

T.C
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

NÖTROZOFİ YAKLAŞIMI İLE RENKLİ GÖRÜNTÜ BÖLÜTLEME

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisi Ebru KARABATAK

Anabilim Dalı: Bilgisayar Mühendisliği

Programı: Donanım

Tez Danışmanı: Yrd. Doç. Dr. Abdulkadir ŞENGÜR

ŞUBAT-2010

T.C
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

NÖTROZOFİ YAKLAŞIMI İLE RENKLİ GÖRÜNTÜ BÖLÜTLEME

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisi Ebru KARABATAK

(03129105)

Tezin Enstitüye Verildiği Tarih : 5 Şubat 2010

Tezin Savunulduğu Tarih : 24 Şubat 2010

Tez Danışmanı : Yrd. Doç. Dr. Abdulkadir ŞENGÜR (F.Ü.)

Diğer Jüri Üyeleri : Yrd. Doç. Dr. Burhan ERGEN (F.Ü.)

Yrd. Doç. Dr. İbrahim TÜRKOĞLU (F.Ü.)

ŞUBAT-2010

ÖNSÖZ

Bu tez çalışmasında, n trozofiyeye dayanan yeni bir renkli g r nt  b l tleme yaklařımı geliřtirilmiřtir. Geliřtirilen bu yeni yaklařım ile renkli g r nt ler daha homojen ve sınırları belirgin alanlara b l tlenmektedir. Bu çalışmanın renkli g r nt  b l tlemeyle  nemli bir ivme kazandıracakını  mit etmekteyim. Gelecekte de bu konuyu geliřtirmek iin gerekli alıřmalar yapmaya devam edeceėim. Bu alıřmamda verdiėi desteėe ve gelecekte yapacaėım diėer alıřmalarda da desteėini esirgemeyeceėini d ř nd ėim deėerli hocam Yrd. Do. Dr. Abdulkadir Őeng r'e ve alıřma arkadařı Yanhui Guo teřekk r  bir bor bilirim.

İÇİNDEKİLER

Sayfa No

ÖNSÖZ.....	II
İÇİNDEKİLER	III
ÖZET.....	V
SUMMARY	VI
ŞEKİLLER LİSTESİ.....	VII
TABLolar LİSTESİ.....	IX
SEMBOLLER LİSTESİ.....	X
KISALTMALAR LİSTESİ.....	XI
1. GİRİŞ	1
1.1. Görüntü İşlemlerinin Karakteristikleri	3
1.1.1. İşlem Tipleri	3
1.1.2. Komşuluk Tipleri	4
1.2. Görüntü Bölütleme.....	5
1.2.1. Kümeleme Metotları	6
1.2.2. Histogram Tabanlı Metotlar	7
1.2.3. Kenar Belirleme	8
1.2.4. Alan Büyütme Metotları.....	9
1.2.5. Seviye Küme Metodu.....	10
1.2.6. Çizge Ayırma Metotları	11
1.2.7. Su Sınırı Dönüşümü	11
1.2.8. Model Tabanlı Bölütleme.....	12
1.2.9. Çoklu Ölçek Bölütleme.....	12
1.2.9.1. Tek Boyutlu Hiyerarşik Sinyal Bölütleme	12
1.2.9.2. Görüntü Bölütleme ve Temel Taslak	13
1.2.10. Yarı Otomatik Bölütleme	13
1.2.11. Sinir Ağı Bölütleme	14
1.3. Monokrom Görüntü Bölütleme	14
1.4. Renk Uzayları.....	15
1.4.1. Doğrusal Dönüşümler	15
1.4.1.1. KYM	15
1.4.1.2. YIQ.....	16
1.4.1.3. YUV	17

1.4.1.4. $I_1I_2I_3$	17
1.4.2. Doğrusal Olmayan Dönüşümler.....	18
1.4.2.1. Normalize KYM (Nrgb).....	18
1.4.2.2. HSI	19
1.4.2.3. CIE	21
1.4.2.4. Munsell.....	23
1.5. Renkli Görüntü Bölütleme	24
2. GÖRÜNTÜ BÖLÜTLEMeye YENİ BİR NÖTROZOFİK YAKLAŞIM.....	26
2.1. Nötrozofik Küme	28
2.2. Nötrozofik Görüntü Bölütleme	28
2.3. Nötrozofik Görüntü Entropisi	29
2.4. α -Ortalama İşlemi.....	30
2.5. β -İyileştirme İşlemi	31
2.6. NS Üzerindeki γ -Ortalamalar Kümeleme Analizi.....	31
2.7. Nötrozofik Görüntü Bölütleme	33
2.8. Yapay Görüntüler Üzerindeki İncelemeler	35
2.9. Gerçek Görüntüler Üzerindeki İncelemeler	37
3. NÖTROZOFİK RENKLİ GÖRÜNTÜ BÖLÜTLEME	41
3.1. Nötrozofik Görüntü Bölütleme	44
3.1.1. NS de Görüntü.....	44
3.2. Nötrozofik Görüntü Entropisi	44
3.3. α -ortalama ve β -iyileştirme İşlemleri	45
3.4. NS' dayalı Görüntü Bölütlemenin Dezavantajları	45
3.5. δ -medyan İşlemi.....	47
3.6. δ ve β Parametrelerinin Belirlenmesi	48
3.7. NS Üzerinde γ -medyan Kümeleme Analizi	48
3.8. Önerilen Metot	49
3.9. Nötrozofik Renkli Görüntü Bölütleme.....	49
3.10. Deneyler ve Tartışmalar	52
3.10.1. Ortalama Kayma	52
3.10.2. Ortalama Kayma Tabanlı Görüntü Bölütleme	54
3.10.3. Waveseg.....	55
3.11. Performans Değerlendirmesi.....	55
4. SONUÇLAR VE TARTIŞMA	63
KAYNAKLAR.....	64
ÖZGEÇMİŞ.....	68

ÖZET

Bu tezde, n6trozofik gri seviye g6r6nt6 b6l6tleme yaklařımı incelenmiřtir. Y6ntem, gri seviye g6r6nt6lerin b6l6tlenmesinde olduka iyi olmasına raėmen, bazı aksaklıklar hala mevcuttur. Bu aksaklıklar giderilerek elde edilen bu yeni yaklařım renkli g6r6nt6lerin b6l6tlenmesi iin kullanılmıřtır. B6l6tlenecek renkli g6r6nt6ler ilkönce L, a, b renk uzayına d6n6řt6r6lerek, her bir renk kanalı baėımsız olarak n6trozofik b6lgeye d6n6řt6r6l6r. N6trozofik b6lgenin belirsizlik 6yeliėini hesaplamak iin 6nceki y6ntemlerden farklı olarak, yerel entropi filtresi kullanılmıřtır. δ -medyan ve β -iyileřtirme g6r6nt6n6n belirsizliėini azaltmak iin kullanılır. δ -medyan iřlemi orijinal NS b6l6tleme algoritmasını d6zeltmek iin kullanılır. Her bir g6r6nt6 iin δ ve β parametrelerini belirlemek iin entropi tabanlı yeni bir y6ntem kullanılmıřtır. Sonu olarak NS b6lgedeki ki her bir renk kanalı, γ -medyan k6meleme metodu kullanılarak b6l6tlenir.

Geliřtirilen bu yaklařım, yapay g6r6nt6lere, gerek g6r6nt6lere ve g6r6lt6l6 gerek g6r6nt6lere uygulanmıřtır. Kullanılan bu yeni algoritmanın performansını deėerlendirmek iin b6l6tleme sonuları Ortalama Kayma ve Waveseg algoritmalarının 6rettiėi sonular ile karřılařtırılmıřtır. Elde edilen sonular, 6nerilen y6ntemin bařarımının iyi olduėunu g6stermiřtir.

Anahtar Kelimeler: G6r6nt6 B6l6tleme, N6trozofi, Renkli G6r6nt6 B6l6tleme

SUMMARY

In this thesis, neutrosophic grey level image segmentation has been examined. Although this method is pretty good at grey level image segmentation, it has some drawbacks. This new approach obtained by eliminating these drawbacks has been used for image segmentation. First, by converting color images to be segmented into L, a, b color space, each color channel is transformed to neutrosophic domain independently. To calculate indefinite membership of neutrosophic domain, local entropy filter has been used different from previous methods. δ median and β enhancement are used for modifying segmentation algorithm. For each image, a new entropy-based method has been used to determine δ and β . Consequently, each color channel in NS domain is segmented by using γ -median clustering method.

This approach developed has been applied to real images, unreal images and noised real images. Segmentation results have been compared with the results which are generated by mean shift and Waveseg algorithm to evaluate the performance of this newly used algorithm. Obtained results showed that success of proposed method is good.

Key Words: Image Segmentation, Neutrosophy, Colour Image Segmentation

ŞEKİLLER LİSTESİ

Sayfa No

Şekil 1.1. Sürekli bir görüntünün sayısallaştırılması. Koordinatları $[m=10, n=3]$ olan piksel 110 parlaklık değerine sahiptir.....	2
Şekil 1.2. Çeşitli görüntü işlem tiplerinin açıklanması.....	4
Şekil 1.3. Komşuluk tipleri.....	5
Şekil 1.4. Kümeleme Analizi.....	7
Şekil 1.5. KYM renk uzayının üç boyulu küp şeklinde gösterimi [20].....	16
Şekil 1.6. HSI renk uzayı [14].	20
Şekil 1.7. Munsell Renk Uzayı [40].	23
Şekil 1.8. Renkli Görüntü Bölütleme Yaklaşımları.....	25
Şekil 2.1. Bölütleme algoritmasının akış diagramı.....	34
Şekil 2.2. (a) Gauss gürültüsüne sahip orijinal görüntü (b) MFCM metodunun ürettiği sonuçlar (c) Önerilen metodun ürettiği sonuçlar.	35
Şekil 2.3. (a) Gauss gürültüsüne sahip orijinal görüntü (b) MFCM metodunun ürettiği sonuçlar (c) Önerilen metodun ürettiği sonuçlar.	36
Şekil 2.4. (a) Lena görüntüsü (b) Lena görüntüsünün histogramı (c) MFCM metodu tarafından üretilen bölütleme sonuçları (d) Önerilen metot tarafından üretilen bölütleme sonuçları.	38
Şekil 2.5. (a) Manzara görüntüsü (b) Manzara görüntüsünün histogramı (c) MFCM metodu tarafından üretilen bölütleme sonuçları (d) Önerilen metot tarafından üretilen bölütleme sonuçları.	39
Şekil 2.6. (a) Gauss gürültüsüne sahip Lena görüntüsü (b) Gauss gürültüsüne sahip Lena görüntüsünün histogramı (c) MFCM metodu tarafından üretilen bölütleme sonuçları (d) Önerilen metot tarafından üretilen bölütleme sonuçları.....	40
Şekil 3.1. (a) Gaussian gürültülü orijinal görüntü, (b) NS bölütleme sonucu	46
Şekil 3.2. (a) Gaussian gürültülü orijinal görüntü, (b) NS bölütleme sonucu	46
Şekil 3.3. (a) Gauss gürültülü original görüntü, (b) $\alpha = 0.85$ ve $\beta = 0.85$ ile NS bölütleme sonucu (c) $\alpha = 0.25$ ve $\beta = 0.95$ ile NS bölütleme sonucu.....	47
Şekil 3.4. Renkli görüntü bölütleme algoritmasının akış diyagramı.	51
Şekil 3.5. (a) Orijinal görüntü (b) Kesin referans görüntüsü (c) Önerilen yöntem ile elde edilen bölütleme (d) Ortalama kayma ile elde edilen bölütleme (e) Waveseg ile elde edilen bölütleme	56

Şekil 3.6. (a) Orijinal görüntü (b) Kesin referans görüntüsü (c) Önerilen yöntem ile elde edilen bölütleme (d) Ortalama kayma ile elde edilen bölütleme (e) Waveseg ile elde edilen bölütleme	57
Şekil 3.7. (a) Orijinal görüntü (b) Kesin referans görüntüsü (c) Önerilen yöntem ile elde edilen bölütleme (d) Ortalama kayma ile elde edilen bölütleme (e) Waveseg ile elde edilen bölütleme	58
Şekil 3.8. (a) Gürültülü kadın görüntüsü (b) Kesin referans bölütleme sonucu (c) Önerilen yaklaşım kullanıldığında görüntü bölütleme sonucu (d) Ortalama kayma görüntü bölütleme sonucu (e)Waveseg [61]	59
Şekil 3.9. Önerilen metot, Ortalama kayma ve Waveseg için FOM değerleri	60
Şekil 3.10. (a) Önerilen metot kullanıldığında görüntü bölütleme sonuçları, (b) Kesin referans bölütleme, (c) Ortalama kayma görüntü bölütleme, (d)Waveseg görüntü bölütleme	62

TABLolar LİSTESİ

Sayfa No

Tablo 1.1. Görüntü işlem tipleri. Görüntü boyutu $N \times N$; komşuluk boyutu $P \times P$. Karmaşıklık her bir piksel işlemine göre belirlenmiştir.	3
Tablo 3.1. Önerilen metot, Ortalama kayma ve Waveseg için FOM sonuçları	59
Tablo 3.2. Önerilen metot, Ortalama kayma ve Waveseg için doğal görüntülerin FOM sonuçları.....	61

SEMBOLLER LİSTESİ

P_{NS} :	Nötrozofik Görüntü
λ :	Dalga Boyu
$E(\lambda)$:	Renk Filtresi
T:	Doğruluk Kümesi
I:	Belirsizlik Kümesi
F:	Yanlışlık Kümesi
U:	Evrensel Küme
W:	Parlak Piksellerin Oluşturduğu Küme
E_{NT} :	Doğruluk Kümesinin Entropisi
E_{NI} :	Belirsizlik Kümesinin Entropisi
E_{NF} :	Yanlışlık Kümesinin Entropisi
P_T :	T kümesindeki Elemanların Olasılıkları
P_I :	I kümesindeki Elemanların Olasılıkları
P_F :	F kümesindeki Elemanların Olasılıkları
J_C :	Hedef fonksiyon
m:	Toplam Küme Sayısı
n_j :	j. Kümedeki Toplam Piksel Sayısı
X:	n Parçadan Oluşan Veri Kümesi
x:	K Çekirdeğinin Merkez Noktası
mk:	Ortalama Kayma Vektörü
h:	K Çekirdeğinin Boyutu

KISALTMALAR LİSTESİ

GMI:	Gradient Magnitude Intensity (Eğim Büyüklük Yoğunluğu)
LIM:	Local Intensity Minimum (Yerel Yoğunluk Minimumu)
PCNNs:	Pulse-Coupled Neural Network (Darbe Kuplajlı Yapay Sinir Ağı)
KYM:	Red Green Blue Color Spatial (Kırmızı Yeşil Mavi Renk Uzayı)
HSI:	Hue-Saturation-Intensity System (Ton Saturasyon Yoğunluk Sistemi)
HSB:	Hue-Saturation-Brightness System (Ton Saturasyon Parlaklık Sistemi)
HSV:	Hue-Saturation-Value System (Ton Saturasyon Değer Sistemi)
NTSC:	National Television Standarts Committee (Ulusal Televizyon Standartları Komitesi)
FCM:	Fuzzy C-Means Algorithm (Bulanık C- Ortalamalar Algoritması)
NS:	Neutrosophy Set (Nötrozofi Küme)
SNR:	Signal-to-Noise Ratio (Sinyal Gürültü Oranı)

1. GİRİŞ

Görüntü İşleme, sayısal bir resim haline getirilmiş olan gerçek yaşamdaki görüntülerin, bir girdi resim olarak işlenerek, o resmin özelliklerinin ve görüntüsünün değiştirilmesi sonucunda yeni bir resmin oluşturulmasıdır. Bir görüntü işleme sistemi; görüntü veri kaynağı, işleme elemanı ve işlenmiş sonuçlar için bir hedeften oluşur. Görüntü verisinin kaynağı bir kamera, bir tarayıcı, bir matematiksel denklem, WEB, bir SONAR sistem vb. olabilir. Kısacası iki boyutlu bir veri yapısını üreten veya toplayan herhangi bir şey, görüntü verisinin geçerli bir kaynağı olarak düşünülebilir. Dahası bu veri zamanın bir fonksiyonu olarak değişebilmektedir. İşleme elemanı bir bilgisayardır. Bir bilgisayar farklı şekillerde uygulanabilir. Örneğin, beynin görüntü işleme yapabilen bir çeşit biyolojik bilgisayar olduğu söylenebilir. Bir beyin, bir saatte iki tatlı kaşığı şeker ve 20 watt'lık bir güç harcamaktadır. Optik bir eleman hesaplama yapmak için kullanılabilir ve bu hesaplama işlemini ışık hızında yapar.

İşlem çıktısı insan görüş sistemi için oluşturulmuş bir görüntü olabilir. Çıkış herhangi bir akış da olabilir. Java da bir akış kesintiye uğramamış ardışık byte'lar olarak tanımlanmıştır. Yani çıkış her zaman bir görüntü verisi olmamaktadır. Örneğin çıkış bir histogram, bir global ortalama vb. olabilmektedir. Örneğin görüntü işleme, masadaki madeni paraların kenarlarını bulmak için kullanılabilir. Bilgisayar görüşü masada kaç tane para olduğunu söyleyebilir. Böylece bilgisayar görüşü görüntü işlemenin alt bir görevi olarak sık sık düşünülmektedir.

Modern dijital teknoloji çok boyutlu sinyallere sahip sistemleri işleyebilmek için basit bir devreden ileri paralel bilgisayarlara kadar uzanan geniş bir aralığa sahiptir. Bu işlemin amacı üç kategoriye ayrılabilir:

- Görüntü işleme görüntü giriş → görüntü çıkış
- Görüntü analizi görüntü giriş → ölçümler çıkış
- Görüntü anlama görüntü giriş → yüksek seviyeli tanımlama çıkış

2D ayrık bir uzayda tanımlanan dijital bir $a[m,n]$ görüntüsü, 2D sürekli uzaydaki bir $a(x,y)$ analog görüntüden sayısallaştırma olarak tanımlanan örnekleme ve kuantalama işlemi sonucu elde edilir.

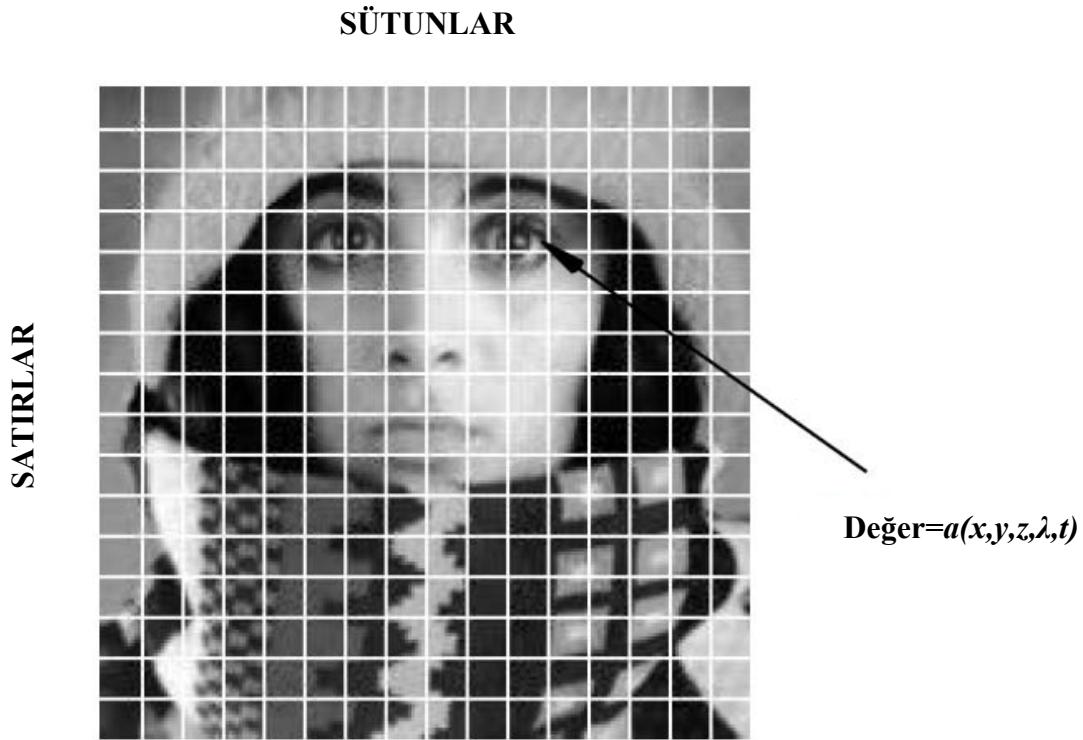
Sayısallaştırma, sürekli sinyallerden sayısallaştırılmış örneklerin elde edilmesi işlemidir. Bu sinyaller bazı verilerin şifrelerini göstermektedir. Örneğin, bir mikrofon elektrik sinyali üreten bir dönüştürücüdür. Elektrik sinyali akustik dalgaları (ses) gösterir. Analog terimi, sürekli değişen yoğunluk örneklerine sahip bir sinyali anlatır. Dijital terimi, ayrık değerlerden alınan verileri göstermektedir. $s(t)$, sürekli bir sinyal olursa sürekliliğin tanımı:

$$\lim_{t \rightarrow a} s(t) = s(a)$$

$$t \rightarrow a \quad a \in R.$$

R , sembolü bir reel sayı kümesini göstermektedir. Böylece $R = \{x: x \text{ bir reel sayıdır}\}$, R tüm x 'lerin kümesi, öyle ki x bir reel sayıdır.

Sayısallaştırma işleminin anlamı Şekil 1.1 de görülmektedir.



Şekil 1.1. Sürekli bir görüntünün sayısallaştırılması. Koordinatları $[m=10, n=3]$ olan piksel 110 parlaklık değerine sahiptir

2B sürekli bir $a(x,y)$ görüntüsü N satır ve M sütuna bölünür. Satır ve sütunların keşişimi piksel olarak adlandırılır. Sayısal $[m,n]$ koordinatlarına, $\{m=0,1,2,\dots,M-1\}$ ve

$\{n=0,1,2,\dots,N-1\}$, atanan deęer $a[m,n]$ 'dir. Pek çok durumda $a(x,y)$; derinlik (z), renk (λ) ve zaman (t) deęişkenlerini içeren bir fonksiyondur.

Şekil 1.1 deki görüntü $N=16$ satır ve $M=16$ sütuna sahiptir. Her bir piksele atanan deęer pikselin en yakın tamsayı deęerine yuvarlanan ortalama piksel parlaklığıdır. Verilen koordinatlarda 2D sinyalin genliğini L farklı gri seviyede tamsayı olarak gösterme işlemi genellikle genliğin sayısallaştırılması veya daha basitçe sayısallaştırılma olarak adlandırılır.

1.1. Görüntü İşlemlerinin Karakteristikleri

Görüntü işlemlerini sınıflandırmak için çeşitli yollar vardır. Bunu yapmanın nedeni verilen işlem tipi ile sonuç tiplerini veya verilen işleme baęlı hesaplama yükünü anlamaktır.


1.1.1. İşlem Tipleri

$a[m,n]$ giriş görüntüsünü $b[m,n]$ çıkış görüntüsüne dönüştürmek için dijital görüntülere uygulanabilen işlem tipleri Tablo 1.1 deki gibi üç kategoride sınıflandırılabilir.

Tablo 1.1. Görüntü işlem tipleri. Görüntü boyutu $N \times N$; komşuluk boyutu $P \times P$. Karmaşıklık her bir piksel işlemine göre belirlenmiştir.

İşlem	Karakter Belirleme	Karmaşıklık/Piksel
Nokta	Belli bir koordinattaki çıkış deęeri sadece aynı koordinattaki giriş deęerine baęlıdır.	Sabit
Lokal	Belli bir koordinattaki çıkış deęeri aynı koordinatın komşuluęundaki giriş deęerine baęlıdır.	P^2
Global	Belli bir koordinattaki çıkış deęeri giriş görüntüsündeki tüm deęerlere baęlıdır.	N^2

Bu durum Şekil 1.2 de grafiksel olarak görülmektedir.



Şekil 1.2. Çeşitli görüntü işlem tiplerinin açıklanması


1.1.2. Komşuluk Tipleri

Komşuluk işlemleri, modern dijital görüntü işlemede önemli rol oynamaktadır. Bu nasıl görüntülerin örneklenebileceği ve görüntü işlemede kullanılan çeşitli komşuluk ilişkileri ile ne kadar ilgili olduğunu anlamak için önemlidir.


Dikdörtgen Örnekleme: Pek çok durumda, Şekil 1.1 de gösterildiği gibi görüntü üzerine dikdörtgen bir ızgara yerleştirilerek görüntüler örneklenir. Bu örnekleme tipindeki sonuçlar Şekil 1.3 (a) ve Şekil 1.3 (b) de görülmektedir.

Altıgen Örnekleme: Alternatif örnekleme planı Şekil 1.3 (c) de gösterilmektedir ve bu örnekleme altıgen örnekleme olarak adlandırılmıştır.


Her iki örnekleme planı geniş şekilde çalışılmıştır [1] ve sürekli bir görüntü uzayının muhtemel periyodik döşenmesini göstermektedir. Lokal işlemler $a[m=m_0, n=n_0]$ komşuluklarındaki piksel değerlerine bağlı olarak $b[m=m_0, n=n_0]$ çıkış değerlerini üretirler. Dikdörtgen örnekleme durumunda en yaygın komşuluklar 4-bağlantılı komşuluk ve 8-bağlantılı komşuluklar altıgen örnekleme durumunda da 6-bağlantılı komşuluklardır. Bu durum Şekil 1.3 te gösterilmiştir.



(a) 4-Bağlantılı dikdörtgen
Örnekleme



b) 8-Bağlantılı dikdörtgen örnekleme



c) 6-Bağlantılı dikdörtgen
örnekleme

Şekil 1.3. Komşuluk tipleri

1.2. Görüntü Bölütleme

Görüntü bölütleme, görüntüyü farklı alanlara, her bir alanın homojen olduğu fakat yakın iki alanın birleşimlerinin homojen olmadığı, bölme işlemidir. Bölütlemenin amacı, görüntü gösterimini basitleştirmek ve/veya değiştirmektir. Amaç analiz için görüntüyü daha kolay ve anlamlı hale getirmektir. Görüntü bölütlemenin biçimsel olarak tanımlanması şu şekildedir [1]:

Eğer $P()$ bir grup bağlantılı piksel üzerinde tanımlanan homojenliği gösteriyorsa, bölütleme altküme veya alanlar (S_1, S_2, \dots, S_n) ile bağlantılı F kümesinin bir parçasıdır.

$$\bigcup_{i=1}^n S_i = F, \quad S_i \cap S_j = \emptyset \quad (i \neq j)$$

Benzerlik gösterimi tüm S_i alanlar için $P(S_i) = \text{doğru}$ S_i ve S_j komşu ve $(i \neq j)$ iken $P(S_i \cup S_j) = \text{yanlış}$ tır.

Görüntü bölütleme, genellikle görüntüdeki nesne ve sınırların (çizgi, kıvrım, vs.) yerlerini belirlemek için kullanılır. Daha kesin bir ifadeyle, görüntü bölütleme bir resimde aynı görsel karakteristikleri paylaşan piksellere aynı etiketi atama işlemidir.

Görüntü bölütlemenin sonucu toplu olarak tüm görüntüyü kaplayan bir bölüt kümesi veya görüntüden çıkarılan bir çevre (contour) kümesidir. Bir bölgedeki piksellerin her biri renk, yoğunluk, doku gibi hesaplanabilir özellikler veya bazı karakteristikler

açısından benzerlik gösterirler. Ayrık alanlar aynı karakteristikler açısından birbirleri ile önemli ölçüde farklıdır.

Görüntü bölütleme, görüntü analiz ve örüntü tanımada ilk adımdır. Görüntü analiz ve/veya örüntü tanıma sistemlerinin temel ve kritik bileşenlerinden biri olan görüntü bölütleme, görüntü işlemenin en zor işlerinden biridir ve son analiz sonuçlarının kalitesini belirler.

Kaynak [2]'ye göre görüntü bölütleme problemi basitçe fiziksel bir algıdır ve bu yüzden tamamen analitik çözüme uygun değildir. Monokrom görüntü bölütleme teknikleri üzerine pek çok makale ve araştırma yapılmıştır. Renkli görüntü bölütleme aşağıdaki sebeplerden dolayı giderek daha cazip hale gelmeye başlamıştır:

- Renkli görüntüler, gri seviyeli görüntülerden daha fazla bilgi sağlamaktadır.
- Kişisel bilgisayarların gücü hızlı bir şekilde artmaktadır ve PC'ler renkli görüntüleri işlemek için şimdilerde kullanılabilirler.
- Monokrom görüntüler için bölütleme teknikleri K, Y ve M veya bunun doğrusal/doğrusal olmayan dönüşümleri kullanılarak renkli görüntüler içinde genişletilebilmektedir.

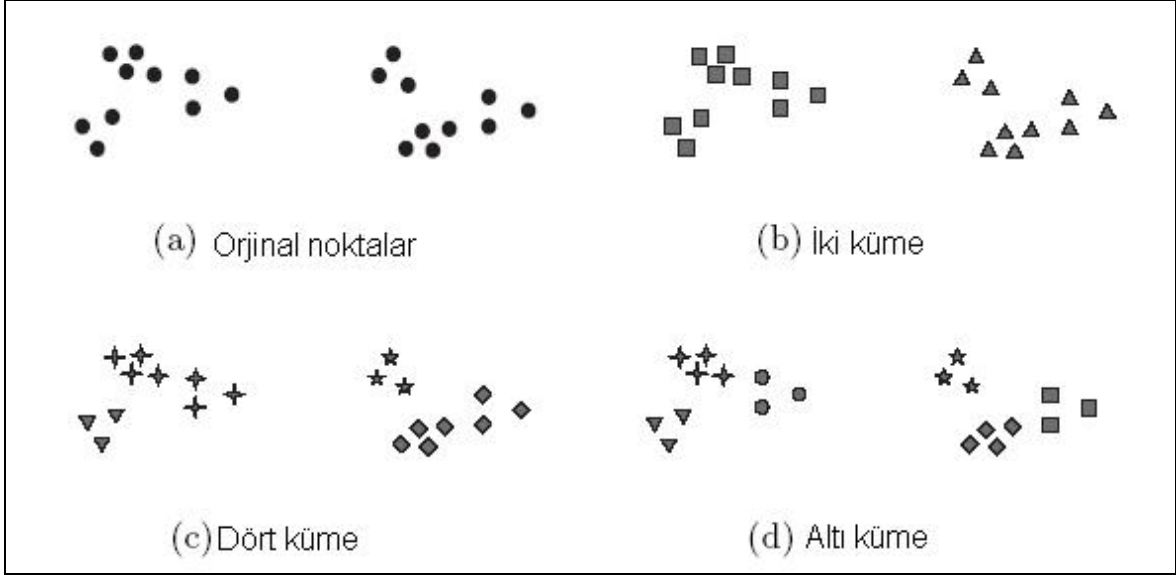
Görüntü bölütleme için bazı genel amaçlı algoritmalar ve teknikler geliştirilmiştir. Görüntü bölütleme problemi için genel bir çözüm olmadığından, bu tekniklerin sıklıkla alan bilgisi ile birleştirilmesi gerekmektedir. Görüntü bölütleme metotları aşağıda açıklanmıştır.

1.2.1. Kümeleme Metotları

Kümeleme verilerden çıkartılacak bilgiler ışığında veri nesnelere ve ilişkilerini tanımlayan bir bölütleme yöntemidir. Amaç aynı grup içerisindeki nesnelere birbirine benzer veya ilişkili olması; farklı gruptakilerin ise birbirinden farklı olması ya da ilişkilerinin bulunmamasıdır. Aynı gruptakilerin birbirine benzeme oranı ya da farklı gruptakilerin ise birbirinden farklı olma oranları kümelemenin ne kadar iyi olduğunun ya da kümelerin birbirlerinden ne kadar kesinlikle ayrıldıklarının göstergesidir.

Birçok uygulamada, küme kavramı net bir şekilde tanımlanmamıştır. Bir kümeyi ortaya koyan özelliklerin neler olduğuna karar vermek oldukça güçtür. Bu durumun anlaşılması için Şekil 1.4 incelendiğinde 20 değişik nokta ve bu noktaları kümelere

ayırmak için üç farklı yol gösterilmektedir. İşaretlerin şekilleri küme üyeliklerini göstermektedir.



Şekil 1.4. Kümeleme Analizi

Şekil 1.4 (b) ve Şekil 1.4 (d) sırasıyla veriyi iki ve altı parçaya ayırır. Bununla beraber, iki tane büyükçe kümenin her birinin daha küçük üç alt kümeye net olarak bölünmesi yalnızca insanın görme sistemine ilişkin bir yanılma olabilir. Aynı zamanda, “noktalar dört tane küme oluşturur” denebilir ve bu durum Şekil 1.4 (c)’ de görülmektedir. Bu şekil bir küme tanımının kesin ve net olmadığını, en iyi kümelemenin de verinin doğasına ve arzu edilen sonuçlara bağlı olduğunu gösterir.

Kümeleme analizi veri nesnelere gruplara ayıran diğer tekniklerle de ilişkilidir. Örneğin kümeleme bir çeşit sınıflandırma olarak düşünülebilir öyle ki, sınıf etiketlerine göre nesnelere etiketlerini oluşturur. Bununla beraber, kümeleme bu bilgiyi yalnızca veriden alır. Diğer taraftan, sınıflandırma anlamıyla bir yönetilmiş sınıflandırmadır. Yani, yeni ve etiketlenmemiş nesnelere, daha önceden bilinen sınıf etiketlerinden oluşturulmuş bir model aracılığıyla birer sınıf etiketine sahip olurlar.

1.2.2. Histogram Tabanlı Metotlar

Histogram tabanlı metotlar (Histogram based methods), diğer görüntü bölütleme metotları ile karşılaştırıldığında oldukça etkilidirler. Bu teknikte görüntüdeki tüm

piksellerden bir histogram hesaplanır ve histogramdaki zirve ve çukurlar görüntüdeki kümelerin yerlerini saptamak için kullanılır [2]. Ölçüm olarak renk veya yoğunluk kullanılabilir.

Bu tekniğin düzenlenmesi histogram arama metodunun yinelemeli olarak kümelere daha küçük kümelere bölmek için uygulanmasıdır. Bu işlem kümeler artık biçimlenmeyinceye kadar devam eder.

Histogram-arama metodunun dezavantajlarından biri görüntüdeki önemli zirve ve çukurları tanımlamanın zorluğudur.

1.2.3. Kenar Belirleme

Kenar belirleme (Edge detection), görüntü işlemede oldukça gelişmiş bir alandır. Alan sınırlarında genellikle ani yoğunluk değişimleri yaşandığından alan sınırları ve kenarlar yakından ilişkilidir. Kenar belirleme teknikleri bu nedenle diğer bölütleme tekniklerinin temeli olarak kullanılır. Kenar belirleme ile tanımlanan kenarlar genellikle bağlantısızdır. Görüntüden bir nesneyi bölütlemek için kenarların alan sınırlarına yakın olması gerekir.

Kenar tabanlı yaklaşımlar, farklı alanlar arasında görüntü özelliklerinde süreksizliğe dayanan yaklaşımlardır. Kenar tabanlı bölütleme algoritmalarının amacı özellik değerlerinde görüntünün yüksek değişime sahip olduğu noktalarda nesne sınırlarının yerini belirlemektir. Kenar tabanlı algoritmaların çoğu görüntüdeki yerel kenar bilgisini inceleyerek uzamsal bilgiyi kullanır. Kenar tabanlı yaklaşımların uygulamaları kolay, hesaplamaları hızlıdır. Ayrıca görüntü içeriği hakkında öncül bir bilgiye gerek duymazlar. Sobel, Prewitt, Laplacian veya Canny kenar belirleyiciler sadece birkaç örnektir. Basit gürültüsüz görüntüler için, kenar belirleme anlaşılır sınır çizimleri ile sonuçlanır. Fakat gürültü uygulandığında ya da görüntü karmaşık hale geldiğinde, kenar belirleyiciler üç temel probleme sahiptirler.

- Kenar belirleyiciler gürültüye karşı oldukça hassastırlar.
- Kenar belirleyiciler bir kenar eşik değeri seçimi gerektirirler.
- Kenar belirleyiciler nesnenin sınırlarını tam olarak üretmezler. Çünkü görüntüdeki gürültüden ya da nesnenin üst üste binmesinden dolayı kenarlar nesneyi tamamen kuşatmazlar.

Bu zorlukların üstesinden gelmek zordur. Çünkü birindeki problem çözümü diğerlerinde problem artışına neden olmaktadır. Gürültüyü azaltmak için kenar işlemleri uygulanmadan önce düşük geçirgenli bir filtre görüntüye uygulanabilir. Fakat düşük geçirgenli filtreler yumuşak kenarları da bastırıldığından, bu durum daha fazla tamamlanmayan kenarların oluşmasına neden olur ve nesnenin sınırları tam olarak belirlenemez. Diğer yandan daha bütün kenarlar elde etmek için, eşik değeri daha düşük bir değere ayarlanabilir ve daha zayıf kenarlarında ortaya çıkması sağlanabilir. Fakat bu durumda gürültüden dolayı daha yapay kenarların görünmesine neden olmaktadır. Kenar tabanlı tekniklerden daha memnun edici bölütleme sonuçları elde etmek için, Casadei and Mitter [3-4]'in vektör grafik metodu gibi sonraki işlemler kenar tabanlı metotlardan sonra uygulanabilir. Bu işlemlerin amacı aynı nesne sınırına uygun kenarları gruptandırmak ve diğer yapay kenarları göz ardı etmektir. Fakat bu tür otomatik kenar gruptandırma algoritmaları oldukça uğraştırıcıdır ve genellikle çok güvenilir değillerdir.

1.2.4. Alan Büyütme Metotları

Alan tabanlı yaklaşımlar (Region growing methods), kenar belirleme yaklaşımlarından farklı olarak, komşu piksel kümesi içinde görüntü özelliğindeki örüntü benzerliğine dayanır. Alan tabanlı teknikler, alan büyütme veya alan birleştirme gibi, homojen istatistiğe bağlı olarak, nesneye üyelik ataması yaparlar [5-7]. İstatistikler dinamik olarak üretilip güncellenir. Alan büyütme metotları tohum (seed) adında küçük bir alan ile başlayarak bir bölütleme haritası üretirler. Tohum alanlarını daha büyük alanlar şeklinde büyütme için, komşuluk pikselleri incelenir. Komşu pikseller tohum alanına yeterince benzerlik gösteriyorsa, benzerlik testine bağlı olarak, bu pikseller büyütülecek alana atanır. Bu işlem eklenecek piksel kalmayınca kadar devam eder. Alan tabanlı modellerin avantajı, yerel görüntü bilgisinden ziyade tüm görüntü istatistiğine dayanmasıdır. Sonuç olarak bu teknikler gürültüye karşı sağlamdır ve büyük görüntü değişimlerine uygun olmayan sınırları bulmak için kullanılabilirler. Fakat karar verme işleminde, alan tabanlı çalışmalarda nesne sınırını içerecek bir hazırlık yoktur. Bu durum nesne içinde düzensiz veya gürültülü sınırlara ve deliklere neden olmaktadır. Dahası tohum alanı, başlangıçta önemli alanda olacak şekilde bir operatör tarafında seçilmek zorundadır, aksi takdirde istenmeyen sonuçların elde edilmesi olasıdır.

Alan büyütme metotlarında görüntü boyunca giriş olarak bir tohum kümesi alınır. Tohum alanlar bölütlenecek her bir nesneyi işaretler. Ayrılmamış komşu pikseller ile alanlar yinelemeli olarak karşılaştırılarak tohum alanlar büyütülür. Bir pikselin yoğunluk değeri ile alanın ortalaması arasındaki fark, benzerlik ölçüsü olarak kullanılır. Ölçülmüş en küçük farka sahip piksel ilgili alana yerleştirilir. Bu işlemler tüm pikseller bir alana yerleşene kadar devam eder. Bölütleme sonuçları tohum alanlarının seçimine bağlıdır. Görüntüdeki gürültü tohum alanlarının yanlış yerleşmesine neden olabilir. Tohumsuz (Unseeded) alan büyütme belirgin tohum alanları gerektirmeyen düzenlenmiş bir algoritmadır. Bu algoritma tek bir alan ile başlar, buradaki piksel seçimi son bölütlemeyi önemli ölçüde etkilemez. Her bir adımda algoritma komşu pikselleri tohumlu alan büyütmede olduğu gibi aynı yolla hesaba katar. Tohumsuz alan büyütme algoritması tohum alan büyütme algoritmasından farklılık gösterir. Alan ortalaması önceden tanımlanmış eşik değerinden küçükse piksel ilgili alana eklenir. Değilse bu piksel tüm mevcut alanlardan farklı olarak düşünülür ve bu pikseli içeren yeni bir alan oluşturulur.

Haralick ve Shapiro tarafından önerilen bu tekniğin bir çeşidi piksel yoğunluğuna dayanmaktadır [8]. Alanın ortalama ve dağılımı ve aday pikselin yoğunluğu test istatistiğini hesaplamak için kullanılır. Test istatistik oldukça küçükse piksel alana eklenir ve alanın ortalama ve dağılımı yeniden hesaplanır. Aksi durumda piksel ret edilir ve yeni bir alanı şekillendirmesi için kullanılır.

1.2.5. Seviye Küme Metodu

Kıvrım yayılma (curve propagation) nesne çıkarma, nesne takibi, stereo yapılandırma için görüntü analizinde kullanılan popüler bir tekniktir [8]. Bu yaklaşımın arkasındaki temel fikir, en düşük potansiyel maliyet fonksiyonu yönünde kıvrımın geliştirilmesidir. En düşük potansiyel maliyet fonksiyonunda belli düzgünlük sabitleri belirlenir ve etkilenir. Lagrangian teknikleri, bazı örnekleme stratejilerine göre çevrenin parametrelerle izahına dayanır ve görüntüye göre her bir eleman ve içsel şartlar geliştirilir. Böyle bir teknik çok etkili olabilirken, örnekleme stratejisine karar verme, kıvrımın içsel geometrik özelliğini tahmin etme, topolojisini değiştirme, yüksek boyutlarda problemler ele alma gibi çeşitli sınırlamalara sahiptir.

Seviye küme metodu (Level set methods), 1988 yılında Osher ve Sethian tarafından başlangıçta hareket ara yüzünü izlemek için önerildi ve doksanların sonunda çeşitli görüntüleme alanlarına kadar yayılmıştır [9]. Bu metot üstü kapalı biçimlerde

kıvrım/yüzey yayılması problemlerini etkili şekilde ele almak için kullanılır. Temel fikir, sıfır seviyesi gerçek şekle uyan işaretlenmiş bir fonksiyon kullanarak geliştirilen şekli göstermektir. Sonrasında şeklin hareket denkleminde uyararak, şeklin yayılımını etkileyecek sıfır seviye uygulandığında kapalı yüzey için benzer bir akış kolayca türetilir. Seviye küme metodu pek çok avantaj sağlamaktadır: parametreler serbesttir, gelişen yapının geometrik özelliğini tahmin edecek direkt bir yol sağlar, topolojiyi değiştirebilir. Dahası 1996 da Zhao, Merriman ve Osher tarafından önerildiği gibi bir optimizasyon taslağı tanımlamak için kullanılabilir. Böylece bu metod bilgisayar görmesi ve medikal görüntü analizinin çeşitli uygulamalarını ele almak için uygun taslaklar oluşturabilir [9].

1.2.6. Çizge Ayırma Metotları

Çizgeler görüntü bölütleme için etkili şekilde kullanılabilir. Bir piksel veya piksel grubu sürekli olarak köşedir ve kenarlar komşu pikseller arasındaki ayrımı tanımlarlar. Rastlantısal yürüyüş (Random walker), minimum ortalama kesimi (minimum mean cut), minimum mesafe ağacı tabanlı bölütleme (minimum spanning tree-based segmentation), normalize edilmiş kesim (normalized cut) bu kategorinin popüler algoritmalarındandır. Normalize edilmiş kesim metodu ilk olarak 1997 yılında Shi ve Malik tarafından önerilmiştir [10]. Bu metotta bölütlenecek görüntü ağırlaştırılmış yönsüz çizge gibi modellenir. Her bir piksel grafikteki bir düğümdür ve kenarlar her piksel çifti arasında oluşturulur. Bir kenarın ağırlığı pikseller arasındaki benzerliğin ölçüsüdür. Kümeler ile bağlantılı kenarlar kaldırılarak görüntü ayrık kümelere ayrılır. Shi'nin algoritması kümedeki tüm kenarların kesim oranı olan normalize edilmiş kesim'i minimize etmeye çabalamaktadır.

1.2.7. Su Sınırı Dönüşümü

Su sınırı dönüşüm (Watershed Transformation) metodu, bir görüntünün eğim büyüklüğünü topografik yüzey olarak düşünür. En yüksek eğim büyüklük yoğunluğuna (GMIs) sahip pikseller alan sınırını gösteren ayırım hattı çizgisine uygundur. Su sınırı çizgisi lokal yoğunluk minimumuna (LIM) akar ve su en yakın piksele yerleşir. Piksellerin minimuma boşalması bölmeyi gösteren bir havuz oluşturur [11].

1.2.8. Model Tabanlı Bölütleme

Böyle bir yaklaşımın temel fikri, geometrinin tekrarlı biçimine sahip parçaların yapısıdır. Böylece parçanın çeşitli şekillerini açıklamak için bir olasılıklı model aranabilir ve görüntü bölütleneceği zaman bu modeli kullanarak sabitleri kabul eder [12]. Böyle bir metot,

- Eğitim örneklerinin kaydını
- Kaydedilmiş çeşitli örneklerin olasılık gösterimini
- Model ve görüntü arasında istatistiksel bir sonuç çıkarmayı gerektirir.

Bilgi tabanlı bölütleme için art metot evreleri aktif Şekil ve görüntü modeli, aktif çevre ve şekil değiştirebilen kalıplar ve seviye küme tabanlı metotlarını içermektedir.

1.2.9. Çoklu Ölçek Bölütleme

Görüntü bölütleme ölçek uzayında çok tipli ölçeklerde hesaplanır. Bölütleme kriteri oldukça karmaşık olabilir ve yerel kriterlerin yanında genel kriterlerinde hesaba katılması gerekebilir. Yaygın bir gereksinim her bir alanın bazı sense ile bağlantılı olması zorunluluğudur. [13]

1.2.9.1. Tek Boyutlu Hiyerarşik Sinyal Bölütleme

Witkin'in ölçek uzayındaki seminer çalışması, bir boyutlu sinyali anlamlı alanlara bölütleyebilen bölütleme ölçeğini kontrol eden tek ölçekli parametreye sahip bir gösterimi içermektedir [13].

Temel fikir, bir sinyalin çok ölçekli düzgün çeşitlerinin ikinci türevlerinin işaret değişikliğinin küme ağacını biçimlendirmesidir. Bu küme ağacı farklı ölçeklerde bölütler arasındaki hiyerarşik ilişkiyi tanımlar. Özellikle, kaba ölçekte uç değer olan eğim ince ölçekte özelliklere uygun olarak geri izleme yapabilir. Bir eğim maksimum ya da minimum olduğunda daha büyük ölçekte diğerlerini yok eder böylece bölütleme hiyerarşisi tanımlanır.

1.2.9.2. Görüntü Bölütleme ve Temel Taslak

Bu alanda çeşitli çalışmaları yapılmıştır. Birkaçı dışında diğerleri etkileşimli manuel müdahale yoluyla veya tam otomatik olarak uygulanabilecek duruma ulaşmıştır. Witkin tarafından tanımlanan küme yapısı bir boyutlu sinyallere özgüdür ve yüksek boyutlu görüntülere dönüştürülemez. Yine de bu genel için fikir birkaç araştırmacıya görüntü bölütleme için kabadan inceye şemayı araştırmak için ilham kaynağı olmuştur. Koenderink[14], ölçekler üzerine eş yoğunluk çevresinin nasıl geliştirildiğini çalışmayı önermiştir. Ne yazık ki görüntü özelliklerinin yoğunluğu, eş yoğunluk bilgisi kullanılarak kaba ölçekli görüntü özelliklerinden ince ölçeklilere takip etmenin zor olduğunu gösteren ölçekler üzerinde değişiklik gösterir.

Lindeberg [15,16] yerel uç noktaları bağlama ve ölçekler üzerindeki noktaları yükleme problemlerini çalışmıştır ve farklı ölçeklerdeki yapılar arasında açık bir ilişki kuran ölçek-uzay temel taslak adında bir görüntü gösterimini önermiştir. Bergholm ölçek-uzayında kaba ölçekte kenar belirlemeyi önermiştir ve hem kaba buluş ölçeği hem de ince yerleştirme ölçeğinin manuel seçimi ile bunları ince ölçeğe geri takip etmiştir.

Gauch ve Pizer çoklu ölçekte zirve ve vadi problemlerini çalışmıştır ve çoklu ölçek su sınırı tabanlı etkileşimli görüntü bölütleme için bir araç geliştirmiştir. Olsen ve Nielsen[11] tarafından eğim haritası için çok ölçekli su ayrımı kullanımı uygulaması geliştirilmiştir ve bu uygulama Dam ve Vincken tarafından kliniksel kullanıma taşınarak farklı ölçeklerde görüntü yapıları arasında olasılıklı ilişki tanımlamasında kullanılmak üzere önerilmiştir. Stabil görüntü yapılarının ölçekler üzerinde kullanımı Ahuja [17] tarafından ilerletilmiştir ve çalışanları ile tam otomatik sistem haline getirilmiştir.

Bijaoui ve Reu [18] minimum gürültü eşiğinde ölçek uzayında belirlenen yapıları çok tipli ölçekleri içeren nesne ağacına bağlar ve orijinal sinyaldeki özellik çeşidine uydurur.

1.2.10. Yarı Otomatik Bölütleme

Bu çeşit bölütlemede, kullanıcı fare ile alanı çizer ve algoritma görüntünün kenarlarına en iyi uyan yolun görülmesi için uygulanır.

Livewire veya Intelligent Scissors benzeri teknikler bu bölütleme çeşidinde kullanılır.

1.2.11. Sinir Ağı Bölütleme

Sinir ağı bölütleme (Neural Network Segmentation), yapay sinir ağı veya bir dizi sinir ağı kullanarak görüntünün küçük bir alanını işlemeye dayanır. Bu işlemden sonra karar verme mekanizması sinir ağı tarafından tanımlanan kategoriye uygun görüntü alanını işaretler. Özellikle bunun için tanımlanan ağ tipi Kohonen haritasıdır.

Darbe kuplajlı sinir ağları (PCNNs) bir kedinin görme korteksi modellenerek önerilen sinir modelleridir ve yüksek performanslı biyonik görüntü işleme için geliştirilmiştir. Eckhorn modeli küçük memelilerin görme kortekisini çalışmak için basit ve etkili bir araç sunar ve görüntü işlemede önemli uygulama potansiyeline sahiptir. 1994 yılında Eckhorn modeli Johnson tarafından görüntü işleme algoritmalarına adapte edilmiştir. Son on yılda, PCNNs görüntü işleme uygulamalarının pek çok çeşidi için – görüntü bölütleme, özellik üretimi, yüz çıkartma, hareket belirleme, alan büyütme, gürültü azaltımı vb kullanılmıştır. PCNN iki boyutlu bir sinir ağıdır. Ağdaki her nöron giriş görüntüsündeki bir piksele karşılık gelir. Dış uyarıcı olarak pikselin renk bilgisi kullanılır. Komşu nöronlarla bağlantılı her nöron onlardan yerel uyarıcı alır. İç ve dış uyarıcı birlikte içsel aktivasyon sistemini oluşturur. Dinamik bir eşik değeri aşılmaya kadar uyarıcıların toplanması çıkış sinyalini üretir. Yinelemeli hesaplamalara rağmen, PCNN nöronları sinyal çıkışlarının geçici serilerini üretirler. Sinyal çıkışlarının geçici serileri, giriş görüntülerinin bilgilerini içerir ve görüntü bölütleme ve özellik çıkartımı gibi çeşitli görüntü işleme uygulamaları için kullanılabilir. Geleneksel görüntü işleme ifadeleri ile karşılaştırıldığında, PCNNs gürültüye karşı güvenilirlik, giriş görüntülerindeki geometrik çeşitliliğin bağımsızlığı, giriş görüntülerindeki desteklenen küçük yoğunluk çeşitliliğinin kapasitesini içeren pek çok önemli değere sahiptir.

1.3. Monokrom Görüntü Bölütleme

Monokrom görüntü bölütleme yaklaşımları süreksizliğe ve/veya bir alandaki gri seviye değerlerinin homojenliğine dayanır. Süreksizliğe dayanan yaklaşım gri seviyedeki ani değişikliklere göre ayırık nokta, çizgi ve kenarları belirleyerek görüntüyü bölme eğilimindedir [47]. Homojenliğe dayalı yaklaşımlar eşikleme (thresholding) [48], kümeleme (clustering) [49], alan büyütme (region growing) [7], alan bölme (region splitting) ve alan birleştirme (region merging)'yi [56] kapsamaktadır.

1.4. Renk Uzayları

Renk insan tarafından algılanan temel renkler olarak adlandırılan K (red-kırmızı), Y (green-yeşil), M (blue-mavi)'nin bir birleşimidir. KYM gösteriminin doğrusal/doğrusal olmayan dönüşümleri kullanılarak diğer renk uzayları da elde edilebilmektedir. KYM, HSI, CIEL*u*v gibi bazı renk uzayları renkli görüntü bölütleme de kullanılmaktadır fakat bunlardan hiçbiri diğer tüm çeşit renk uzaylarına baskın değildirler. Renk uzayının seçimi hala renkli görüntü bölütlemeye karşılaşılan zorluklardan biridir [19].

K, Y, M bileşenleri aşağıdaki denklemlere bağlı olarak üç ayrı filtre (K, Y, M filtreleri) ile elde edilen manzaranın parlaklık değerleri ile gösterilir.

$$K = \int_{\lambda} E(\lambda)S_K(\lambda)d\lambda ,$$

$$Y = \int_{\lambda} E(\lambda)S_Y(\lambda)d\lambda ,$$

$$M = \int_{\lambda} E(\lambda)S_M(\lambda)d\lambda ,$$

S_K , S_Y , S_M gelen ışık veya $E(\lambda)$ parlaklık üzerindeki renk fitlerleridir ve λ dalga boyudur.

KYM renk uzayı geometrik olarak üç boyutlu küp şeklinde Şekil 1.5'de gösterilmektedir. [20]. Küp içerisindeki her bir noktanın koordinatları sırasıyla kırmızı, yeşil ve mavi değerlerini göstermektedir.

Colorimetry kanunları şu şekildedir[21]:

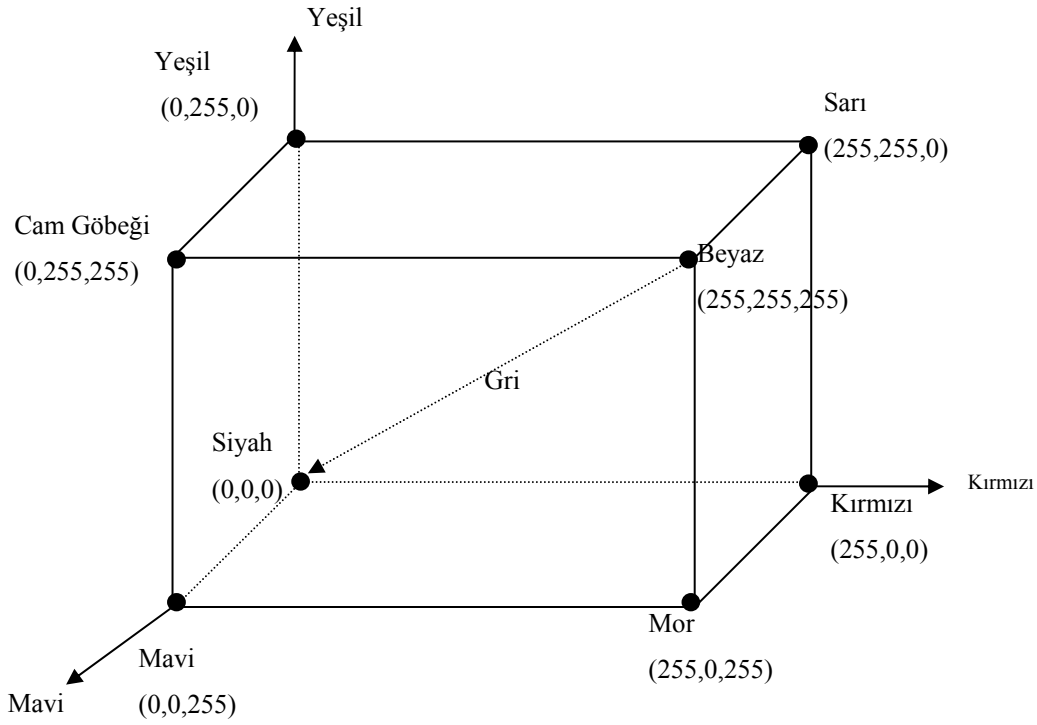
- Herhangi bir renk bu üç temel renk ile oluşturulabilir ve bu üç rengin oluşturduğu bileşim tekdir.
- Eğer iki renk eşit ise, bu rengin her üç bileşeni aynı sayı ile çarpılır ya da aynı sayıya bölünse bile bu renkler yine eşit çıkacaktır.
- Bir renk karışımının parlaklığı, her bir rengin parlaklıklarının toplamına eşittir.

1.4.1. Doğrusal Dönüşümler

1.4.1.1. KYM

KYM, televizyonlar ve dijital kameraların sahip olduğu görüntüler için en yaygın kullanılan modeldir. Video monitörleri, renkli görüntüleri görüntünün her bir pikselinde bu üç temel rengin yoğunluklarını ayarlayarak görüntüler [22, 23]. KYM renk gösterimi

için uygundur fakat renk bileşenleri arasındaki yüksek bağımlılıktan dolayı renkli görüntü bölütleme ve analizi için uygun olmayabilmektedir [24,25]. Yüksek bağımlılık ile anlatılmak istenen, eğer yoğunluk değişirse tüm bu üç renge yoğunluklarının buna bağlı olarak değişeceği bilgisidir. Ayrıca, KYM uzayındaki bir rengin ölçümü tek bir ölçekte renk farklılıklarını göstermez ve bu nedenle KYM uzayındaki mesafe farkından iki rengin benzerliğini değerlendirmek imkansızdır.



Şekil 1.5. KYM renk uzayının üç boyulu küp şeklinde gösterimi [20]

1.4.1.2. YIQ

Amerikan sistemleri için TV sinyalindeki renk bilgisini kodlamak için kullanılır. YIQ, KYM modelinden doğrusal dönüşümle elde edilir.

$$\begin{pmatrix} Y \\ I \\ Q \end{pmatrix} = \begin{pmatrix} 0.299 & 0.587 & 0.114 \\ 0.596 & -0.274 & -0.322 \\ 0.211 & -0.253 & -0.312 \end{pmatrix} \begin{pmatrix} K \\ Y \\ M \end{pmatrix} \quad 0 \leq K \leq 1, 0 \leq Y \leq 1, 0 \leq M \leq 1$$

Y bileşeni rengin parlaklık değeridir ve genelde renkli görüntülerde kenar belirleme için kullanılır. I ve Q ortak olarak rengin tonunu ve koyuluk değerini tanımlar [26]. YIQ renk uzayı, görüntüdeki kırmızı, yeşil ve mavi bileşenlerin bağımlılığını kısmen gidermektedir. YIQ uzayının, doğrusal olmayan sistemler için daha tercih edilebilir olmasının nedeni doğrusal dönüşümlerin doğrusal olmayanlara göre daha az hesaplama zamanı gerektirmesidir.

1.4.1.3. YUV

YUV , Avrupa TV sistemlerine uygun bir çeşit TV renk gösterimidir. Bu dönüşüm şu şekilde gerçekleşir:

$$\begin{pmatrix} Y \\ U \\ V \end{pmatrix} = \begin{pmatrix} 0.299 & 0.587 & 0.114 \\ -0.147 & -0.289 & 0.437 \\ 0.615 & -0.515 & -0.100 \end{pmatrix} \begin{pmatrix} K \\ Y \\ M \end{pmatrix} \quad 0 \leq K \leq 1, \quad 0 \leq Y \leq 1, \quad 0 \leq M \leq 1$$

1.4.1.4. $I_1I_2I_3$

Kaynak [27], bir dizi etkin renk özelliklerini türetmek için alan bölütlemenin sistematik deneylerini uygulamıştır. Özyinelemeli alan bölütlemenin her bir adımında, KYM renk uzayının Karhunen–Loeve dönüşümleri ile yeni renk özellikleri hesaplanır. 8 çeşit renk tanımı uygulanmış ve 100 renk özelliği analiz edilerek etkin bir dizi renk özelliği aşağıdaki şekilde bulunmuştur.

$$I_1 = (K + Y + M) / 3,$$

$$I_2 = (K - M) / 2,$$

$$I_3 = (2Y - K - M) / 4.$$

Kaynak [21]'e göre, $I_1I_2I_3$ diğer yedi renk uzayları ($KYM, YIQ, HSI, Nrgb, CIE, XYZ, CIE(L^*u^*v)$) ile karşılaştırıldığında hem dönüşümün hesaplama karmaşıklığı açısından hem de bölütleme kalitesi açısından daha etkili olduğu görülmüştür.

1.4.2. Doğrusal Olmayan Dönüşümler

1.4.2.1. Normalize KYM (Nrgb)

Renkli görüntü bölütleme işleminde, renklerin ışığın yoğunluğundan bağımsız olması istenir. Etkili bir metot, yoğunluk düzeninin değişimini spektral dağılım genişliğinde elde etmektir. Normalize edilmiş renk uzayı şu şekilde formüle edilir:

$$k = K / (K + Y + M),$$

$$y = Y / (K + Y + M),$$

$$m = M / (K + Y + M).$$

$k + y + m = 1$ olduğundan, iki bileşen verildiğinde diğer üçüncü bileşen hesaplanılabilmektedir [28].

Kaynak [29], diğer bir normalize edilmiş renk uzayını şu şekilde tanımlamaktadır:

$$Y = c_1 K + c_2 Y + c_3 M,$$

$$T_1 = \frac{K}{K + Y + M},$$

$$T_2 = \frac{Y}{K + Y + M}.$$

$c_1 + c_2 + c_3 = 1$; c_1, c_2 ve c_3 sabitler olup görüntü pikselinin aydınlığını elde etmek için birleştirilebilir. T_1 ve T_2 , KYM bileşenlerin yüzdesidir. Böylece bu değerler görüntünün parlaklıktan bağımsız gerçek renk değerlerini gösterirler. Bu da normalize edilmiş KYM renk sisteminin avantajlarından biridir [30]. Nrgb, renk değerlerini dar bir şekilde sınırladığından bu renk uzayında renk düzlemini göstermek daha uygundur.

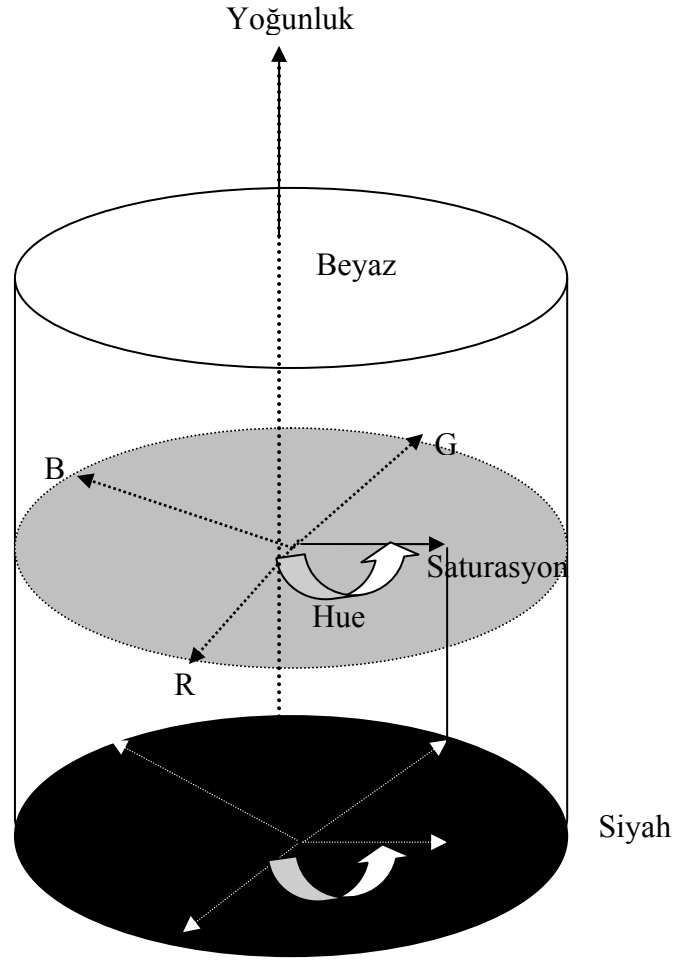
Normalizasyon, renk değişkenliğine karşı hassas dağılımı azaltır [31]. Nrgb, aydınlanma değişimine karşı oldukça güvenilirdir. Fakat normalize edilmiş KYM renk uzayının açık bir dezavantajı düşük yoğunlukta normalize edilmiş renklerin çok gürültülü oluşudur. Bu eksiklik, KYM renk uzayının normalize edilmiş KYM renk uzayına doğrusal olmayan dönüşüm yapılmasından kaynaklanmaktadır.

1.4.2.2. HSI

HSI (hue-saturation-intensity) sistemi insan görüşüne daha sezgisel olan görüntü işlemede yaygın olarak kullanılan bir başka renk uzayıdır [32-35]. HSI renk uzayının HSB(hue-saturation-brightness), HSL(hue-saturation-brightness) ve HSV(hue-saturation-value) gibi çeşitleri de vardır [36-38].

HSI renk uzayı, görüntünün renk bilgisinden yoğunluk bilgisini ayırmaktadır. Görüntünün parlaklığını veren yoğunluk ışık miktarı ile belirlenirken, renk bilgisi renk tonu ve koyuluğu ile belirlenmektedir. Hue, temel bir rengi gösterir ve ışığın dalga boyunun spektral dağılımında baskın dalga boyu ile belirlenir. Saturasyon, rengin saflığının bir ölçüsüdür ve renk tonu ile karışık beyaz ışık miktarını gösterir.

HSI renk uzayı geometrik olarak Şekil 1.6 [20] de gösterilmiştir. Genellikle hue, referans çizgi ile KYM renk uzayı arasındaki açı olarak düşünülür. Hue aralık değeri 0° ile 360° arasındadır. Örneğin mavi 2400, sarı 600, yeşil 1200 ve magenta 3000 dir. Saturasyon bileşeni, silindirin merkezinden yarıçap uzaklığıdır. Bir nokta silindir merkezine ne kadar yakın ise rengi o kadar açıktır. Yoğunluk eksen yönündeki yüksekliktir. Silindirin ekseni gri seviyeyi tanımlar. Örneğin sıfır yoğunluk siyah, maksimum yoğunluk beyazdır. Yoğunluk eksenine dik silindirin her bir dilimi, aynı yoğunluktaki bir düzlemi göstermektedir.



Şekil 1.6. HSI renk uzayı [14].

Gri seviye algoritmalar HSI renk uzayının yoğunluk bileşeni üzerinde işlem yapabilirler. Farklı renkli nesnelere bölütleme için, bölütleme algoritmalarını yalnızca hue bileşenine uygulayabiliriz. Farklı nesnelere kolayca bölmek için hue aralığına eşik değerleri konulabilir. Fakat hue, saturation ve intensity değerleri KYM değerleri içinde kodlandığından bu eşik değerlerini KYM'ye dönüştürmek zordur. Hue, yoğunluk değerinden bağımsız olduğundan, görüntü gölge gibi düzensiz aydınlanmaya sahip olduğunda özellikle etkilidir. Bu eşik değerleri etkili bir şekilde hue, saturation ve intensity bileşenlerine sırasıyla uygulanabilir. Amaç alan büyütme algoritmaları için uygun olabilecek bazı alanları şekle sokmaktır. Hue özellikle aydınlanma seviyesi noktadan noktaya veya görüntüden görüntüye değişkenlik gösterdiği durumlarda kullanışlıdır. Hue'nin dezavantajlarından biri, K, Y, M değerlerindeki küçük bir değişikliğin dönüştürülen değerlerde büyük bir sıçramaya neden olduğu renk silindirin eksenine

yakın sabit bir özelliğe sahip olmasıdır. Bu özellikler, renk gösteriminde süreksizliği oluşturmaktadır [21]. Özelliğe yakın hue değeri sayıca stabil değildir. Bunun nedeni düşük saturasyona sahip piksellerin pek çok bölütleme algoritmasında her hangi bir alana atanmamış olmasıdır. Rengin yoğunluğu siyah ya da beyaza yakınsa, hue ve saturasyon da renk ayırt etmede küçük bir rol oynar.

1.4.2.3. CIE

CIE(Commision International de l'Eclairage) renk sistemi algısal değişmezliği göstermek için geliştirilmiştir ve böylece insan gözlemciler için fiziksel bir ihtiyacı karşılamaktadır. X , Y , Z olarak üç temel göstergesi vardır. Herhangi bir renk X , Y ve Z 'nin birleşimi ile belirlenir. X , Y ve Z değerleri, KYM üçlü koordinatlarından doğrusal dönüşüm ile hesaplanır. Özellikle NTSC (National Television Standarts Committee) alıcı temel sistem için dönüşüm matrisi aşağıdaki gibidir.

$$\begin{pmatrix} X \\ Y \\ Z \end{pmatrix} = \begin{pmatrix} 0.607 & 0.174 & 0.200 \\ 0.299 & 0.587 & 0.114 \\ 0.000 & 0.066 & 1.116 \end{pmatrix} \begin{pmatrix} K \\ Y \\ M \end{pmatrix}.$$

X , Y , Z üçlü koordinatları bilindiğinde oluşturulabilecek CIE renk uzayları vardır. $CIE(L^*a^*b)$ uzayı ve $CIE(L^*u^*v)$ uzayı iki tipik örnektir. Bunlar X , Y , Z değerlerinin doğrusal olmayan dönüşümleri ile elde edilirler. $CIE(L^*a^*b)$ aşağıdaki şekilde tanımlanır.

$$L^* = 116 \left(3 \sqrt{\frac{Y}{Y_0}} \right) - 16,$$

$$a^* = 500 \left[3 \sqrt{\frac{X}{X_0}} - 3 \sqrt{\frac{Y}{Y_0}} \right],$$

$$b^* = 200 \left[3 \sqrt{\frac{Y}{Y_0}} - 3 \sqrt{\frac{Z}{Z_0}} \right]$$

$$Y/Y_0 > 0.01, X/X_0 > 0.01 \text{ ve } Z/Z_0 > 0.01.$$

(X_0, Y_0, Z_0) , standart beyaz için X , Y , Z değerleridir. $CIE(L^*u^*v)$ aşağıdaki şekilde tanımlanır.

$$L^* = 116 \sqrt[3]{\frac{Y}{Y_0}} - 16,$$

$$u^* = 13L^*(u' - u_0),$$

$$v^* = 13L^*(v' - v_0).$$

$Y/Y_0 > 0.01$, Y_0 , u_0 , v_0 standart beyaz için değerlerdir ve $u' = \frac{4X}{X+15Y+3Z}$,
 $v' = \frac{6Y}{X+15Y+3Z}$ dir.

Bu iki renk uzayındaki her bir nokta, $CIE(L^*a^*b)$ veya $CIE(L^*u^*v)$ üç boyutlu renk uzayında bir nokta olarak kabul edilir. Böylece iki rengin farkı, iki renk noktası arasındaki Öklit mesafesi gibi hesaplanır. Renk farkları için formül aşağıdaki gibidir.

$CIE(L^*a^*b)$ için,

$$\Delta E_{ab} = \sqrt{(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2} .$$

$CIE(L^*u^*v)$ için,

$$\Delta E_{uv} = \sqrt{(\Delta L^*)^2 + (\Delta u^*)^2 + (\Delta v^*)^2} .$$

İnsanın renk farklılığını algılama yeteneğini Öklit mesafesi ile açıklamak renkli bölütleme için oldukça önemlidir. $CIE(L^*a^*b)$ veya $CIE(L^*u^*v)$ kabaca değişmeyen renksel ölçektir. KYM veya XYZ renk uzayları böyle bir özelliğe sahip değilken bunlar, insan gözünün hassaslığı ile bilgisayar işlemini eşleştirirler [39]. Böylece rahatlıkla intensity, hue ve saturasyon gibi algısal renk özellikleri türetilebilir. (L^*, u^*, v^*) veya (L^*, a^*, b^*) uzayının silindirik koordinatlarıyla eşleşen ve HSI renk uzayını tanımlamak için CIE renk uzaylarından biri ve ilgili renk fark formülü kullanılabilir.

$CIE(L^*a^*b)$ uzayı için:

$$I = L^* ,$$

$$H = \arctan(a^*/b^*) ,$$

$$S = \sqrt{(a^*)^2 + (b^*)^2} .$$

$CIE(L^*u^*v)$ uzayı için:

$$I = L^* ,$$

$$H = \arctan(u^*/v^*) ,$$

$$S = \sqrt{(u^*)^2 + (v^*)^2} .$$


İki CIE uzayı bir rengin parlaklığını veya yoğunluğunu tanımlayan aynı L^* değerini paylaşırlar.

CIE uzayları renk ve yoğunluk bilgisini KYM renklerinden daha bağımsız ve kolay kontrol ederler. Direkt renk karşılaştırılması renk uzayındaki geometrik aralığa bağlı olarak

uygulanır. Bu özellikle küçük renk farkının ölçümünde etkilidir. Fakat diğer doğrusal olmayan dönüşümler gibi özelliğin aynı problemine sahiptir.

1.4.2.4. Munsell

Munsell renk sistemi 1969 yılında oluşturulmuştur [40]. Renkleri tanımlamak için kullanılan en eski metotlardan biridir. Munsell renk sistemi renk algısının üç özelliğini kullanır; Munsell Hue, Value, Chroma. Şekil 1.7 Munsell renk uzayını tanımlamaktadır.



Şekil 1.7. Munsell Renk Uzayı [40].

Beş renk (red (R), yellow (Y), green (G), blue (B), purple (P)) temel renk tonu olarak kabul edilmiştir. Renklerin bileşimleri (YR, GY, BG, PB, RP) beş alt renk tonudur. Beş temel ve beş alt renk tonunun eşit aralıklarla yerleştiği hue çemberi 100 eşit parçaya

ayrılmıştır. Tüm renk tonları hue çemberi üzerinde sıralanmıştır ve iki şekilde tanımlanabilmektedir. Bunlardan biri, belli bir renk ile bağlı birlikteliğini göstermek için kullanılmaktadır. Örneğin K, 2K ve 10K gibi. Diğer bir yol ise renk tonuna bir sayı atamaktır: 5K=0, 6K=1 ve bu numara her bir ton için bir numara olarak renk tonu boyunca saat yönünde artarak devam eder.

Munsell value (V), bir rengin aydınlığını gösterir. Siyah value 0 olarak beyaz value 1 olarak tanımlanmıştır. Aşağıdaki denklem V ile parlaklık Y arasındaki ilişkiyi tanımlamaktadır.

$$Y = 1.2219V - 0.23111V^2 + 0.23951V^3 - 0.021009V^4 + 0.0008404V^5,$$

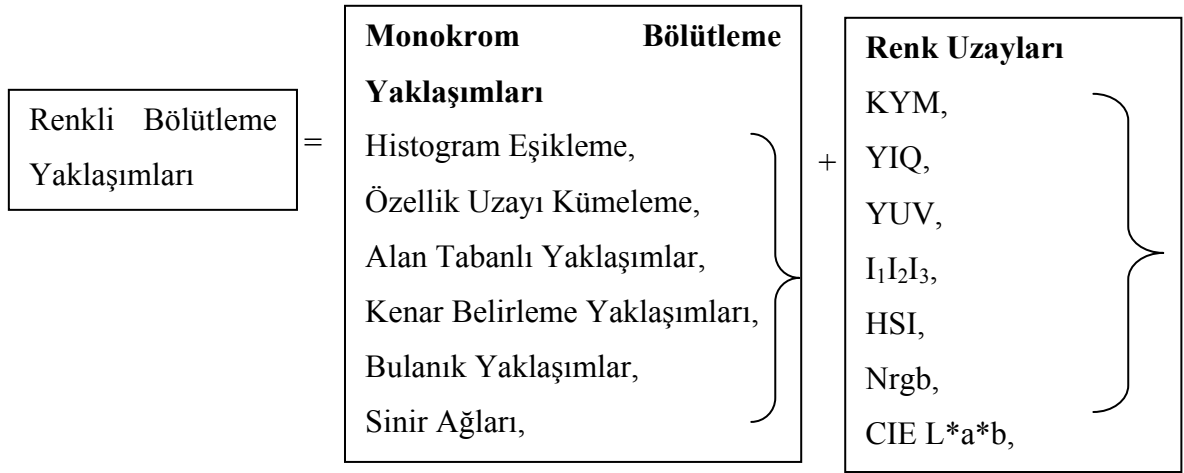
Chroma (C), CIE gösterimindeki saturasyon bileşeni gibidir ve bir rengin saflığını tanımlar. C sıfır olduğunda, bu achromatic bir renktir.

HSI uzayı gibi, Munsell renk uzayı da H , V ve C 'den oluşan bir silindirik koordinat sistemi ile gösterilebilir. Fakat Munsell renk uzayı bir formül ile CIE standart tanımına çevrilemez. Bu yüzden gerçek renk sinyallerini Munsell uzayı ile eşleştirecek bir metot oluşturulmak zorunludur [40].

1.5. Renkli Görüntü Bölütleme

İnsan gözü binlerce renk tonunu ve yoğunluğunu algılayabilmesine rağmen yalnızca iki düzine gri tonu algılayabilmektedir. Bu nedenle gri ölçek kullanılarak bir nesne seçilip algılanamazken renk bilgisi kullanıldığında algılanabilmektedir. Gri ölçek ile karşılaştırıldığında renk, yoğunluğa ek olarak bilgiler içermektedir. Renk, görüntü tanımada ve bilgisayar görmesinde oldukça kullanışlı ve kimi zaman gereklidir. Yüksek boyutlu renk uzaylarının neden olduğu hesaplama karmaşıklığının üstesinden gelen renkli görüntüleri toplayan ve işleyen donanımlar daha ulaşılabilir ve mevcut hale gelmiştir. Bu nedenle, renkli görüntü işleme zamanla daha pratik hale gelmiştir.

Renkli görüntülerde yapılan literatür çalışması monokrom görüntü bölütleme kadar yaygın değildir. En çok yayınlanan renkli görüntü bölütleme sonuçları, Şekil 1.8'de görüldüğü gibi farklı renk uzayları ile gri seviye görüntü bölütlemeye dayanan yaklaşımlardır.



Şekil 1.8. Renkli Görüntü Bölütleme Yaklaşımları

Kaynak [41]'de renkli görüntü, multi-spektral görüntünün özel bir hali olarak düşünülmüş ve multi-spektral görüntüler için herhangi bir bölütleme yönteminin renkli görüntülere de uygulanabileceği söylenmiştir. Kaynak [42]'de karmaşık yapıya sahip renkli görüntüleri bölütlemeye karşılaşılan zorlukları analiz etmiştir. KYM ve HSI olmak üzere iki renk uzayı kullanılmıştır. Doku, tüm görüntü bölütleme tekniklerinde temel sorun olarak görülmektedir. Bu nedenle renk uzayı gösteriminden daha fazla tartışma doku analizi için yapılmıştır. Özellikle de farklı dokuya sahip görüntülerdeki özellik çıkartma problemi üzerinde durulmuştur.

Histogram eşikleme [49], kümeleme [51], alan büyütme [56], kenar çıkartma [36], bulanık yaklaşımlar [48] ve yapay sinir ağları [25] gibi gri seviye bölütleme tekniklerinin çoğu renkli görüntülere genişletilebilir. Gri seviye bölütleme metotları, renk uzayının her bir bileşenine direkt olarak uygulanabilir ve son bölütleme sonuçlarını elde etmek için sonuçlar çeşitli yollarla birleştirilebilir. Fakat buradaki problemlerden biri renk bilgisinin tüm pikseller için bir bütün olarak nasıl kullanılacağıdır. Renk üç bileşene ayrıldığında, renk bilgisi o kadar dağılmaktadır ki renkli görüntü basit bir multi-spektral görüntüye dönüşmektedir ve insanın algılayabildiği renk bilgisi kaybolmaktadır. Bir diğer problem ise bölütleme için renk uzayının nasıl seçileceği problemidir. Her bir renk uzayı avantaj ve dezavantajlara sahiptir. Bölütlenecek tüm görüntüler için baskın olan tek bir renk gösterimi yoktur.

2. GÖRÜNTÜ BÖLÜTLEMeye YENİ BİR NÖTROZOFİK YAKLAŞIM

Nötrozofi, felsefenin bir dalı, mantığın bir genellemesi, kökeni, doğayı ve nötrallitenin kapsamını inceleyen ve diğer fiziksel izgeler ile etkileşimini araştıran yeni bir alandır [43].

Nötrozofi teorisi, herhangi bir (A) önermesini, teorisini, olayını, kavramını veya niceliğini onun karşıtı (Anti-A) ve onu nötralize eden (Neut-A) ile birlikte inceler. Burada (Neut-A), ne (A) ne de (Anti-A)'dır. Ne (Anti-A) ne de (Neut-A) ,(A) değildir. Bu teoreme göre doğadaki her (A) olayı, (Anti-A) ve (Neut-A) ile dengelenir ya da nötralize edilir.

Klasik bir (A) yönteminde, (Neut-A) ve (Anti-A) bir birinden ayrıktır. Bazı durumlarda, kavramlar arasındaki sınır belirsiz ve muğlaktır. (A), (Anti-A) veya (Neut-A) yine ikişerli olarak ortak bölümlere sahip olabilirler.

Nötrozofi, nötrozofik mantık, nötrozofik olasılık, nötrozofik küme ve nötrozofik istatistiğin temelidir.

Klasik küme teorisinde, her bir elemanın belirsizliği değerlendirilmemekte ve açıklanamamaktadır. Bulanık küme, belirsizliklerin değerlendirilmesi amacıyla birçok gerçek probleme uygulanmıştır [44]. Geleneksel bulanık küme, gerçek bir üyeliği tespit etmek için $\mu_A(x)$ [0,1] gibi reel bir sayı kullanır. Eğer $\mu_A(x)$ kendisi belirsiz ise, kesin bir değer ile tanımlanamaz [45]. Uzman sistemler, düşünce sistemi ve bilgi birleşimi gibi bazı uygulamalarda, hem olayın desteklediği doğru üyeliği hem de olaya karşı yanlış üyeliği düşünmek gereklidir. Bu tür problemleri çözmek klasik bulanık kümesi için bile zordur [45].

Nötrozofik kümede (NS), belirsizlik açıkça ölçülür ve doğru üyelik, belirsiz üyelik ve yanlış üyelik bağımsız olabilir.

NS, görüntü eşikleme ve görüntüdeki gürültüyü azaltma için uygulanmıştır. Cheng ve Guo, eşik değerlerini etkili ve otomatik olarak seçen nötrozofi temelli bir eşikleme algoritması önermiştir [46]. Guo ve Cheng, NS temelli bazı içerik ve işlemler tanımlamışlar ve bunları görüntüdeki gürültüyü azaltmak için kullanmışlardır. Bu uygulama hem farklı gürültü seviyelerine sahip gürültülü görüntüler için hem de farklı çeşitte gürültüye sahip gürültülü görüntüler için uygulanabilir.

Görüntü bölütleme, robot görüşü, nesne tanıma, tıbbi görüntüleme gibi çeşitli uygulamalarda önemli rol oynayan görüntü tanıma ve görüntü işlemede ki en zor görevlerden biridir.

Görüntü bölütleme, görüntüyü farklı alanlara bölme işlemidir. Bölütlenen her bir alan homojen iken yakın iki alanın birleşimi homojen değildir. Bölütleme I görüntüsünün çakışmayan S_i alanlarına bölünme işlemidir:

$$I = \cup S_i \text{ ve } S_i \cap S_j = \phi, i \neq j$$

Görüntü bölütleme, görüntünün çeşitliliğinden ve karmaşıklığından dolayı zor bir iştir. Bölütleme sonuçları ışıklandırma, zıtlık (kontrast), gürültü gibi pek çok faktörden etkilenebilir.

Gri görüntü bölütleme yaklaşımları, görüntüdeki gri seviye değerlerinin homojenliğine ve/veya süreksizliğine dayanır. Süreksizliğe dayalı yaklaşım, ani yoğunluk değişimine bağlı olarak ayrık nokta, çizgi ve kenarları belirleyerek görüntüyü bölme eğilimindedir. Homojenliğe dayalı yaklaşımlar genellikle eşikleme (thresholding), kenar belirleme (edge detection), sınıflandırma (clustering), alan büyütme ve birleştirme (region growing and merging) şeklinde sınıflandırılabilir [47]. Bu metotlar bazı uygulamalarda başarılı olsalar da, bazı eksiklikleri hala mevcuttur ve özel uygulamalar için farklı algoritmalar elverişlidir [48]. Eşikleme teknolojileri gürültüye karşı duyarlıdır ve uzamsal bilgileri yok saymaktadırlar. Alan büyütme algoritmaları, zaman tüketimi ve aşırı bölütleme konularından muzdariptir. Kenar belirleme algoritmaları için, gürültü bu algoritmaların yanlış sonuç üretmesine neden olmaktadır. Aşırı bölütleme, sınıflandırma metotlarında da görülen bir eksikliklerdir.

Bulanık küme teorisi, belirsizliğin üstesinden geldiği için geleneksel yöntemlere göre daha avantajlı görünmektedir. Bulanık C-ortalamlar (FCM), veri parçalarının iki veya daha fazla sınıfa ait olduğunu gösteren, bilgisayar görüşü, görüntü tanıma, görüntü işlemede sıklıkla kullanılan bir sınıflandırma metodudur. FCM algoritmaları, bölütleme sonuçlarını bulanık sınırlandırma ile elde eder. Bir piksel grubunun bir sınıfa ait olduğu katı sınıflandırma metotlarından farklı olarak, FCM bir pikseli çoklu sınıflara farklı üyelik dereceleri ile atar [48]. FCM yöntemi, görüntü bölütleme için oldukça etkili bir yöntemdir.

Bulanık küme teorisine ve FCM'ye dayanan bazı bölütleme algoritmaları görülmektedir. Tobias ve Seara, gri seviyedeki benzerliğe göre histogram eşikleme yöntemi önermişlerdir ve bu benzerlik bulanık ölçüm ile değerlendirilir [49]. Chaira ve Ray, dört tip bulanık eşikleme metodu ve piksellerin üyelik derecelerini belirlemek için

Gamma üyeliğini kullanan bir görüntü eşikleme metodunu anlatmışlardır [50]. Yang, görüntü bölütleme için Ant-Tree algoritmasına dayanan bir bulanık küme yaklaşımı sunmuştur [48]. Gri değer, eğim ve pikselin komşuluğunu içeren üç özellik sınıflandırma için çıkarılır. Üç seviyeli ağaç modeli, bölütleme için sınıflandırma yapısını daha uygun hale getirir.

Fakat geleneksel bulanık teori bazı uygulamalar için sınıflandırılır. Örneğin bulanık küme, gürültüsüz görüntüleri verimli bir şekilde ele alırken gürültüye karşı hala hassastır ve uzaysal belirsizlikleri yönetirken dezavantajlara sahiptir [48].

2.1. Nötrozofik Küme

U bir evrensel küme olsun ve U evrensel kümesi NS A 'yı içersin. A kümesi içerisindeki bir x elemanı, t 'nin T içinde, i 'nin I içinde ve f 'nin F içinde değişkenlik gösterdiği $x(t,i,f)$ olarak gösterilsin. $x(t,i,f)$ elemanı, aşağıdaki yolla A 'ya ait olur:

Bu eleman % t doğru, % i belirsiz, % f yanlıştır (t elemanı T içinde, i elemanı I içinde ve f elemanı F içinde çeşitlilik gösterir). Statik olarak T , I , F üyelik kümeleridir fakat dinamik olarak T , I ve F bilinen ve/veya bilinmeyen parametrelere bağlı olarak fonksiyon/işlemlerdir. T , I ve F kümelerinin aralık olmak zorunluluğu yoktur, gerçek alt-tek altküme olabilirler: ayrık veya sürekli; tekli-eleman, sonlu, sayılabilir veya sayılamaz sonsuz; tek veya çeşitli altkümelerle kesişim halinde vs.

2.2. Nötrozofik Görüntü Bölütleme

U evrensel küme ve pikselin parlaklığını gösteren $\omega \subseteq U$ olsun. Bir nötrozofik görüntü P_{NS} T, I ve F olmak üzere üç üyelik kümesi tarafından karakterize edilir. Görüntüdeki bir P pikseli $p(t,i,f)$ olarak tanımlanır ve aşağıdaki yol ile ω 'ye ait olur. P pikseli, piksel parlaklığı kümesi içerisinde % t doğru, % i belirsiz ve % f yanlıştır. Görüntü alanındaki $P(i, j)$ pikseli, nötrozofik bölgeye dönüştürülür.

$P_{NS}(i, j) = \{ T(i, j), I(i, j), F(i, j) \}$. $T(i, j)$, $I(i, j)$ ve $F(i, j)$ üyelik değerleri aşağıdaki şekilde tanımlanır.

$$T(i, j) = \frac{\overline{g(i, j)} - \overline{g_{\min}}}{\overline{g_{\max}} - \overline{g_{\min}}} \quad (2.1)$$

$$\bar{g}(i, j) = \frac{1}{W \times W} \sum_{m=i-w/2}^{i+w/2} \sum_{n=j-w/2}^{j+w/2} g(m, n) \quad (2.2)$$

$$I(i, j) = \frac{\delta(i, j) - \delta_{\min}}{\delta_{\max} - \delta_{\min}} \quad (2.3)$$

$$\delta(i, j) = \text{abs}(g(i, j) - \bar{g}(i, j)) \quad (2.4)$$

$$F(i, j) = 1 - T(i, j) \quad (2.5)$$

$g(i, j)$ sembolü (i, j) pikselinin yoğunluk değerini gösterirken, $\bar{g}(i, j)$ sembolü $g(i, j)$ değerinin lokal ortalama değerini göstermektedir. $\delta(i, j)$ sembolü ise, $g(i, j)$ ve onun lokal ortalama değerini gösteren $\bar{g}(i, j)$ arasındaki mutlak değer farkıdır.

2.3. Nötrozofik Görüntü Entropisi

Gri seviye bir görüntü için, entropi yoğunlukların dağılımını hesaplamaktadır. Eğer entropi maksimum ise, yoğunluk eşit olasılığa sahiptir ve dağılım düzgündür. Eğer entropi düşük ise, dağılım farklı olasılıklara sahiptir ve yoğunlukların dağılımı düzgün değildir. Nötrozofik görüntü entropisi, nötrozofik bölgede elemanların dağılımını hesaplamak için kullanılan T , I ve F kümelerinin entropi toplamı olarak tanımlanır.

$$En = En_T + En_I + En_F \quad (2.6)$$

$$En_T = - \sum_{i=\min(T)}^{\max(T)} P_T(i) \ln P_T(i) \quad (2.7)$$

$$En_I = - \sum_{i=\min(I)}^{\max(I)} P_I(i) \ln P_I(i) \quad (2.8)$$

$$En_F = - \sum_{i=\min(F)}^{\max(F)} P_F(i) \ln P_F(i) \quad (2.9)$$

En_T , En_I ve En_F sembolleri sırasıyla T , I ve F kümelerinin entropi değerlerini gösterirken $P_T(i)$, $P_I(i)$ ve $P_F(i)$ sembolleri ise yine sırasıyla T , I ve F kümelerindeki elemanların olasılıklarını göstermektedir.

2.4. α -Ortalama İşlemi

$I(i, j)$ değeri, $P_{NS}(i, j)$ elemanının belirsizliğini ölçmek için kullanılır. T ve F kümelerini I kümesi ile ilişkilendirmek için, T ve F kümelerindeki değişikliklerin I 'nin eleman dağılımını ve entropisini etkilemesi gerekmektedir.

Gri seviye bir lm görüntü için, ortalama işlemi:

$$\overline{lm}(i, j) = \frac{1}{W \times W} \sum_{m=i-w/2}^{i+w/2} \sum_{n=j-w/2}^{j+w/2} lm(m, n) \quad (2.10)$$

P_{NS} için, α -ortalama işlemi \overline{P}_{NS} olarak aşağıdaki şekilde tanımlanır:

$$\overline{P}_{NS}(\alpha) = P(\overline{T}(\alpha), \overline{I}(\alpha), \overline{F}(\alpha)) \quad (2.11)$$

$$\overline{T}(\alpha) = \begin{cases} T, & I < \alpha \\ \overline{T}\alpha, & I \geq \alpha \end{cases} \quad (2.12)$$

$$\overline{T}_\alpha(i, j) = \frac{1}{W \times W} \sum_{m=i-w/2}^{i+w/2} \sum_{n=j-w/2}^{j+w/2} T(m, n) \quad (2.13)$$

$$\overline{F}(\alpha) = \begin{cases} F, & I < \alpha \\ \overline{F}, & I \geq \alpha \end{cases} \quad (2.14)$$

$$\overline{F}_\alpha(i, j) = \frac{1}{W \times W} \sum_{m=i-w/2}^{i+w/2} \sum_{n=j-w/2}^{j+w/2} F(m, n) \quad (2.15)$$

$$\overline{I}_\alpha(i, j) = \frac{\overline{\delta}_T(i, j) - \overline{\delta}_T \min}{\overline{\delta}_T \max - \overline{\delta}_T \min} \quad (2.16)$$

$$\overline{\delta}_T(i, j) = \text{abs}(\overline{T}(i, j) - \overline{\overline{T}}(i, j)) \quad (2.17)$$

$$\overline{\overline{T}}(i, j) = \frac{1}{W \times W} \sum_{m=i-w/2}^{i+w/2} \sum_{n=j-w/2}^{j+w/2} \overline{T}(m, n) \quad (2.18)$$

$\overline{\delta}_T(i, j)$, $\overline{T}(i, j)$ ortalama değeri ile α -ortalama işleminden sonraki $\overline{\overline{T}}(i, j)$ ortalama değeri arasındaki farkın mutlak değeridir. α -ortalama işleminden sonra, I belirsizlik kümesinin entropisi artar ve I 'daki elemanların dağılımı daha düzgün hale gelir.

2.5. β -İyileştirme İşlemi

Bulanık kümede, μ üyelik için yoğunluk işlemi aşağıdaki gibi tanımlanmaktadır:

$$\mu'(i, j) = \begin{cases} 2\mu^2(i, j), & \mu(i, j) \leq 0.5 \\ 1 - 2(1 - \mu(i, j))^2, & \mu(i, j) > 0.5 \end{cases} \quad (2.19)$$

P_{NS} için, bir β -iyileştirme işlemi $P'_{NS}(\beta)$ dır ve aşağıdaki gibi tanımlanmaktadır:

$$P'_{NS}(\beta) = P(T'(\beta), I'(\beta), F'(\beta)) \quad (2.20)$$

$$T'(\beta) = \begin{cases} T, & I < \beta \\ T'_A, & I \geq \beta \end{cases} \quad (2.21)$$

$$T'_\beta(i, j) = \begin{cases} 2T^2(i, j), & T(i, j) \leq 0.5 \\ 1 - 2(1 - T(i, j))^2, & T(i, j) > 0.5 \end{cases} \quad (2.22)$$

$$F'(\beta) = \begin{cases} F, & I < \beta \\ F'_\lambda, & I \geq \beta \end{cases} \quad (2.23)$$

$$F'_\beta(i, j) = \begin{cases} 2F^2(i, j), & F(i, j) \leq 0.5 \\ 1 - 2(1 - F(i, j))^2, & F(i, j) > 0.5 \end{cases} \quad (2.24)$$

$$I'_\beta(i, j) = \frac{\delta'_T(i, j) - \delta'_T \min}{\delta'_T \max - \delta'_T \min} \quad (2.25)$$

$$\delta'_T(i, j) = abs(T'(i, j) - \overline{T'}(i, j)) \quad (2.26)$$

$$\overline{T'}(i, j) = \frac{1}{w \times w} \sum_{m=i-w/2}^{i+w/2} \sum_{n=j-w/2}^{j+w/2} T'(m, n) \quad (2.27)$$

$\delta'_T(i, j)$ değeri, $T'(i, j)$ yoğunluğu ile β -iyileştirme işleminden sonraki $\overline{T'}(i, j)$ yerel ortalama değeri arasındaki mutlak değer farkıdır.

β -iyileştirme işleminden sonra, T kümesi üyeliği bölütleme için uygun olan daha farklı hale gelir.

2.6. NS Üzerindeki γ -Ortalamalar Kümeleme Analizi

Kümeleme benzer örnek noktaları aynı gruba sınıflandırma işlemidir [51-52]. $X = \{X_i, i = 1, 2, \dots, n\}$ bir veri kümesi ve X_i d boyutlu bir uzayda bir örnek olsun.

Kümeleme problemi aşağıdaki ifadeleri doğrulayan bir $C = \{C_1, C_2, \dots, C_m\}$ parçası bulmaktır.

$$X = \bigcup_{i=1}^m C_i \quad (2.28)$$

$$C_i \neq \emptyset \quad i = 1, 2, \dots, m \text{ için}$$

$$C_i \cap C_j = \emptyset \quad i, j = 1, 2, \dots, m, \quad i \neq j$$

Kümeleme algoritmaları arasında K-ortalamalar algoritması yaygın olarak kullanılmaktadır. Kümeleme analizi metodu için, hedef fonksiyonu tanımlamak önemlidir: Her bir küme mümkün olduğunca yoğun olmalıdır. K-ortalamalar kümeleme algoritmasının hedef fonksiyonu aşağıdaki şekilde tanımlanır:

$$J_c = \sum_{j=1}^m \sum_{i=1}^{n_j} \|X_i - Z_j\| \quad (2.29)$$

Z_j , j 'inci kümenin merkezi iken, m toplam küme sayısı ve n_j ise j 'inci kümenin piksel sayısıdır. Minimum J_c 'nin gerekli şart:

$$Z_j = \frac{1}{n_j} \sum_{X_i \in C_j} X_i \quad (2.30)$$

n_j , C_j kümesindeki eleman sayısıdır.

Nötrozofik kümeye α -ortalama ve β -iyileştirme işlemleri uygulandıktan sonra $\bar{P}_{NS}(\alpha, \beta)$ ile ilgilenen yeni bir kümeleme metodu tanımlanmıştır.

$$X(i, j) = \begin{cases} T(i, j), & I(i, j) \leq \gamma \\ \bar{T}_\gamma(i, j), & I(i, j) > \gamma \end{cases} \quad (2.31)$$

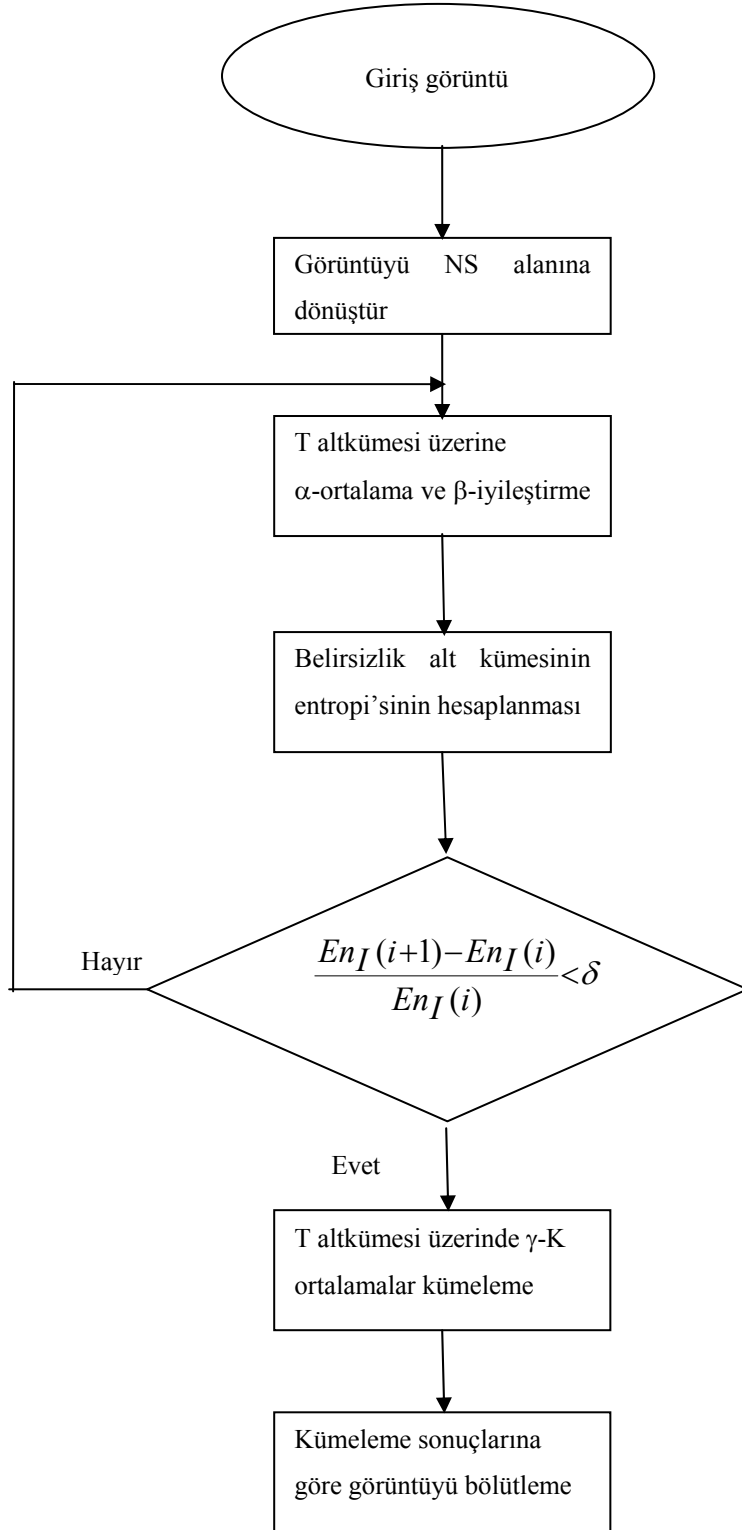
NS için yeni kümeleme algoritması, γ -ortalamalar kümeleme, T alt kümesine uygulanır. γ -ortalamalar algoritmasının yeni hedef fonksiyonu aşağıdaki denklemler ile hesaplanır.

$$J_{TC} = \sum_{I=1}^K \sum_{i=1}^H \sum_{j=1}^W \|X(i, j) - Z_I\|^2 \quad (2.32)$$

$$Z_I = \frac{1}{n_I} \sum_{X(i, j) \in C_I} X(i, j) \quad (2.33)$$

2.7. Nötrozofik Görüntü Bölütleme

İlk adımda görüntü nötrozofik bölgeye dönüştürülür. Görüntü alanındaki $P(i, j)$ pikseli (2.1-2.5) denklemleri kullanılarak nötrozofik bölgeye dönüştürülür. Nötrozofik bölgenin belirsizliği P_{NS} , T kümesi üzerine α -ortalama ve β -iyileştirme işlemleri (2.20-2.27) arasındaki denklemler kullanılarak azaltılmaya çalışılır. Bu işlem belirsizlik kümesinin entropisi I değişmeyene kadar devam ettirilir. Bu işlem sonucunda gürültü giderilirken, kullanışlı bilgilerin korunumu sağlanmaktadır. Gürültüden arındırılan görüntü NS için önerilen γ -ortalama kümeleme algoritması kullanılarak bölütlenir. T kümesi içindeki elemanlar, kümeleme algoritmasının girişidir ve hedef fonksiyon denklem (2.32-2.33)'ye göre belirlenir.



Şekil 2.1. Bölütleme algoritmasının akış diagramı

Algoritma aşağıdaki gibi özetlenir:

Adım 1: (2.1-2.5) denklemleri kullanılarak görüntüyü NS alanına dönüştürme;

Adım 2: Denklem (2.20-2.27) kullanarak T altkümesi üzerinde α -ortalama ve β -iyileştirme işlemlerini uygulama;

Adım 3: Belirsizlik kümesi I 'nın entropisini $En_I(i)$, denklem (2.6-2.9)'u kullanarak hesaplama;

Adım 4: $\frac{En_I(i+1) - En_I(i)}{En_I(i)} < \delta$ ise beşinci adıma git, değilse ikinci adıma git;


Adım 5: T altkümesi üzerine γ -ortalamalar kümelemeyi uygulama;

Adım 6: Beşinci adımdaki sonuçlara göre, görüntüyü bölütleme.


Algoritmanın akış diagramı Şekil 2.1'de görülmektedir.

2.8. Yapay Görüntüler Üzerindeki İncelemeler

FCM algoritması piksel komşuluklarının yoğunluğuna ve ortalama yoğunluğuna bağlıdır. Bu durum klasik FCM yaklaşımının özünde olan bölütleme hata sayısını önemli ölçüde azaltır. Bu metotta yinelemeli FCM algoritması eşiklenmiş aydınlatma alan tahmini içermesi için düzenlenmiştir. Yeni küme merkezleri ve bulanık küme fonksiyonları piksel komşuluklarının yoğunluk ve ortalama yoğunluğuna bağlıdır.



Şekil 2.2. (a) Gauss gürültüsüne sahip orijinal görüntü (b) MFCM metodunun ürettiği sonuçlar (c) Önerilen metodun ürettiği sonuçlar.



Şekil 2.3. (a) Gauss gürültüsüne sahip orijinal görüntü (b) MFCM metodunun ürettiği sonuçlar (c) Önerilen metodun ürettiği sonuçlar.

Performans karşılaştırması için öncelikle bazı yapay görüntüler kullanılmıştır. Şekil 2.2(a) ortalama değeri 0 ve varyans değeri 127 olan Gauss gürültüsü eklenmiş üç yoğunluk seviyesine(0, 127, 255) sahip yapay bir görüntüdür. Şekil 2.3(a) ortalama değeri 0 ve varyans değeri 255 olan Gauss gürültüsü eklenmiş üç yoğunluk seviyesine (0, 127, 255) sahip bir diğer yapay görüntüdür. Şekil 2.2(b) ve Şekil 2.3(b), MFCM kullanıldığında elde edilen bölütleme sonuçlarını göstermektedir. Şekil 2.2(c) ve Şekil 2.3(c), önerilen metod kullanıldığında elde edilen bölütleme sonuçlarıdır. Şekil 2.2(b) ve Şekil 2.3(b) de ki bazı pikseller yanlış bölütlenmişken, bu pikseller Şekil 2.2(c) ve Şekil 2.3(c) de doğru olarak bölütlenmiştir. Şekil 2.2(c) ve Şekil 2.3(c) deki alanlar nesne çıkartımı ve sınıflandırma gibi daha sonraki işlemler için daha düzgün ve homojendir. Bu görüntüler incelendiğinde farklı gri seviyelere ve farklı gürültü seviyelerine sahip yapay görüntülerin bölütlenmesinde önerilen metodun MFCM algoritmasından daha iyi sonuçlar ürettiği anlaşılmaktadır.

Bölütleme algoritmalarının performansını değerlendirmede henüz genel kabul görmüş bir hedef fonksiyon yoktur. Fakat yapay görüntüler için istenilen sonuçlar açıkça bilindiğinden algoritmaları değerlendirmek için bazı hedef kriterler kullanılabilir. Yapay görüntülerin bölütleme sonuçlarını açıkça karşılaştırmak için MFCM metodunda bazı metrikler kullanıldığında bölütleme hatası aşağıdaki gibi tanımlanır:

$$e = (\text{ideal nesne pikselleri} - \text{gerçek nesne pikselleri}) / \text{ideal nesne pikselleri}$$

Bölütleme hatası, ideal bölütlenmiş görüntü ile önerilen metot tarafından bölütlenmiş yanlış sınıflandırılmış piksellerin bir ölçüsünü sunar. Bir görüntünün kalitesi SNR açısından aşağıdaki gibi tanımlanabilir:

$$SNR = 10 \log \left[\frac{\sum_{r=0}^{H-1} \sum_{c=0}^{W-1} I^2(r, c)}{\sum_{r=0}^{H-1} \sum_{c=0}^{W-1} (I(r, c) - I_n(r, c))^2} \right] \quad (2.34)$$

Önerilen metodun bölütleme hatası 0.0155 ten daha küçük iken, MFCM metodunun hataları önerilen metodunkilerden daha büyüktür. SNR düşük iken önerilen metodun performansı MFCM'den daha iyidir. SNR 2.2936 dB iken önerilen metot optimum değerini hata oranı 0.0155 ile elde ederken, MFCM yaklaşımının hata oranı 0.205'e yaklaşmaktadır.

2.9. Gerçek Görüntüler Üzerindeki İncelemeler

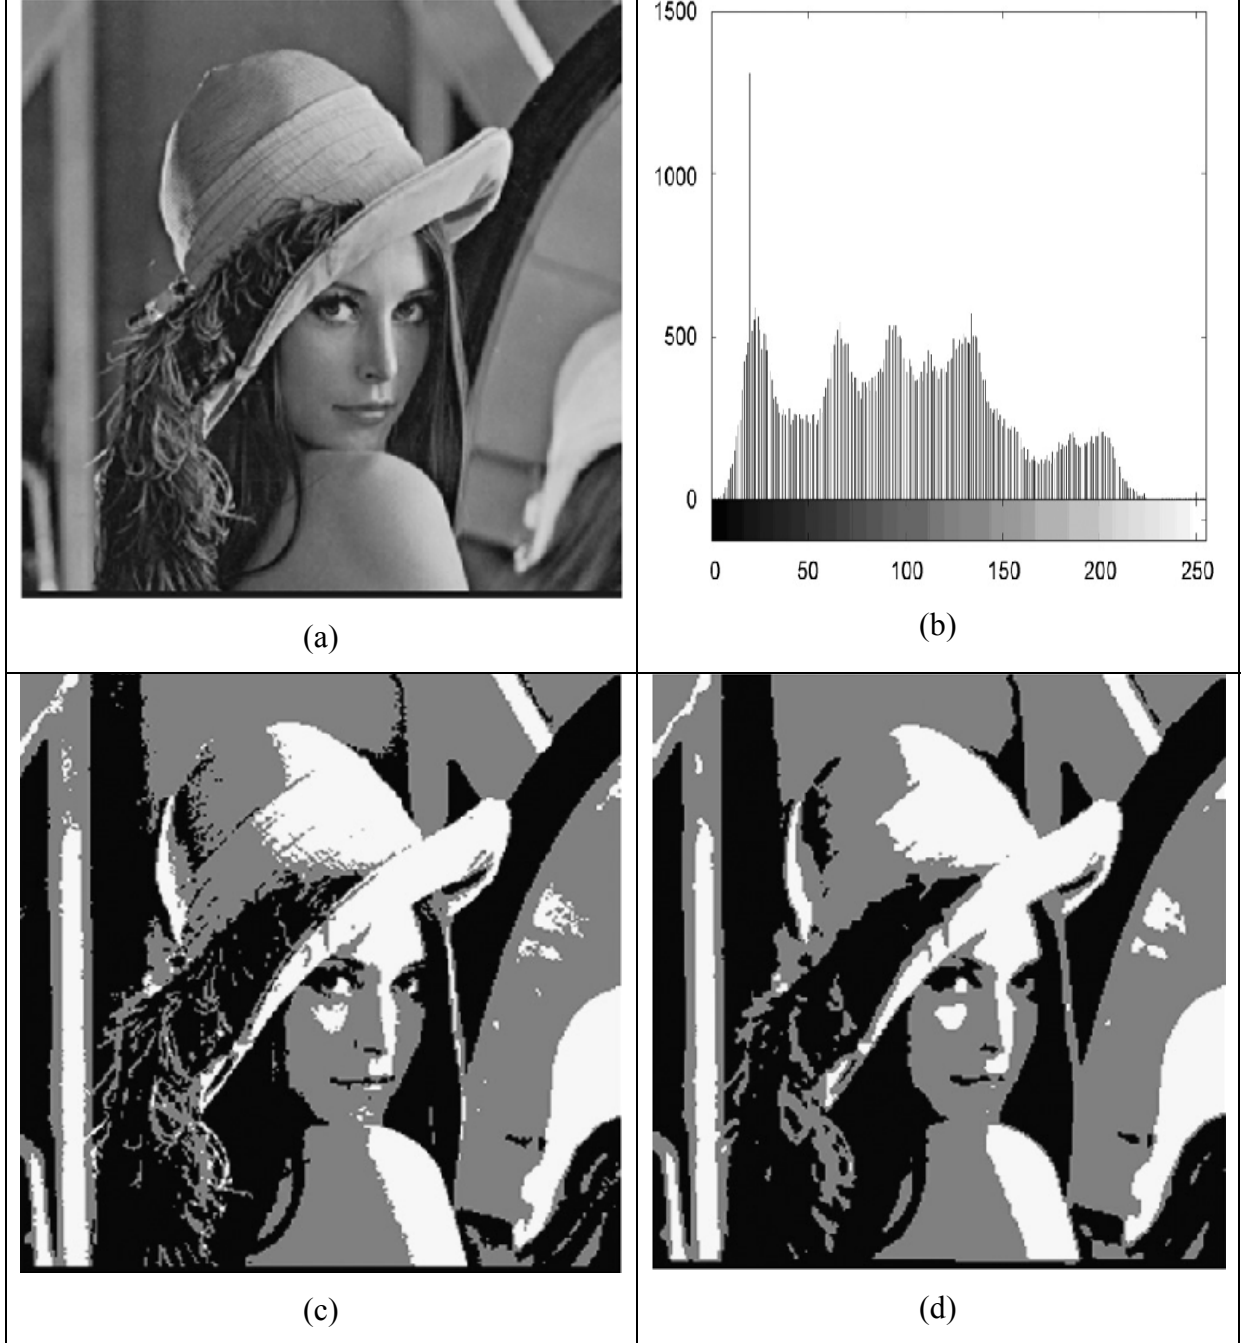
Önerilen yaklaşım çeşitli gerçek görüntülere uygulanmıştır. Şekil 2.4(a)-2.6(a) orijinal görüntülerdir. Şekil 2.4(b)-2.6(b), MFCM metodu kullanıldığında elde edilen sonuçları gösterirken, Şekil 2.4(c)-2.6(c) önerilen metot kullanıldığında elde edilen sonuçları göstermektedir.

Şekil. 2.4(a), 0-255 gri değerine sahip Lena görüntüsüdür ve bu görüntünün histogramı Şekil. 2.4(b) de gösterilmiştir. Şekil. 2.4(c), MFCM algoritması kullanılarak üç sınıfa bölütlenmiştir. Saç ve şapka alanları homojen değildir ve bölütleme sonuçlarında farklılık vardır. Bu duruma gürültü ile birlikte saç ve şapkanın dokusu neden olmuştur. Fakat önerilen metot başarılı bir şekilde görüntüyü bölütlemiştir ve bu durum Şekil.2.4(c) de gösterilmiştir. Şekil. 2.4(c) de alanlar daha tutarlıdır ve saç ile şapkanın gürültüsünden etkilenmemiştir.

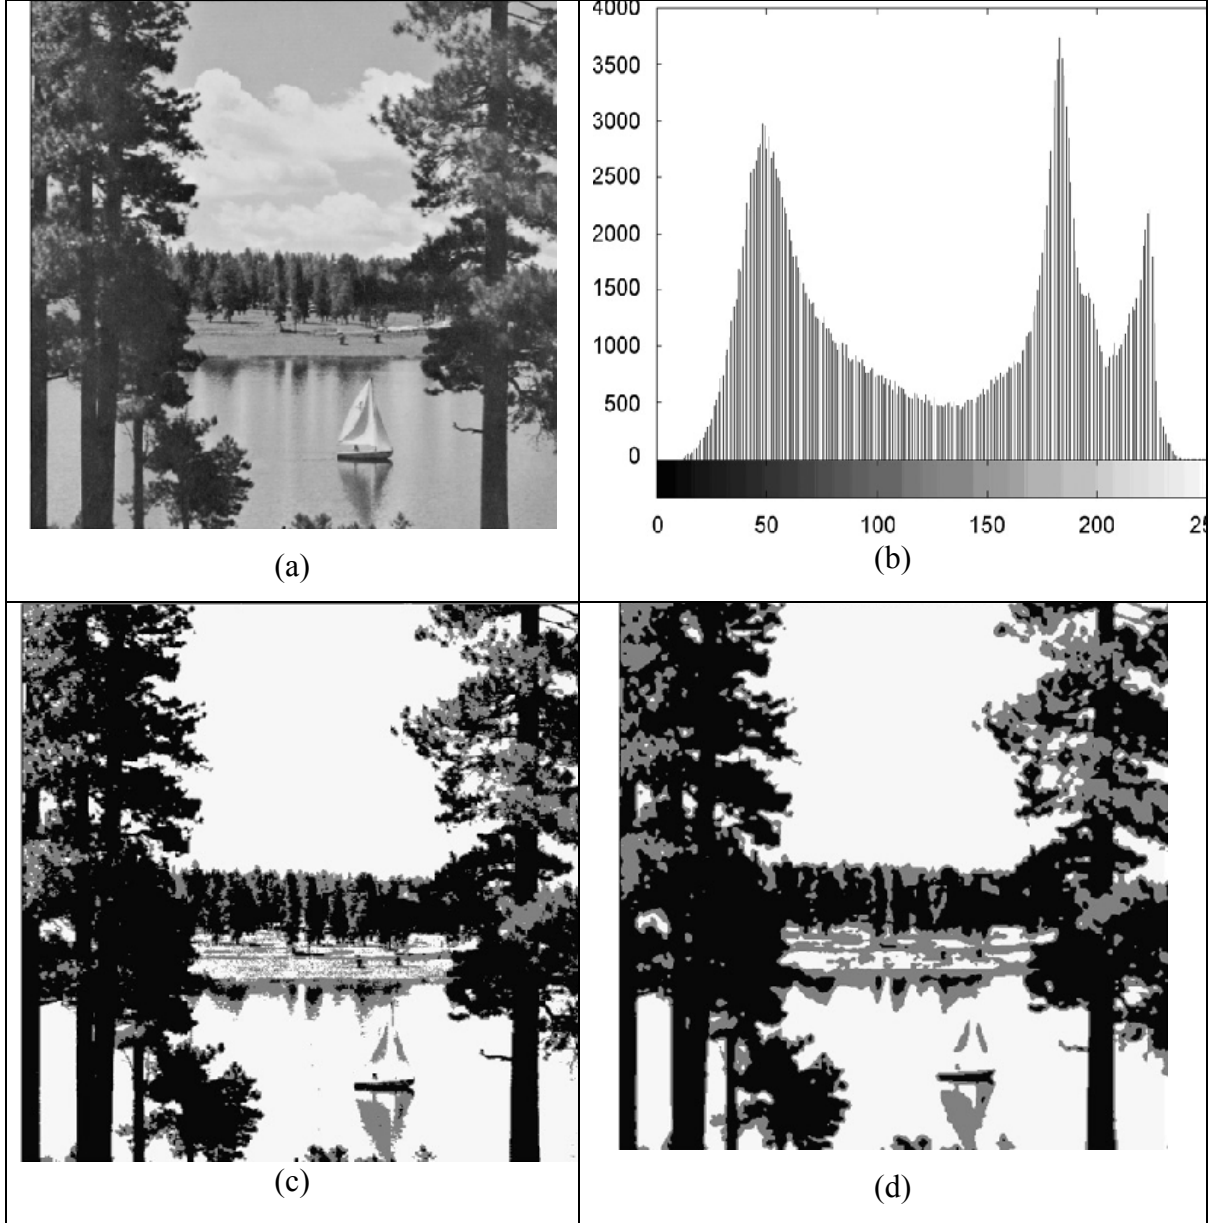
Şekil. 2.5(a), dört temel alana sahip (gökyüzü, ağaç, çimen, göl) bir göl görüntüsüdür. Dört alan arasında gökyüzü ve gölün yoğunlukları neredeyse aynı kabul edilebilir. Şekil. 2.5(b) deki histogram görüntüyü üç alana bölen iki çukurluğa sahiptir.

Şekil. 2.5(c), MFCM algoritmasının sonucudur ve özellikle çim alanlarda yanlış sınıflandırılmış alanlar içermektedir. Şekil. 2.5(d) de, önerilen metot tanımlaması kolay dört ayırık alan oluşturmuştur. Şekil. 2.6(a), Gauss gürültüsüne sahip bir Lena görüntüsüdür. Şekil 2.6(b), bu görüntünün histogramını göstermektedir ve histogramda

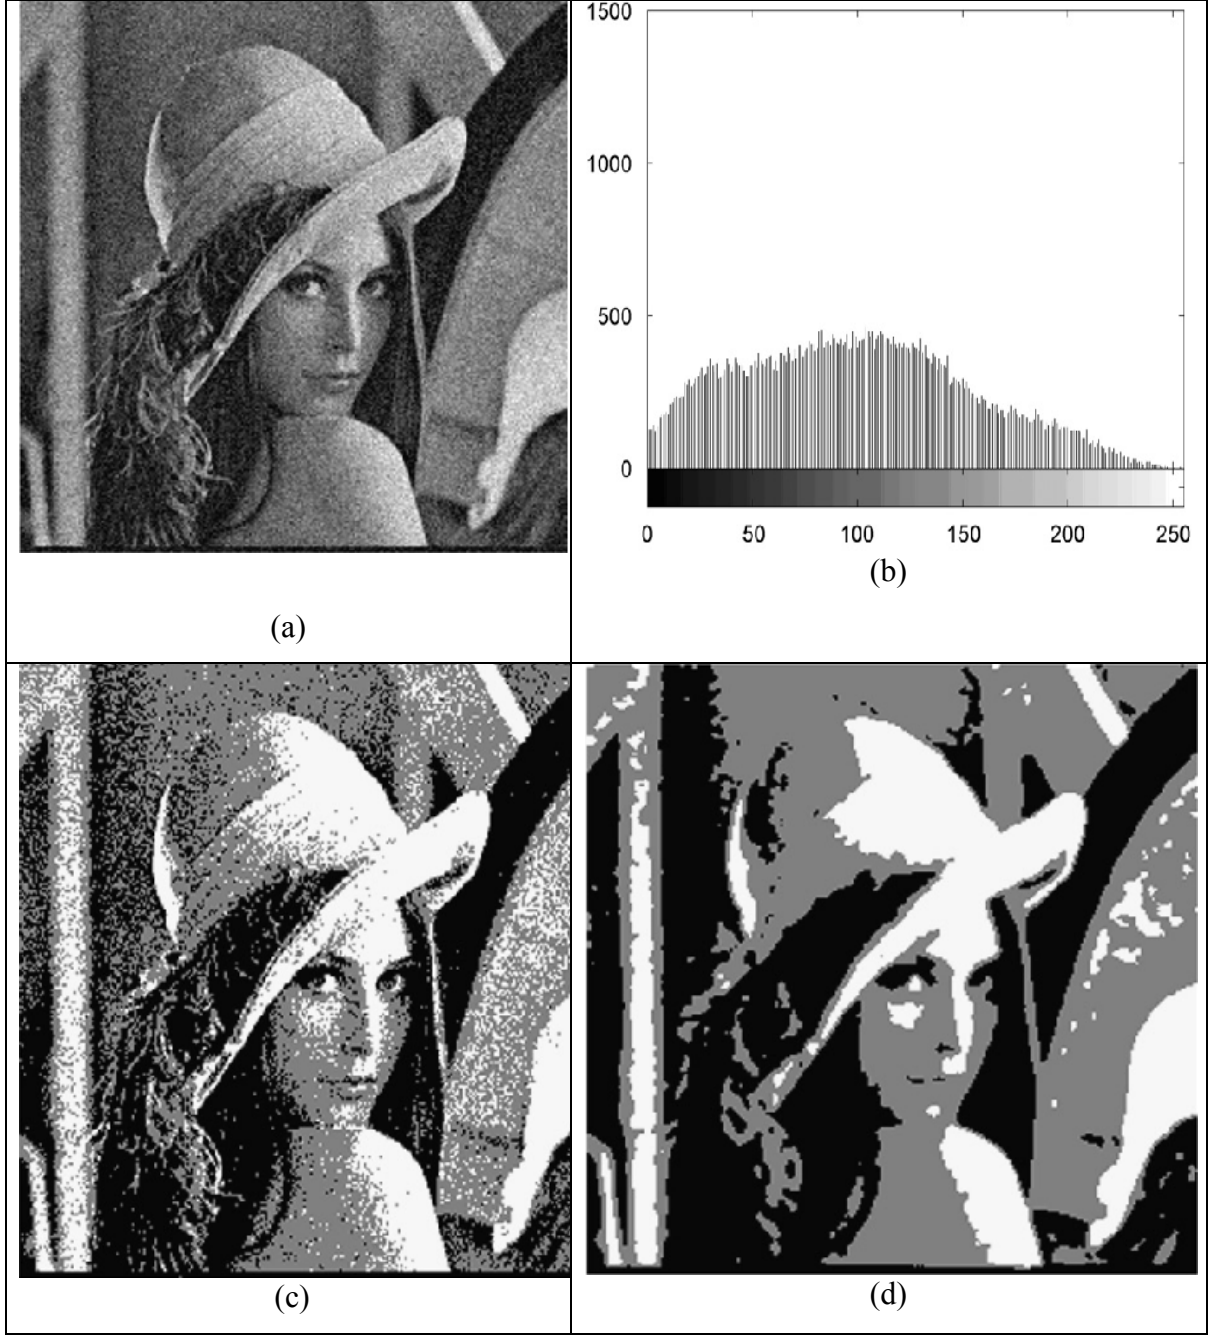
belirgin bir pik değeri yoktur. Şekil. 2.6(c), MFCM metodu kullanıldığındaki bölütleme sonuçlarıdır. Bu sonuçlara göre, bölütleme sonuçları gürültüden oldukça etkilenmiştir. Önerilen metodun bölütleme sonuçlarının daha iyi olduğu görüntü Şekil 2.6(d) de gösterilmiştir. Şapka, saç ve kadının yüzü doğru olarak bölütlenmiştir.



Şekil 2.4. (a) Lena görüntüsü (b) Lena görüntüsünün histogramı (c) MFCM metodu tarafından üretilen bölütleme sonuçları (d) Önerilen metod tarafından üretilen bölütleme sonuçları.



Şekil 2.5. (a) Manzara görüntüsü (b) Manzara görüntüsünün histogramı (c) MFCM metodu tarafından üretilen bölütleme sonuçları (d) Önerilen metot tarafından üretilen bölütleme sonuçları.



Şekil 2.6. (a) Gauss gürültüsüne sahip Lena görüntüsü (b) Gauss gürültüsüne sahip Lena görüntüsünün histogramı (c) MFCM metodu tarafından üretilen bölütleme sonuçları (d) Önerilen metot tarafından üretilen bölütleme sonuçları.

3. NÖTROZOFİK RENKLİ GÖRÜNTÜ BÖLÜTLEME

Bu çalışmada, nörtrozofik kümeye dayalı bir görüntü bölütleme algoritması geliştirilmiş ve geliştirilen yeni metot renkli görüntü bölütlemeye uygulanmıştır. Orijinal nörtrozofik görüntü bölütleme yaklaşımı görüntüyü üç üyelik kümesi T, I, F ve küme belirsizliğini azaltmak için uygulanan iki işlem α -ortalama ve β -iyileştirme ile ifade edilen nörtrozofik bölgeye çevirir. Bu metot görüntü bölütleme yaklaşımında oldukça başarılı olmasına rağmen aşırı bölütleme ve sabit α ve β parametreleri gibi bazı eksiklikleri hala mevcuttur. Böylece NS'ye dayalı görüntü bölütleme algoritmasının sınırlamalarının üstesinden gelmek için yeni bir algoritma önerilmiştir. Daha sonra NS renkli görüntü bölütlemeye genişletilmiştir. NS'ye dayalı görüntü bölütleme algoritması, renk uzayının her bir renk kanalına bağımsızca uygulanır. Daha sonra elde edilen her bir NS alanındaki renk bileşeni, γ -medyan kümeleme algoritması ile sınıflandırılmaktadır. Deneysel çeşitli görüntüler üzerinde uygulanmış ve sonuçlar ortalama kayma bölütleme algoritması ve waveseg yöntem ile karşılaştırılmıştır. Deneysel sonuçlar göstermiştir ki önerilen yaklaşım renkli görüntüleri etkili şekilde bölütleyebilmektedir.

Nörtrozofik küme (NS), Florentin Smarandache tarafından “farklı fikirsel spektralar ile etkileşiminin yanında tarafsızlığın kökeni, doğası ve alanı” ile ilgilenen felsefenin bir dalı olarak önerilmiştir [43]. Nörtrozofi teorisinde, her olayın birbirinden bağımsız olarak düşünülen belli bir doğruluk derecesinin yanında bir yanlışlık derecesine ve bir belirsizlik derecesine sahip olması gerektiği düşünülür [43]. Böylece, bir {A} teorisi, olayı veya varlığı karşıtı {Anti-A} ve tarafsızlığı {Neut-A} ile birlikte düşünülür. {Neut-A} ne {A} nede {Anti-A}'dır. {Neut-A} ve {Anti-A} ile {Non-A} kastedilmektedir. Bu teoriye göre, her {A} fikri {Anti-A} ve {Non-A} tarafından tarafsız ve dengeli hale getirilme eğilimindedir [43]. Nörtrozofik kümede, belirsizlik doğru-üyelik, belirsiz-üyelik ve yanlış üyelik kullanılarak sayısallaştırılır. Bu varsayım pek çok uygulamada oldukça önemlidir [44].

Nörtrozofik taslak ilişkiyel veri tabanı sistemleri, semantik web servisleri [46], finansal datakümesi belirleme [45] ve yeni ekonomik büyüme ve düşme analizleri gibi farklı alan türlerinde pratik uygulamalar bulurken, şimdiye kadar nörtrozofik cebir yapısı incelenmiştir [45].

Nötrozifik küme Guo ve Cheng tarafından görüntü eşikleme, gürültü giderme ve görüntü bölütleme uygulamalarına uygulanmıştır [46-47]. Cheng ve Guo, nötrozofi temelli eşikleri otomatik ve etkili şekilde seçen bir eşikleme algoritması önermiştir. Kaynak [46]'da nötrozofiye dayanan bazı içerik ve işlemler görüntüdeki gürültüyü gidermek için uygulanmıştır. Bu içerik ve işlemler sadece farklı gürültü seviyesine sahip görüntüler için değil aynı zamanda farklı çeşit gürültüye sahip görüntüler içinde uygulanmıştır. Görüntü bölütleme için NS Kaynak [46]'da çalışılmıştır. İlk olarak görüntü NS alana dönüştürülür. Nötrozofik kümede entropi tanımlanır ve belirsizliği değerlendirmek için kullanılır. α -ortalama ve β -iyileştirme işlemleri küme belirsizliğini azaltmak için önerilir. Son olarak, önerilen bu metot γ -medyan kümeleme kullanarak görüntüyü bölütlemek için uygulanır.

Görüntü bölütleme; robot görmesi, nesne tanıma, medikal görüntüleme gibi çeşitli uygulamalarda önemli rol oynayan görüntü işlemede ve görüntü tanımadaki en zor işlerden biridir.

Renkli görüntü bölütleme alandaki nesneyi ve önemli alanları tanımlama, içerik tabanlı görüntü kurtarma, nesne tespiti ve tanımlama, video kodlama vb. gibi pek çok uygulamada kullanışlıdır. Son birkaç on yıl boyunca, renkli görüntüleri bölütlemek için pek çok metot önerilmiştir [47]. Bu metotların çoğu piksellerin yerel komşuluk ilişkilerindeki iki temel özelliğine dayanır: süreksizlik ve benzerlik. Süreksizliğe dayanan yaklaşımlar kenar belirleme teknikleri olarak bilinen ayrık nokta, çizgi ve kenarlar bularak görüntüyü bölmeye çalışırlar.

Bölütleme, renk ve uzamsal özelliklere dayanan bir sınırlandırma problemi olarak ta düşünülebilir. Böylece, renk bölütleme metotları denetlenen veya denetlenmeyen öğrenme /sınıflandırma işlemleri olarak kategorize edilebilir.

Algoritmanın başlığı “iyi” bir bölütleme için bir kriter olarak tanımlanan J ölçümünden gelmektedir. Bölütleme işleminde, renk benzerliği ve rengin uzamsal dağılımı görüntüdeki farklı homojen renk-doku alanlarını karakterize etmek için ayrı ayrı göz önünde bulundurulur.

Nesne modeline dayanmayan enerji fonksiyonunu yapılandıran bazı bölütleme yaklaşımları da vardır. Özgün bir örnek, Shi ve Malik tarafından tanıtılan normalize edilmiş kesim ile bölütlemedir [10]. Normalize edilmiş kesimin temel bir avantajı nesne modeli olmaksızın pikselin optimal bölmesinin etkili şekilde hesaplanabilmesine iyi yaklaşmasıdır.

Enerji-tabanlı optimizasyon yaklaşımlarından farklı olarak, Comaniciu ve Meer tarafından tanıtılan ortalama kayma kümeleme yerel bilgi kararına dayanan bir yaklaşımdır [57]. Ortalama kayma kullanan geleneksel bölütleme yaklaşımları doku özelliği olmaksızın piksel yoğunluğuna dayanır ve pikselleri tahmin edilen bant genişliğine ve ortalama kayma vektöre göre gruplar. Kaynak [57]'deki deneysel sonuçlar göstermiştir ki doku bilgisini hesaba katmamasına rağmen geleneksel ortalama kayma bölütlemenin performansı iyidir. En önemli şey geleneksel yaklaşımlar enerji-tabanlı optimizasyon yaklaşımlarından daha az hesaplamaya gerek duyarlar ve gerçek zamanlı uygulamalara enerji-tabanlı optimizasyon yaklaşımlarından daha uygulanabilir yapan nesne takibi gibi gerçek zamanlı işlemlerde kullanılabilirler.

Özden ve Polat tarafından renk, doku ve uzamsal bilgiyi içeren düşük seviyeli özelliklere dayanan yeni bir renkli görüntü bölütleme metodu önerilmiştir [60]. Renk ve uzamsal bilgiyi ele alan önerilmiş bu metot, üst seviye bölütleme problemleri için yeterli değildir. Böylece doku özellikleri ek bir özellik olarak kullanılır. Küçük dalgalık çerçeveyi kullanan bu metot sabit doku analiz dönüşümü sağlar. Bu metot ek doku özelliğini renk ve standart ortalama kayma algoritmasının uzamsal uzayına ekler. Özellik uzayı genişletilmiş yüksek boyutlu bu yeni algoritma deneysel sonuçlarda görüldüğü gibi standart ortalama kayma bölütleme algoritmasına göre daha iyi sonuçlar üretmektedir.

Bu çalışmada, NS bölütleme algoritması geliştirilmiş ve renkli görüntü bölütleme için uygulanmıştır. NS tabanlı görüntü bölütleme algoritması L, a, b renk kanallarına bağımsızca uygulanmıştır. Daha sonra her bir kanal γ -medyan kümeleme ile kümelenecek için kullanılır. İlk olarak, renkli görüntünün L, a ve b kanalları NS'ye dönüştürülür. Nötrozofik bölgenin belirsizlik üyeliğini hesaplamak için yerel entropi filtresine dayalı yeni bir entropi önerilir. δ -medyan ve β -iyileştirme görüntünün belirsizliğini azaltmak için kullanılır. δ -medyan işlemi orijinal NS bölütleme algoritmasını düzeltmek için kullanılır. Her bir görüntü için δ ve β parametrelerini uyarlamalı olarak belirlemek için kritler tabanlı yeni bir entropi kullanılır. Sonuç olarak NS alanda ki her bir renk kanalı γ -medyan kümeleme metodu kullanılarak bölütlenir. Farklı görüntü seviyelerine sahip yapay görüntüler ve gürültülü ve gürültüsüz gerçek görüntüler üzerine deneysel sonuçlar göstermiştir ki önerilen metot bölütlemeyi iyi bir şekilde uygulamıştır.

3.1. Nötrozofik Görüntü Bölütleme

3.1.1. NS de Görüntü

Görüntü işlemeye yeni bir nötrozofik yaklaşım geliştirilmiştir:

Tanım 1 (Nötrozofik Görüntü): U bir evren olsun ve parlak piksellerden oluşan $W, W \subseteq U$ olsun. P nötrozofik görüntü T, I ve F üyelik kümeleri ile tanımlanır. P görüntüsünde ki bir piksel $P(t, i, f)$ olarak gösterilir ve W kümesine aşağıdaki şekilde bağlanır: Parlak piksel kümesinde $t\%$ true, $i\%$ belirsiz ve $f\%$ yanlış ve t, T içinde i, I içinde ve f, F içinde değişkenlik gösterir. Görüntü alanındaki $P(i, j)$ pikseli nötrozofik bölgeye dönüştürülür, $P(i, j) = \{T(i, j), I(i, j), F(i, j)\}$. Nötrozofik üyelik değerleri olan $T(i, j), I(i, j)$ ve $F(i, j)$ aşağıdaki şekilde tanımlanır:

$$T(i, j) = \frac{\bar{g}(i, j) - \bar{g}_{\min}}{\bar{g}_{\max} - \bar{g}_{\min}} \quad (3.1)$$

$$\bar{g}(i, j) = \frac{1}{w \times w} \sum_{m=i-w/2}^{i+w/2} \sum_{n=j-w/2}^{j+w/2} g(m, n) \quad (3.2)$$

$$I(i, j) = - \sum_{m=i-w/2}^{i+w/2} \sum_{n=j-w/2}^{j+w/2} P_{\delta}(m, n) \log_2 P_{\delta}(m, n) \quad P_{\delta}(m, n) = \delta(i, j) \quad (3.3)$$

$$\delta(i, j) = |g(i, j) - \bar{g}(i, j)| \quad (3.4)$$

$$F(i, j) = 1 - T(i, j) \quad (3.5)$$

$g(i, j)$, (i, j) pikselinin yoğunluk değeri, $\bar{g}(i, j)$ değeri $g(i, j)$ 'nin yerel ortalama değeri, $\delta(i, j)$ değeri, $g(i, j)$ yoğunluk ile onun yerel ortalama değeri olan $\bar{g}(i, j)$ ile arasındaki mutlak değer farkıdır. $P_{\delta}(m, n)$ değeri (m, n) pikselinin olasılığı ve w ise yerel pencere boyutudur.

3.2. Nötrozofik Görüntü Entropisi

Gri seviye bir görüntü için, entropi yoğunluk dağılımını değerlendirir. Entropi maksimum ise, yoğunluklar eşit olasılığa sahiptirler ve düzgün dağılırlar. Entropi küçük ise, yoğunluklar farklı olasılıklara sahiptir ve düzgün dağılmazlar. Bu çalışmada, entropi

nötrozofik görüntüdeki elemanların dağılımını ölçmek için kullanılır ve aşağıdaki şekilde tanımlanır:

Tanım 2 (Nötrozofik Görüntü Entropisi): Nötrozofik görüntü entropisi nötrozofik bölgede elemanların dağılımlarını değerlendirmek için kullanılan üç küme T, I ve F 'nin entropi toplamları olarak tanımlanır:

$$En_{NS} = En_T + En_I + En_F \quad (3.6)$$

$$En_T = - \sum_{i=\min(T)}^{\max(T)} P_T(i) \log_2 P_T(i) \quad (3.7)$$

$$En_I = - \sum_{i=\min(I)}^{\max(I)} P_I(i) \log_2 P_I(i) \quad (3.8)$$

$$En_F = - \sum_{i=\min(F)}^{\max(F)} P_F(i) \log_2 P_F(i) \quad (3.9)$$

En_T , En_I ve En_F sembolleri sırasıyla T, I ve F kümelerinin entropi değerlerini gösterirken $P_T(i)$, $P_I(i)$ ve $P_F(i)$ sembolleri ise yine sırasıyla T, I ve F kümelerindeki elemanların olasılıklarını göstermektedir.

3.3. α -ortalama ve β -iyileştirme İşlemleri


Orijinal NS görüntü bölütleme yaklaşımında, α -ortalama ve β -iyileştirme olarak adlandırılan iki yinelemeli işlem küme belirsizliğini azaltmak için kullanılır. Detaylar için kaynak [46]'e bakılabilir.

3.4. NS' dayalı Görüntü Bölütlemenin Dezavantajları


[49]'daki orijinal NS bölütleme algoritmasında görüntü NS alanına dönüştürülür ve α -ortalama ve β - iyileştirme işlemleri küme belirsizliğini azaltmak için kullanılır. Deneysel sonuçlar göstermiştir ki bu algoritma temiz görüntüleri ve farklı gürültü seviyelerine sahip gürültülü görüntüleri bölütleyebilmektedir. Bu metot görüntü bölütleme uygulamalarında oldukça başarılı olmasına rağmen bazı eksiklikleri hala mevcuttur.

İlk olarak, bu NS bölütleme yaklaşımında fazla bölütlemeler vardır. Kaynak [46]'da kullanılan Şekil 3.1(a) basit bir görüntüdür ve NS bölütleme sonuçlarının oldukça iyi

olduğunu göstermektedir. Fakat nesnelerin gri seviyeleri Şekil 3.2(a)'daki gibi değiştirildiğinde NS fazla bölütleme sonuçları göstermiştir.




Şekil 3.1. (a) Gauss gürültülü orijinal görüntü, (b) NS bölütleme sonucu



Şekil 3.2. (a) Gauss gürültülü orijinal görüntü, (b) NS bölütleme sonucu

Algoritmanın ikinci eksikliği algoritmanın α ve β parametrelerinin seçimine bağımlı olmasıdır. Kaynak [46]'da, α ve β parametreleri sabit 0.85 seçilmiştir. Fakat farklı görüntüler için farklı α ve β parametreleri seçilmelidir. Görüntünün doğasına göre uyarlanabilir α ve β parametreleri düşünülmelidir.



Şekil 3.3. (a) Gauss gürültülü original görüntü, (b) $\alpha = 0.85$ ve $\beta = 0.85$ ile NS bölütleme sonucu (c) $\alpha = 0.25$ ve $\beta = 0.95$ ile NS bölütleme sonucu

Şekil 3.3 NS bölütleme yaklaşımında α ve β parametre seçiminin eksikliğini göstermektedir. Görüntü ortalamasının 0 ve varyansın 31.365 olduğu Gauss gürültüsü ile bozulmuştur. $\alpha=0.85$ ve $\beta=0.85$ olduğunda, bölütleme sonuçları Şekil 3.3(b) deki gibi görülmektedir. Fakat $\alpha=0.25$ ve $\beta=0.95$ olduğunda, Şekil 3.3(c) de görüldüğü gibi daha homojen ve uyumlu alanlar elde edilebilmektedir. Bu nedenle, α ve β 'nin değerleri görüntünün karakteristiğine dayalı seçilmelidir.

3.5. δ -medyan İşlemi

$I(i, j)$ değeri, $P_{NS}(i, j)$ elemanının belirsizliğini ölçmek için kullanılır. T ve F 'yi I ile ilişkilendirmek için, T ve F 'deki NS değişimlerin I 'nın eleman dağılımını ve entropisini etkilemesi gerekir. Gri seviye bir lm görüntüsü için, median işlemi:

$$\overline{lm}(i, j) = \underset{(m,n) \in S_{ij}}{\text{median}}(lm(m, n)) \quad (3.10)$$

Tanım 3. (δ -medyan işlemi): P_{NS} için δ -medyan işlemi, $P_{NS}(\delta)$ aşağıdaki gibi tanımlanır:

$$\overline{P}_{NS}(\delta) = P(T(\delta), I(\delta), F(\delta)) \quad (3.11)$$

$$\overline{T}(\delta) = \begin{cases} T, & I < \delta \\ \overline{T}_\delta, & I \geq \delta \end{cases} \quad (3.12)$$

$$\overline{T}_\delta(i, j) = \underset{(m,n) \in S_{ij}}{\text{median}}(T(m, n)) \quad (3.13)$$

$$\bar{F}(\delta) = \begin{cases} F, & I < \delta \\ \bar{F}_\delta, & I \geq \delta \end{cases} \quad (3.14)$$

$$\bar{F}_\delta(i, j) = \text{median}_{(m,n) \in \mathcal{S}_{ij}}(F(m, n)) \quad (3.15)$$

$$\bar{\delta}_T(i, j) = \left| \bar{T}(i, j) - \bar{\bar{T}}(i, j) \right| \quad (3.16)$$

$$\bar{I}_\delta(i, j) = - \sum_{m=i-w/2}^{i+w/2} \sum_{n=j-w/2}^{j+w/2} P_{\bar{\delta}_T}(m, n) \log_2 P_{\bar{\delta}_T}(m, n) \quad (3.17)$$

$$\bar{\bar{T}}(i, j) = \text{median}_{(m,n) \in \mathcal{S}_{ij}}(T(m, n)) \quad (3.18)$$

$\bar{\delta}_T(i, j)$, medyan yoğunluk $\bar{T}(i, j)$ ve onun medyan değeri $\bar{\bar{T}}(i, j)$ arasındaki farkın mutlak değeridir. δ -medyan işleminden sonra, I belirsizlik kümesinin entropisi artar ve I 'daki elemanların dağılımı daha düzenli hale gelir.

3.6. δ ve β Parametrelerinin Belirlenmesi

δ ve β parametreleri aşağıdaki şekilde belirlenir:

$$EnI = - \sum_{i=1}^h \sum_{j=1}^w p(i, j) \log_2 p(i, j) \quad (3.19)$$

$$En_{\max} = - \log_2 \frac{1}{hw} \quad (3.20)$$

$$\delta = \delta_{\min} + \frac{(\delta_{\max} - \delta_{\min})(EnI - En_{\min})}{(En_{\max} - En_{\min})} \quad (3.21)$$

$$\beta = 1 - \delta \quad (3.22)$$

h ve w görüntünün yükseklik ve genişliğidir. Burada, $En_{\min} = 0$, $\delta_{\min} = 0.01$ ve $\delta_{\max} = 0.1$ değerleri tecrübe ile belirlenmiştir.

3.7. NS Üzerinde γ -medyan Kümeleme Analizi

NS için yeni bir kümeleme metodu tanımlanmıştır ve bu metot $\bar{P}_{NS}(\delta, \beta)$ 'yi ele almaktadır. Belirsizliğin etkisi düşünülerek kümeleme için iki küme T ve I yeni bir değer içinde oluşturulur:

$$X(i, j) = \begin{cases} T(i, j), & I(i, j) \leq \gamma \\ T_\gamma(i, j), & I(i, j) > \gamma \end{cases} \quad (3.23)$$

NS için yeni kümeleme algoritması olan γ -medyan kümeleme algoritması T altkümese uygulanır. γ -medyan'ın yeni hedef fonksiyonu aşağıdaki şekilde tanımlanır:

$$J_{TC} = \sum_{l=1}^K \sum_{i=1}^{H_j} \sum_{j=1}^W \|X(i, j) - Z_l\|^2 \quad (3.24)$$

$$Z_l = \frac{1}{n_l} \sum_{X(i, j) \in C_l} X(i, j) \quad (3.25)$$

3.8. Önerilen Metot

Bu çalışmada, Nötrozofiye dayalı orijinal görüntü bölütleme algoritması üzerinde bazı değişiklikler yapılmış ve bu yeni algoritma renkli görüntüler üzerine genişletilmiştir. NS alanının belirsiz üyelerini hesaplamak için yerel entropi filtresi önerilmiştir. Dahası, yeni bir işlem δ -medyan tanımlandı ve β -iyileştirme işlemi ile birlikte görüntünün belirsizliğini azaltmak için kullanılmıştır. δ ve β parametrelerinin belirlenmesi kriter temelli bir entropi uygulanır. Bu yeni metot ile her görüntü için δ ve β parametreleri uyarlanabilir şekilde belirlenebilir. Görüntü bölütleme algoritmasına dayanan düzeltilmiş NS'nin genişletilmiş hali renkli görüntülere uygulanmıştır ve genişletilme yöntemi bir sonraki bölüme verilmiştir.

3.9. Nötrozofik Renkli Görüntü Bölütleme

Anlamli bir bölütleme elde etmek için, algılanan renk farklılıkları pikselleri göstermek için seçilen renk uzayındaki Öklit mesafesine uygun olmalıdır. CIE L^*a^*b özellikle algılamaya en yakın şekilde tasarlanan bir renk uzayıdır [47]. L^*a^*b , insan görmesine uygun olarak tasarlanmıştır. Bu renk uzayı algısal bir tekdüzeliği amaçlar ve L bileşeni ışığın insan algılaması ile yakın olarak eşleşir. Böylece bu renk uzayı a ve b bileşenlerindeki çıkış kıvrımlarını düzelterek ya da kullanılan L bileşenine zıt olarak ışığı ayarlayarak doğru renk denge ayarını yapmak için kullanılabilir.

Bu makalede, nötrozofik kümeleme dayanan renkli görüntü bölütleme önerilmiştir. İlk olarak KYM renk uzayı L^*a^*b renk uzayına dönüştürülür ve her bir renk kanalını bağımsız

olarak elde etmek için ayrıştırılır. Görüntü alanındaki $P(i, j)$ pikseli, her bir kanal için denklem (3.1-3.5) kullanılarak nötrozofik bölgeye dönüştürülür. Daha sonra δ ve β parametreleri denklem (3.19-3.22) kullanılarak giriş görüntüsünün doğasına göre otomatik olarak belirlenir. Her L, a ve b kanalının T altkümesi üzerinde denklem (3.11-3.18) kullanılarak I 'nin belirsizliği değişmeye kadar δ -median ve β -iyileştirme işlemleri uygulanıp NSP_{NS} 'nin belirsizliği azaltılır. Bu uygulama gürültüyü ortadan kaldırırken kullanışlı bilgileri korur. Sonuç olarak, NS için önerilen γ -medyan kümeleme kullanılarak görüntü bölütlenir. Kümeleme işlemi denklem (3.23-3.25)'e göre tanımlanan algoritma ve hedef fonksiyon ile kullanılır.

Algoritma aşağıdaki şekilde özetlenir:

Adım 1: KYM renk uzayı $L*a*b$ renk uzayına dönüştürülür ve her bir kanal L, a, b ayrıştırılır;

Adım 2: Görüntünün her bir renk kanalı bağımsız olarak NS alanına denklem (3.1-3.5) kullanılarak dönüştürülür;

Adım 3: δ -medyan ve β -iyileştirme uygulanmadan önce, denklem (3.19-3.22) kullanılarak δ ve β parametreleri her bir renk kanalı için otomatik olarak belirlenir;

Adım 4: Her bir renk kanalının T altkümesi üzerine denklem (3.11-3.18) kullanılarak δ -medyan ve β -iyileştirme işlemleri uygulanır;

Adım 5: Her bir renk kanalı için denklem (3.6-3.9) kullanılarak $I_{En_I}(i)$ belirsizlik altkümesinin entropisi hesaplanır ve tüm kanallar için $M_{En_I}(i)$ toplam entropi değeri hesap edilir.

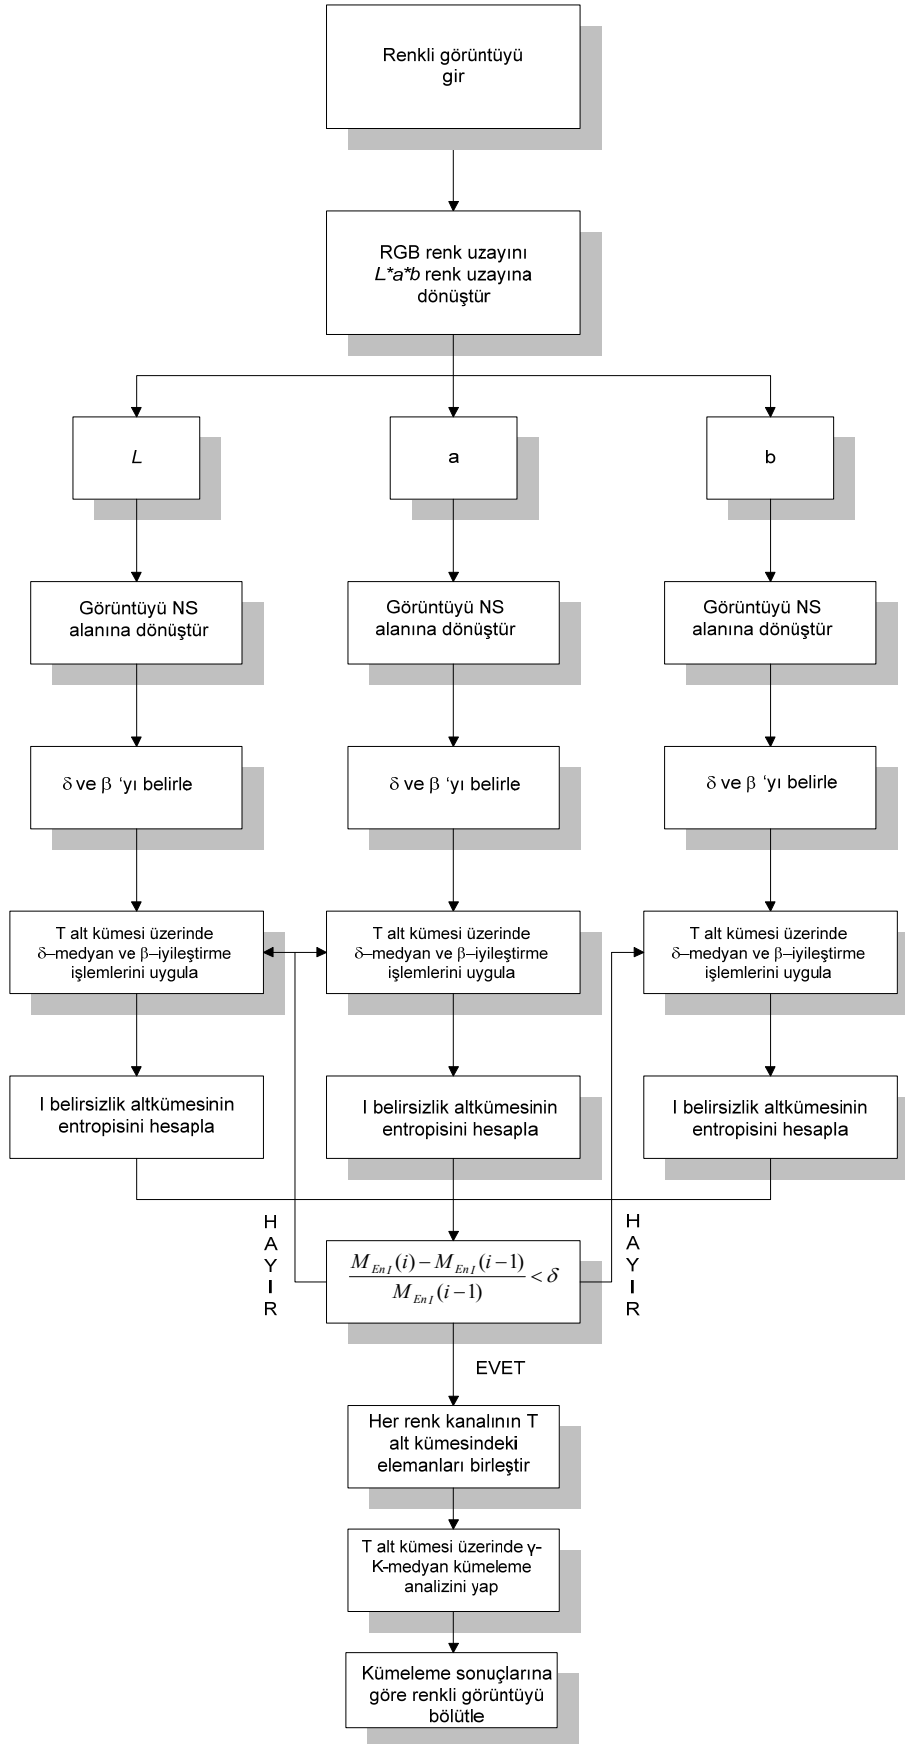
Adım 6: $\frac{M_{En_I}(i) - M_{En_I}(i-1)}{M_{En_I}(i-1)} < \delta$ ise Adım 7'ye gidilir

Değilse $i = i + 1$, Adım 4'e gidilir.

Adım 7: Her bir renk kanalının T altkümesindeki elemanlar giriş kümesini γ -medyan kümelemede oluşturmak için birleştirilir.

Adım 8: Giriş kümesine göre γ -medyan kümeleme uygulanır ve γ -medyan kümeleme sonuçlarına göre görüntü bölütlenir.

Önerilen algoritmanın akış şeması Şekil 3.4'te gösterilmiştir.



Şekil 3.4. Renkli görüntü bölütleme algoritmasının akış diyagramı.

3.10. Deneyleer ve Tartışmalar

Önerilen metot çeşitli görüntülere uygulanmış ve sonuçlar bazı mevcut yaklaşımlar ile kıyaslanmıştır.

3.10.1. Ortalama Kayma

“ d ” boyutlu R^d uzayında bulunan n nokta için x_i vektörü ($i = 1 \dots n$) verilsin. Herhangi bir K çekirdeği kullanılarak çok değişkenli ortalama kayma vektörü - $m_K(x)$ aşağıdaki formülle hesaplanır:

$$m_K(x) \equiv \frac{\sum_{i=1}^n x_i K\left(\frac{x-x_i}{h}\right)}{\sum_{i=1}^n K\left(\frac{x-x_i}{h}\right)} - x \quad (3.26)$$

Yukarıdaki denklemde x kullanılan K çekirdeğinin merkez noktası, h ise kullanılan çekirdeğin boyutunu tanımlamaktadır. Eğer (3.26) numaralı formül de K çok değişkenli simetrik gauss dağılımlı bir çekirdek olarak tanımlanırsa (3.27) numaralı formüldeki halini alır:

$$K(x) = (2\pi)^{-d/2} \exp\left(-\frac{1}{2}\|x\|^2\right) \quad (3.27)$$

Yukarıdaki denklemde $\|x\|$, x parametresinin normunu göstermektedir. Örüntü tanımlama yöntemlerinden biri olan çekirdek dağılım tahmini (Parzen window) metodu en popüler dağılım tahmini metotlarından biridir. Bu metot ilk olarak herhangi bir öznitelik uzayında var olan bir $f(x)$ fonksiyonunun dağılımının modlarını bulmayı amaçlar. Modlar ise fonksiyonların eğimlerinin sıfır olduğu noktalarda bulunmaktadır ($f'(x) = 0$). Ortalama kayma işlemi ise öznitelik uzayında var olan bu modları fonksiyonun dağılım tahminini yapmadan bulmaktadır. x noktasındaki ortalama kayma vektörü, K çekirdeği ile hesaplanan normalize dağılım eğim tahmini ile orantılıdır. (3.26) numaralı denklemdeki çekirdek için:

$$m_K(x) = h^2 \frac{\widehat{\nabla} f_k(x)}{f_k(x)} \quad (3.28)$$

(3.27) numaralı denklemden anlaşıldığı gibi ortalama kayma vektörü her zaman öznelik uzayında var olan dağılımın en çok artan yönünü göstermektedir. Çekirdeğin merkezi, yine çekirdeğin içine düşen noktaların yoğun olduğu bölgeye doğru kaydırılmaktadır. Ortalama kayma vektörü yerel eğim tahmini ile uyduğu sürece, öznelik uzayında var olan dağılımın durağan noktalarına (stationary points) kadar bir yol izleyebilir. Öznelik uzayının modları ise bu durağan noktalardır. Dolayısıyla ortalama kayma işlemi iki basamaklı bir iterasyon olarak yazılabilir:

- $m_K(x)$ ortalama kayma vektörünün hesaplanması
- $K(x)$ çekirdeğinin $m_K(x)$ kadar ötelenmesi

Bu iterasyonun tahmini yapılan dağılımın eğiminin sıfır olduğu herhangi bir noktada duracağı ispatlanmıştır. Fakat tahmini yapılan bir dağılımın eğiminin sıfır olduğu noktaların bulunması o fonksiyon için birinci-dereceden gerekli koşul olarak tanımlanır ve tek başına o fonksiyonun yerel minimum, yerel maksimum veya eyer noktalarını (saddle point) tanımlayabilmek için yeterli değildir. Ortalama kayma işlemi her zaman öznelik uzayında var olan dağılımın en çok artan yönünü göstermekte olduğundan bulunan noktalar yalnızca maksimum veya eyer noktası olabilmektedir. Bu noktaları tanımlayabilmek için kullanılacak temel yol, Hessian matrisi olarak tanımlanan fonksiyonun ikinci dereceden türevinin incelenmesi ve Hessian matrisi için ikinci-dereceden yeterlilik koşulunun sağlanmasıdır. Bir başka ve daha kolay bir yöntem ise eğimi sıfır olarak bulunan noktaların kararlılığını test etmektir. Bunun için küçük bir norma sahip rasgele bir vektör dağılımın ortalama kayma işlemi uygulanarak bulunan durağan noktalara eklenir. Eğer bulunan durağan nokta tekrar aynı noktada (belirli bir tolerans içerisinde kalarak) sabitleniyorsa, bu nokta tahmini yapılan dağılımın yerel maksimum noktası veya modu olarak tanımlanır. Dolayısıyla, tahmini yapılan dağılımın yerel maksimum değerlerinin bulunması için algoritma şu şekilde geliştirilebilir:

- Öznelik uzayının durağan noktalarının bulunması için ortalama kayma işleminin çalıştırılması
- Bulunan durağan noktaları noktaların kararlılığının test edilmesi sonucunda tahmini yapılan dağılımın modlarının bulunması

3.10.2. Ortalama Kayma Tabanlı Görüntü Bölütleme

Gri veya renkli görüntülerdeki birbirine yakın olan hücre değerlerinin homojenleştirilerek bir araya getirildiği işleme görüntü bölütleme adı verilmektedir. Ortalama kayma tabanlı görüntü bölütlemeyi açıklamak için öncelikle kullanılan renk uzayının tanımlanması gerekmektedir. Sağlıklı bir görüntü bölütleme gerçekleştirebilmek için görüntüde algılanan renk farklılıklarını tanımlayan renk uzayının öklit metriğine uygun olması gerekmektedir. Fakat görüntülerin doğasında bulunan kırmızı-yeşil-mavi (KYM) renk uzayı öklit metriğini garanti etmemektedir. Bu nedenle uniform renk uzayı teorisine en çok yaklaşan uzay olan L^*u^*v uzayı tercih edilmiştir. Dolayısıyla, bölütlere ayrılacak olan görüntü öncelikle KYM renk uzayından L^*u^*v uzayına dönüştürülmektedir. Bölütlere ayrılacak olan bir görüntü p -boyutlu olabilen iki boyutlu matrislerden (gri tonlara sahip bir görüntü için $p=1$, KYM uzayındaki bir görüntü için $p=3$, çok-bantlı görüntüler için ise $p>3$ olmaktadır) oluşmaktadır dolayısıyla, bölütlere ayrılacak olan görüntü aslında iki kısımdan oluşmaktadır. Bunlardan birincisi iki boyutlu matrisin oluşturduğu uzaysal kısımdır. İkincisi ise o matrisleri dolduran spektral değerlerin oluşturduğu spektral mesafe uzayıdır. Her iki kısmın öklit metriği geometrisine uygun olduğu kabul edilmiştir. Dolayısıyla, görüntü bölütleme işlemi sırasında bu iki kısmın beraber ele alınması ve karakteristiklerine uygun bir şekilde normalizasyona tabi tutulmaları gerekmektedir. Bu nedenle, görüntü bölütlemesi için kullanılacak olan K çekirdeği adı geçen iki kısmı simgeleyen iki simetrik çekirdeğin çarpımı şeklinde oluşturulacak ve iki kısım için farklı çekirdek boyutları tanımlanacaktır.

$$K_{h_s, h_r}(x) = \frac{C}{h_s^2, h_r^p} K\left(\left\|\frac{x^s}{h_s}\right\|^2\right) K\left(\left\|\frac{x^r}{h_r}\right\|^2\right) \quad (3.29)$$

(3.29) numaralı formülde x^s uzaysal kısmı, x^r spektral kısmı, h_s ve h_r uzaysal ve spektral kısımlar için uygulanan çekirdek boyutlarını ve C ise tanımlanacak olan normalizasyon katsayısını belirtmektedir. Genellikle (3.27) numaralı denklemde verilen gauss dağılımı çekirdek için iyi sonuçlar verdiği için (3.29) numaralı formülde tanımlanması gereken sadece iki parametre (h_s ve h_r) kalmaktadır. Bu iki parametre bölütlere ayrılacak olan görüntüdeki modların belirlenmesi için uzaysal ve spektral kısımlar için gerekli çekirdek boyutunu tanımlar.

Ortalama kayma tabanlı görüntü bölütleme aslında L^*u^*v uzayında dağılımın yerel maksimum değerlerinin bulunması işleminin gerçekleştirildiği sırada başlamaktadır. Dağılım modları yani yerel maksimum değerleri bulunduktan sonra her modun bulunması sırasında üzerinde geçilen noktalar o modun “çekim bölgelerini oluşturmaktadır”. Bu çekim bölgeleri ise sonuçta otomatik olarak görüntünün bölütlere ayrılmasında kullanılmaktadır. Ortalama kayma tabanlı görüntü bölütleme algoritmasının ilk adımı yine ortalama kayma tabanlı olan ve görüntüdeki süreksizliklerin korunduğu filtreleme işlemleridir. Bu işlem sonucunda hem görüntü filtrelenmekte hem de L^*u^*v uzayında görüntünün modları bulunmaktadır. Devamında modların bulunmasında kullanılan “çekim bölgeleri” bilgisi kullanılarak görüntü bölütlere ayrılmaktadır. Son olarak, isteğe bağlı olarak bölütlere ayrılmış görüntü üzerinde belli bir M hücre sayısı değerinden küçük değere sahip olan bölütler temizlenebilmektedir.

3.10.3. Waveseg

Waveseg, renkli görüntü gösterim ve bölütleme için, özellikle gürültülü görüntülere uyan, yeni bir çoklu çözünürlük tekniğidir. Dalga dönüşümü başlangıçta görüntünün her bir renk kanalına uygulanır ve çoklu çözünürlük gösterimi seçilmiş 2^j bir ölçekte oluşturulur. Renk eğim genliği 2^j kaba ölçekte hesaplanır ve uyarlamalı eşik yapay cevapları ortadan kaldırmak için uygulanır. Daha sonra başlangıcı bölütleme, su sınırı dönüşümü eşiklenmiş genliklere uygulanarak hesaplanır ve bu başlangıç bölütleme, tüm çözünürlük 20 olana kadar ters dalga dönüşümü ve çevre geliştirme kullanılarak daha hassas çözünürlük şeklinde tasarlanır. Son olarak, benzer renkteki iki alanları birleştirmek için bir alan büyütme tekniği uygulanır. Waveseg, doğal görüntüler için diğer state-of-art algoritmalar ile karşılaştırılabilir sonuçlar üretmiş gürültülü görüntüler için daha iyi performans gösteren bir algoritma olarak görülmektedir.

3.11. Performans Değerlendirmesi

Önerilen yöntem farklı görüntüler üzerinde uygulanmış ve literatürde en çok kullanılan ortalama kayma [57] ve Waveseg [61] olarak adlandırılan iki farklı yöntem ile karşılaştırılmıştır. Ortalama kayma [57] algoritması için h_s , h_r ve M parametreleri manuel

olarak seçilirken, Waveseq yöntemi için gerekli olan J ve T_c parametreleri, varsayılan (default) değerler olarak seçilmiştir [61].


Renkli görüntü bölütleme algoritmalarını değerlendirebilecek evrensel bir yaklaşım henüz bulunmamakla beraber, gerçek kesin referans (ground-truth) görüntüleri veya insan bölütlemesi (human-segmentation) görüntüleri ile gerçekleştirilen bölütleme sonuçları değerlendirilebilmektedir. Burada kullanılan değerlendirme yöntemi, kesin referans görüntüsünün kenarları ile gerçekleştirilen bölütleme sonucu elde edilen kenarların uyumluluklarını inceleyen, Pratt'ın başarımlı ölçüsü FOM'dur [59]. Pratt, kenarın belirlenmesi ile ilgili oluşan hataları üç ana alana ayırmıştır: geçerli kayıp kenarlar; yanlış olarak yerleştirilen kenarlar ve gürültüden ötürü kenar olarak nitelendirilen noktalar. Pratt'ın değerlendirme ölçütü aşağıdaki denklemle hesaplanmaktadır;

$$FOM = \frac{1}{\max\{I_D, I_I\}} \sum_{k=1}^{I_D} \frac{1}{1 + \alpha(d_k)^2} \quad (3.30)$$

Burada, I_I ve I_D sırası ile ideal kenarları ve tespit edilen kenarları göstermektedirler ve d_k ise k. tespit edilen kenar ile gerçekte olması gereken kenar arasındaki ayrımı gösteren bir parametredir. Ölçeklendirme parametresi α>0 seçilmeli ve bu çalışma da bu değer 0.2 olarak belirlenmiştir. FOM değerinin 1 olması gerçekleştirilen bölütleme ile kesin referans görüntüsünün tam olarak eşleştiğini gösterirken, FOM değerinin 0 yakın olması durumunda ise eşleştirmenin kötü olduğunu göstermektedir.

Karşılaştırma amaçlı kullanılan algoritmaların başarımlarının değerlendirilmesi için farklı görüntüler kullanılmıştır.

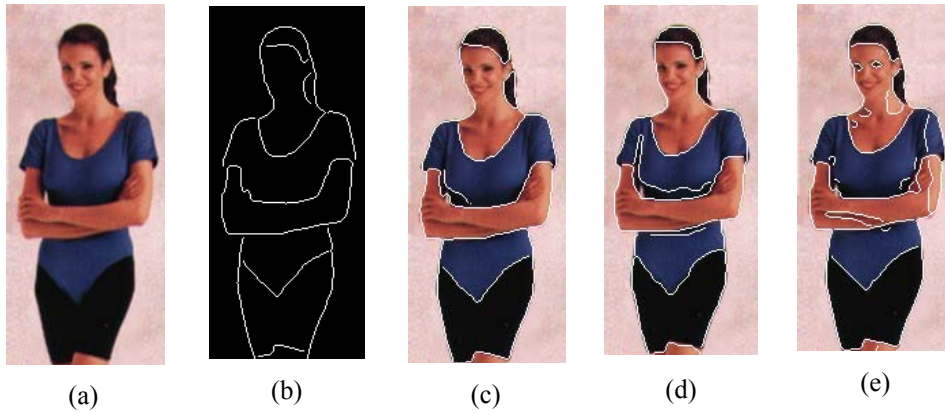
<http://vismod.media.mit.edu/vismod/imagery/VisionTexture/vistex.html> sayfasından alınan ilk görüntü, 4 bölgeden oluşan bir doku görüntüsüdür. Şekil 3.5'te elde edilen bölütleme sonuçları verilmiştir.



Şekil 3.5. (a) Orijinal görüntü (b) Kesin referans görüntüsü (c) Önerilen yöntem ile elde edilen bölütleme (d) Ortalama kayma ile elde edilen bölütleme (e) Waveseq ile elde edilen bölütleme

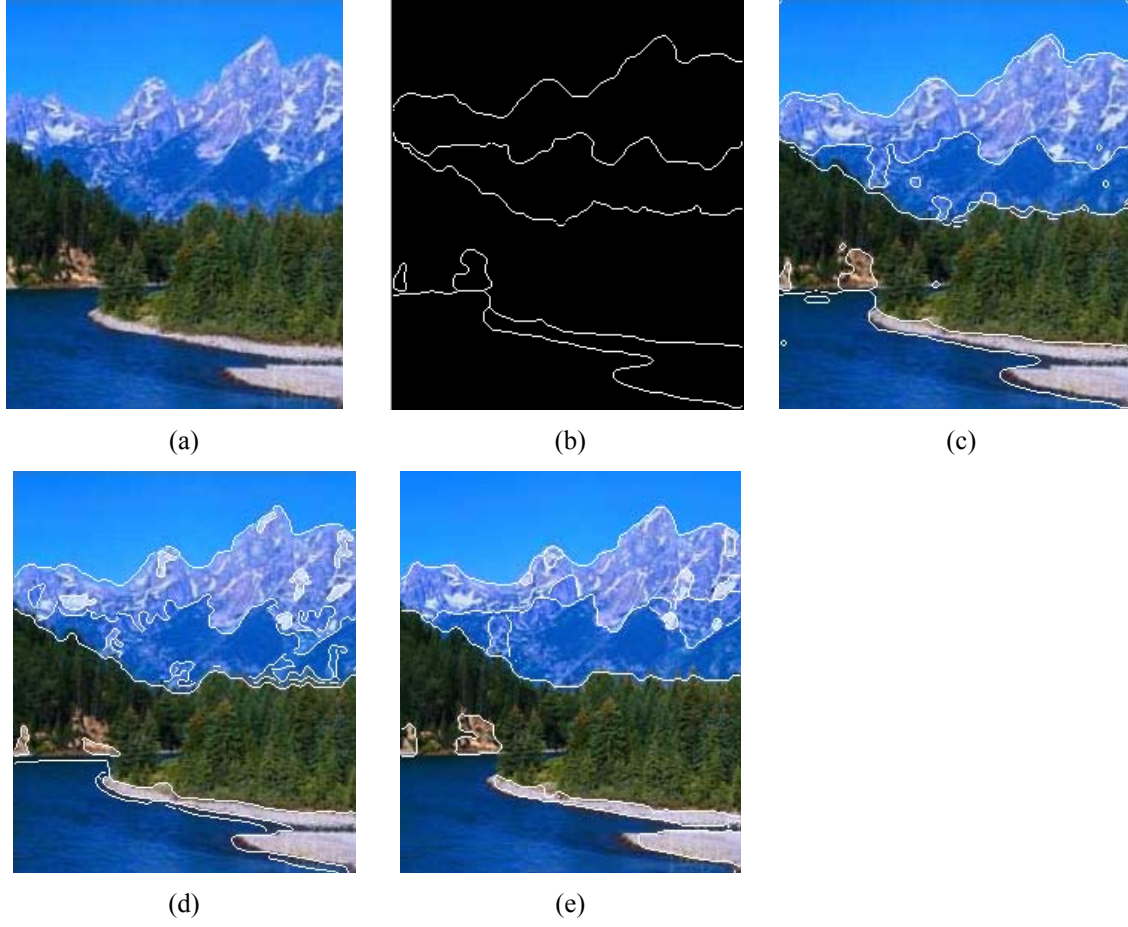
Ortalama kayma algoritması için $h_s = 8$, $h_r = 4$ ve $M = 50$ seçilmiştir. Elde edilen bölütleme sonuçlarından, önerilen yöntem ile elde edilen bölütlemenin, kesin referans görüntüsüne çok yakın olduğu sadece lacivert bölgede küçük bir alanda hata yapıldığı görülmektedir. Diğer taraftan karşılaştırma amaçlı kullanılan yöntemlerin her ikisi de hatalı sonuçlar üretmiştir. Waveseg en kötü sonucu üretirken, ortalama kayma, Waveseg'e oranla daha iyi bölütleme gerçekleştirmiştir.

Kaynaktan alınan diğer bir görüntü ise Şekil 3.6'da verilmiştir. Bu görüntü 4 ayrı bölgeden oluşmaktadır. Bunlar arka plan, ten rengi, mavi mayo ve siyah tayttır. Her bir yöntem ile elde edilen bölütleme sonuçları Şekil 3.6'da gösterilmiştir.



Şekil 3.6. (a) Orijinal görüntü (b) Kesin referans görüntüsü (c) Önerilen yöntem ile elde edilen bölütleme (d) Ortalama kayma ile elde edilen bölütleme (e) Waveseg ile elde edilen bölütleme

Elde edilen sonuçlara bakıldığında yine önerilen yöntemin en iyi bölütleme sonucunu ürettiği görülmektedir. Ortalama kayma yöntemi için $h_s = 8$, $h_r = 8$ ve $M = 100$ değerleri seçilirken. Elde edilen bölütleme sonucunda, mavi bölgelerde aşırı bölütmeleme bölgelerinin olduğu görülmektedir. Waveseg yöntemi ile elde edilen bölütleme sonucunda ise özellikle ten rengi bölümlerinde aşırı bölütlemelerin meydana geldiği görülmektedir.



Şekil 3.7. (a) Orijinal görüntü (b) Kesin referans görüntüsü (c) Önerilen yöntem ile elde edilen bölütleme (d) Ortalama kayma ile elde edilen bölütleme (e) Waveseg ile elde edilen bölütleme

Şekil 3.7’de beş ana bölgeden oluşan bir manzara resmi verilmiştir. Bunlar; göl, sahil, ormanlık, iki farklı dağ dokusu ve gökyüzüdür. Ortalama kayma algoritması için $h_s = 8$, $h_r = 12$ ve $M = 100$ değerleri seçilmiştir. Kolayca görülebilmektedir ki alan sınırları düzgün değildir ve bazı alanlar yanlış sınıflandırılmıştır. Şekil 3.7(b) deki kesin referans görüntü sonucu gözönüne alındığında, ormanlık alandaki zemin alanı ortalama kayma algoritma tarafından yanlış sınıflandırılmıştır. Dahası, dağlık alanlandaki bazı alanlar ortalama kayma tarafından fazla bölütlenmiştir. Ayrıca, kıyı ve göl sınırları oldukça kötü bölütlenmiştir. Waveseg tarafından üretilen bölütleme sonuçları Şekil 3.7(e) de gösterilmiştir. Benzer sınıflandırılmış yanlış pikseller bu algoritmada da görülmektedir. Özellikle dağlık alanda yanlış sınıflandırılmış bazı alanlar mevcuttur. Ayrıca kıyı doğru bölütlenmemiştir. Diğer yandan Şekil 3.7(c) de önerilen algoritmanın sonucu daha


homojendir ve sınırlar ortalama kayma algoritmasının ürettiği sonuçlardan daha düzgündür. Zemin alanları doğru bölütlenmiştir. Dağlık alanlarda daha homojendir.

Tablo 3.1 de, üç metodun bölütleme kalitesini göstermek için FOM değerleri verilmiştir. FOM sonuçlarına göre, önerilen metod bir kez daha ortalama kayma ve Waveseg'den daha iyi bölütleme sonuçları sağlamıştır.

Tablo 3.1. Önerilen metod, Ortalama kayma ve Waveseg için FOM sonuçları

Görüntü	Önerilen Metod	Ortalama kayma	Waveseg
Şekil.3.5	0.8397	0.4253	0.1927
Şekil.3.6	0.9601	0.8542	0.7866
Şekil.3.7	0.8677	0.5995	0.5736

Önerilen bölütleme metodu gürültülü görüntülerde de değerlendirilmiştir. Şekil 3.8 gürültüye sahip bir görüntü örneğidir. Bu kadın görüntüsü Gauss gürültüsü ile oluşturulmuştur ve ilgili bölütleme sonuçları Şekil 3.8 (c),(d),(e) de sırasıyla verilmiştir.




Şekil 3.8. (a) Gürültülü kadın görüntüsü (b) Kesin referans bölütleme sonucu (c) Önerilen yaklaşım kullanıldığında görüntü bölütleme sonucu (d) Ortalama kayma görüntü bölütleme sonucu (e)Waveseg [61]

Kadın görüntüsü, Gauss gürültüsü ile bozulmuş olmasına rağmen, önerilen metod neredeyse Şekil 3.8(b)'de verilen kesin referans sonucunu üretmiştir. Sadece sen rengi ve mavi alanlarda küçük yanlış sınıflandırılmış bazı alanlar olmasına rağmen, bölütleme sınırları düzgündür ve neredeyse kesin referans bölütlemeye uymaktadır. Diğer yandan,

ortalama kayma algoritma başarılı bir bölütleme üretmemiştir. Aynı parametre kümesi kadın görüntüsünün gürültülü versiyonu için oldukça kötü bölütleme sonucu ile sonuçlanmış ve kabul edilebilir bir bölütleme elde etmek için, Şekil 3.8(d) de gösterildiği gibi, tekrar ayarlanması gerekmiştir ($h_s = 8$, $h_r = 16$ and $M = 200$). Kadın görüntüsünün alan sınırları doğru saptanmamıştır. Dahası, kadın yüzünde ve mavi bluzunda yanlış sınıflandırılmış pikseller vardır. Gerçekten de, Waveseg metodu gürültülü kadın görüntüsüne uygulandığında tekrar daha kötü bölütleme sonuçları üretmiştir. Waveseg metodu mavi bluzu ve siyah şortu doğru bölütleyememiştir.

Son olarak, karşılaştırılacak metotlar çeşitli seviyelerde Gaussian gürültüsü ile bozulmuş kadın görüntüsü üzerinde uygulanmıştır ve her bir bölütleme metodunun performansını değerlendirmek için Gaussian gürültüsünün her seviyesi için FOM değeri hesaplanmıştır. Önerilen metot, ortalama kayma ve Waveseg için FOM değerleri Şekil 3.9 da gösterilmektedir. Görüntü kalitesi 0-10 dB arasındadır. FOM değeri tüm bölütleme metotları için oldukça düşüktür. Waveseg en kötü sonucu üretmiştir ve Ortalama kayma metodu Waveseg'den daha iyi sonuç üretmiştir. Dahası, önerilen metot en iyi sonucu üretmiştir. Gauss gürültüsünün seviyesi arttığında, her bir metoddun bölütleme performansı artmıştır. Ayrıca SNR değerleri 30 ve 35 dB olduğunda, önerilen metot ve Waveseg neredeyse benzer performans üretmiştir. Bu şartlar altında Ortalama kayma kötü sonuçlar üretmiştir.

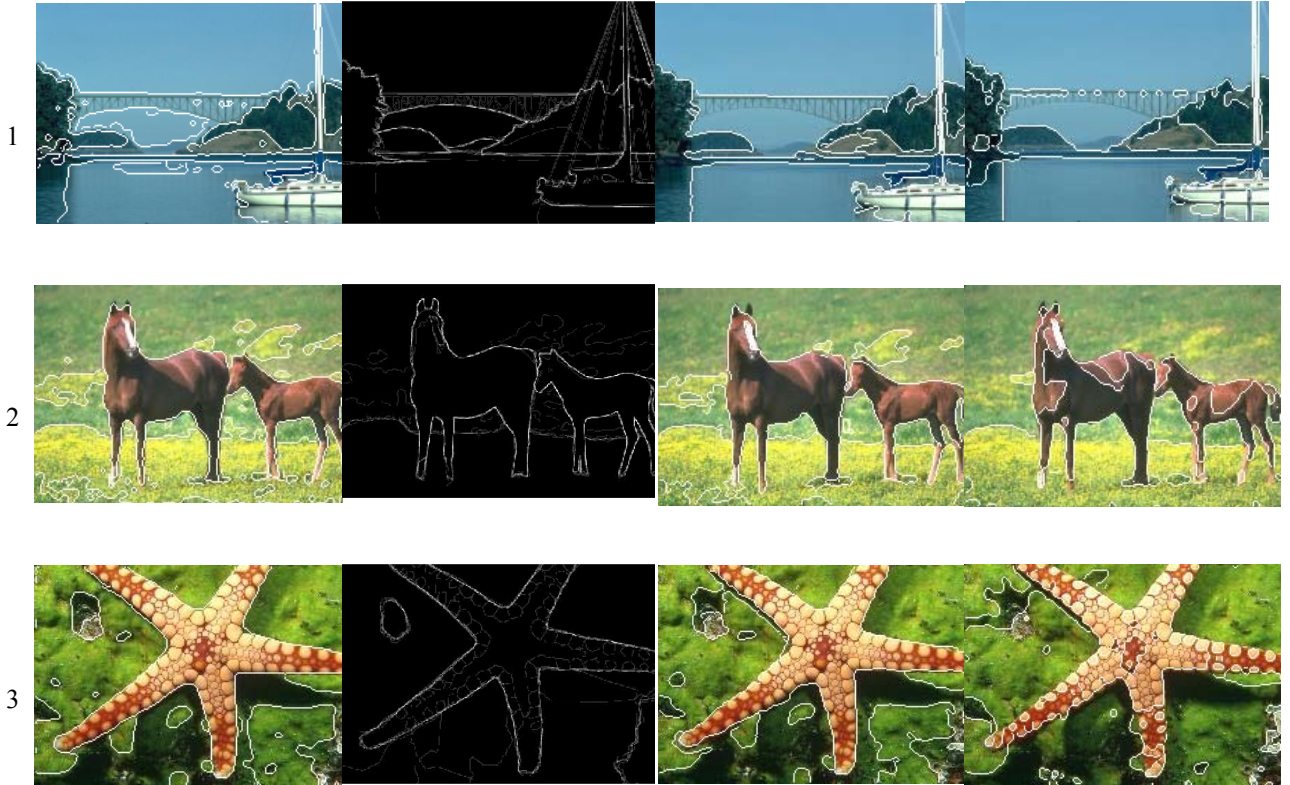



Şekil 3.9. Önerilen metot, Ortalama kayma ve Waveseg için FOM değerleri

Önerilen metot Berkeley verikümesi içinde bulunan bazı doğal görüntüde uygulanmış ve sonuçlar ortalama kayma ve Waveseg ile karşılaştırılmıştır. Tüm görsel incelemeler göstermiştir ki önerilen metot Şekil 3.10 da gösterildiği gibi daha iyi bölütleme sonuçları üretmiştir. Her bir görüntü için FOM değerleri önerilen metodun başarısını göstermektedir. Bu sonuçlar Tablo. 2 de gösterilmiştir.

Tablo 3.2. Önerilen metot, Ortalama kayma ve Waveseg için doğal görüntülerin FOM sonuçları

	Önerilen Metot	Ortalama kayma	Waveseg
Şekil. 8(1)	0.8790	0.8105	0.6110
Şekil. 8(2)	0.9101	0.9016	0.6410
Şekil. 8(3)	0.8997	0.8890	0.5910
Şekil. 8(4)	0.9012	0.8840	0.3940
Şekil. 8(5)	0.8622	0.8734	0.8421
Şekil. 8(6)	0.8109	0.7038	0.6962





(a)

(b)

(c)

(d)

Şekil 3.10. (a) Önerilen metot kullanıldığında görüntü bölütleme sonuçları, (b) Kesin referans bölütleme, (c) Ortalama kayma görüntü bölütleme, (d)Waveseg görüntü bölütleme

4. SONUÇLAR VE TARTIŞMA

Nötrozofi teorisi, herhangi bir (A) önermesini, teorisini, olayını, kavramını veya niceliğini onun karşıtı (Anti-A) ve onu nötralize eden (Neut-A) ile birlikte inceleyen felsefenin bir dalıdır. Nötrozofi, nötrozofik mantık, nötrozofik olasılık, nötrozofik küme ve nötrozofik istatistiğin temelini oluşturur.

Klasik bir küme teorisinde her bir elemanın belirsizliğini değerlendirmek mümkün değilken, nötrozofik kümede belirsizlik açıkça ölçülür ve elemanların üyeliği T, I, F üyelik kümeleri kullanılarak ifade edilir.

Literatürde nötrozofi teorisine dayanan bazı uygulamalar, görüntü bölütleme ve otomatik eşikleme amacıyla kullanılmıştır. Gri seviye görüntüler için kullanılan nötrozofik yaklaşımın bazı eksiklikleri giderilerek bu yaklaşım renkli görüntüler için genişletilmiştir.

NS görüntü bölütleme algoritması düzenlenmiş ve NS renkli görüntü bölütlemeye genişletilmiştir. NS tabanlı görüntü bölütleme algoritması her bir renk kanalına bağımsız olarak uygulanmıştır. Daha sonra her bir renk kanalı γ -median kümeleme ile renk uzayını kümelemek için kullanılır. Öncelikle, renkli görüntünün her bir kanalı NS alana dönüştürülür. Burada nötrozofik bölgenin belirsizlik üyeliğini hesaplamak için lokal entropi filtre temelli yeni bir entropi tabanlı yapı önerilmiştir. Yeni bir işlem olan δ -medyan tanımlanmış ve β -iyileştirme işlemi ile birlikte görüntünün belirsizliğini azaltmak için uygulanmıştır. δ ve β parametrelerinin belirlenmesi, kriter tabanlı yeni bir entropi ile gerçekleştirilmiştir. Bu yeni metot ile, her bir görüntü için δ ve β parametreleri uyarlamalı olarak belirlenebilir. Sonuç olarak NS alandaki her bir renk kanalı γ -medyan kümeleme metodu kullanılarak bölütlenir.

Önerilen metot çeşitli görüntülere uygulanmış ve performansları Ortalama kayma ve Waveseg ile karşılaştırılmıştır. Önerilen metot kullanıldığında bölütleme sonuçları Ortalama kayma ve Waveseg metotlarından daha iyidir. Önerilen metot daha homojen alanlar üretmiştir ve alanlar arasındaki sınırlar Ortalama kayma ve Waveseg sonuçlarından daha düzgündür.

KAYNAKLAR

- [1] **Dudgeon, D.E. and Mersereau R.M.**, 1984. Multidimensional Digital Signal Processing. Englewood Cliffs, Prentice-Hall, New Jersey
- [2] **Saphiro, L.G. and Stockman G.C.**, 2001. Computer Vision, Prentice-Hall, New Jersey, Prentice-Hall, 279-325.
- [3] **Casadei, S. and Mitter, S.**, 1988. Hierarchical image segmentation — Part I: Detection of regular curves in a vector graph. International Journal of Computer Vision, **27** 71–100.
- [4] **Casadei, S. and Mitter, S.**, 1999. Beyond the uniqueness assumption: Ambiguity representation and redundancy elimination in the computation of a covering sample of salient contour cycles. Computer Vision and Image Understanding **76**, 19–35
- [5] **Adams, R. and Bischof, L.**, 1994. Seeded region growing. IEEE Transactions on Pattern Recognition and Machine Intelligence, **16**, 641–647
- [6] **Leonardis, A., Gupta, A. and Bajcsy, R.**, 1995, Segmentation of range images as the search for geometric parametric models. International Journal of Computer Vision, **14**, 253–277
- [7] **Pavlidid, T. and Liow, Y.T.**, 1988. Integrating region growing and edge detection. Proceedings of Computer Vision and Pattern Recognition (IEEE).
- [8] **Haralick, R.M. and Shapiro, L.G.**, 2002. Computer and Robot Vision (Volume I-II). Addison Wesley Longman, New York, USA.
- [9] **Osher, S. and Paragios, N.**, 2003. Geometric level set methods in imaging vision and graphics, Springer Verlag.
- [10] **Jianbo, S. and Jitendra M.**, 2000. Normalized cuts and image segmentation, IEEE Transactions on Pattern Analysis and Machine Intelligence, **22**, 888-905.
- [11] **Olsen, O., and Nielsen, M.**, 1997. Multiscale gradient magnitude watershed segmentation, Proc of ICIAP 97, Springer Verlag, 6-13
- [12] **Szekely, G., and Gerig, G.**, 2000. Model based segmentation of radiological images, K untslische Intelligenz, **3**, 18-23.
- [13] **Witkin, A.P.**, 1983. Scale-space filtering, Proc. 8th Int. Joint Conf. Art. Intell., Karlsruhe, Germany, 1019-1022.
- [14] **Koenderink, J.** 1984. The structure of images, Biological Cybernetics, **50**, 363-370.

- [15] **Lindeberg, T.** 1993. Detecting salient blob-like image structures and their scales with a scale-space primal sketch: A method for focus-of-attention, *International Journal of Computer Vision*, **11**, 283-318.
- [16] **Lindeberg, T.**, 1994. *Scale-Space theory in computer vision*, Kluwer Academic Publishers.
- [17] **Tabb, M. and Ahuja, N.**,1997. Unsupervised multiscale image segmentation by integrated edge and region detection, *IEEE Transactions on Image Processing*, **6**, 642-655.
- [18] **Bijaoui, A. ve Rué, F.**, 1995. A multiscale vision model, *Signal Processing*, **46**, 345
- [19] **Gauch, J. and Hsia, C.W.**,1992. A comparison of three color image segmentation algorithm in four color space, *Visual Communications and Image Processing*, **1818**, 1168-1181,
- [20] **Hoy, D.E.P.**, 1997. On the use of color imageing in experimental applications, *Experimantal Techniques*, 17-19
- [21] **Chapron, M.**, 1992. A newChromatic edge detector used for color image segmentation, *IEEE International Conference on Pattern Recognition*, 311-314.
- [22] **Orchard, M.T. and Bouman, C.A.**, 1991. Color quantization of images, *IEEE Trans, on Signal Processing*, **39**, 677-2690.
- [23] **Comuaniciu, D. and Meer, P.**, 1997. Robust analysis of feature space: Color image segmentation, *IEEEConference on Computer Vision and Pattern Recognition*, 750-755.
- [24] **Pietikainen, M.**, 1996. Accurate color discrimination with classifcation based on feature distributions, *International Conference on Pattern Recognition*, 833-838.
- [25] **Littmann, E., and Ritter, H.**, 1997. Adaptive color segmentation – A comparison of neural and statistical methods, *IEEE Trans, on Neural Network*, **8**, 175-185,
- [26] **Robinson, G.S.**, 1997. Color edge detection, *Optical Engineering*, Vol. 16, No. 5.
- [27] **Ohta, Y, Kanade, T. and Sakai, T.**, 1980. Color information for region segmentation, *Computer Graphics and Image Processing*, **13**, 222-241.
- [28] **Golland, P. and Bruckstein, A.M.**, 1996. Why R.G.B.? or how to design color displays for martians, *Graphical Models and Image Processing*, **58**, 405-402.
- [29] **Nevatia**, 1977. A color edge detector and its use in scene segmentation, *IEEE Trans. On System, Man and Cybernetics*, 820-826.
- [30] **Andreadis, I., Browne, M.A. and Swift, J.A.**, 1990. Image pixel classification by chromaticity analysis, *Pattern Recognition Letters*, **11**, 51-58.

- [31] **Terrillon, J.C, David, M. and Akamatsu, S.**, 1998. Detection of human faces in complex scene images by use of a skin color model and of invariant Fourier-Mellin moments, IEEE International Conference on Pattern Recognition, 1350-1355.
- [32] **Huntsberger, T.L, Jacobs, C.L. and Cannon, R.L.**, 1985. Iterative fuzzy image segmentation, Pattern Recognition, **18**, 131-138.
- [33] **Carron, T. and Lambert, P.**, 1994. Color edge detector using jointly hue, saturation and intensity, IEEE International Conference on Image Processing, Austin, USA, 977-081.
- [34] **Rui, Y., She, A.C and Huang, T.S.**, 1996. Automated region segmentation using attraction-based grouping in spatial-color-texture space, International Conference on Image Processing, 53-56.
- [35] **Kim, W.S. and Park, R.H.**, 1996. Color image palette construction based on the HSI color system for minimizing the reconstruction error, IEEE International Conference on Image Processing, 1041-1044.
- [36] **Tsang, P.W.M. and Tsang W.H**, 1996. Edge detection on objection color, IEEE International Conference on Image Processing, 1049-1052.
- [37] **Tepichin, E, Suarez-Romero, J.G. and Ramirez, G.**, 1995. Hue, brightness and saturation manipulation of diffractive colors, Optical Engineering, **34**, No. 10.
- [38] **Kim, K.M., Lee, C. S. and Ha, Y.H.**, 1996. Color image quantization using weighted distortion measure of HSV color activity, IEEE International Conference on Pattern Recognition, 1035-1039.
- [39] **Tseng, D.C. and Chang, C.H.**, 1992. Color segmentation using perceptual attributes, IEEE International Conference on Pattern Recognition, 228-231.
- [40] **Tominaga, S.**, 1987 Expansion of color images using three perceptual attributes, Pattern Recognition Letters, **6**, 77-85.
- [41] **Pal, S. K.**, 1993. A review on image segmentation techniques, Pattern Recognition, **29**, 1277-1294.
- [42] **Riseman, E.M. and Arbib, M.A.**, 1977. Computational techniques in the visual segmentation of static scenes, Computer Vision, Graphics and Image Processing, **6**, 221-276.
- [43] **Smarandache, F.**, 2003. A unifying field in logics neutrosophic logic. Neutrosophy, Neutrosophic set, Neutrosophic probability, third ed, American Research Press.
- [44] **Zadeh, L.A.**, 1965. Fuzzy sets, Inf. Control **8**,338–353.
- [45] **Wang, H., Sunderraman, R., Smarandache, F. and Zhang, Y.Q.**, 2005. Interval Neutrosophic sets and logic: Theory and applications in computing, Infinite Study,

- [46] **Cheng, H.D. and Guo, Y.**, 2008. A new neutrosophic approach to image thresholding, *New Math. Nat. Comput.*, **4**,291–308.
- [47] **Cheng, H.D., Jiang, X.H., Sun, Y. and Wang, J.L.**, 2001. Color image segmentation: advances and prospects, *Pattern Recognition*, **34**, 2259–2281.
- [48] **Yang, X.C., Zhao, W.D., Chen, Y.F. and Fang, X.**, 2008. Image segmentation with a fuzzy clustering algorithm based on Ant-Tree, *Signal Process.*, **88**, 2453–2462.
- [49] **Tobias, O.J. and Seara, R.**, 2002, Image segmentation by histogram thresholding using fuzzy sets, *IEEE Trans. Image Process.*, **11**, 1457–1465.
- [50] **Chaira, T. And Ray, A.K.**, 2004. Threshold selection using fuzzy set theory, *Pattern Recognition Lett*, **25**, 865–874.
- [51] **Anderberg, M.R.**, 1973. Cluster analysis for applications.
- [52] **Duda, R.O, Hart, P.E. and Stork, D.G.**, 2000. Pattern classification, Wiley–Interscience, New York.
- [53] **Cheng, H. D. and Li, J.**, 2003. Fuzzy homogeneity and scale-space approach to color image segmentation, *Pattern Recognition*, **36**, 1545-1562.
- [54] **Deng, Y. and Manjunath, B.S.**, 2001. Unsupervised segmentation of color-texture regions in images and video. *IEEE Trans. PAMI* 8, 800–810.
- [55] **Nock, R. and Nielsen, F.**, 2005. Semi-supervised statistical region refinement for color image segmentation. *Pattern Recognition*, **38**, 835–846.
- [56] **Nock, R. and Nielsen, F.**, 2003. On region merging: The statistical soundness of fast sorting, with applications. In: *Conf. Comput. Vision Pattern Recognition* pp. II, 19–26.
- [57] **Comanicui, D. and Meer, P.**, 2002, Mean shift: a robust approach toward feature space analysis, *IEEE Trans. Pattern Anal. Mach. Intell.* 24 (5).
- [58] **Zheng, L., Zhang, J. and Wang, Q.**, 2009. Mean-shift-based color segmentation of images containing green vegetation, *Computers and Electronics in Agriculture*, **65**, 93–98.
- [59] **Abdou, I.E. and Pratt, W.K.**, 1979. Quantitative design and evaluation of enhancement / thresholding edge detectors, *Proc.IEEE*, **67**, 753–763.
- [60] **Özden, M., Polat, E. ve Tuna, E.**, 2005. IEEE 13. Sinyal işleme ve iletişim uygulamaları kurultayı, Kayseri,
- [61] **Jung, C. O.** 2006. *Pattern recognition letters*, Elsevier, **28**, 523-533

ÖZGEÇMİŞ

19.10.1980 Elazığ doğumluyum. Lise eğitimimi yabancı dil ağırlıklı Mehmet Akif Ersoy Lisesinde, lisans eğitimimi 1999-2003 yılları arasında Fırat Üniversitesi Bilgisayar Mühendisliği Bölümünde tamamladım. Aynı yıl Bilgisayar Mühendisliği Bölümüne Araştırma Görevlisi olarak atanarak 3 yıl görev yaptım. 2009 Temmuz ayında Emniyet Genel Müdürlüğüne bilgisayar mühendisi olarak atandım ve halen Ankara Emniyet Müdürlüğü Bilgi İşlem Şubesinde bilgisayar mühendisi olarak çalışmaktayım.