin Y , C_b ve C_r bileşenlerinin standart sapmaları, $\sigma_Y, \sigma_{C_b}, \sigma_{C_r}$ değerleri eşitlik (2.5), eşitlik (2.6) ve eşitlik (2.7) 'den ayrı ayrı hesaplanır.

$$\sigma_Y = \sqrt{\frac{1}{9} \sum_{i=1}^9 (Y_i - \bar{Y})^2} \quad (2.5)$$

$$\sigma_{C_b} = \sqrt{\frac{1}{9} \sum_{i=1}^9 (C_{bi} - \bar{C}_b)^2} \quad (2.6)$$

$$\sigma_{C_r} = \sqrt{\frac{1}{9} \sum_{i=1}^9 (C_{ri} - \bar{C}_r)^2} \quad (2.7)$$

Bir piksel için standart sapma değeri, σ ; Y , C_b ve C_r bileşenlerinin standart sapmalarının, σ_Y , σ_{C_b} , σ_{C_r} değerlerinin toplamıdır.

$$\sigma = \sigma_Y + \sigma_{C_b} + \sigma_{C_r} \quad (2.8)$$

Eşitlik (2.8)' den elde edilen toplam standart sapma değeri 1 den büyük çıkabilir. Bu sebepten dolayı maksimum değerine bölünerek $[0, 1]$ arasına normalize edilmiştir. σ_{\max} değeri bütün görüntü pikselleri için hesaplanan ve görüntüyle aynı boyutta olan σ matrisindeki maksimum değerdir.

$$\sigma_N = \sigma / \sigma_{\max} \quad (2.9)$$

İlgili pikselin benzerlik değeri Hh , σ_N normalize standart sapmanın 1 değerinden çıkarılmasıyla elde edilmiştir.

$$Hh = 1 - \sigma_N \quad (2.10)$$

Bütün pikseller için aynı işlem yapılarak görüntü benzerlik matrisine ulaşılmıştır. Tohum piksel adaylarını belirlemek için birinci koşul benzerlik ile tanımlanır.

Koşul 1: Tohum pikseli adayının benzerlik değeri belirlenen bir eşik değerinden, $T_{eşik}$, daha büyük olmalıdır. Benzerlik matrisinden Otsu metoduyla eşik değeri belirlenmiştir.

Otsu metoduna göre ayırma kriterini, diğer bir deyişle σ_B^2 / σ_W^2 'yi maksimum yapan değer, benzerlik matrisinden eşik değeri olarak seçilir. Ayırma kriterinin maksimum değerinde, σ_B^2 sınıflar arası varyans maksimum; σ_W^2 sınıf içi varyans minimumdur.

İkincil koşulda değerlendirilecek ölçüt, ilgili pikselin 8-komşuluğuyla olan bağlı öklid uzaklığı d' dir.

$$d_i = \frac{\sqrt{(Y - Y_i)^2 + (C_b - C_{bi})^2 + (C_r - C_{ri})^2}}{\sqrt{Y^2 + C_b^2 + C_r^2}} \quad i = 1, 2, \dots, 8 \quad (2.11)$$

$$d_{\max} = \max_{i=1}^8 (d_i) \quad (2.12)$$

Görüntüdeki her bir piksel için piksele 8-komşuluğundaki pikseller kullanılarak bağıl öklid uzaklığı hesaplanmıştır. 8-komşuluğundaki i . piksel için uzaklık d_i 'dir. Bir piksel için 8-komşuluğundaki 8 pikselle uzaklığı hesaplanmış ve bu değerler arasından maksimum değer seçilerek maske merkezindeki piksel için bağıl öklid uzaklığı olarak kaydedilmiştir. Bütün pikseller için bu işlem tekrarlanmış ve bağıl öklid uzaklığı matrisi elde edilmiştir.

Bağıl öklid uzaklığıyla ikincil koşul incelenir.

Koşul 2. İlk koşulu geçen tohum piksel adaylarının 8-komşuluğundaki piksellerden elde edilmiş ve maksimumu alınmış bağıl öklid uzaklıklarına bakılır. Tohum piksel adaylarından bağıl öklid uzaklığı, önceden belirlenen bir eşik değeri olan $T_{eşik1}$ 'den, büyük olanlar tohum pikseli olarak seçilir. Shih [5] yaptığı deneyler sonucunda bu eşik değeri, bir sabit olan 0.05 değeri olarak belirlemiştir.

Bu eşik değer ne kadar iyi belirlenirse, sınıflandırılmamış piksel sayısı o kadar azalır. Dolayısıyla işlem yükü hafifler ve piksellerin yanlış sınıflandırılma olasılığı diğer bir deyişle hata olasılığı düşer.

Bu eşik değerini dinamik olarak belirlemek için RGB görüntü HSV uzayına taşınmış ve piksel değerleri H (*hue*, ton), S (*saturation*, doyum), V (*value*, parlaklık) değerleriyle ifade edilmiştir. H üzerinden canny kenar belirleme algoritmasıyla kenarların koordinatları belirlenmiş ve $Y C_b C_r$ uzayında bu kenar pikseller için öklid uzaklığı hesaplanarak eşik değeri formüle edilmeye çalışılmıştır.

RGB'den HSV'ye dönüşüm aşağıdaki gibidir:

$$H \in [0, 360] \quad S, V, R, G, B \in [0, 1] \quad \text{olmak üzere,}$$

$$MAX = \max \{R, G, B\} \quad (2.13)$$

$$MIN = \min \{R, G, B\} \quad (2.14)$$

$$S = \begin{cases} 0, & MAX = 0 \text{ ise} \\ 1 - \frac{MIN}{MAX}, & MAX \neq 0 \text{ ise} \end{cases} \quad (2.15)$$

$$V = MAX \quad (2.16)$$

Canny Kenar Belirleme: Canny kenar belirleme ile doğru kenarlara olabildiğince yakın kenar tespiti yapılabilir. Bu algoritma 4 adımdan oluşur [20].

Adım1: Gauss filtresi ile filtreleme

Maske gezdirmek, maske katsayılarına denk gelen piksellerle maske katsayılarını çarparak merkezdeki piksele yeni değer atama işlemidir.

İlk adımda görüntü şekil 2.5'te verilmiş olan ve standart sapma değeri 1 olan 3x3 boyutundaki gauss maskesiyle süzgeçlenir. İmge gürültüden temizlenirken bunun yanı sıra istenmese de kenarlar yumuşatılmış olur.

0.0625	0.125	0.0625
0.125	0.25	0.125
0.0625	0.125	0.0625

-1	0	1
-2	0	2
-1	0	1

-1	-2	-1
0	0	0
1	2	1

G_x
 G_y

Şekil 2.5. Gauss maskesi ve Sobel Operatörü

Adım 2: Sobel operatörü ile filtreleme

G_x ve G_y sobel maskelerinin görüntüde sırasıyla x ve y eksenleri doğrultusunda gezdirilir. Gradyan büyüklüğü Z ve gradyan vektör yönü θ 'dir.

$$Z = \sqrt{G_x^2 + G_y^2} \quad (2.17)$$

$$\theta(x, y) = \tan^{-1}\left(\frac{G_y}{G_x}\right) \quad (2.18)$$

Adım 3: Local maksimumları bulma

θ boyunca Z değerine bakılarak yerel maksimumlar tespit edilir.

Adım 4: Eşikleme


Histerezis eşiklemeyle en düşük ve en yüksek eşik değerleri elde edilir. Eğer Z en düşük eşik değerinden küçükse kenar değildir. En düşük ve en yüksek eşik değerleri arasında ise zayıf kenardır. En yüksek eşik değerine eşit veya büyükse kuvvetli kenardır.

Homojen bölgelerde, Hh benzerlik matrisi için piksel benzerlik değerlerinin 1 veya 1'e yakın, kenar bölgelerinde ise 0 veya 0'a yakın çıkması beklenir. Bunun sebebi, kenar bölgelerinde standart sapma değerinin diğer bir deyişle değişimin büyük olması; homojen bölgelerde ise standart sapma değerinin diğer bir deyişle değişimin küçük olmasıdır.

Şekil 2.6.(a)' da görüldüğü gibi 10x10 görüntü boyutundaki Hh benzerlik matrisinde piksel benzerlik değerleri homojen bölgelerde 1, kenar bölgelerinde ise 0'a yakın çıkmıştır.

	0	0	0	0	0	0	0	0	0
0	1	1	1	0,167846	0,167846	1	1	1	0
0	1	1	1	0,167846	0,167846	1	1	1	0
0	1	1	1	0,167846	0,167846	1	1	1	0
0	0,22095	0,22095	0,22095	0,008459	0,057314	0,431293	0,431293	0,431293	0
0	0,22095	0,22095	0,22095	0	0,048421	0,431293	0,431293	0,431293	0
0	1	1	1	0,138016	0,138016	1	1	1	0
0	1	1	1	0,138016	0,138016	1	1	1	0
0	1	1	1	0,138016	0,138016	1	1	1	0
0	0	0	0	0	0	0	0	0	0

(a) Hh benzerlik matrisi



(b) Hh benzerlik matrisinin 3-boyutlu gösterimi


Şekil 2.6.(a) Hh benzerlik matrisi, (b) Hh benzerlik matrisinin 3-boyutlu gösterimi

Otsu metoduyla belirlenen eşik değerinden, test görüntüsü için 0.0196' dan büyük değerler tohum piksel adayı olmuştur ve tohum adayı pikseller şekil 2.6.(a)'da sarı renkle gösterilmişlerdir.

Test görüntüsüyle aynı boyutta benzerlik matrisi elde edilmiştir. Şekil 2.6.(a)'da gri renkle gösterilen görüntü kenar pikselleri için 3x3 alt görüntüden söz edilemediği için benzerlik hesaplanamamıştır.

0	0	0	0	0	0	0	0	0	0
0	0	0	0	0,812209	1,379642	0	0	0	0
0	0	0	0	0,812209	1,379642	0	0	0	0
0	0	0	0	0,812209	1,379642	0	0	0	0
0	0,760378	0,760378	0,760378	0	1,431004	0,942869	0,942869	0,942869	0
0	0,764034	0,764034	0,764034	0	0,763344	0,503627	0,503627	0,503627	0
0	0	0	0	0,845371	0,763344	0	0	0	0
0	0	0	0	0,845371	0,763344	0	0	0	0
0	0	0	0	0,845371	0,763344	0	0	0	0
0	0	0	0	0	0	0	0	0	0

(a) Tohum piksel adaylarının öklid uzaklıkları




(b) Tohum piksel adaylarının öklid uzaklık matrisinin 3-boyutlu gösterimi

Şekil 2.7. (a) Tohum piksel adaylarının öklid uzaklıkları, (b) Tohum piksel adaylarının öklid uzaklık matrisinin 3-boyutlu gösterimi

Tohum piksel adaylarından öklid uzaklığı eşitlik 2.22'den 0.289 olarak hesaplanmış ve değeri 0.289 'dan küçük tohum piksel adayları tohum pikseli olarak belirlenmiştir. Şekil 2.7.(a)'da kırmızı renkle gösterilmişlerdir. Sarı renkli pikseller tohum aday pikselleri, beyaz renkli pikseller ise tohum olmaya aday olamayan pikselleri göstermektedir. Şekil 2.7.(a)'da gri renkle gösterilen görüntü kenar pikselleri için 3x3 alt görüntüden söz edilemediği için öklid uzaklıkları hesaplanamamıştır.

Tohum piksellerinin görüntüdeki gösterimi şekil 2.8' de verilmiştir.



Şekil 2.8. Test görüntüsü için tohum pikselleri


Şekil 2.8' de siyah pikseller tohum pikselidir. 4 tohum bölgesi vardır ve sınıflandırılmayan pikseller bu bölgelere komşuluk ve öklid uzaklıklarına göre sınıflandırılır.




Şekil 2.9. İncelenecek görüntü çeşitleri

Şekil 2.9' da incelenecek 6 farklı görüntü sınıfı belirtilmiştir. Net, tek cisimli görüntü NT ile; net, aynı ve çok cisimli görüntü NÇA ile; net, farklı ve çok cisimli görüntü NÇF ile; bulanık, tek cisimli görüntü BT ile; bulanık, aynı ve çok cisimli görüntü BÇA ile; bulanık, farklı ve çok cisimli görüntü BÇF ile ifade edilmiştir.

Canny kenar belirleme operatörü ile NT, NÇA, NÇF, BT, BÇA ve BÇF görüntülerinin H bileşeni üzerinden sırasıyla şekil 2.10, şekil 2.11, şekil 2.12, şekil 2.13, şekil 2.14, ve şekil 2.15’ de görüldüğü gibi görüntü kenarları tespit edilmiştir.



Şekil 2.10. (a) NT görüntü, (b) Kenarları belirlenmiş NT görüntü




Şekil 2.11. (a) NÇA görüntü, (b) Kenarları belirlenmiş NÇA görüntü



(a)

(b)

Şekil 2.12. (a) NÇF görüntü, (b) Kenarları belirlenmiş NÇF görüntü



(a)

(b)

Şekil 2.13. (a) BT görüntü, (b) Kenarları belirlenmiş BT görüntü



(a)

(b)

Şekil 2.14. (a) BÇA görüntü, (b) Kenarları belirlenmiş BÇA görüntü



(a)

(b)

Şekil 2.15. (a) BÇF görüntü, (b) Kenarları belirlenmiş BÇF görüntü

Canny kenar belirleme operatörüyle, görüntü H bileşeni üzerinden belirlenen kenar piksellerinin bağıl öklid uzaklığı hesaplanmıştır. Canny kenar belirleme operatörüyle U tane kenar pikseli kaydedilmiştir. u . kenar pikseli için öklid uzaklığı, d_u eşitlik (2.19) ve eşitlik (2.20)'den hesaplanmıştır.

$$d_{iu} = \frac{\sqrt{(Y_u - Y_{iu})^2 + (C_{bu} - C_{bui})^2 + (C_{ru} - C_{rui})^2}}{\sqrt{Y_u^2 + C_{bu}^2 + C_{ru}^2}} \quad i = 1, 2, \dots, 8 \quad (2.19)$$

$$d_u = \max_{i=1}^8 (d_{ui}) \quad (2.20)$$


Her bir kenar pikseli için hesaplanan bağıl öklid uzaklıkları toplanarak kenar piksel sayısına bölünmüştür.

$$d_{ort} = \frac{1}{U} \sum_{u=1}^U d_u \quad (2.21)$$

Eşitlik (2.19)'da elde edilen ortalama uzaklık ile $T_{eşik1}$ değeri dinamik olarak belirlenmeye çalışılmıştır. Kenar piksellerinin d_{ort} ortalama uzaklık değerinin ve d_u 'nun ortanca terimi $ortanca(d_u)$ 'nın farklı katları farklı görüntülerde denenmiştir. Sonuçta en uygun değerlere eşitlik (2.22)'deki $T_{eşik1}$ formüle ile ulaşılmıştır.

$$T_{eşik1} = \begin{cases} 0.9(0.7d_{ort} - 0.97ortanca(d_u)) & \text{if } ortanca(d_u) < 0.5d_{ort} \\ 0.9(0.97d_{ort} - 0.7ortanca(d_u)) & \text{if } d_{ort} < 0.5ortanca(d_u) \\ 0.9(0.5d_{ort}) & \text{if diğ er} \end{cases} \quad (2.22)$$

NT, NÇA, NÇF, BT, BÇA ve BÇF için tohum seçimi Shih'in belirlediği 0.05 eşik değeriyle ve eşitlik 2.22'de verilen koşullara göre belirlenen dinamik eşik değeriyle gerçekleştirilmiştir. Tohum pikselleri görüntülerde kırmızı veya mavi renkle gösterilmiştir.




(a) $T_{eşik1} = 0.05$ [5]

(b) $T_{eşik1} = 0.0329$

Şekil 2.16. NT için tohumlandırılmış görüntüler

Şekil 2.16.(a)'daki 200x200 boyutundaki görüntü için tohum pikselleri 0.05 [5] eşik değeriyle belirlenmiştir. Şekil 2.16.(b)'de dinamikleştirilmiş ve değeri 0.0329 olan, görüntüden belirlenmiş eşik değeriyle seçilmiş tohum pikselleri kırmızıyla gösterilmiştir.

Şekil 2.16.(b)'de 40000 piksellik görüntüde 23426 piksel tohum pikseli olarak işaretlenmiştir. Sınıflandırılmayan piksel sayısı 16574'tür. Tohum piksel sayısı şekil 2.16.(a)'daki görüntüye göre daha azdır. Böylelikle görüntüde daha fazla ayrıntı yakalanmıştır.



(a) $T_{eshik1} = 0.05$ [5]

(b) $T_{eshik1} = 0.0243$

Şekil 2.17. NÇA için tohumlandırılmış görüntüler

Şekil 2.17.(a)'daki 314x204 boyutundaki görüntü için tohum pikselleri 0.05 [5] eşik değeriyle belirlenmiştir. Şekil 2.17.(b)'de dinamikleştirilmiş ve değeri 0.0243 olan, görüntüden belirlenmiş eşik değeriyle seçilmiş tohum pikselleri kırmızıyla gösterilmiştir.


Şekil 2.17.(b)'de 64056 piksellik görüntüde 29957 piksel tohum pikseli olarak işaretlenmiştir. Sınıflandırılmayan piksel sayısı 34099'dur. Tohum piksel sayısı şekil 2.17.(a)'daki görüntüye göre daha azdır. Böylelikle görüntüde daha fazla ayrıntı yakalanmıştır.

(a) $T_{eshik1} = 0.05$ [5](b) $T_{eshik1} = 0.0883$

Şekil 2.18. NÇF için tohumlandırılmış görüntüler

Şekil 2.18.(a)'deki 250x187 boyutundaki görüntü için tohum pikselleri 0.05 [5] eşik değeriyle belirlenmiştir. Şekil 2.18.(b)'de dinamikleştirilmiş ve değeri 0.0883 olan, görüntüden belirlenmiş eşik değeriyle seçilmiş tohum pikselleri kırmızıyla gösterilmiştir.


Şekil 2.18.(b)'de 46750 piksellik görüntüde 37021 piksel tohum pikseli olarak işaretlenmiştir. Sınıflandırılmayan piksel sayısı 9729'dir. Tohum piksel sayısı şekil 2.18.(a)'daki görüntüye göre daha fazladır. Böylelikle pek fazla farklı renk içermeyen görüntüde gereksiz bölütlemeyen kaçınılmıştır.

(a) $T_{eshik1} = 0.05$ [5](b) $T_{eshik1} = 0.0817$

Şekil 2.19. BT için tohumlandırılmış görüntüler

Şekil 2.19.(a)'daki 160x160 boyutundaki görüntü için tohum pikselleri 0.05 [5] eşik değeriyle belirlenmiştir. Şekil 2.19.(b)'de dinamikleştirilmiş ve değeri 0.0817 olan, görüntüden belirlenmiş eşik değeriyle seçilmiş tohum pikselleri kırmızıyla gösterilmiştir.

Şekil 2.19.(b)'de 25600 piksellik görüntüde 14983 piksel tohum pikseli olarak işaretlenmiştir. Sınıflandırılmayan piksel sayısı 10617'dir. Tohum piksel sayısı şekil 2.19.(a)'daki görüntüye göre daha fazladır. Böylelikle pek fazla farklı renk içermeyen görüntüde gereksiz bölütlemeyen kaçınılmıştır.



(a) $T_{eşik1} = 0.05$ [5]

(b) $T_{eşik1} = 0.0566$

Şekil 2.20. BÇA için tohumlandırılmış görüntüler

Şekil 2.20.(a)'daki 127x204 boyutundaki görüntü için tohum pikselleri 0.05 [5] eşik değeriyle belirlenmiştir. Şekil 2.20.(b)'de dinamikleştirilmiş ve değeri 0.0566 olan, görüntüden belirlenmiş eşik değeriyle seçilmiş tohum pikselleri kırmızıyla gösterilmiştir.

Şekil 2.20.(b)'de 25908 piksellik görüntüde 6815 piksel tohum pikseli olarak işaretlenmiştir. Sınıflandırılmayan piksel sayısı 19093'dir. Tohum piksel sayısı şekil 2.20.(a)'daki görüntüye göre daha fazladır. Böylelikle pek fazla farklı renk içermeyen görüntüde gereksiz bölütlemeyen kaçınılmıştır.

(a) $T_{eşik1} = 0.05$ [5](b) $T_{eşik1} = 0.0589$

Şekil 2.21. BÇF için tohumlandırılmış görüntüler

Şekil 2.21.(a)'deki 272x235 boyutundaki görüntü için tohum pikselleri 0.05 [5] eşik değeriyle belirlenmiştir. Şekil 2.21.(b)'de dinamikleştirilmiş ve değeri 0.0589 olan, görüntüden belirlenmiş eşik değeriyle seçilmiş tohum pikselleri kırmızıyla gösterilmiştir.

Şekil 2.21.(b)'de 63920 piksellik görüntüde 46781 piksel tohum pikseli olarak işaretlenmiştir. Sınıflandırılmayan piksel sayısı 17139'dur. Tohum piksel sayısı şekil 2.21.(a)'daki görüntüye göre daha azdır. Böylelikle görüntüde daha fazla ayrıntı yakalanmıştır.

2.2.3. Tohumlandırılmalı Bölge Büyütme

Bölge büyütme, otomatik tohumlandırılmalı bölge büyütme algoritmasının üçüncü basamağıdır. Birbiriyle bağlantılı tohum pikselleri tek bir bölge olarak düşünülür. Sınıflandırılmayan pikseller değerlendirilerek tohum bölgelerinden birine dahil edilir.

Bağlantılı tohum piksellerinin oluşturduğu bütün bölge kenar piksellerinin 4-komşuluğundaki henüz bir bölgeye dahil edilmemiş piksellere bakılmış ve bu pikseller Q gibi bir kümede listelenmiştir.


Q kümesindeki bütün piksellerin komşu oldukları bölgelere göre bağlı öklid uzaklığı hesaplanmıştır. Q kümesindeki herhangi bir t pikseli için bağlı öklid uzaklığı d_t ; t

pikselinin Y_t , C_{bt} ve C_{rt} değerleri ile t pikselinin komşu olduğu k. bölgenin ortalama değerleri \bar{Y}_k , \bar{C}_{bk} ve \bar{C}_{rk} ile eşitlik (2.23)' deki gibi hesaplanmıştır.

$$d_t = \frac{\sqrt{(Y_t - \bar{Y}_k)^2 + (C_{bt} - \bar{C}_{bk})^2 + (C_{rt} - \bar{C}_{rk})^2}}{\sqrt{Y_t^2 + C_{bt}^2 + C_{rt}^2}} \quad (2.23)$$

En küçük öklid uzaklık değerine sahip piksel komşu olduğu bölgeye dahil edilirken 4-komşuluğundaki sınıflandırılmamış pikseller Q kümesine alınmıştır. Bu işleme sınıflandırılmamış bütün pikseller sınıflandırılincaya kadar devam edilmiştir.


Bölge büyütme sürecini anlatan için bir örnek aşağıda verilmiştir.



Şekil 2.22. Tohumlandırılmalı bölge büyütme, (a) Tohum ve komşu pikseller, (b) Sınıflandırılacak pikselin belirlenmesi, (c) Yeni piksellerin Q kümesine dahil edilmesi

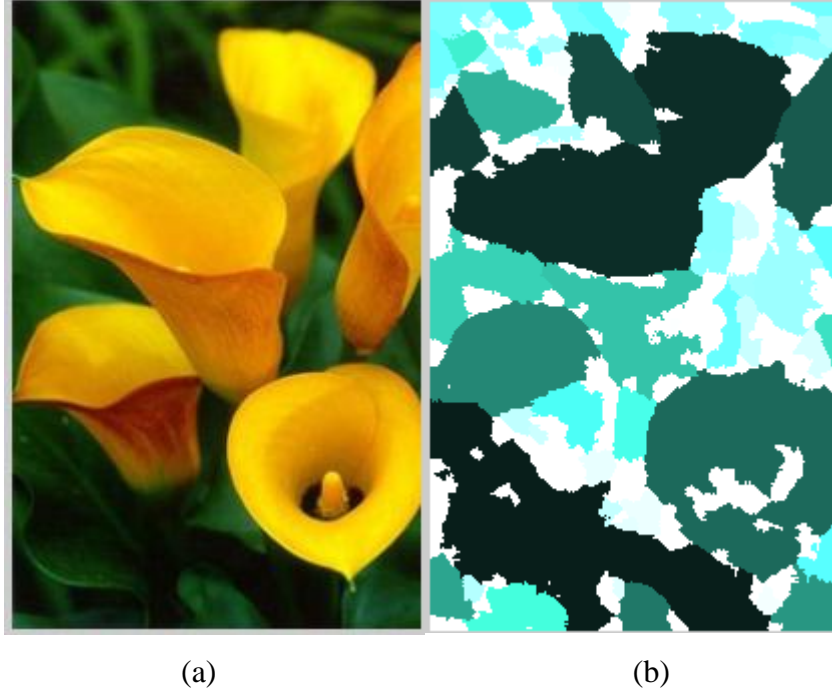
Şekil 2.22(a) 'da kırmızı pikseller tohum pikselleri, yeşil pikseller de Q kümesinde yer alan sınıflandırılmamış tohum bölge kenar piksellerinin komşularıdır. Yapılan sıralama sonucunda en düşük öklid uzaklığına sahip piksel şekil 2.22(b) de görülen beyaz renge boyanmış pikseldir. Beyaz piksel bağlantılı olduğu tohum bölgesine dahil edilirken şekil 2.22(c)'de gösterilen beyaz pikselin 4-komşuluğundaki sınıflandırılmamış siyah pikseller de Q kümesine atanır.

Tohum seçimiyle elde edilen tohum bölgelerine, dinamik eşik değeri kullanılarak sınıflandırılmamış pikseller dağıtılmıştır.



Şekil 2.23.(a) NT imge, (c) Sınıflandırma bittikten sonra bölgeler

Şekil 2.23.(a)'daki orijinal görüntü otomatik tohumlandırıldığında, 99 farklı tohum bölgesinin varlığı söz konusu olmuştur. Sınıflandırılmayan pikseller bu 99 bölgeye bağlı öklid uzaklıklarına göre dahil edilmişlerdir.



Şekil 2.24.(a) NÇA imge, (c) Sınıflandırma bittikten sonra bölgeler

Şekil 2.24.(a)'daki orijinal görüntü otomatik tohumlandırıldığında 327 farklı tohum bölgesinin varlığı söz konusu olmuştur. Sınıflandırılmayan pikseller bu 327 bölgeye bağlı öklid uzaklıklarına göre dahil edilmişlerdir.




(a)

(b)

Şekil 2.25.(a) NÇF imge, (c) Sınıflandırma bittikten sonra bölgeler

Şekil 2.25.(a)'daki orijinal görüntü otomatik tohumlandırıldığında 67 farklı tohum bölgesinin varlığı söz konusu olmuştur. Sınıflandırılmayan pikseller bu 67 bölgeye bağlı öklid uzaklıklarına göre dahil edilmişlerdir.

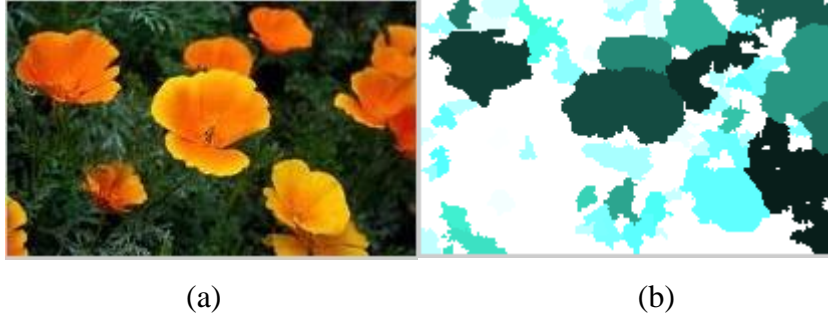


(a)

(b)


Şekil 2.26.(a) BT imge, (c) Sınıflandırma bittikten sonra bölgeler

Şekil 2.26.(a)'daki orijinal görüntü otomatik tohumlandırıldığında 73 farklı tohum bölgesinin varlığı söz konusu olmuştur. Sınıflandırılmayan pikseller bu 73 bölgeye bağlı öklid uzaklıklarına göre dahil edilmişlerdir.



Şekil 2.27.(a) BÇA imge, (c) Sınıflandırma bittikten sonra bölgeler

Şekil 2.27.(a)'daki orijinal görüntü otomatik tohumlandırıldığında 309 farklı tohum bölgesinin varlığı söz konusu olmuştur. Sınıflandırılmayan pikseller bu 309 bölgeye bağlı öklid uzaklıklarına göre dahil edilmişlerdir.



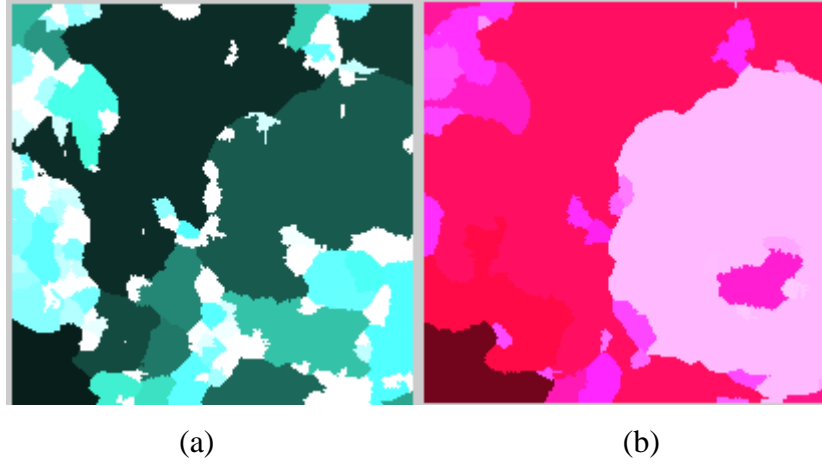
Şekil 2.28.(a) BÇF imge, (c) Sınıflandırma bittikten sonra bölgeler

Şekil 2.28.(a)'daki orijinal görüntü otomatik tohumlandırıldığında 100 farklı tohum bölgesinin varlığı söz konusu olmuştur. Sınıflandırılmayan pikseller bu 100 bölgeye bağlı öklid uzaklıklarına göre dahil edilmişlerdir.

2.2.4. Bölge Birleştirme


Çeşitli tohumlar aşırı bölütlemeye sebep olacağından sonraki adımda bölge birleştirme yapılması gerekir.

Komşu herhangi iki bölge arasındaki uzaklık belirlenen $T_{eşik2}$ eşik değerinden küçük olmuşsa bu iki bölge birleştirilmiştir. Burada $T_{eşik2} = 0.1$ seçilmiştir[5]. Bölge birleştirme işlemi, birleşme olacak bölge kalmayana kadar devam eder.




Şekil 2.29. (a) NT için öklid uzaklığına göre bölge birleştirmeden önce bölgeler, (b) NT için öklid uzaklığına göre bölge birleştirmeden sonra bölgeler

Şekil 2.23.(a)'daki 99 bölgeye ayrılmış görüntü komşu bölgelerinden öklid uzaklıkları 0.1'den küçük olanlar birleştirilmiş ve birleşme sonucunda görüntüdeki bölge sayısı azalmıştır. Şekil 2.29.(a)'da görüldüğü gibi 99 bölgeden oluşmuş görüntü şekil 2.29.(b)'deki gibi 35 bölgeye indirgenmiştir.




Şekil 2.30. (a) NÇA için öklid uzaklığına göre bölge birleştirmeden önce bölgeler, (b) NÇA için öklid uzaklığına göre bölge birleştirmeden sonra bölgeler

Şekil 2.24.(a) 'daki 327 bölgeye ayrılmış görüntü komşu bölgelerinden öklid uzaklıkları 0.1'den küçük olanlar birleştirilmiş ve birleşme sonucunda görüntüdeki bölge sayısı azalmıştır. Şekil 2.30.(a)'da görüldüğü gibi 327 bölgeden oluşmuş görüntü şekil 2.30.(b)'deki gibi 73 bölgeye indirgenmiştir.



Şekil 2.31. (a) NCF için öklid uzaklığına göre bölge birleştirmeden önce bölgeler (b) NCF için öklid uzaklığına göre bölge birleştirmeden sonra bölgeler


Şekil 2.25.(a) 'daki 67 bölgeye ayrılmış görüntü komşu bölgelerinden öklid uzaklıkları 0.1'den küçük olanlar birleştirilmiş ve birleşme sonucunda görüntüdeki bölge sayısı azalmıştır. Şekil 2.31.(a)'da görüldüğü gibi 67 bölgeden oluşmuş görüntü şekil 2.31.(b)'deki gibi 22 bölgeye indirgenmiştir.



Şekil 2.32. (a) BT için öklid uzaklığına göre bölge birleştirmeden önce bölgeler, (b) BT için öklid uzaklığına göre bölge birleştirmeden sonra bölgeler

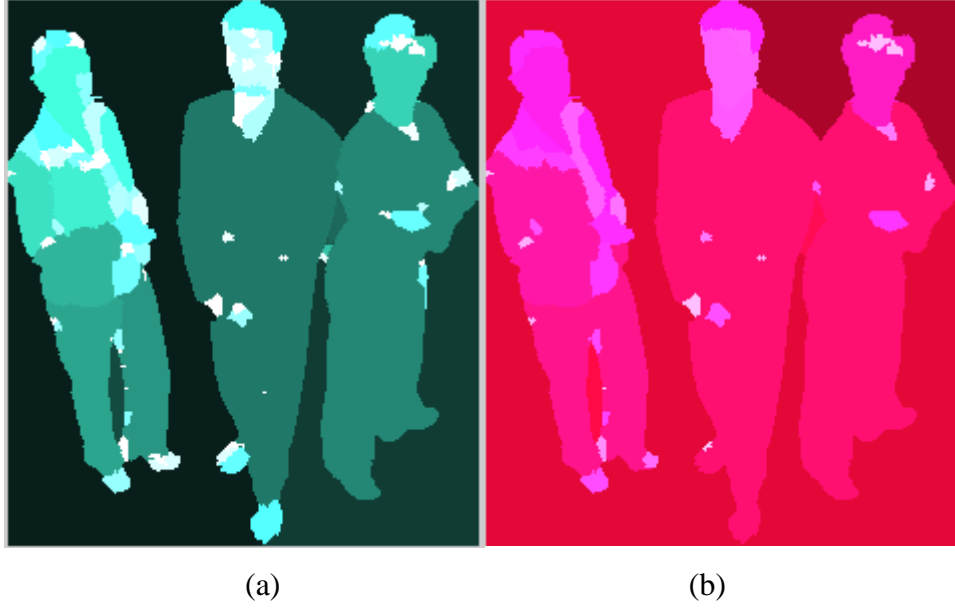
Şekil 2.26.(a)'daki 73 bölgeye ayrılmış görüntü komşu bölgelerinden öklid uzaklıkları 0.1'den küçük olanlar birleştirilmiş ve birleşme sonucunda görüntüdeki bölge

sayısı azalmıştır. Şekil 2.32.(a)'da görüldüğü gibi 73 bölgeden oluşmuş görüntü şekil 2.29(b)'deki gibi 44 bölgeye indirgenmiştir.



Şekil 2.33. (a) BÇA için öklid uzaklığına göre bölge birleştirmeden önce bölgeler, (b) BÇA için öklid uzaklığına göre bölge birleştirmeden sonra bölgeler

Şekil 2.27.(a)'daki 309 bölgeye ayrılmış görüntü komşu bölgelerinden öklid uzaklıkları 0.1'den küçük olanlar birleştirilmiş ve birleşme sonucunda görüntüdeki bölge sayısı azalmıştır. Şekil 2.33.(a)'da görüldüğü gibi 309 bölgeden oluşmuş görüntü şekil 2.33.(b)'deki gibi 40 bölgeye indirgenmiştir.



Şekil 2.34. (a) BÇF için öklid uzaklığına göre bölge birleştirmeden önce bölgeler, (b) BÇF için öklid uzaklığına göre bölge birleştirmeden sonra bölgeler


Şekil 2.28.(a)'daki 100 bölgeye ayrılmış görüntü komşu bölgelerinden öklid uzaklıkları 0.1'den küçük olanlar birleştirilmiş ve birleşme sonucunda görüntüdeki bölge sayısı azalmıştır. Şekil 2.34.(a)'da görüldüğü gibi 100 bölgeden oluşmuş görüntü şekil 2.34.(b)'deki gibi 42 bölgeye indirgenmiştir.

Öklid uzaklığına göre yapılan birleştirmeden sonra bölge boyutuna göre de birleşme gerçekleştirilir. $T_{eşik2}$ 'ye göre birleşmeden sonra oluşan bölgeler ikinci bir sınımadan geçirilmiştir. Bölge boyutu, görüntüdeki toplam piksel sayısının 1/150[5]'den küçük olan bölgeler; komşu bölgelerden renk uzaklığı en küçük olanla birleştirilmiştir [5].

$$d(R_m, R_n) = \frac{\sqrt{(\bar{Y}_m - \bar{Y}_n)^2 + (\bar{C}_{bm} - \bar{C}_{bn})^2 + (\bar{C}_{rm} - \bar{C}_{rn})^2}}{\min\left(\sqrt{\bar{Y}_m^2 + \bar{C}_{bm}^2 + \bar{C}_{rm}^2}, \sqrt{\bar{Y}_n^2 + \bar{C}_{bn}^2 + \bar{C}_{rn}^2}\right)} \quad (2.24)$$

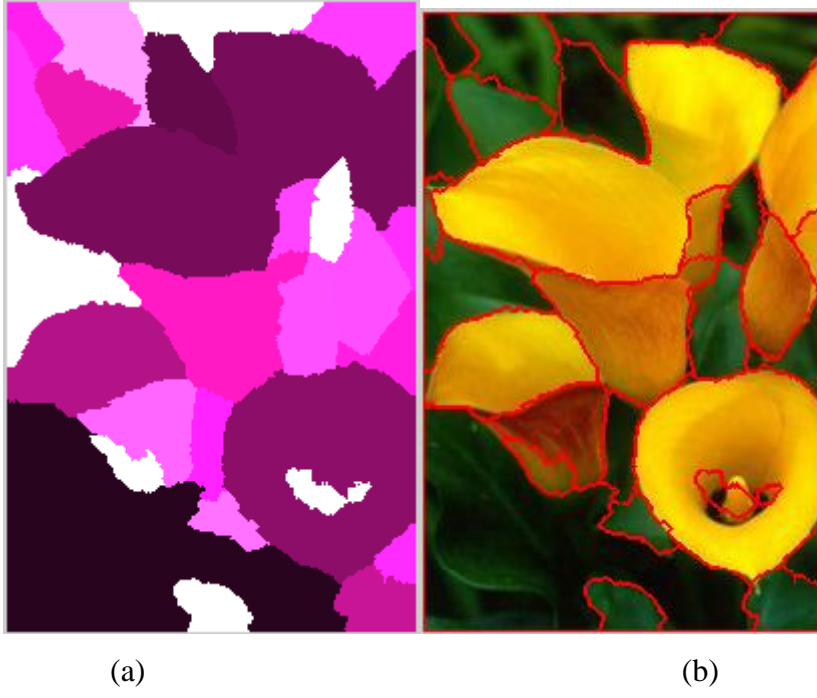
R_m ; boyutu, toplam piksel sayısının 1/150[5]'den küçük olan bölge; R_n ise R_m bölgesinin komşu bölge veya bölgeleridir. R_m 'e komşu bütün R_n bölgeler için öklid uzaklığına bakılmış ve en kısa uzaklığa sahip R_n bölgesine dahil edilmiştir.

Sonuç olarak bu son işlemle bölütleme diğer bir deyişle bölge ve kenar belirleme süreci tamamlanmıştır.




Şekil 2.35. NT için bölge boyutuna göre bölge birleştirme, (a) Bölgeler, (b) Kenarlar

Şekil 2.29.(b) 'deki 35 bölgeye ayrılmış görüntü bölgelerinin boyutlarına bakılıp toplam piksel sayısının $1/150$ 'dan küçük komşu bölgeler birleştirilmiştir. Birleşme sonucunda görüntüdeki bölge sayısı azalmış ve 15 bölgeye indirgenmiştir. Şekil 2.35.(a)'da görüldüğü gibi görüntü bölütleme tamamlanmıştır. Şekil 2.35(b)'de ise bölge kenarları gösterilmiştir.




Şekil 2.36. NÇA için bölge boyutuna göre bölge birleştirme, (a) Bölgeler, (b) Kenarlar

Şekil 2.30.(b) 'deki 73 bölgeye ayrılmış görüntü bölgelerinin boyutlarına bakılıp toplam piksel sayısının $1/150$ 'den küçük komşu bölgeler birleştirilmiştir. Birleşme sonucunda görüntüdeki bölge sayısı azalmış ve 28 bölgeye indirgenmiştir. Şekil 2.36.(a)'da görüldüğü gibi görüntü bölütleme tamamlanmıştır. Şekil 2.36(b)'de ise bölge kenarları gösterilmiştir.



Şekil 2.37. NCF için bölge boyutuna göre bölge birleştirme, (a) Bölgeler, (b) Kenarlar

Şekil 2.31.(b) 'deki 22 bölgeye ayrılmış görüntü bölgelerinin boyutlarına bakılıp toplam piksel sayısının 1/150'den küçük komşu bölgeler birleştirilmiştir. Birleşme sonucunda görüntüdeki bölge sayısı azalmış ve 12 bölgeye indirgenmiştir. Şekil 2.37 (a)'da görüldüğü gibi görüntü bölütleme tamamlanmıştır. Şekil 2.37(b)'de ise bölge kenarları gösterilmiştir.



Şekil 2.38. BT için bölge boyutuna göre bölge birleştirme, (a) Bölgeler, (b) Kenarlar

Şekil 2.32(b) 'deki 44 bölgeye ayrılmış görüntü bölgelerinin boyutlarına bakılıp toplam piksel sayısının 1/150'den küçük komşu bölgeler birleştirilmiştir. Birleşme

sonucunda görüntüdeki bölge sayısı azalmış ve 10 bölgeye indirgenmiştir. Şekil 2.38.(a)'da görüldüğü gibi görüntü bölütleme tamamlanmıştır. Şekil 2.38.(b)'de ise bölge kenarları gösterilmiştir.



Şekil 2.39. BÇA için bölge boyutuna göre bölge birleştirme, (a) Bölgeler, (b) Kenarlar

Şekil 2.33.(b) 'deki 40 bölgeye ayrılmış görüntü bölgelerinin boyutlarına bakılıp toplam piksel sayısının 1/150'den küçük komşu bölgeler birleştirilmiştir. Birleşme sonucunda görüntüdeki bölge sayısı azalmış ve 14 bölgeye indirgenmiştir. Şekil 2.39.(a)'da görüldüğü gibi görüntü bölütleme tamamlanmıştır. Şekil 2.39.(b)'de ise bölge kenarları gösterilmiştir.



(a)

(b)

Şekil 2.40. BÇF için bölge boyutuna göre bölge birleştirme, (a) Bölgeler, (b) Kenarlar

Şekil 2.34.(b) 'deki 42 bölgeye ayrılmış görüntü bölgelerinin boyutlarına bakılıp toplam piksel sayısının $1/150$ 'den küçük komşu bölgeler birleştirilmiştir. Birleşme sonucunda görüntüdeki bölge sayısı azalmış ve 14 bölgeye indirgenmiştir. Şekil 2.40. (a)'da görüldüğü gibi görüntü bölütleme tamamlanmıştır. Şekil 2.40.(b)'de ise bölge kenarları gösterilmiştir.

3. İRDELEME VE SONUÇLAR

Bu çalışmada tohum piksel adayları arasından tohumlara karar veren $T_{eşik1}$ değeri, görüntüden elde edilen bilgilerle dinamik hale getirilmiştir.

Tohum piksellerinin seçimi, sınıflandırılmayan piksel sayısını ve sınıflandırılmayan piksellerin bölgelerle olan bağıl öklid uzaklığını etkiler. Sınıflandırılmayan piksellerin bölgelere dahil edilmesi öklid uzaklığı üzerinden yapılır. Bu da tohum piksel adayları arasından tohumlara karar veren $T_{eşik1}$ değerinin seçimini önemli kılar. Tohum belirleme, otomatik tohumlandırılmalı bölge büyütme metodunun ilk adımıdır. Sonraki adımlar önceki basamakta elde edilen verilere bağlı olduğundan ilk basamakta verilerin iyi seçilmesi metodu daha etkin kılacaktır.



(a)

(b)

Şekil 2.41. (a) NT görüntüyü $T_{eşik1} = 0.05$ [5] ile bölütleme, (b) NT görüntüyü dinamikleştirilmiş $T_{eşik1} = 0.0329$ ile bölütleme



(a)

(b)

Şekil 2.42. (a) NÇA görüntüyü $T_{eşik1} = 0.05$ [5] ile bölütleme, (b) NÇA görüntüyü dinamikleştirilmiş $T_{eşik1} = 0.0243$ ile bölütleme



(a)

(b)

Şekil 2.43. (a) NÇF görüntüyü $T_{eşik1} = 0.05$ [5] ile bölütleme, (b) NÇF görüntüyü dinamikleştirilmiş $T_{eşik1} = 0.0883$ ile bölütleme



(a)

(b)


Şekil 2.44. (a) BT görüntüyü $T_{eshik1} = 0.05$ [5] ile bölütleme, (b) BT görüntüyü dinamikleştirilmiş $T_{eshik1} = 0.0817$ ile bölütleme



(a)

(b)

Şekil 2.45. (a) BÇA görüntüyü $T_{eshik1} = 0.05$ [5] ile bölütleme, (b) BÇA görüntüyü dinamikleştirilmiş $T_{eshik1} = 0.0566$ ile bölütleme



Şekil 2.46. (a) BÇF görüntüyü $T_{eşik1} = 0.05$ [5] ile bölütleme, (b) BÇF görüntüyü dinamikleştirilmiş $T_{eşik1} = 0.0589$ ile bölütleme

Dinamikleştirilmiş $T_{eşik1}$ ile kenarların ve bölgelerin daha iyi belirlendiği görülmüştür. Ayrıca genelde sınıflandırılmayan piksel sayısı azaldığı için işlem sayısı azalmış ve süre kısalmıştır.

4. ÖNERİLER

Yapılan çalışmada tohum piksel adayları arasından tohum piksellerini belirleyen $T_{eşik1}$ değeri dinamik bir özellik kazanmış olmasına rağmen bölge birleştirmede belirlenmiş eşik değerleri birer sabittir. Bu eşik değerleri de görüntüden elde edilen veriyle dinamik hale getirilebilir.

Renkli görüntüyü YC_bC_r yerine diğer renk uzaylarında inceleyerek belirlenen $T_{eşik1}$ değerinin dinamikliği test edilebilir ve diğer eşik değerleri de bu uzaylarda dinamik hale getirilmeye çalışılabilir.

Tohum piksellerinin seçilmesi, geri kalan piksellerin sınıflandırılması, komşu bölgelerin kıyaslanarak birleştirilmesi gibi işlemler programın yavaş çalışmasına sebep olmuştur. Süreyi kısaltmak için program paralel koşturulabilir.

Otomatik tohumlandırılmalı bölge büyütme metoduyla imgenin bölge ve kenarları elde edilmiştir. Bu algoritma nesne tanımaya yönelik yapılandırılabilir. Örneğin, insan teninin renk modellerindeki ortalama değerleri belirlenerek bölgelerin ortalama değerleriyle kıyaslanır ve sonuç olarak insan tenini içeren bölge diğer bölgeler arasından seçilebilir.

5. KAYNAKLAR

1. Uslu, R., Elektronik Bir Hücreli Yapay Sinir Ağı Gerçekleşmesi Olan ACE16K Üzerinde Görüntü Bölütleme, Yüksek Lisans Tezi, İ.T.Ü., Fen Bilimleri Enstitüsü, İstanbul, 2007.
2. Tang, J., A Color Image Segmentation Algorithm Based on Region Growing, Nisan 2010, 2nd International Conference on Computer Engineering and Technology (ICCET), Xi'an, China, Bildiriler Kitabı: 634 -637.
3. Karabatak, E., Nötrozofi Yaklaşımı ile Renkli Görüntü Bölütleme, Yüksek Lisans Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ, 2010.
4. Plataniotis, K., N. and Venetsanopoulos, A., N., Color Image Processing and Applications, First Edition, Springer, 2000, Almanya.
5. Shih, F.,Y. and Cheng, S., Automatic Seeded Region Growing for Color Image Segmentation, Image and Vision Computing, 23 (2005) 877–886.
6. Bischof, R., A. and Bischof, L., Seeded Region Growing, Pattern Analysis and Machine Intelligence, 16, 6 (1994) 641-647.
7. Revol, C. and Jourlin, M., A new minimum variance region growing algorithm for image segmentation, Pattern Recognition Letters, 18, 3(1997) 249-258.
8. Wan, S. and Higgins, W., E., Symmetric region growing, Image Processing, 12, 9 (2003) 1007-1015.
9. Zhi, L. and Jie, Y., Interactive video object segmentation: fast seeded region merging approach, Electronics Letters, 40, 5 (2004) 1-2.
10. Feng, Y., Fang, H. and Jiang, J., Region Growing with Automatic Seeding for Semantic Video Object Segmentation, Ağustos 2005, ICAPR, UK, Bildiriler Kitabı: 542-549
11. Fleyeh, H. , Computer Vision, Höğskolan Dalarna, İsveç, 2010.
12. Gonzalez, R.C. and Woods, R.E., Digital Image Processing, Second Edition, Prentice-Hall, New Jersey, 2002.
13. Liu, D. and Yu, J., Otsu method and K-means, Ağustos 2009, Hybrid Intelligent Systems, Beijing, China, Bildiriler Kitabı: 344-349.
14. Karaboga, D. ve Basturk, B., Diferansiyel Gelişim Algoritması ile İmge Bölütleme , Mayıs 2005, Signal Processing and Communications Applications Conference, Kayseri, Türkiye, Bildiriler Kitabı: 33-36.

15. Srinivasan, D., N. and Shobha, G., Segmentation Techniques for Target Recognition, International Journal of Computers and Communication, 1, 3 (2007) 75-81.
16. Zhang, Y., Qu, H. and Wang, Y., Adaptive Image Segmentation Based on Fast Thresholding and Image Merging, Kasım 2006, International Conference on Artificial Reality and Telexistence--Workshops (ICAT'06), Bildiriler Kitabı: 308-311.
17. Canny, J., A Computational Approach To Edge Detection, IEEE Transactions on Pattern Analysis and Machine Intelligence, 8 (1986) 679- 698.
18. Snyder, W. and E., Cowart, A., An Iterative Approach to Region Growing Using Associative Memories, IEEE Transactions on Pattern Analysis and Machine Intelligence, 5, 3 (1983) 349-352.
19. Cho, K. and Meer, P., Image Segmentation from Consensus Information, Computer Vision And Image Understanding, 68, 1(1997) 72–89.
20. Ogawa, K., Ito, Y. and Nakano, K., Efficient Canny Edge Detection Using a GPU, Kasım 2010, First International Conference on Networking and Computing (ICNC), Bildiriler Kitabı: 279-280.

ÖZGEÇMİŞ

Seniha KETENCİ, 15.01.1986 tarihinde Rize’de doğdu. İlköğretim öğrenimini Mehmet Akif Ersoy İlköğretim Okulu’nda, lise öğrenimini Trabzon Fatih (Y.D.A) Lisesi’nde tamamladı. 2003 – 2008 eğitim-öğretim yılında, Karadeniz Teknik Üniversitesi Mühendislik Fakültesi Elektrik- Elektronik Mühendisliği Bölümü’nü kazandı. 2008 yılında bu bölümden Elektrik- Elektronik Mühendisi olarak mezun oldu. Aynı yıl Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda yüksek lisans öğrenimine başladı. Ocak 2009’da aynı bölümde araştırma görevlisi olarak göreve başladı. Halen bu görevine devam etmektedir. 2009-2010 eğitim-öğretim yılını katıldığı öğrenci değişim programıyla İsveç’te Dalarna Üniversitesinde geçirdi. Yabancı dil olarak iyi derecede İngilizce ve temel seviyede İsveççe bilmektedir.