



**GENETİK ALGORİTMA KULLANILARAK RENK VE DOKU  
ÖZELLİKLERİNE DAYALI İÇERİK TABANLI GÖRÜNTÜ ERİŞİM  
SİSTEMİ TASARIMI VE UYGULAMASI**

**Mehmet AYAN**

**YÜKSEK LİSANS TEZİ  
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**GAZİ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**HAZİRAN 2016**

Mehmet AYAN tarafından hazırlanan “GENETİK ALGORİTMA KULLANILARAK RENK VE DOKU ÖZELLİKLERİNE DAYALI İÇERİK TABANLI GÖRÜNTÜ ERİŞİM SİSTEMİ TASARIMI VE UYGULAMASI” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Gazi Üniversitesi Bilgisayar Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

**Danışman:** Prof. Dr. O. Ayhan ERDEM

Bilgisayar Mühendisliği, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum

.....

**Başkan:** Doç. Dr. İlyas ÇANKAYA

Elektrik-Elektronik Mühendisliği, Yıldırım Beyazıt Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum

.....

**Üye:** Doç. Dr. Nurettin DOĞAN

Bilgisayar Mühendisliği, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum

.....

Tez Savunma Tarihi: 03/06/2016

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Prof. Dr. Metin GÜRÜ

Fen Bilimleri Enstitüsü Müdürü

## ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
  - Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
  - Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
  - Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
  - Bu tezde sunduğum çalışmanın özgün olduğunu,
- bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Mehmet AYAN

03/06/2016



GENETİK ALGORİTMA KULLANILARAK RENK VE DOKU ÖZELLİKLERİNE  
DAYALI İÇERİK TABANLI GÖRÜNTÜ ERİŞİM SİSTEMİ TASARIMI VE  
UYGULAMASI

(Yüksek Lisans Tezi)

Mehmet AYAN

GAZİ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

Haziran 2016

ÖZET

Son yıllarda teknolojinin gelişmesi ve kamera, telefon, tarayıcı gibi sayısal görüntü sağlayan araçların artmasıyla sayısal görüntülerin hacmi hızlıca artmıştır. Bu görüntülere gerektiğinde erişim sağlama fikri görüntü erişim sistemlerini ortaya çıkarmıştır. Büyük görüntü veritabanlarından istenen görüntülere erişim önemli bir problemdir. Bu probleme çözüm için içerik tabanlı görüntü erişim (İTGE) sistemleri geliştirilmiştir. İTGE sistemleri görüntünün görsel özelliklerini çıkarır ve elde edilen bu özellikleri görüntü erişiminde kullanır. Görüntüler zengin içeriğe sahip olduklarından dolayı tek özelliğe dayalı İTGE sistemleri düşük performans gösterir. Bu yüzden çalışmada görüntülerin renk ve doku özelliklerini çıkaran beş farklı yöntem birleştirilerek yeni bir İTGE sistemi geliştirilmiştir. Renk özellik çıkarımı için renk momenti, renk histogramı ve renk uyum vektörü kullanılmıştır. Doku özellik çıkarımı için gri seviye eş oluşum matrisi ve dalgacık dönüşümü doku analizi kullanılmıştır. Eşit ağırlıkta birleştirilen özelliklerin iyi sonuç vermediği görülmüştür. Bu yüzden genetik algoritma ile özellikler optimize edilerek sistemin performansı artırılmıştır. Sonunda tüm yöntemler WANG veritabanı üzerinde ayrı ayrı test edilmiş ve mevcut İTGE sistemleri ile karşılaştırılmıştır. Renk ve doku özelliklerine dayalı önerilen İTGE sisteminin sadece renk veya doku özelliklerini kullanan sistemlere göre ve yapılmış mevcut İTGE sistemlerine göre daha iyi sonuç verdiği görülmüştür. Bu durum önerilen İTGE sisteminin daha etkin ve başarılı olduğunu göstermiştir.

Bilim Kodu : 92418

Anahtar Kelimeler : İçerik tabanlı görüntü erişimi (İTGE), Renk histogramı, Renk momenti, Renk uyum vektörü, Gri seviye eş oluşum matrisi, Dalgacık dönüşümü, Genetik algoritma (GA)

Sayfa Adedi : 85

Danışman : Prof. Dr. O. Ayhan ERDEM

THE DESIGN AND APPLICATION OF CONTENT BASED IMAGE RETRIEVAL  
SYSTEM BASED ON COLOR AND TEXTURE FEATURES BY USING GENETIC  
ALGORITHM

(M. Sc. Thesis)

Mehmet AYAN

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

June 2016

ABSTRACT

In recent years, with the development of technology and spread of digital devices such as cameras, mobile phones and scanners, a number of digital images have been dramatically increased. Searching, browsing and retrieving in the mass image database has become hot topic. But retrieving similar images from large image database is a significant problem. To overcome this problem, content based image retrieval (CBIR) systems are emerged. In CBIR system, images are defined by using visual features. CBIR retrieves images according to their features. CBIR system based on a single feature has a low performance. Hence in this thesis, five different methods which extract color and texture features were combined to develop a new CBIR system. Color histogram, color moment and color coherence vector were used for color feature extraction and grey level co-occurrence matrix (GLCM) and wavelet transform were used for texture feature extraction. Then, all extracted features were integrated for image retrieval. Equally weighted combined features did not give the best result. Thus, genetic algorithm (GA) was used to train these features with different weights to achieve good results. As a result, all methods were tested on WANG database. The proposed system using GA was compared with other existing systems. The results showed that the proposed system gave successful performance.

Science Code : 92418

Key Words : Content based image retrieval (CBIR), Color histogram, Color moment, Color coherence vector (CCV), Gray level co-occurrence matrix (GLCM), Wavelet transform, Genetic algorithm (GA)

Page Number : 85

Supervisor : Prof. Dr. O. Ayhan ERDEM

## TEŐEKKÖR

Yaptığım alıŐmalar boyunca yardım ve katkılarıyla beni yönlendiren, vakit ayıran ve kıymetli tecrübe ve yorumlarından faydalandığım danışman hocam Sayın Prof. Dr. O. Ayhan ERDEM ve hocam Sayın Do. Dr. Hasan Őakir BİLGE' ye Őükranlarımı sunarım.





## İÇİNDEKİLER

	Sayfa
ÖZET .....	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER .....	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	xi
RESİMLERİN LİSTESİ.....	xii
SİMGELER VE KISALTMALAR.....	xiv
1. GİRİŞ.....	1
2. İÇERİK TABANLI GÖRÜNTÜ ERİŞİMİ ALANINDA YAPILMIŞ ÇALIŞMALAR.....	7
3. ÖNERİLEN YÖNTEM.....	13
3.1. Renk Özellik Çıkarımı .....	13
3.1.1. Renk histogramı .....	13
3.1.2. Renk momenti .....	16
3.1.3. Renk uyum vektörü.....	18
3.2. Doku Özellik Çıkarımı.....	21
3.2.1. Gri seviye eş oluşum matrisi .....	21
3.2.2. Dalgacık dönüşümü .....	26
3.3. Normalizasyon.....	29
3.4. Benzerlik Ölçümü.....	30
3.5. Özellik Birleştirme .....	34
3.6. Genetik Algoritma ile Ağırlıklandırma.....	35

3.7. Önerilen Sistemin Mimarisi .....	39
4. DENEYSEL SONUÇLAR.....	41
4.1. Veritabanı.....	41
4.2. Performans Değerlendirme Metrikleri .....	43
4.3. Renk Yöntemlerinin Test Sonuçları .....	43
4.3.1. Renk histogramı test sonuçları .....	44
4.3.2. Renk momenti test sonuçları .....	49
4.3.3. Renk uyum vektörü test sonuçları.....	54
4.3.4. Birleştirilen renk yönteminin test sonuçları .....	56
4.4. Doku Yöntemlerinin Test Sonuçları .....	60
4.4.1. Gri seviye eş oluşum matrisi test sonuçları .....	60
4.4.2. Dalgacık dönüşümü analizi test sonuçları .....	62
4.4.3. Birleştirilen doku yönteminin test sonuçları .....	64
4.5. Önerilen Yöntemin Test Sonuçları.....	67
4.6. Ağırlıklı Önerilen Yöntemin Test Sonuçları .....	69
4.7. Ağırlıklı Önerilen Yöntemin Diğer Yöntemlerle Kıyaslanması .....	73
5. SONUÇLAR .....	77
KAYNAKLAR .....	79
ÖZGEÇMİŞ .....	85

## ÇİZELGELERİN LİSTESİ

<b>Çizelge</b>	<b>Sayfa</b>
Çizelge 3.1. Gri seviyeli I görüntüsü .....	19
Çizelge 3.2. Nicelenen I görüntüsü.....	19
Çizelge 3.3. Bileşenleri bulunan I görüntüsü .....	20
Çizelge 3.4. Bileşenlerin aitlik tablosu .....	20
Çizelge 3.5. I görüntüsünün renk uyum değerleri.....	20
Çizelge 3.6. 4 X 4 boyutlu gri seviyeli görüntü .....	22
Çizelge 3.7. İlgili konumlar matrisi .....	23
Çizelge 3.8. 4 X 4 boyutlu gri seviyeli görüntüsüne ait GLCM .....	23
Çizelge 3.9. 4 X 4 boyutlu gri seviyeli görüntüsüne ait simetrik GLCM .....	24
Çizelge 3.10. 4 X 4 boyutlu gri seviyeli görüntüsüne ait normalize simetrik GLCM....	24
Çizelge 4.1. Wang veritabanı.....	41
Çizelge 4.2. HSV (8, 2, 2) için renk histogramı hassasiyet oranı .....	44
Çizelge 4.3. HSV (8, 3, 3) renk histogramı hassasiyet oranı .....	45
Çizelge 4.4. HSV (10, 4, 4) renk histogramı hassasiyet oranı .....	46
Çizelge 4.5. HSV (16, 4, 4) renk histogramı hassasiyet oranı .....	46
Çizelge 4.6. Renk histogramlarının birbirleriyle kıyası.....	47
Çizelge 4.7. Tüm görüntünün renk momenti hassasiyet oranı (RGB-RMT).....	49
Çizelge 4.8. RGB-RMY hassasiyet oranı .....	50
Çizelge 4.9. RGB-RMD hassasiyet oranı .....	51
Çizelge 4.10. HSV-RMT hassasiyet oranı .....	51
Çizelge 4.11. HSV-RMY hassasiyet oranı .....	52
Çizelge 4.12. HSV-RMD hassasiyet oranı .....	52
Çizelge 4.13. Renk momentlerinin birbirleriyle kıyası.....	53

<b>Çizelge</b>	<b>Sayfa</b>
Çizelge 4.14. CCV hassasiyet oranı.....	55
Çizelge 4.15. BRY-1 hassasiyet oranı .....	57
Çizelge 4.16. BRY-2 hassasiyet oranı .....	58
Çizelge 4.17. BRY-2' nin kategori bazında hassasiyet oranı .....	58
Çizelge 4.18. GLCM hassasiyet oranı .....	61
Çizelge 4.19. Dalgacık doku analizi hassasiyet oranı.....	63
Çizelge 4.20. BDY hassasiyet oranı .....	65
Çizelge 4.21. BDY' nin kategori bazında hassasiyet oranı .....	65
Çizelge 4.22. Önerilen yöntem 1' in hassasiyet oranı .....	67
Çizelge 4.23. Önerilen yöntem 2' nin hassasiyet oranı .....	67
Çizelge 4.24. Ağırlıklı önerilen yöntemin hassasiyet oranı (Ki Kare Uzaklık).....	70
Çizelge 4.25. Ağırlıklı önerilen yöntemin farklı erişim sayılarındaki hassasiyet oranı (Ki Kare Uzaklık) .....	70
Çizelge 4.26. Ağırlıklı önerilen yöntemin diğer yöntemlerle kıyası (N=10).....	74
Çizelge 4.27. Ağırlıklı önerilen yöntemin diğer yöntemlerle kıyası (N=20).....	75
Çizelge 4.28. Ağırlıklı önerilen yöntemin diğer yöntemlerle kıyası (N=30 ve N=40)...	75
Çizelge 4.29. Ağırlıklı önerilen yöntemin diğer yöntemlerle kıyası (N=50 ve N=100).	76

**ŞEKİLLERİN LİSTESİ**

<b>Şekil</b>	<b>Sayfa</b>
Şekil 1.1. İTGE sistemi aşamaları.....	2
Şekil 1.2. RGB renk küpü.....	4
Şekil 1.3. HSV renk uzayı.....	5
Şekil 3.1. Renk histogramı hesaplama aşamaları.....	13
Şekil 3.2. Çözünürlük hücrelerinin mekânsal ilişkileri.....	22
Şekil 3.3. Filtre seti .....	28
Şekil 3.4. Ayırıştırma .....	28
Şekil 3.5. Öklit uzaklık .....	30
Şekil 3.6. Cityblock uzaklık.....	31
Şekil 3.7. Korelasyon uzaklık .....	33
Şekil 3.8. Genetik algoritmanın elemanları .....	35
Şekil 3.9. Genetik algoritmanın akış şeması.....	35
Şekil 3.10. Genetik algoritmanın çalışma prensibi .....	38
Şekil 3.11. Önerilen sistemin blok şeması .....	39
Şekil 4.1. GA kullanılarak elde edilen yöntemlerin ağırlıkları.....	69

## RESİMLERİN LİSTESİ

<b>Resim</b>	<b>Sayfa</b>
Resim 1.1. Görüntü etiketleme .....	1
Resim 3.1. (a) Tüm görüntü (b) Yatay olarak üç parçaya bölünmüş görüntü (c) Dikey olarak üç parçaya bölünmüş görüntü .....	17
Resim 4.1. Wang veritabanına ait her kategoriden rastgele seçilen 5 görüntü .....	42
Resim 4.2. Sahil kategorisine ait 112 numaralı görüntünün erişim sonuçları (RH (10, 4, 4)-Ki Kare Uzaklık) .....	48
Resim 4.3. Dağ kategorisine ait 812 numaralı görüntünün erişim sonuçları ( RH (10, 4, 4)-Ki Kare Uzaklık) .....	48
Resim 4.4. Yemek kategorisine ait 995 numaralı görüntünün erişim sonuçları (RGB-RMY-Kosinüs Uzaklık) .....	54
Resim 4.5. Otobüs kategorisine ait 354 numaralı görüntünün erişim sonuçları (RGB-RMY-Kosinüs Uzaklık) .....	54
Resim 4.6. Fil kategorisine ait 577 numaralı görüntü için erişim sonuçları (CCV-Ki Kare Uzaklık) .....	55
Resim 4.7. At kategorisine ait 756 numaralı görüntü için erişim sonuçları (CCV-Ki Kare Uzaklık) .....	56
Resim 4.8. a) RM (16, 4, 4) erişim sonuçları b) RGB-RMY erişim sonuçları c) CCV erişim sonuçları d) BRY-2 erişim sonuçları (Ki Kare Uzaklık).....	59
Resim 4.9. At kategorisine ait 719 numaralı görüntü için erişim sonuçları (GLCM-Öklit) .....	61
Resim 4.10. Afrika kategorisine ait 6 numaralı görüntü için erişim sonuçları (GLCM-Öklit Uzaklık) .....	62
Resim 4.11. Dinozor kategorisine ait 490 numaralı görüntü için erişim sonuçları (Dalgacık-Öklit Uzaklık).....	63
Resim 4.12. Çiçek kategorisine ait 632 numaralı görüntü için erişim sonuçları (Dalgacık- Öklit Uzaklık).....	64
Resim 4.13. Yemek kategorisine ait 944 numaralı görüntü için erişim sonuçları a) GLCM erişim sonuçları b)Dalgacık dönüşümü erişim sonuçları c) BDY erişim sonuçları (Kosinüs Uzaklık).....	66

<b>Resim</b>	<b>Sayfa</b>
Resim 4.14. Dağ kategorisine ait 891 numaralı görüntü için erişim sonuçları a) BRY-2 erişim sonuçları b) BDY erişim sonuçları c) Önerilen sistem 2 erişim sonuçları (Ki Kare Uzaklık) .....	68
Resim 4.15. Afrika kategorisine ait 50 numaralı görüntü için erişim sonuçları a) Önerilen yöntem 2 b) Ağırlıklı önerilen yöntem (Ki Kare Uzaklık) .....	71
Resim 4.16. Yemek kategorisine ait 903 numaralı görüntü için erişim sonuçları a) Önerilen yöntem 2 b) Ağırlıklı önerilen yöntem (Ki Kare Uzaklık) .....	72
Resim 4.17. Bina kategorisine ait 217 numaralı görüntü için erişim sonuçları a) Önerilen yöntem 2 b) Ağırlıklı önerilen yöntem (Ki Kare Uzaklık) .....	73



## SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

<b>Kısaltmalar</b>	<b>Açıklamalar</b>
<b>BRY</b>	Birleştirilmiş Renk Yöntemi
<b>BDY</b>	Birleştirilmiş Doku Yöntemi
<b>CCH</b>	Cell Color Histogram-Hücre Renk Histogramı
<b>CCV</b>	Color Coherence Vector-Renk Uyum Vektörü
<b>CLD</b>	Color Layout Descriptor-Renk Düzen Tanımlayıcı
<b>CMY</b>	Cyan, Magenta, Yellow-Camgöbeği, Galibarda, Sarı
<b>CMYK</b>	Cyan, Magenta, Yellow, Key-Camgöbeği, Galibarda, Sarı, Siyah
<b>CSD</b>	Color Structure Descriptor-Renk Yapı Tanımlayıcı
<b>DCD</b>	Dominant Color Histogram-Baskın Renk Tanımlayıcı
<b>DCT</b>	Discrete Cosine Transform-Ayrık Kosinüs Dönüşümü
<b>DLEP</b>	Directional Local Extrema Pattern-Yönlü Yerel Ekstreum Örüntü
<b>DWT</b>	Discrete Wavelet Transform-Ayrık Dalgacık Dönüşümü
<b>GA</b>	Genetik Algoritma
<b>GCH</b>	Global Color Histogram-Global Renk Histogramı
<b>GLCM</b>	Gray Level Co-occurrence Matrix-Gri Seviye Eş Oluşum Matrisi
<b>HSI</b>	Hue, Saturation, Intensity-Renk Özü, Doymunluk Yoğunluk
<b>HSV</b>	Hue, Saturation, Value-Renk Özü, Doymunluk Değer
<b>ITGE</b>	İçerik Tabanlı Görüntü Erişimi
<b>LBP</b>	Local Binary Pattern-Yerel İkili Örüntü
<b>LCH</b>	Local Color Histogram-Yerel Renk Histogramı
<b>LMEBP</b>	Local Maximum Edge Binary Pattern-Yerel Maksimum Kenar İkili Örüntü



**Kısaltmalar****Açıklamalar****LOCSEP**

Local Opposite Color Space Extrema Pattern-Yerel Karşıt Renk Uzayı Ekstremum Örüntü

**LQP**

Local Quantized Pattern-Yerel Nicelenmiş Örüntü

**LTP**

Local Tetra Pattern-Yerel Dörtlü Örüntü

**MTGE**

Metin Tabanlı Görüntü Erişimi

**RGB**

Red, Green, Blue-Kırmızı, Yeşil, Mavi

**SCD**

Scale Color Descriptor-Ölçeklenebilir Renk Tanımlayıcı

**WT**


Wavelet Transform-Dalgacık Dönüşümü



## 1. GİRİŞ

Son yıllarda teknolojinin hızla gelişmesiyle sayısal görüntü sağlayan araçlar artmaktadır. Bu araçlar vasıtasıyla her gün büyük sayıda sayısal veri üretilmekte ve saklanmaktadır. Sadece kişisel cihazlardan her gün gigabaytlarca sayısal görüntü üretilmektedir. Büyük miktarda oluşan bu verilerin etkin ve hızlı bir şekilde saklanması ve yönetilmesi her geçen gün zorlaşmaktadır. Bilgisayar ve İnternet gibi donanım ve yazılım alanındaki gelişmeler büyük miktardaki verilere ulaşmamızı kolaylaştırırken, bu veriler arasından istenilen veriyi bulmak her geçen gün zorlaşmaktadır. Bu amaçla görüntü arama, tarama ve erişim sistemlerine ihtiyaç duyulmuştur. Doğru veriye hızlı ulaşma isteği bu alanda yapılan çalışmaları arttırmıştır. Bu çalışmalar kapsamında metin tabanlı görüntü erişim (MTGE) sistemleri ve içerik tabanlı görüntü erişim (İTGE) sistemleri geliştirilmiştir.

MTGE sistemlerinin temeli 1970' lere dayanmaktadır. MTGE sistemlerinde görüntüler saklanmadan önce her birine etiket tanımlanır. Görüntülere erişilmek istenildiğinde bu etiketler vasıtasıyla arama yapılır. Resim 1.1' deki görüntüde *Deniz*, *Dağ*, *Yat*, *İnsan* ve *Gökyüzü* içeriğine sahip olduğundan dolayı veri tabanına bu etiketler ile saklanır. Kullanıcı *Deniz* içeriğine sahip görüntülere ulaşmak istediğinde *Deniz* etiketine sahip olan görüntülere ulaşacaktır [1].



Resim 1.1. Görüntü etiketleme

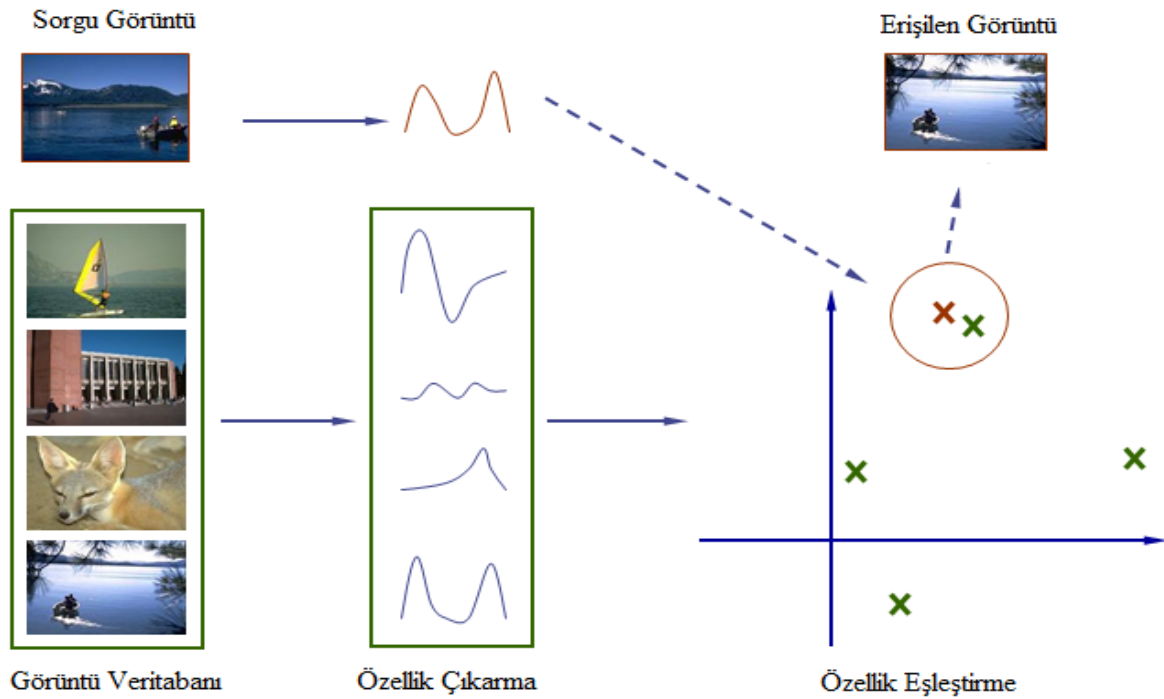
MTGE sisteminin birçok olumsuz yönü vardır. Bunlardan biri ve en önemlisi etiketleme işlemi elle yapıldığı için büyük bir insan işçiliği gerektirmektedir. Her gün üretilen görüntülerin hepsinin etiketlenmesi oldukça zordur. İkincisi, etiketlerin ismi insandan insana farklılık göstermektedir. Her insan bir nesneyi farklı bir şekilde yorumlayabilir. Üçüncüsü, kelimelerin eş ve çok anlam taşımalarıdır. Dördüncüsü ise etiketler girilirken yapılan yazım

yanlırları MTGE sistemleri için büyük problem oluşturmaktadır. Son olarak çok dillilik de bir başka problemdir [1].

Bu olumsuzlukları gidermek için 1980' llerde İTGE yaklaşımı ortaya çıkmıştır. Bu yaklaşımda etiketleme yerine görüntünün renk, doku ve şekil gibi görsel özellikleri kullanılır. Bu yaklaşımdan sonra bu alanda birçok çalışma yapılmıştır. QBIC [2] bu alanda ticari amaçla yapılan ilk İTGE sistemidir. QBIC görüntülerin görsel özelliklerini kullanarak büyük görüntü veritabanından sorgu görüntüsüyle ilişkili olan görüntüleri getirmeyi amaçlamaktadır. Photobook [3], VisualSeek [4], Netra [5], SIMPLiCITY [6] bu alanda geliştirilen diğer İTGE sistemlerindedir.

### İTGE sisteminin yapısı

İTGE sistemi özellik çıkarımı ve özellik eşleştirme olmak üzere iki temel aşamadan oluşur (Şekil 1.1). Özellik çıkarım aşamasında görüntülerin renk, doku, şekil gibi düşük seviyeli özellikleri çıkarılır. Veritabanında görüntüler çıkarılan bu özellikleri ile saklanır. Özellik eşleştirme aşamasında sorgu görüntü ile veritabanındaki görüntülerin özellik vektörleri kıyas edilir ve uzaklık mesafesi yakın olan görüntülerin erişimi sağlanır.



Şekil 1.1. İTGE sistemi aşamaları

## Özellik çıkarımı

Özellik çıkarımında görüntüyü olduğunca az tanımlayıcı ile tanımlamak İTGE sistemlerinin en önemli adımıdır. Tanımlayıcılar görüntüyü karakterize eden renk, şekil, doku, çizgi gibi özelliklerdir. Bu tanımlayıcılar ile görüntünün içeriği hakkında bilgi edinilir ve benzer içeriğe sahip görüntülerin erişimi sağlanır.

Özellik çıkarımında kullanılan birçok tanımlayıcı vardır. Fakat önemli olan hangi tanımlayıcıların seçileceğidir. Tanımlayıcılar ne kadar uygun seçilirse, görüntünün içeriği o kadar iyi tanımlanır. Renk, doku ve şekil özellik çıkarımında kullanılan bazı özelliklerdir. Renk özelliği bazı görüntüleri iyi bir şekilde tanımlarken, yüzey özelliği olan görüntülerde doku özelliğini kullanmak gerekir. Görüntüler çok zengin içeriğe sahip olduklarından dolayı tek özellik görüntüleri tanımlamada yeterli olmamaktadır. Birden fazla özellik kullanılarak görüntünün içeriği hakkında daha detaylı bilgiye sahip olunur. Örneğin kelebek görüntülerinin olduğu büyük bir veritabanında benzer kelebeklerin erişileceği bir sistemde renk ve doku özelliğinin beraber kullanılması başarı oranını arttıracaktır. Çünkü kelebekler için renk önemli olmasına rağmen tek başına yeterli değildir. Renk kadar doku özelliğine de ihtiyaç vardır.

## Renk özelliği

Renk İTGE sistemlerinde kullanılan en önemli ve en yaygın özelliklerden biridir. Çünkü görüntülerin renk özelliği belli bir kararlılığa sahiptir ve gürültü, görüntü boyutu, yönü ve çözünürlük değişiminde güçlü bir sağlamlık gösterirler. Görüntülerin renk özelliğini çıkarmadan önce öncelikle uygun renk uzayı ve tanımlayıcı belirlenir.

## Renk uzayı

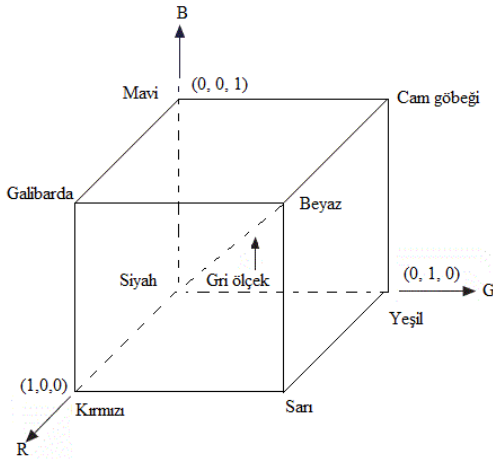
Renk uzayının amacı belli standartlar ile renk tanımlamasını yapmaktır. Genelde renk üç-boyutlu renk uzaylarında tanımlanır ve her bir boyut renk bileşenini ifade eder. Farklı amaçlarla görüntüleri tanımlamada birçok renk uzayı kullanılmıştır. Yaygın olarak kullanılan belli başlı renk uzayları RGB (Red, Green, Blue- Kırmızı, Yeşil Mavi), HSV (Hue, Saturation, Value- Renk özü, Doygunluk, Parlaklık), HSI (Hue, Saturation, Intensity- Renk özü, Doygunluk, Yoğunluk), CMY (Cyan, Magenta, Yellow- Camgöbeği, Galibarda,

Sarı) ve CMYK (Cyan, Magenta, Yellow, Key- Camgöbeği, Galibarda, Sarı, Siyah)' tır. Renkli videolar için RGB; renkli baskı için CMY ve CMYK; ve insan gözünün rengi tarif etmesine yakın olan HSV renk uzayı kullanılmıştır [7].

Çalışmada RGB ve HSV renk uzayları tercih edilmiştir. Çünkü RGB renk uzayı sayısal görüntüleri tanımlamada iyi sonuç vermektedir. RGB' nin iyi sonuç vermediği durumlarda ise HSV renk uzayı kullanılmıştır.

### RGB renk uzayı

RGB renk uzayı İTGE sistemlerinde en çok kullanılan renk uzaylarından biridir. Bu model kartezyan koordinat sistemine dayanır (Şekil 1.2). Küpün üç köşesinde ana renkler diğer üç köşesinde ise ara renkler bulunur. Siyah rengi merkezde ve beyaz rengi siyaha en uzak noktada bulunur. İki arasında mesafede gri ölçekli renkler bulunur. RGB görüntüler kırmızı, yeşil ve mavi bileşenlerinin görüntülerinden oluşur. RGB renk uzayında her bir piksel 8 bit ile ifade edilir. Her bir R, G, ve B bileşen görüntüsü için 8 bit görüntü olduğu için toplamda RGB görüntüsü 24 bit ile ifade edilir. RGB görüntü için renk sayısı  $(2^8)^3 = 16,777,216$ ' dır [7].




Şekil 1.2. RGB renk küpü

### HSV renk uzayı

HSV renk uzayı İTGE sistemlerinde yaygın olarak kullanılan renk uzaylarından biridir. HSV renk uzayının bileşenleri renk tonu, doygunluk ve parlaklık' tır. Renk tonu rengi (saf sarı,

kırmızı, mavi) diğer renklerden ayırt eden özelliktir. Bu ayırım rengin çeşidine veya tonuna göre yapılır. Açısal bir değerdir ve  $0^\circ$  ile  $360^\circ$  arasında bir değer alır. Doygunluk rengin beyaz ışık tarafından ne derece açıldığıнын ölçüsünü verir. Başka bir deyişle rengin canlılığını gösterir. 0 ile 1 arasında değer alır. Parlaklık ise rengin aydınlığını gösterir ve açık bir rengi koyu bir renkten ayırt etmede kullanılır ve rengi tarif etmede anahtar faktörlerden biridir. 0 ile 1 arasında değer alır. HSV renk uzayının şekli altıgen konidir (Şekil 1.3) [8].



Şekil 1.3. HSV renk uzayı

### Renk özellik çıkarım yöntemleri

Renk histogramı ve renk momenti renk özellik çıkarımında kullanılan en yaygın yöntemlerdir. Renk histogramı görüntünün renk dağılımını verirken; renk momenti renk dağılımının istatistiksel özelliklerini verir. Renk özellik çıkarımında kullanılan bir başka yöntem ise CCV (Color Coherence Vektor-Renk Uyum Vektörü)' dir. Bu yöntem renk histogramının gelişmiş halidir. Renk histogramından farkı renklerin bağlı bileşenler oluşturup oluşturmadığını bakar. Yapılmış çalışmalarda renk özellik çıkarımı için bu yöntemlerden başka birçok yöntem kullanılmıştır. Bu yöntemler Bölüm 2' de anlatılmıştır.

Çalışmada renk özellik çıkarım için renk histogramı, renk momenti ve CCV yöntemlerinin görüntü erişimindeki performansı incelenmiştir. Bu yöntemler ayrıntılı olarak Bölüm 3' de anlatılmıştır.

### Doku özelliđi

Doku konumsal düzlem üzerindeki tekrar eden piksellerin oluşturduđu desen olarak düşünülebilir. Doku için herhangi bir tanım yapmak zordur. Ancak doku tanımı çeşitli doku analiz yöntemleri ile yapılabilir. Örneđin bir yüzeyin dokusuna bakıldığında kaba, düzenli, düzensiz, pürüzlü, pürüzsüz, yönlü ve yönsüz gibi özelliklerle tanımlanır. Fakat bazı durumlarda bu tanımlama o kadar kolay olmaz.

Görüntünün doku özelliklerini tanımlamak için üç yaklaşım vardır. Bunlar istatistiksel, model tabanlı ve dönüşüm tabanlı yaklaşımlardır [9]. İstatistiksel yaklaşımlar ortalama, standart sapma, üçüncü moment, düzgünlük, kabalık, tanecik gibi görüntünün dokusunun karakteristiđini verir. Biçimsel yaklaşımlar, görüntünün ana düzeni hakkında bilgi verir. Spektral yaklaşımlar ise görüntüdeki global periyodiklikleri tanımlamak için kullanılır [7]. Yapılmış çalışmalarda kullanılan doku özellik çıkarım yöntemleri Bölüm 2' de anlatılmıştır.

Çalışmada istatistiksel yaklaşımlardan GLCM (Gray Level Co-Occurance Matrix – Gri Seviye Eş Oluşum Matrisi) yöntemi ve dönüşüm tabanlı yaklaşımlardan dalgacık dönüşümü doku özellik çıkarımı için kullanılmıştır. Bu yöntemler ayrıntılı olarak Bölüm 3' de anlatılmıştır.

### Şekil özelliđi

Şekil görüntü erişiminde kullanılan güçlü özelliklerden biridir. Şekil tanımlayıcılarını basit olarak sınır ve bölge bazlı olarak iki gruba ayrılabilir. Fourier tanımlayıcıları ve istatistiksel momentler sınır bazlı tanımlayıcılara örnektir. Topolojik tanımlayıcılar ise bölge bazlı tanımlayıcılara örnektir [7]. Yapılmış çalışmalarda kullanılan şekil özellik çıkarım yöntemleri Bölüm 2' de anlatılmıştır.

Çalışmada mevcut İTGE sistemlerinin başarımlarını arttırmak için yukarıda anlatılan renk ve doku özellik çıkarım yöntemlerini beraber kullanarak yeni bir İTGE yöntemi önerilmiştir. Sistemin performansını arttırmak için birden fazla yöntemin birleştirilmesi yapılmıştır. Her özelliđe eşit ağırlıklar atanarak yapılmış birleştirme işleminin iyi sonuçlar vermediđi görülmüştür. Bu problemi çözmek için genetik algoritma (GA) ile özellikler ağırlıklandırılmıştır.



## 2. İÇERİK TABANLI GÖRÜNTÜ ERİŞİMİ ALANINDA YAPILMIŞ ÇALIŞMALAR

Renk özellik çıkarımı için yapılmış çalışmalarda birçok yöntem görülmektedir. Renk histogramı, değişmez renk histogramı, renk momenti, dominant renk, korelogram ve CCV yöntemleri bu alanda en yaygın kullanılan yöntemlerden bazılarıdır.

Swain ve Ballard renk histogramının dizinleme için güçlü ve etkin bir yöntem olduğunu yapmış olduğu çalışmalarında göstermiştir [10]. Renk histogramı görüntüdeki renk dağılımını temsil eder. Zhang ve Lin çalışmalarında renk histogramını kullanarak görüntüdeki renk bilgisini elde etmiştir [11]. Alata ve arkadaşları üç boyutlu renk histogramını üç farklı renk uzayında kullanmıştır [12].

Renk histogramı İTGE sistemlerinde en yaygın kullanılan yöntemlerden biridir. Renk histogramı global ve yerel renk histogramı olarak iki gruba ayrılabilir. GCH (Global Color Histogram-Global renk histogramı) görüntüdeki aynı renkteki piksellerin sayısını verir. Hesaplaması kolay ve hızlıdır. Görüntünün dönmesine ve ölçeklenmesine karşı güçlüdür. Fakat görüntüdeki yerel ayrıntıları fark etmede yetersizdir. Bu yüzden bu sorunu gidermek için LCH (Local Color Histogram-Yerel Renk Histogramı) geliştirilmiştir. LCH' nin temel mantığında görüntüler bloklara ayrılır ve her bloğun GCH' si hesaplanır. LCH' de görüntüler arası benzerlik hesaplanırken aynı konumdaki tüm blokların birbiriyle olan uzaklıkları hesap edilir ve tüm uzaklıklar toplanır. Bu yöntem ise GCH' nin aksine görüntünün dönmesi, ölçeklenmesi veya ötelenmesi gibi durumlarda etkili değildir [13].

Bu olumsuzluğu gidermek için Wang, LCH yöntemini güçlendirmiştir. Yönteminde görüntüleri bloklara ayırmış ve sorgu görüntüdeki her bir bloğu hedef görüntüdeki tüm bloklarla karşılaştırmıştır. Görüntüler arasındaki minimum uzaklığı hesaplamıştır. Fakat bu yöntemin olumsuzluğu ise çok fazla hesaplama zamanı gerektirmesidir [14].

Stehling ve arkadaşları LCH' deki olumsuzlukları gidermek için CCH (Cell Color Histogram-Hücre Renk Histogramı) yöntemini geliştirmiştir [15]. Bu yöntemle görüntüyü hücrelere ayırmış ve nicelenmiş hücrelerin renk histogramını hesaplamıştır.

Manjunanth ve arkadaşları rengi tanımlamak için birçok yöntem geliştirmiştir. Bu yöntemleri SCD (Scable Color Descriptor- Ölçeklenebilir Renk Tanımlayıcısı), CSD (Color Structure Descriptor-Renk Yapısı Tanımlayıcısı, DCD (Dominant Color Descriptor- Baskın Renk Tanımlayıcısı) ve CLD (Color Layout Descriptor-Renk Düzeni Tanımlayıcısı) olarak adlandırmıştır. SCD renk histogramıdır. CLD renk dağılımının konumsal bilgisini verir. CSD görüntüdeki yerel renk özellikleri verir [16].

Liu ve arkadaşları görüntüdeki baskın rengi ayırt etmiştir. Bunu yaparken öncelikle görüntüyü bloklara ayırıp her bir bloktaki ortalama rengi hesap etmiştir. Elde edilen bloklardaki ortalama renk gerçek görüntüden farklı olabilir. Görüntüden baskın rengi elde etmek için öncelikle blokların histogramını hesap etmişler ve maksimum büyüklüğe sahip renk değeri baskın renk olarak kabul edilmiştir [17]. Fakat bu yöntemde bloklara ayrılan görüntülerin ortalama renkleri doğrusallık göstermezse, ortalama renk iyi bir seçim olamayacaktır.

Stricker ve Orengo görüntünün renk dağılımından moment değerlerini hesaplamışlar ve bu dağılım momentlerini görüntü erişiminde kullanmıştır [18]. Singh ve Hemachandran renk histogramı ve renk momenti yöntemini birleştirerek bir İTGE sistemi tasarlamıştır [19].

Satyawati ve arkadaşları CCV yöntemini kullanarak görüntülerin renk özelliklerini çıkarmıştır. Bu yöntem görüntüdeki aynı renkte olan piksellerin büyük bileşenler oluşturup oluşturmadığıyla ilgilenir [20]. Salmi ve Boucheham görüntüleri hücrelere bölerek her bir hücrenin CCV' sini hesaplamıştır. Bu yöntemini Hücre-CCV olarak adlandırmıştır [13]. Ravani ve arkadaşları paralel algoritma kullanarak CCV olarak adlandırdıkları yöntemi kullanarak bir erişim sistemi oluşturmuştur. Bu yöntemle standart CCV' nin başarımını arttırmıştır [21]. Al-Hamami ve Al-Rashdan renk uyum bölgelerine dayalı CCV yöntemini geliştirmiştir. Bu yöntem renk uyum bölgelerinin uzaklığına ve açısına bağlı olarak hesaplanır. Bu yöntemin standart CCV' den avantajı mekan bilgisini ve uyumlu bölge sayısını tutmasıdır [22].

LBP (Local Binary Pattern-Yerel İkili Örüntü) yöntemi görüntülerin doku özelliklerini tanımlamada kullanılan özellik çıkarım yöntemidir. İlk olarak 1994 yılında Ojala ve arkadaşları tarafından önerilmiştir [23]. LBP yöntemi yapılmış çalışmalarda görüntülerin doku analizi, yüz tanıma, nesne takibi, görüntü erişimi ve parmak izi tanıma olmak üzeri

birçok alanda kullanılmıştır [24]. Ahonen ve arkadaşları LBP kullanarak yüz tanımaya çalışmıştır [25]. LBP ve versiyonları dokunun sabit olmadığı görüntülerde ve aydınlatma, poz açısı, yüz ifadesi gibi durumlara bağlı olarak yeteri kadar başarılı olmadığı için bu yöntemi güçlendirmek için LTP (Local Triple Pattern-Yerel Üçlü Örüntü) yöntemini geliştirilmiştir [26]. Bu yöntem ile farklı aydınlanma koşulları altında yüz tanımlaması yapılmıştır.

Takala ve arkadaşları blok tabanlı LBP yöntemi önermiştir [27]. Bu yöntemle görüntüleri bloklara ayırarak her bir bloğun LBP dağılımını hesap etmiştir. Heikkila ve arkadaşları her bir pikseli merkez piksel ile karşılaştırma yerine piksellerin merkez simetrik çiftlerini kıyas etmiştir. Bu yöntemi CS-LBP (Center Symetric Local Binary Pattern – Merkez Simetrik Yerel İkili Örüntü) olarak adlandırmıştır [28]. Hussain ve Trigges görsel tanıma için LQP (Local Quantized Pattern-Yerel Nicelenmiş Örüntü) yöntemini tanımlamıştır [29]. LQP ile görüntülerin yatay, dikey, diyagonal ve diyagonal karşıtı olmak üzere görüntünün yönlü geometrik özellik bilgilerini elde etmiştir.

Subrahmanyam ve arkadaşları DLEP (Directional Local Extrema Pattern-Yönlü Yerel Ekstreum Örüntü) yöntemini tanımlamıştır. DLEP, gri seviyeli merkez pikselin yerel ekstremumlarını kullanarak yerel dokunun konumsal yapısını tanımlar [30]. Aynı zamanda LMEBP (Local Maximum Edge Binary Pattern-Terel Maksimum Kenar İkili Örüntü) [31] ve LTrP (Local Tetra Pattern-Yerel Dörtlü Örüntü) [32] yöntemlerini doku görüntü erişiminde kullanmıştır. Hariprasad ve Subhash görüntü erişimi için LOCSEP (Local Opposite Color Space Extrema Pattern-Yerel Karşı Renk Uzayı Ekstreum Örüntüsü) yöntemini geliştirmiştir. Bu yöntem DLEP ile görüntüdeki yönlü yerel ekstremum noktalarını hesaplayarak renk ve doku özelliklerini birleştirir [33]. Koteswara ve Venkata LQEP (Local Quantized Extrema Pattern-Yerel Nicelenmiş Ekstreum Örüntü) olarak adlandırdıkları yöntemi görüntü erişiminde kullanmıştır [24]. Bu yöntemle LQP ile merkez piksel ile komşuluklarındaki piksellerin arasındaki yönlü ilişkiyi hesaplamış ve DLEP ile verilen merkez piksel için yerel ekstremumlarını hesap etmiştir.

Haralick ve arkadaşları doku özelliklerini çıkarmak için GLCM yöntemini tanımlamıştır. GLCM'yi oluşturduktan sonra bu matris üzerinden çeşitli doku analizleri yapmıştır. [34]. Viminia ve Jacob renk özelliği için görüntüleri bloklara ayırıp renk histogramını

hesaplamıştır ve doku özelliklerini hesaplamak için GLCM yöntemini kullanmıştır. Bu iki yöntemi birleştirerek yeni bir yöntem geliştirmiştir [35].

Tamura ve arkadaşları doku analizi için 6 farklı özellik tanımlamıştır. Bu özellikler kabalık, zıtlık, yönlülük, benzerlik, düzenlilik ve pürüzlülüktür [36]. Puviarasan ve arkadaşları şekil ve doku özelliklerini beraber kullanarak yeni bir erişim yöntemi geliştirmiştir. Doku özellikleri için Tamura özelliklerinden kabalık, zıtlık ve yönlülük ve Haralick özelliklerinden kontrast, enerji, entropi, korelasyon ve homojenlik özelliklerini kullanmıştır. Şekil özellikleri için moment değişmezlerini kullanmıştır [37].

WT (Wavelet Transform-Dalgacık Dönüşümü), Fourier dönüşümünün geliştirilmiş bir versiyonu olan bir fonksiyondur. WT görüntü erişiminde kullanılan önemli yöntemlerden biridir. WT ile görüntü farklı çözünürlüklere ve boyutlara getirilerek doku bilgisi elde edilir.

Verma ve arkadaşları yön tabanlı özellik tanımlayıcıları önermiştir. Bu yöntemle görüntülere DWT (Discrete Wavelet Transform-Ayrık Dalgacık Dönüşümü) uygulayarak görüntüleri alt bantlara ayırmıştır. Bu alt bant görüntülere DLEP yöntemini uygulayarak yöne bağlı özellikler çıkarılmıştır [38]. Dalavi ve arkadaşları daubechies dalgacık dönüşümünü kullanarak görüntü dizinleme ve erişim için bir yöntem geliştirmiştir [39]. Giveki ve arkadaşları farklı renk uzayındaki görüntüleri WT ile alt bantlara ayırmıştır. Farklı çözünürlüklere indirgenen görüntüler üzerinden birinci, ikinci ve üçüncü sıra moment hesaplaması yapılarak görüntü erişimi sağlanmıştır [40]. Arai ve Rahmad görüntüye dalgacık dönüşümü uygulayarak 4 farklı alt görüntü elde etmiştir. Bu alt görüntüler üzerinden birinci ve ikinci sıra moment hesaplaması yaparak görüntünün doku özellik vektörlerini çıkarmıştır. Bu vektörleri de görüntü erişiminde kullanmıştır [41]. Gonde ve arkadaşları karmaşık dalgacık dönüşümü ile görüntülerin yönlü detay bilgilerini elde etmiştir [42].

Thakkar ve arkadaşları görüntüden renk özelliklerini çıkarmak için renk momentini hesaplamıştır. Doku özellikleri çıkarmadan önce görüntüye ranklet dönüşümünü uygulamıştır. Bu işlem sonucu yatay, dikey ve diyagonal olmak üzere üç farklı ranklet görüntüleri elde etmiştir. Bu görüntüler üzerinden ranklet histogramı ve ranklet GLCM' yi hesaplayarak doku analizi yapmıştır. Şekil özelliklerini çıkarmak için hough dönüşümünü kullanmıştır [43]. Afifi ve Ashour tasarlamış oldukları İTGE sisteminde renk özelliği için

renk momentini, doku özelliği için ranklet dönüşümü yapılan görüntülerde doku momentlerini hesap edip bu iki özelliği birleştirmiştir [44].

Gabor filtreleri görüntü erişimi alanında çokça kullanılmaktadır. Gabor filtreleri görüntüdeki gürültüye karşı güçlüdür. Görüntüdeki fazlalıkları azaltmada da etkin bir yöntemdir. Gabor filtreleri görüntünün farklı bölgelerine uygulanabilir. Böylelikle farklı açılar, frekanslar ve yönelimlerde farklı gabor değerleri elde edilir. Irtaza ve arkadaşları gabor filtrelerini görüntü erişiminde kullanmıştır [45]. Singh ve Hemachandran görüntüye 4 ölçekte ve 6 yönde 24 farklı gabor filtresi uygulamış ve her biri için ortalama ve standart sapma momentlerini hesap etmiştir. Oluşturdukları bu özellik vektörü ile görüntü erişimi gerçekleştirmiştir [46].

Malik ve Baharudin yaptıkları çalışmada görüntüleri bloklara ayırmıştır. Her bir bloğa DCT (Discrete Cosine Transform – Ayrık Kosinüs Dönüşümü) yöntemini uygulamıştır. Elde ettikleri katsayıları yedi farklı istatistiksel doku özelliği hesap etmişlerdir [47].

Kenar tespit etme yöntemi görüntünün geneli hakkında temel bilgi vermektedir. Görüntülerdeki kenar bilgisi canny, sobel gibi kenar tespit etme algoritmaları ile bulunabilir. Thepade ve Shinde yapmış oldukları çalışmalarında sobel, canny, prewitt, laplacian ve Frei-Chen kenar tespit algoritmalarını kullanarak görüntülerin şekil özellik vektörlerini çıkarmıştır [48].

Bölgesel tabanlı şekil tanımlayıcılar arasında moment yaklaşımının kullanımı çok yaygındır. Değişmez momentleri, Zernike momentleri ve Legendre momentleri bölgesel tabanlı tanımlayıcılara örnektir.

Değişmez momentleri belirli dönüşüm sınıflarında değişmezler elde etme için kullanılır. Bu değişmezler çevirme, döndürme ve ölçeklemeden etkilenmezler. Chaudhry ve arkadaşları değişmez momentleri kullanarak insan aktivitelerini tanıyan bir sistem geliştirmiştir [49].

Nugroho ve Utomo şekil tanımlaması için Zernike momentlerini kullanmıştır. Zernike momentleri de değişmez momentler gibi çevirme, ölçekleme ve döndürmeden etkilenmezler. Ayrıca bu momentler görüntüdeki gürültü ve şekil bozukluğu gibi durumlarda da güçlüdür. Fakat hesaplama zamanı yüksektir [50].

Rao ve arkadaşları Legendre momentlerini kullanarak bir İTGE sistemi tasarlamıştır. Legendre momentleri çekirdek fonsiyon olarak Legendre polinomlarını kullanır [51].

Tajeripour ve arkadaşları görüntü erişimi için şekil özelliği için üst şapka dönüşümünü ve doku özelliği için LBP yöntemini kullanmıştır. Üst şapka yöntemi ile görüntüdeki küçük ayrıntıları tespit etmiştir. Şekli tespit edilen nesnenin üzerine LBP yöntemini uygulayarak görüntü erişimini sağlamıştır [52].



### 3. ÖNERİLEN YÖNTEM


Bu çalışmada beş farklı görüntü erişim yöntemi kullanılarak görüntülerin renk ve doku özellikleri çıkarıldı. Bu yöntemler sonucunda oluşan özellik vektörlerinin birlikte kullanılabilmesi için özellik vektörleri aynı değer aralığına normalize edildi. Normalize edilen özellik vektörlerinin benzerlik ölçümünü yapmak için çeşitli benzerlik metrikleri kullanıldı. Bu aşamadan sonra tüm özellik vektörleri birleştirildi. Başarım oranını arttırmak için genetik algoritma kullanarak yöntemlerin ağırlıklandırılması yapıldı.

#### 3.1. Renk Özellik Çıkarımı

Bu çalışmada görüntülerin renk özelliklerini çıkarmak için üç farklı renk özellik çıkarım yöntemi kullanıldı. Bu yöntemler renk histogramı, renk momenti ve CCV yöntemleridir.

##### 3.1.1. Renk histogramı

Görüntünün renk histogramını hesaplamak üç aşamadan oluşur. İlk olarak uygun bir renk uzayı seçilir ve görüntüler seçilen renk uzayına dönüştürülür. İkinci olarak dönüştürülen renk uzayı nicelenir. En son aşamada görüntünün renk histogramı hesaplanır (Şekil 3.1).



Şekil 3.1. Renk histogramı hesaplama aşamaları

##### Renk uzayı dönüşümü

Renk özellik çıkarımında temel olan en doğru renk uzayını seçebilmektir. Renk uzayı renkleri ifade eden matematiksel ifadelerdir. Renk uzayları başka bir renk uzayına doğrusal veya doğrusal olmayan yöntemlerle dönüştürülebilir [8].

RGB renkli görüntü üretmek için ideal olsa da, insan açısından renkleri tanımlamak için uygun değildir. Örneğin renkli bir nesnenin rengini tanımlarken bu rengi oluşturan ana renklerin yüzdesi verilmez. Renk tonu, doygunluk ve parlaklık ile ifade edilir. Bu yüzden bu çalışmada insanlar için, doğal ve sezgisel olan renk tariflerine dayalı olan HSV renk uzayı kullanıldı [7].

Bu çalışmada RGB renk uzayına sahip görüntüler doğrusal olmayan dönüşümle HSV renk uzayına dönüştürüldü. Her RGB pikselinin renk tonu bileşeni Eş. 3.1 kullanılarak elde edilir.

$$H = \cos^{-1} \frac{(0.5x(R - G) + (R - B))}{\sqrt{((R - G)^2 + (R - B)(G - B))}} \quad (3.1)$$

Burada H renk tonu değerini, R kırmızı bileşen değerini; G yeşil bileşen değerini ve B ise mavi bileşen değerini göstermektedir. Doygunluk bileşeni Eş. 3.2 kullanılarak elde edilir.

$$S = 1 - \left( \frac{3 \times \min(R, G, B)}{(R + G + B)} \right) \quad (3.2)$$

Burada S doygunluk değerini gösterir. Son olarak parlaklık bileşeni Eş. 3.3 kullanılarak elde edilir.

$$V = \frac{R+G+B}{3} \quad (3.3)$$

Burada V parlaklık değerini gösterir [53].

### Renk niceleme

H,S ve V bileşeninin değer aralığı geniş olmasından dolayı, gerçek HSV renk değerlerinden özellik çıkarımı yüksek hesaplama zamanı gerektirir. İnsan gözünün farklı renkleri ayırt etme yeteneği sınırlı olduğu için tüm farklı renkleri özellik çıkarımında kullanılmasına gerek yoktur. Bu yüzden görüntüdeki farklı renk sayısı insan gözünün algılayabileceği bir değere nicelenirse hem hesaplama zamanı azalacak hem de bellekten tasarruf edilmiş olacaktır. Bu çalışmada HSV renk uzayına sahip görüntüler için HSV (8, 2, 2), HSV (8, 3, 3), HSV (10,



4, 4) ve HSV (16, 4, 4) olmak üzere dört farklı nicelme test edildi. Görüntü erişiminde HSV (10, 4, 4) ve HSV (16, 4, 4) ile nicelenen görüntülerin renk histogramları benzer ve iyi sonuç verdiği için önerilen İTGE yönteminde bu iki yöntem ayrı ayrı test edildi. Eş. 3.4, Eş. 3.5 ve Eş. 3.6 ile H=8, S=3 ve V=3 değerlerine ait nicelmenin nasıl yapıldığını göstermektedir [54].

$$H = \begin{cases} 0 & \text{Eğer} & h \in [0,45] \\ 1 & \text{Eğer} & h \in [46,90] \\ 2 & \text{Eğer} & h \in [91,135] \\ 3 & \text{Eğer} & h \in [136,180] \\ 4 & \text{Eğer} & h \in [181,225] \\ 5 & \text{Eğer} & h \in [226,270] \\ 6 & \text{Eğer} & h \in [271,315] \\ 7 & \text{Eğer} & h \in [316,360] \end{cases} \quad (3.4)$$

$$S = \begin{cases} 0 & \text{Eğer} & h \in [0,0.3] \\ 1 & \text{Eğer} & h \in [0.3,0.7] \\ 2 & \text{Eğer} & h \in [0.7,1] \end{cases} \quad (3.5)$$

$$V = \begin{cases} 0 & \text{Eğer} & h \in [0,0.3] \\ 1 & \text{Eğer} & h \in [0.3,0.7] \\ 2 & \text{Eğer} & h \in [0.7,1] \end{cases} \quad (3.6)$$

### Renk histogramı hesaplama

Renk histogramı görüntüdeki renklerin dağılımını gösterir.  $[0,L-1]$  yeğinlik seviyesi aralığına sahip bir görüntünün histogramı Eş. 3.7 ile gösterilen ayrık bir fonksiyondur.

$$h(r_k) = n_k \quad (3.7)$$

Burada  $r_k$ , görüntüdeki k. yeğinlik değerine sahip piksellerin sayısıdır [7].

Bir görüntünün renk histogramı Eş. 3.8 ile gösterilir. Bu çalışmada HSV (8, 2, 2), HSV (8, 3, 3), HSV (10, 4, 4) ve HSV (16, 4, 4) renk uzayına nicelenen görüntülerin renk histogramları test edildiği için her bir görüntü için sırasıyla bir-boyutlu 32, 72, 160 ve 256 büyüklüğünde vektörler elde edildi.

$$h = \{h[r0], h[r1], \dots, h[rk], \dots, h[rL - 1]\} \quad (3.8)$$

### 3.1.2. Renk momenti

Renk momenti İTGE sitemlerinde çokça kullanılmakta ve görüntüler arasındaki benzerlik hakkında bilgi vermektedir. Görüntünün renk kompozisyonu olasılık teorisi anlamında bir renk dağılımı olarak görülebilir. Olasılık teorisiyle, görüntünün olasılık dağılımı momentler ile karakterize edilebilir. Eğer bir görüntünün renk dağılımını olasılık dağılımı olarak yorumlanırsa, momentler renk dağılımını karakterize etmek için kullanılabilir. Görüntüdeki bir renk belirli bir olasılık dağılımını izliyorsa, bu dağılım momentleri resmi tanımlamada bir özellik olarak kullanılır [18].

M. A. Stricker ve M. Orengo (1990) tarafından yapılmış çalışmada görüntünün renk dağılımından özellik çıkarımı için üç merkezi momenti kullanmıştır. Bunlar ortalama, standart sapma ve çarpıklık'tır. Ortalama, görüntünün ortalama renk değeridir. Standart sapma renk dağılımının varyansının kareködür. Çarpıklık ise asimetrik dağılımın nasıl olduğunu ölçer ve görüntünün şekli hakkında bilgi verir [18].

Eğer  $p_{ij}$   $i$ . renk kanalında  $j$ . pikseli ise ortalama Eş. 3.9 kullanılarak elde edilir.

$$E_{r,i} = \frac{1}{N} \sum_{j=1}^N p_{ij} \quad (3.9)$$

Bu eşitlikte  $E$  ortalama değeri,  $r$  görüntünün bölgesini ve  $N$  toplam piksel sayısını gösterir. Standart sapma Eş. 3.10 kullanılarak elde edilir.

$$\sigma_{r,i} = \left( \frac{1}{N} \sum_{j=1}^N (p_{ij} - E_i)^2 \right)^{\frac{1}{2}} \quad (3.10)$$

Bu eşitlikte  $\sigma$  standart sapma değerini gösterir. Çarpıklık Eş. 3.11 kullanılarak elde edilir

$$s_{r,i} = \left( \frac{1}{N} \sum_{j=1}^N (p_{ij} - E_i)^3 \right)^{\frac{1}{3}} \quad (3.11)$$

Burada  $s$  görüntünün çarpıklık değerini göstermektedir [55,56].



Resim 3.1. (a) Tüm görüntü (b) Yatay olarak üç parçaya bölünmüş görüntü (c) Dikey olarak üç parçaya bölünmüş görüntü

Bu çalışmada Resim 3.1' deki gibi gösterilen bir görüntünün RGB ve HSV renk uzaylarındaki renk momentleri test edildi. Tüm görüntü için renk momenti özellik vektörü (RMT) çıkarılırken her bir R, G, B ve H, S, V kanalı için ayrı ayrı moment hesaplaması yapıldı. Her bir renk kanalı için ortalama, standart sapma ve çarpıklık olmak üzere üç merkezi moment hesaplandığından dolayı RGB ve HSV renk uzayları için bir boyutlu 9 büyüklüğünde sırasıyla Eş. 3.12 ve Eş. 3.13 ile gösterilen özellik vektörleri oluşturuldu.

$$m_{RGB}^{tüm} = \{E_{1,R}, \sigma_{1,R}, s_{1,R}, E_{1,G}, \sigma_{1,G}, s_{1,G}, E_{1,B}, \sigma_{1,B}, s_{1,B}\} \quad (3.12)$$

$$m_{HSV}^{tüm} = \{E_{1,H}, \sigma_{1,H}, s_{1,H}, E_{1,S}, \sigma_{1,S}, s_{1,S}, E_{1,V}, \sigma_{1,V}, s_{1,V}\} \quad (3.13)$$

Yatay ve dikey olarak üç eşit parçaya bölünmüş görüntünün renk momenti hesaplanırken üç renk kanalı ve üç bölge için üç merkezi moment hesaplaması yapıldığından dolayı RGB ve HSV renk uzayları için 27 büyüklüğünde sırasıyla Eş. 3.14 ve Eş. 3.15 ile gösterilen dört farklı özellik vektörü oluşturuldu.

$$m_{RGB}^{yatay} = m_{RGB}^{dikey} = \{E_{1,R}, \sigma_{1,R}, s_{1,R}, E_{1,G}, \dots \dots \dots, E_{1,B}, \sigma_{3,B}, s_{3,B}\} \quad (3.14)$$

$$m_{HSV}^{yatay} = m_{HSV}^{dikey} = \{E_{1,H}, \sigma_{1,H}, s_{1,H}, E_{1,S}, \dots \dots \dots, E_{1,V}, \sigma_{3,V}, s_{3,V}\} \quad (3.15)$$

Bu çalışmada çıkarılan altı farklı renk moment özellik vektörleri görüntü erişiminde test edildi.  $m_{RGB}^{yatay}$  özellik vektörü diğer özellik vektörlerinden daha iyi sonuç verdiği için önerilen yöntemde görüntüler yatay olarak üç eşit parçaya ayrılıp renk momentleri hesaplandı.

### 3.1.3. Renk uyum vektörü

CCV renk histogramından daha karmaşık bir yöntemdir. Bu yöntem tüm pikselleri ilişkili veya ilişkisiz olarak 2 gruba ayırır. Bir renk görüntüde birbirine bağlı büyük bölgeler oluşturuyorsa ilişkili, küçük bölgeler oluşturuyorsa ilişkisiz olarak adlandırılır. CCV' nin hesaplanması renk histogramının hesaplanmasına benzerdir. Öncelikle görüntünün renk uzayı n farklı renge nicelenir. Daha sonra her bir piksel ilişkili veya ilişkisiz olarak sınıflandırılır. Birbirine bağlı aynı renk bileşenlerini hesaplayarak piksel gruplarını belirleriz. Bağlı bileşenler  $C$  ise herhangi iki piksel ( $p_i, p_j \in C$ ) arasında bir yol vardır. Biçimsel olarak  $C$  sıralı piksel dizisi Eş. 3.16 ile ifade edilir.

$$C = \{p_1, p_2, p_3, \dots \dots, p_n\} \quad (3.16)$$

$C$  bağlı bileşenler dizisindeki her bir  $p_i$  pikseli ve herhangi bir sıralı  $p_i$  ve  $p_{i+1}$  pikselleri birbirine komşu olmak zorundadır. Eğer bir piksel diğer pikselin 8 en yakın komşuluğundan birindeyse bu iki piksel birbirlerine komşudur. Bağlı bileşenler doğrusal zamanda hesaplanabilir. Her bir rengin oluşturduğu bağlı bileşenler hesaplandıktan sonra bir tau sayısı belirlenir. Eğer bağlı bileşenler tau sayısından büyükse ilişkili, küçükse ilişkisiz olarak adlandırılır. Nicelenen  $j$ . rengin ilişkili piksel sayısı  $\alpha_j$  ve ilişkisiz piksel sayısı  $\beta_j$  olsun.  $J$  farklı renge nicelenen rengin toplam sayısı ise  $\alpha_j + \beta_j$  olur. Böylece bir görüntünün renk uyum vektörü Eş. 3.17 ile ifade edilir [20].

$$CCV = \langle (\alpha_1, \beta_1), (\alpha_2, \beta_2), (\alpha_3, \beta_3), \dots \dots, (\alpha_n, \beta_n) \rangle \quad (3.17)$$

Bu çalışmada boyutları 384x256 olan ve toplam piksel sayısı 98304 olan görüntülerin CCV özelliği çıkarıldı. Her bir görüntü 27 farklı renge ayrıştırıldı ve tau sayısı olarak da toplam

piksel sayısının %1' i alındı. Eş. 3.18 bir görüntüye ait 2x27 boyutundaki renk uyum özellik vektörünü göstermektedir.

$$f_{ccv} = \{(\alpha_1, \beta_1), (\alpha_2, \beta_2), (\alpha_3, \beta_3), (\alpha_4, \beta_4), (\alpha_5, \beta_5), \dots, (\alpha_{27}, \beta_{27})\} \quad (3.18)$$

### CCV oluşturma adımları

5X5 boyutunda RGB renk uzayına sahip bir görüntünün renk uyum vektörünü oluşturma adımları aşağıda sıralanmıştır.

1. *Adım*: RGB renk uzayına sahip görüntü gri seviyeli görüntüye dönüştürülür (Çizelge 3.1).

Çizelge 3.1. Gri seviyeli I görüntüsü

12	17	27	22	32
15	10	24	15	15
22	10	25	25	12
36	18	29	36	33
25	29	21	34	35

2. *Adım*: Renk uzayı nicelenir. I görüntüsünün 10 ile 19 arasındaki piksel değerleri 1' e, 20 ile 29 arasındaki piksel değerleri 2' ye ve 30 ile 39 arasındaki piksel değerleri 3' e nicelenir (Çizelge 3.2).

Çizelge 3.2. Nicelenen I görüntüsü

1	1	2	2	3
1	1	2	1	1
2	1	2	2	1
3	1	2	3	3
2	2	2	3	3

3. Adım: Bağlı bileşenler bulunur ve her bir bileşenin büyüklüğü hesaplanır. Her bir bileşeni harflerle adlandırırsak görüntümüz Çizelge 3.3' deki gibi olur.

Çizelge 3.3. Bileşenleri bulanan I görüntüsü

A	A	D	D	G
A	A	D	F	F
B	A	D	D	F
C	A	D	E	E
D	D	D	E	E

Çizelge 3.3' de görüldüğü üzere A,B,C,D,E,F ve G olmak üzere 7 farklı bağlı bileşen bulundu. Bu bileşenlerin hangi renge ait olduğu Çizelge 3.4' de görülmektedir.

Çizelge 3.4. Bileşenlerin aitlik tablosu

Etiket	A	B	C	D	E	F	G
Renk	1	2	3	2	3	1	3
Boyut	6	1	1	9	4	3	1

4. Adım: Bağlı bileşenler bulunduktan sonra bir tau sayısı belirlenir ve bu tau sayısından küçük değerler ilişkisiz, büyük değerler ilişkili olarak adlandırılır. Tau sayımızı 4 belirlersek A,D,E bağlı bileşenler tau sayımızdan büyük ve eşit olduğu için ilişkili, B,C,F ve G bağlı bileşenler tau sayısından küçük olduğu için ilişkisiz olarak adlandırılır. Bu görüntü için renk uyum değerleri Çizelge 3.5' de görülmektedir.

Çizelge 3.5. I görüntüsünün renk uyum değerleri

Renk	1	2	3
$\alpha$ (ilişkili)	6	9	4
$\beta$ (ilişkisiz)	3	1	2

Son durumda I görüntüsünün renk uyum vektörü  $\{(6,3), (9,1), (4,2)\}$  şeklinde olacaktır.

### 3.2. Doku Özellik Çıkarmı

Bu çalışmada görüntülerin doku özelliklerini çıkarmak için iki farklı doku özellik çıkarmı yöntemi kullanıldı. Bu yöntemler GLCM ve dalgacık dönüşümü yöntemleridir.


#### 3.2.1. Gri seviyeli eş oluşum matrisi

Histogram kullanılarak hesaplanan dokunun bilgisi, piksellerin birbirleriyle olan ilişkisine ait bilgiyi içermez. Doku analizinde piksellerin birbiriyle olan ilgililik konumları bilgisinin de hesaba katılması gerekir. Haralick ve arkadaşları gri seviyeli konumsal bağımlılığa dayalı doku özelliklerini tanımlamıştır. Verilen bir gri seviyeli görüntü için piksellerin konumsal durumlarının olasılık dağılımını gösteren matrisler elde etmiştir [34].

Görüntüler bilgisayarda 2 boyutlu diziler halinde saklanır. Eğer  $L_x = \{1,2,3,4,\dots, N_x\}$  ve  $L_y = \{1,2,3,4,\dots, N_y\}$  uzaysal alanlar ise  $L_x \times L_y$  çözünürlük hücreler kümesidir ve sayısal görüntü I tüm çözünürlük hücrelerine nicelenmiş gri seviyeli  $G \in \{1,2,\dots, N_g\}$  değerlerini atayan fonksiyondur;  $I: L_x \times L_y \rightarrow G$ . Doku bilgisi hesaplanırken d uzaklığında ve  $\theta$  komşuluğunda olan iki komşu pikselin  $p(i, j)$  beraber olma olasılığı matrislerde saklanır. Burada  $p(i, j)$  normalize edilmiş gri seviyeli matristeki  $i, j$ ' deki hücreyi gösterir. Bu matrislere GLCM denir. GLCM, Eş. 3.19 ile tanımlanır. GLCM simetri matristir [57].

$$p(i, j|d, \theta) = \frac{p(i, j|d, \theta)}{\sum_i \sum_j p(i, j|d, \theta)} \quad (3.19)$$

Şekil 3.2' de pikseller arasındaki mekânsal ilişki gözükmemektedir. Bu ilişkiye  $p(i, j|d, 0^\circ)$ ,  $p(i, j|d, 45^\circ)$ ,  $p(i, j|d, 90^\circ)$  ve  $p(i, j|d, 135^\circ)$  matrisleri sırasıyla Eş. 3.20 , Eş. 3.21, Eş. 3.22 ve Eş. 23 ile hesaplanır.



Şekil 3.2. Çözünürlük hücrelerinin mekânsal ilişkileri

$$p(i, j | d, 0^\circ) = \{((k, l)(m, n)) \in (L_y \times L_x) \times (L_y \times L_x) | k - m = 0, |l - n| = d, \quad (3.20)$$

$$I(k, l) = i, I(m, n) = j\}$$

$$p(i, j | d, 45^\circ) = \{((k, l)(m, n)) \quad (3.21)$$

$$\in (L_y \times L_x) \times (L_y \times L_x) | (k - m = d, l - n = -d) \text{ veya } (k - m$$

$$= -d, l - n = d), I(k, l) = i, I(m, n) = j\}$$

$$p(i, j | d, 90^\circ) = \{((k, l)(m, n)) \in (L_y \times L_x) \times (L_y \times L_x) | |k - m| = d, l - n = 0, \quad (3.22)$$

$$I(k, l) = i, I(m, n) = j\}$$

$$p(i, j | d, 135^\circ) = \{((k, l)(m, n)) \quad (3.23)$$

$$\in (L_y \times L_x) \times (L_y \times L_x) | (k - m = d, l - n = d) \text{ veya } (k - m$$

$$= -d, l - n = -d), I(k, l) = i, I(m, n) = j\}$$

Bu eşitliklerde  $k, l, m$  ve  $n$  piksel çiftlerinin konumsal bilgisini gösterir.

### GLCM oluşturma adımları

Çizelge 3.6' da  $[0, 3]$  değer aralığına nicelenen görüntü için  $d = 1$  uzaklığında ve  $\theta = 0^\circ$  ( $x = 1, y = 0$ ) yönünde GLCM hesaplamak için aşağıdaki adımlar izlenir.



Çizelge 3.6. 4 X 4 boyutlu gri seviyeli görüntü

0	0	1	1
0	0	1	1
0	2	2	2
2	2	3	3

1. Adım: GLCM referans ve komşu diye adlandırılan iki komşu pikselin arasındaki ilişkiyle ilgilenir. Her referans piksel için sağındaki piksel komşu olarak seçilir ve görüntüdeki her bir piksel sırasıyla referans piksel olur. Görüntüdeki her bir  $p(i, j)$  ( $i$ =referans piksel değeri,  $j$ = komşu piksel değeri) çiftinin sayısı Çizelge 3.7' deki ilgili konumlar matrisine yazılır.

Çizelge 3.7. İlgili konumlar matrisi

Referans/Komşu	0	1	2	3
0	(0,0)	(0,1)	(0,2)	(0,3)
1	(1,0)	(1,1)	(1,2)	(1,3)
2	(2,0)	(2,1)	(2,2)	(2,3)
3	(3,0)	(3,1)	(3,2)	(3,3)

Tüm  $p(i, j)$  çiftlerini sayısı Çizelge 3.7' deki ilgili konumlar matrisine yazıldıktan sonra oluşan GLCM matrisi Çizelge 3.8' de görülmektedir.

Çizelge 3.8. 4 X 4 boyutlu gri seviyeli görüntüsüne ait GLCM

2	2	1	0
0	2	0	0
0	0	3	1
0	0	0	1

2. *Adım*: GLCM matrisi simetrik olmalıdır. Bunun anlamı aynı değerler matrisin diyagonaline göre zıt hücrelerde yer almasıdır. Örneğin  $p(0, 1)$  çiftinden görüntüde 2 tane bulunmaktadır. O zaman  $p(1, 0)$  çifti de 2 tane olmak zorundadır ve bu çiftlerin toplamı matrisde  $(1, 0)$  hücresinde olmalıdır. Böylece matris simetri olur ve  $\theta = 0^\circ$  yatay yöndeki uzaysal ilişkiyi gösterir. GLCM matrisini simetri yapmak için transpozunu ile toplanması gerekir (Çizelge 3.9).

Çizelge 3.9. 4 X 4 boyutlu gri seviyeli görüntüsüne ait simetrik GLCM

4	2	1	0
2	4	0	0
1	0	6	1
0	0	1	2

3. *Adım*: En son adımda simetrik GLCM normalize edilmelidir. Buradaki amaç görüntüdeki bir  $p(i, j)$  çiftinin sayısından ziyade olasılığını bulmaktır. Simetrik GLCM normalize edildikten sonraki hali Çizelge 3.10' da görülmektedir.

Çizelge 3.10. 4 X 4 boyutlu gri seviyeli görüntüsüne ait normalize simetrik GLCM

0,167	0,083	0,042	0
0,083	0,167	0	0
0,042	0	0,25	0,042
0	0	0,042	0,083

### GLCM doku analizi

Bir görüntünün doku analizini yapmak için öncelikle o görüntünün gri seviye eş oluşum matrisi hesaplanır. Bu GLCM matris üzerinden çeşitli doku analizleri yapılır. R.M. Harlick ve arkadaşları 1973' de 14 tane doku özelliği önermiştir. Bu doku özellikleri: açısız ikinci moment, kontrast, korelasyon, varyans, ters diferansiyel moment, toplam ortalama, toplam varyans, toplam entropi, entropi, diferansiyel varyans, diferansiyel entropi, birinci korelasyon ölçüsü, ikinci korelasyon ölçüsü, maksimum korelasyon katsayısı' dır [34].

1999 yılında L.K. Soh ve arkadaşları R.M. Harlick' den farklı olarak 6 farklı doku özelliği önermiştir. Bu özellikler homojenlik, oto korelasyon, farklılık, küme gölge, küme önem ve maksimum olasılık' dır [57].

Bu çalışmada görüntülerin  $d = 1$  uzaklığında ve  $\theta = 0^\circ, 45^\circ, 90^\circ$  ve  $135^\circ$  yönünde dört farklı GLCM hesaplandı. Hesaplanan bu GLCM' ler üzerinden doku özellikleri olarak enerji, kontrast, korelasyon ve homojenlik kullanıldı.

Enerji Eş. 3.24 ile hesaplanır.  $[0,1]$  aralığında benzerliğin bir ölçüsüdür. Benzerlik sabit bir görüntü için 1' dir.

$$E = \sum_i \sum_j p(i,j)^2 \quad (3.24)$$

Bu eşitlikte E görüntünün enerji değerini, i pikselin satır sayısını, j pikselin sütun sayısını ve  $p(i, j)$  GLCM' deki i. sıra ve j. sütundaki pikseli gösterir. Kontrast Eş. 3.25 ile hesaplanır. Görüntüdeki bir piksel ile komşusu arasındaki yeğinlik zıtlığını gösterir. GLCM' de diyagonal üzerindeki hücrelerin kontrast değeri 0' dir. Diyagonalden uzaklaştıkça kontrast değeri karesiyle doğru orantılı biçimde artar.

$$K = \sum_i \sum_j |i - j|^2 p(i, j) \quad (3.25)$$

Bu eşitlikte K görüntünün korelasyon değerini gösterir. Korelasyon Eş. 3.30 ile hesaplanır. Görüntünün doğrusallığının bir ölçüsüdür. "0" yönündeki doğrusal yönlü yapılar bu yönde büyük korelasyon değerleri meydana getirmektedir.

$$\mu_x = \sum_i \sum_j i p(i, j) \quad (3.26)$$

$$\mu_y = \sum_i \sum_j j p(i, j) \quad (3.27)$$

$$\sigma_x = \sum_i \sum_j (i - \mu_x)^2 p(i, j) \quad (3.28)$$

$$\sigma_y = \sum_i \sum_j (j - \mu_y)^2 p(i, j) \quad (3.29)$$

$$R = \frac{\sum_i \sum_j (ij) p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (3.30)$$

Bu eşitliklerde  $\mu_x$  ve  $\mu_y$  beklenti değerini  $\sigma_x$  ve  $\sigma_y$  standart çapma değerini ve R korelasyon değerini gösterir. Homojenlik Eş. 3.31 ile hesaplanır. [0,1] değer aralığındadır. Eş oluşum matrisindeki elemanların dağılımının diyagonale uzamsal yakınlığını ölçer.

$$H = \sum_i \sum_j \frac{p(i, j)}{1 + (i - j)^2} \quad (3.31)$$

Bu eşitlikte H görüntünün homojenlik değerini gösterir. Oluşturulan dört farklı GLCM için dört farklı doku analizi yapıldığından dolayı, her bir görüntü için bir boyutlu 16 büyüklüğünde GLCM doku vektörleri elde edildi (Eş. 3.32).

$$g = \{E_0, K_0, R_0, H_0, E_{45}, K_{45}, R_{45}, H_{45}, \dots, E_{135}, K_{135}, R_{135}, H_{135}\} \quad (3.32)$$

### 3.2.2. Dalgacık dönüşümü

Dalgacık dönüşümü görüntüleri analiz etmek için görüntü işleme alanlarında çokça kullanılmaktadır. Dalgacık dönüşümü görüntüyü farklı frekans alt bantlarına ayırır. Her ayrıştırma seviyesinde yüksek frekanslı altbantlar görüntüdeki detayları yakalar. Örneğin görüntüdeki kenarları tespit etmede kullanılabilir. Düşük seviyeli altbantlar ise ana görüntünün bir alt örneğidir ve ana görüntüyle benzer istatistiksel özellikleri taşır. Sonuç olarak dalgacık dönüşümü görüntüyü farklı çözünürlük seviyelerinde analiz etmemizi sağlar [40].

Ayrık dalgacık dönüşümünün matematiksel ifadesi Eş. 3.33 ile gösterilir.  $a > 0$ ,  $b \in \mathfrak{R}$  olmak üzere a, ölçekleme/yayımla parametresini; b dönüşüm/öteleme parametresini; f (t), işareti;  $\psi$ , ana dalgacık fonksiyonunu; W (a, b) de işaretin sürekli dalgacık dönüşümünü belirtir [7].

$$W(a, b) = \frac{1}{\sqrt{a}} \int f(t) \cdot \psi\left(\frac{t-b}{a}\right) dt \quad (3.33)$$

İki boyutlu  $f(t)$  fonksiyonunun dalgacık analizi için iki boyutlu ölçekleme fonksiyonu  $\phi(x, y)$  ve iki boyutlu yatay  $\psi^Y(x, y)$ , dikey  $\psi^D(x, y)$  ve köşegensel  $\psi^K(x, y)$  dalgacık fonksiyonları gereklidir. Her biri, bir boyutlu  $\phi$  ölçekleme fonksiyonu ve ilgili  $\psi$  dalgacık fonksiyonunun çarpımı ile elde edilir [7, 40,18].

$$\phi(x, y) = \phi(x) \cdot \phi(y) \quad (3.34)$$

$$\psi^Y(x, y) = \psi(x) \phi(y) \quad (3.35)$$

$$\psi^D(x, y) = \phi(x) \psi(y) \quad (3.36)$$

$$\psi^K(x, y) = \psi(x) \psi(y) \quad (3.37)$$

Burada  $\phi$  düşük çözünürlüklü görüntüyü (Eş. 3.34),  $\psi^Y$  sütunlardaki değişiklikleri (yatay kenarlar) (Eş. 3.35),  $\psi^D$  satırlardaki değişiklikleri (dikey kenarlar) (Eş. 3.36) ve  $\psi^K$  köşegenlerdeki değişiklikleri gösterir (Eş. 3.37).

Ayrılabilir iki boyutlu ölçekleme ve dalgacık fonksiyonları verildiğinde ölçeklenmiş ve ötelenmiş taban fonksiyonları sırasıyla Eş. 3.38 ve Eş. 3.39 ile tanımlanır.

$$\phi_{j,m,n}(x, y) = 2^{\frac{j}{2}} \phi(2^j x - m, 2^j y - n) \quad (3.38)$$


$$\psi^i_{j,m,n}(x, y) = 2^{\frac{j}{2}} \psi^i(2^j x - m, 2^j y - n) \quad (3.39)$$

Buradan  $M \times N$  boyutlu bir  $f(x, y)$  görüntüsünün ayrık dalgacık fonksiyonu Eş. 3.40 ve Eş. 3.41 ile hesaplanır.


$$W_\phi(j_0, m, n) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \phi_{j_0, m, n}(x, y) \quad (3.40)$$

$$W_{\psi}^i(j_0, m, n) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \psi_{j,m,n}^i(x, y) \quad (3.41)$$

İki boyutlu bir görüntüyü alt bantlara ayrıştırabilmek için filtre seti kullanılır (Şekil 3.3). Görüntü bu filtre setinden geçirildikten sonra dört tane alt görüntü elde edilir. Elde edilen ölçeklenmiş alt görüntü tekrar filtreden geçirilerek işlem devam eder (Şekil 3.4).



Şekil 3.3. Filtre seti



Şekil 3.4. Ayrıştırma

Elde edilen alt görüntülerin dalgacık katsayıları görüntü hakkında önemli bilgiler verir. Bu dalgacık katsayıları üzerinde çeşitli istatistiksel analizler yapılarak görüntünün dokusu tanımlanabilir [59].

Bu çalışmada RGB renk uzayına sahip görüntülerin renk bileşenlerine ayrıldıktan sonra, her bir bileşen için 3 ölçekli dalgacık dönüşümü uygulandı. Ortaya çıkan öz/yaklaşım alt görüntüleri üzerinde istatistiksel yaklaşımlardan ortalama ve standart sapma kullanarak doku

analizleri yapıldı. Böylece bir boyutlu 6 büyüklüğünde dalgacık özellik vektörü elde edildi (Eş. 3.42).

$$w = \{E_R, \sigma_R, E_G, \sigma_G, E_B, \sigma_B\} \quad (3.42)$$

Bu eşitlikte  $E$  görüntünün ortalama değerini ve  $\sigma$  görüntünü standart çarpma değerini göstermektedir.

### 3.3. Normalizasyon

Önceki İTGE sistemlerinde tek özelliğe dayalı erişim yöntemleri kullanılmıştır. Ancak görüntüler zengin içeriğe sahip olduklarından dolayı, tek özelliğe dayalı erişim yöntemleri resmi tanımlamada yeterli değildir. Bundan dolayı birden fazla yöntem beraber kullanılarak daha etkin bir yöntem geliştirilebilir. Bu amaçla bu çalışmada renk histogramı, renk momenti, CCV, GLCM ve dalgacık dönüşümü yöntemleri birleştirildi. Fakat bu yöntemler sonucunda elde edilen vektörlerin değer aralıkları birbirlerinden farklı olduğu için, tüm vektörler aynı değer aralığına normalize edilmelidir. Çalışmada minimum-maksimum normalizasyon kullanarak tüm vektörler [0,1] değer aralığına getirildi.

#### Minimum-Maksimum normalizasyon

Minimum-Maksimum normalizasyon yöntemi verilerin asıl değer aralığının doğrusal dönüşümünü sağlar. Bu yöntemle verilerin değer aralığı önceden belirlenmiş sınırlara çekilebilir. Minimum-Maksimum normalizasyon yöntemi Eş. 3.43 ile hesaplanır [60].

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} x (D - C) + C \quad (3.43)$$

Burada  $x'$  normalize edilmiş veridir.  $x_{min}$  ve  $x_{max}$  asıl veri aralığının minimum ve maksimum değerleridir. [C,D] ise normalize edilmek istenen sınırdır. Bu çalışmada bu sınırlar [0,1] olarak belirlendi.

### 3.4. Benzerlik Ölçümü


Benzerlik ölçümü İTGE sistemleri için en önemli aşamalardan biridir. Erişim sonuçları kullanılan uzaklık metriklerine göre değişmektedir. Özellik vektörleri çıkarılmış olan görüntülerin benzerlik ölçümünü hesaplamak için çeşitli benzerlik metrikleri kullanılmaktadır. Bu yöntemler iki vektör arasındaki uzaklığı hesap ederek görüntülerin benzerliği hakkında bilgi verirler.

Bu çalışmada elde edilen özellik vektörleri arasındaki benzerlik oranları aşağıda verilen benzerlik metrikleri kullanılarak test edildi.

- Öklit uzaklık
- Histogram Kesişim uzaklık
- Chebychev uzaklık
- Korelasyon uzaklık
- Kosinüs Açısı uzaklık
- Spearman uzaklık
- Ki Kare uzaklık
- Cityblok uzaklık

#### Öklit uzaklık

Öklit uzaklık, İTGE sistemlerinde benzerlik ölçümü için yaygın kullanılan yöntemlerden biridir. İki nokta arasındaki doğrusal uzaklığı ölçmek için kullanılır (Şekil 3.5). Öklit uzaklık Eş. 3.44 ile hesaplanır [61].



Şekil 3.5. Öklit uzaklık




$$d_E(q, p) = \sqrt{\sum_{i=1}^N (q_i - p_i)^2} \quad (3.44)$$

Bu eşitlikte  $d_E(q, p)$  q ve p noktaları arasındaki Öklit uzaklığını ve N ise vektör uzunluğunu göstermektedir.

### Cityblock uzaklık

Cityblock uzaklığı Minkowski uzaklığının  $L = 1$  durumundaki özel halidir. Aynı zamanda Manhattan uzaklığı olarak da adlandırılır (Şekil 3.6). N boyutlu q ve p noktaları arasındaki Cityblock uzaklığı Eş. 3.45 ile hesaplanır [62].



Şekil 3.6. Cityblock uzaklık

$$d_{CB}(q, p) = \sum_i^N |q_i - p_i| \quad (3.45)$$

Bu eşitlikte  $d_{CB}(q, p)$  q ve p noktaları arasındaki Cityblock uzaklığını ve N ise vektör uzunluğunu göstermektedir.

### Histogram Kesişim uzaklık

Histogram Kesişim uzaklık iki histogramın alanları farklı olduğu zaman görüntüdeki bölgesel eşleşmeleri yakalama konusunda başarılı bir yöntemdir. Bu yöntem görüntüler arasındaki benzerlik ölçümünde kullanışlıdır. N boyutlu q ve p histogramları arasındaki Histogram Kesişim uzaklığı Eş. 3.46 ile tanımlanır [62].

$$d_{\cap}(q, p) = 1 - \frac{\sum_i^N \min(q_i, p_i)}{\sum_i p_i} \quad (3.46)$$

Bu eşitlikte  $d_{\cap}(q, p)$  q ve p noktaları arasındaki Histogram Kesişim uzaklığını ve N ise vektör uzunluğunu göstermektedir.

### Chebychev uzaklık

Chebychev uzaklık aynı zamanda en büyük değer uzaklığı olarak da bilinir. İki vektörün aynı koordinat değerine sahip olan çiftlerin arasındaki farkın mutlak büyüğüyle ilgilenir. N boyutlu q ve p vektörleri için Chebychev uzaklığı Eş. 3.47 ile hesaplanır. Aynı zamanda Chebychev uzaklık Minkowski uzaklığının  $L = \infty$  durumundaki özel halidir.

$$d_C(q, p) = \max_i \{|q_i, p_i|\} \quad (3.47)$$

Bu eşitlikte  $d_C(q, p)$  q ve p noktaları arasındaki Chebchev uzaklığını ve N ise vektör uzunluğunu göstermektedir.

### Kosinüs Açısı uzaklık

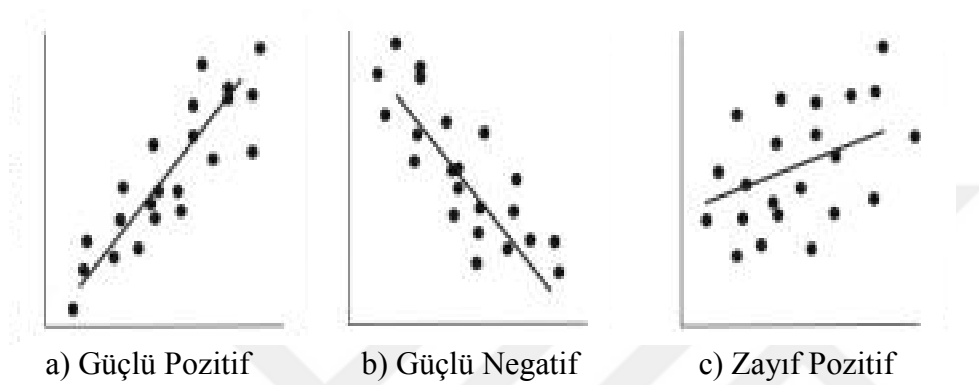
Kosinüs Açısı uzaklığının en önemli özelliği iki vektör arasındaki benzerlik metriğini vermesidir. N boyutlu q ve p vektörleri arasındaki açı  $\cos\theta$  olarak kabul edilir. Kosinüs Açısı uzaklığı Eş. 3.48 ile tanımlanır [63].

$$d_{CAD}(q, p) = \frac{q \cdot p}{\|q\| \|p\|} = \frac{\sum_i^N q_i p_i}{\sqrt{\sum_i^N q_i^2} \sqrt{\sum_i^N p_i^2}} \quad (3.48)$$

Bu eşitlikte  $d_{CAD}(q, p)$  q ve p noktaları arasındaki Kosinüs Açısı uzaklığını ve N ise vektör uzunluğunu göstermektedir.

### Korelasyon uzaklık

Korelasyon uzaklığı iki değişken arasındaki doğrusal ilişkinin gücünü ve yönünü ölçer. Eğer  $r = 1$  ise mutlak pozitif korelasyon vardır. Eğer  $r = -1$  ise mutlak negatif korelasyon vardır (Şekil 3.7). N boyutlu Q ve P vektörleri arasındaki korelasyon uzaklığı Eş. 3.49 ile tanımlanır [64].



Şekil 3.7. Korelasyon uzaklık

$$d_K(q, p) = 1 - \frac{\sum_i^N (q_i - \bar{q})(p_i - \bar{p})}{(N - 1)s_q s_p} \quad (3.49)$$

$$\bar{q} = \frac{1}{n} \sum_i^N q_i \quad (3.50)$$

$$\bar{p} = \frac{1}{n} \sum_i^N p_i \quad (3.51)$$

Bu eşitliklerde  $\bar{q}$  ve  $\bar{p}$   $q_i$  ve  $p_i$  için örneklem aritmetik ortalamaları;  $s_q$  ve  $s_p$   $q_i$  ve  $p_i$  için örneklem standart sapmalarını,  $d_K(q, p)$  q ve p noktaları arasındaki Korelasyon uzaklığını ve N ise vektör uzunluğunu göstermektedir.

### Spearman uzaklık

Spearman uzaklığı iki değişken arasındaki ilişkinin gücünü ölçmede kullanılan parametrik olmayan bir yöntemdir. Spearman korelasyon belirli doğrusal ve doğrusal olmayan

korelasyonları tespit edebilir. Spearman korelasyon değer aralığı -1 ile 1 arasındadır. N boyutlu q ve p vektörleri arasındaki Spearman uzaklığı Eş. 3.52 ile tanımlanır.

$$d_S(Q, P) = 1 - \frac{6 \sum_i^N ((rank(q_i) - rank(p_i))^2)}{n(n^2 - 1)} \quad (3.52)$$

Bu eşitliklerde  $rank(q_i)$  ve  $rank(p_i)$  i. vektör değerinin sıralamasını,  $d_S(q, p)$  q ve p noktaları arasındaki Spearman uzaklığını ve N ise vektör uzunluğunu göstermektedir.

### Ki Kare uzaklık

Ki Kare uzaklığı ayırık olasılık dağılımlarını hesaplamak için kullanılır. Ki Kare uzaklığı Eş. 3.53 ile hesaplanır [63].

$$d_{\chi^2}(q, p) = \sum_i^N \frac{(q_i - m_i)^2}{m_i} \quad (3.53)$$

$$m_i = \frac{q_i + p_i}{2} \quad (3.54)$$

Bu eşitlikte  $q_i$  gözlemlenen değeri,  $m_i$  beklenen değeri,  $d_{\chi^2}(q, p)$  q ve p noktaları arasındaki Ki Kare uzaklığını ve N ise vektör uzunluğunu göstermektedir.


### **3.5. Özellik Birleştirme**

Normalize edilmiş renk ve doku özellik vektörlerinin benzerlik ölçümü yapıldıktan sonra renk histogramı uzaklık ölçüsü ( $d_1$ ), renk momenti uzaklık ölçüsü ( $d_2$ ), ccv uzaklık ölçüsü ( $d_3$ ), GLCM uzaklık ölçüsünü ( $d_4$ ) v dalgacık dönüşümü uzaklık ölçüsü ( $d_5$ ) eşit ağırlıkta birleştirildi ve test edildi (Eş. 3.55).

$$d = d_1 + d_2 + d_3 + d_4 + d_5 \quad (3.55)$$


### 3.6. Genetik Algoritma ile Ağırlıklandırma

Genetik algoritmaları (GA) ilk kez 1975’ de Holland tarafından optimizasyon problemleri için kullanılmıştır [65]. GA’ nın temelinde evrim yasaları vardır. Problemlere karşı tek çözüm yerine birden fazla çözüm kümesi oluşturur. Bu çözüm kümesine nüfus adı verilir. Nüfuslar birey veya kromozom adı verilen sayı dizilerinden oluşur. Bireyler gen adı verilen elemanlardan oluşur. Şekil 3.8’ de her biri üç gene sahip olan dört bireyden oluşan nüfus görülmektedir.



Şekil 3.8. Genetik algoritmanın elemanları

Genetik algoritma evrim süreci gibi doğal seleksiyon sürecini takip eder. Bu süreç seçim, çaprazlama ve mutasyon adımlarından oluşur (Şekil 3.9). En iyi olasılığa sahip bireyler uygunluk fonksiyonu tarafından hayatta kalır. Yeni nesil bireyler en iyi bireylerin çaprazlanması ve mutasyon geçirmesi sonucu üretilir. Bu üretim nesillerin belirlenen sayıya ulaşana dek devam eder. İdeal durumda son nesil tüm bireyler en iyi sonucu veren aynı genlere sahip olur [66].



Şekil 3.9. Genetik algoritmanın akış şeması

Genetik algoritma Eş. 3.56 ile belirtilir. Burada C bağımsız kodlama metodunu, E uygunluk fonksiyonunu,  $P_0$  başlangıç nüfusunu, M nüfus büyüklüğünü, Q seçim operatörünü, L çaprazlama operatörünü, Y mutasyon operatörünü ve T sonlandırma kriterini ifade etmektedir [67]. GA en iyi sonucu seçim, çaprazlama ve mutasyon operatörlerini kullanarak arar.

$$GA = (C, E, P_0, M, Q, L, Y, T) \quad (3.56)$$

### Seçim operatörleri

Seçim işlemi nüfustaki ebeveynler gibi elit çocukları seçer. Uygunluk fonksiyonu çocukların elit olup olmadığına karar verir. İyi bireyleri seçmek için yapılmış çalışmalarda rulet tekerleği seçimi, turnuva seçimi, rütbe seçimi, elitist seçimi, sabit durum seçimi gibi birçok yöntem vardır [68].

- *Rulet Tekerleği Seçimi:* Bireylerin uygunluk dereceleri hesap edilir. Bir bireyin çözüme uygunluk derecesi büyüdükçe yeni nüfusa katılma şansı artar.
- *Rütbe Seçimi:* Bireyler yeni nesle uygunluk derecelerinin sıralamasına göre seçilir.
- *Rastgele Seçim:* Bireylerin çözüme uygunluk derecelerine bakılmaz rastgele olarak yeni nesle seçilirler.
- *Turnuva Seçimi:* Rastgele seçilen iki bireyden uygunluk derecesi yüksek olan yeni nesle seçilir.
- *Elitist Seçimi:* Uygunluk derecesi en iyi olan belirli sayıdaki birey yeni nesle seçilir.
- *Sabit Durum Seçimi:* Uygunluk derecesi yüksek olan bireyler yeni yavrular oluşturulur ve bu yavrular düşük uygunluk derecesine sahip olan bireylerle değiştirilir.

### Çaprazlama operatörleri

Önceki nesilden daha iyi bireyler oluşturmak için çaprazlama işlemi uygulanır. Nüfustan seçim operatörlerine göre seçilen bireyler çaprazlama operatörleri kullanılarak yeni bireyler üretilir. Belli başlı kullanılan çaprazlama operatörleri aşağıdaki gibidir [67].

- *Tek Noktalı Çaprazlama:* Rastgele iki birey birleştirilir. İlk ve son gen haricinde ortadan bir nokta seçilir. Bu noktaya göre çaprazlama işlemi gerçekleşir.

- *Çift Noktalı Çaprazlama:* Rastgele iki birey birleştirilir. İlk ve son gen haricinde ortadan iki nokta seçilir. Bu iki nokta arasında kalan genler karşılıklı olarak değiştirilir.
- *Düzensiz çaprazlama:* Bireylerle aynı uzunlukta 0 ve 1 bitlerinden oluşan maskeler oluşturulur. Bitler geni hangi bireyden alacağını gösterir.
- *Karışık Çaprazlama:* İlk ve son gen haricinde bir nokta belirlenir. Önce tüm genler bireyler arasında karıştırılır ve sonra çaprazlama yapılır.
- *Ara çaprazlama:* Yavrular ebeveynlerin değişkenlerine bağlı olarak seçilir.

### Mutasyon operatörleri

Belirli bir zaman sonra üretilen yeni nesildeki bireyler birbirini tekrar edebilir. Bu durumu engellemek için birey çeşitliliğini arttırmak için her iterasyonda bireyler mutasyona uğrar. Böylece genetik çeşitlilik artar. Aşağıda başlıca kullanılan mutasyon yöntemleri görülmektedir [67].

- *Değiştirme:* Rastgele seçilen genin değerini tersiyle değiştirerek gerçekleştirir.
- *Kaydırma:* Birey içinde rastgele seçilen gen dizisini başka bir konuma kaydırılmasıdır.
- *Yerleştirme:* Birey içinde rastgele seçilen genin başka bir konuma yerleştirilmesidir.


### Sonlandırma kriteri

Seçim, çaprazlama ve mutasyon işleminden sonra yeni bir nesil üretilir ve bu adımlar sürekli tekrar eder. Bu döngüyü sonlandırmak için aşağıdaki adımlar izlenir [67].

- Döngü sayısı belirlenir ve döngü bu sayıya ulaştığında GA sonlanır. Burada üretilen nesil her zaman en iyi sonucu vermeyebilir. Eğer döngü devam etseydi daha iyi nesiller üretililebilirdi.
- Üretilen nesiller aynı sonucu üretirse GA sonlanır.
- Ulaşılmaması istenen sonuç alındığında GA sonlanır.

Şekil 3.10' da Şekil 3.8' deki nüfusun genetik algoritma ile optimize edilme aşamaları görülmektedir. Aşama sonunda en yüksek değerlere sahip olan bireyler seçilir ve nüfustaki diğer bireylerle çoğalmaları sağlanır. Çoğalan bu bireyler çocuk olarak adlandırılır ve ailesinin genlerini taşır. Bu aşamalar en iyi çözüme ulaştığında veya uygunluk

fonksiyonunda belirtilen iterasyon sayısına varıldığında veya üretilen sonuç aynı kalmaya başladığında sona erir.



Şekil 3.10. Genetik algoritmanın çalışma prensibi

### Genetik algoritma kullanarak ağırlıklandırma


Bu çalışmada kullanılan renk ve doku özelliklerine farklı oranlarda ağırlıklar vererek görüntü erişimi sağlandı. En iyi sonucu alabilmek için özelliklerin ağırlıkları GA kullanarak iyileştirildi (Eş. 3.57).

$$d = w_1d_1 + w_2d_2 + w_3d_3 + w_4d_4 + w_5d_5 \quad (3.57)$$

Bu eşitlikte  $d_1, d_2, d_3, d_4, d_5$  sırasıyla renk histogramı uzaklık ölçüsünü, renk momenti uzaklık ölçüsünü, CCV uzaklık ölçüsünü, GLCM uzaklık ölçüsünü ve dalgacık dönüşümü uzaklık ölçüsünü belirtir.  $w_1, w_2, w_3, w_4, w_5$  sırasıyla renk histogramı, renk momenti, CCV, GLCM ve dalgacık dönüşümü için GA ile elde edilen ağırlıkları gösterir.



### 3.7. Önerilen Sistemin Mimarisi



Şekil 3.11. Önerilen sistemin blok şeması



## 4. DENEYSEL SONUÇLAR

Bu çalışmada renk ve doku özelliklerini çıkaran beş farklı görüntü erişim yöntemi Wang veritabanı üzerinde test edildi. Bu aşamadan sonra tüm özellik vektörleri birleştirildi. Başarım oranını arttırmak için GA kullanarak yöntemlerin başarısı test edildi.


### 4.1. Veri Tabanı

Bu çalışmada Wang veritabanı kullanıldı [69,70]. Bu veritabanında 10 farklı kategori ve her bir kategoride 100 görüntü bulunmaktadır. Toplamda ise 1000 görüntü bulunmaktadır. Kategoriler Çizelge 4.1’ de görüldüğü gibi ilişkilendirilmiştir. Şekil 4.1’ de her kategoriden rastgele seçilen 5 görüntü görülmektedir.

Çizelge 4.1. Wang veritabanı

Kategori Etiketi	Kategori İsmi
1	Afrika
2	Sahil
3	Bina
4	Otobüs
5	Dinazor
6	Fil
7	Çiçek
8	At
9	Dağ
10	Yemek

Wang veritabanı yapılmış çalışmalarda verilen bir sorgu görüntüsü için benzer görüntüleri aramada kullanılmıştır. Erişilen görüntüler aynı kategoriye ait ise ilişkili, farklı bir kategoriye ait ise ilişkisiz olarak adlandırılır.



Resim 4.1 Wang veritabanına ait her kategoriden rastgele seçilen 5 görüntü

## 4.2. Performans Değerlendirme Metrikleri

Sistemin performans değerlendirmesi için hassasiyet oranı kullanıldı. Hassasiyet oranı sorgu görüntü için erişilen ilişkili görüntülerin oranını ölçer ve Eş. 4.1 ile hesaplanır [71].

$$\text{Hassasiyet oranı (P)} = \frac{\text{Getirilen ilişkili görüntü sayısı}}{\text{Toplam getirilen görüntü sayısı}} \quad (4.1)$$

Çalışmada  $N = 10, N = 20, N = 30, N = 40, N = 50$  ve  $N = 100$  için benzer görüntüye erişildi ve hassasiyet oranları hesaplandı. Herhangi bir  $i$ . görüntünün hassasiyet oranı Eş. 4.2 ile hesaplanır.

$$P_i = \frac{1}{N} \sum_{1 \leq j \leq 1000, r(i,j) \leq 10, ID(i)=ID(j)} 1 \quad (4.2)$$

Burada  $ID(i)$  ve  $ID(j)$  sırasıyla  $i$  ve  $j$  görüntülerinin kategorisini gösterir.  $r(i, j)$   $i$ . sorgu görüntüsünün  $j$ . hedef görüntüsüne olan uzaklığını gösterir.  $P_i$ , getirilen en yakın  $N$  tane hedef görüntünün  $i$ . sorgu görüntünün kategorisine ait olma yüzdesini gösterir.

Her kategorinin hassasiyet oranı Eş. 4.3 ile hesaplanır. Sistemin ortalama hassasiyet oranı Eş. 4.4 ile hesaplanır.

$$GP_t = \frac{1}{100} \sum_{1 \leq i \leq 1000, ID(i)=t} P_i \quad (4.3)$$

$$OP = \frac{1}{10} \sum_{1 \leq t \leq 10} GP_t \quad (4.4)$$

## 4.3. Renk Yöntemlerinin Test Sonuçları

Bu çalışmada görüntülerin renk özelliklerini çıkarmak renk histogramı, renk momenti ve CCV yöntemi test edildi.

### 4.3.1. Renk histogramı test sonuçları

Bu çalışmada RGB renk uzayına sahip görüntüler HSV renk uzayına dönüştürüldü. HSV renk uzayı geniş renk aralığına sahip olduğundan dolayı renk histogramı hesaplaması çok zaman alacaktır. Bu yüzden HSV renk uzayı, HSV (8, 2, 2), HSV (8, 3, 3), HSV (10, 4, 4) ve HSV (16, 4, 4) renk uzaylarına nicelendi ve renk histogramları test edildi. Böylece görüntüler sırasıyla 32, 72, 160 ve 256 farklı renge nicelenerek hesaplama zamanı azaltıldı.

HSV (8, 2, 2) için renk histogramı hassasiyet oranı Çizelge 4.2' de görülmektedir. *Afrika, Sahil, Otobüs, Dinozor, At ve Dağ* kategorilerinde *Ki Kare Uzaklık* en iyi sonucu verdi. Diğer kategorilerde ise *Spearman Uzaklık* en iyi sonucu verdi. Sistemin ortalama hassasiyet oranına baktığımızda en iyi sonucu % 65,0 ile *Ki Kare Uzaklık* kullanılarak alındı. Bu sonuca en yakın oran % 64,3 ile *Spearman Uzaklık* oldu.

Çizelge 4.2. HSV (8, 2, 2) için renk histogramı hassasiyet oranı

Kategori	N=10										
	Afrika	Sahil	Bina	Otobüs	Dinozor	Fil	Çiçek	At	Dağ	Yemek	Ortalama
Öklit	0,61	0,29	0,35	0,71	0,89	0,41	0,69	0,85	0,32	0,61	0,571
Histogram	0,65	0,31	0,43	0,71	0,92	0,47	0,77	0,91	<b>0,38</b>	0,66	0,621
Chebychev	0,52	0,25	0,31	0,63	0,83	0,35	0,57	0,81	0,29	0,54	0,512
Korelasyon	0,60	0,30	0,41	0,40	0,89	0,43	0,72	0,88	0,34	0,60	0,557
Kosinüs	0,61	0,30	0,40	0,53	0,89	0,43	0,72	0,87	0,35	0,61	0,570
Spearman	0,71	0,34	<b>0,59</b>	0,54	0,90	<b>0,54</b>	<b>0,83</b>	0,90	0,37	<b>0,70</b>	0,643
Ki Kare	<b>0,70</b>	<b>0,35</b>	0,47	<b>0,74</b>	<b>0,95</b>	0,50	0,80	<b>0,92</b>	<b>0,38</b>	0,68	<b>0,650</b>
Cityblock	0,65	0,31	0,43	0,71	0,92	0,47	0,77	0,91	<b>0,38</b>	0,66	0,621

HSV (8, 3, 3) için renk histogramı hassasiyet oranı Çizelge 4.3' de görülmektedir. *Afrika, Sahil, Otobüs, Fil, At ve Dağ* kategorilerinde *Ki Kare Uzaklık* en iyi sonucu verdi. *Bina* ve *Yemek* kategorilerinde *Spearman Uzaklık* en iyi sonucu verdi. Diğer kategorilerde ise

*Cityblock Uzaklık* en iyi sonucu verdi. Sistemin ortalama hassasiyet oranına baktığımızda *Ki Kare Uzaklık* % 70,6 ile en iyi sonucu verdi.

Çizelge 4.3. HSV (8, 3, 3) renk histogramı hassasiyet oranı

Kategori	N=10										
	Afrika	Sahil	Bina	Otobüs	Dinozor	Fil	Çiçek	At	Dağ	Yemek	Ortalama
Öklit	0,70	0,38	0,44	0,72	0,92	0,46	0,62	0,88	0,31	0,64	0,607
Histogram	0,73	0,41	0,58	0,76	0,96	0,57	0,79	0,93	0,37	0,71	0,684
Chebychev	0,57	0,36	0,39	0,55	0,88	0,37	0,52	0,81	0,30	0,54	0,526
Korelasyon	0,63	0,41	0,50	0,43	0,93	0,51	0,72	0,90	0,35	0,60	0,597
Kosinüs	0,65	0,41	0,50	0,52	0,93	0,51	0,71	0,90	0,34	0,62	0,608
Spearman	0,75	0,36	<b>0,73</b>	0,67	0,83	0,58	0,84	0,93	0,37	<b>0,79</b>	0,683
Ki Kare	<b>0,77</b>	<b>0,45</b>	0,60	<b>0,78</b>	0,97	<b>0,61</b>	0,80	<b>0,96</b>	<b>0,38</b>	0,74	<b>0,706</b>
Cityblock	0,74	0,40	0,56	0,76	<b>0,98</b>	0,54	<b>0,85</b>	0,93	0,35	0,66	0,675

HSV (10, 4, 4) için renk histogramı hassasiyet oranı Çizelge 4.4' de görülmektedir. *Bina* ve *Dağ* kategorilerinde *Spearman Uzaklık*, diğer kategorilerde ise *Ki Kare Uzaklık* en iyi sonucu verdi. Sistemin genel ortalamasına baktığımızda *Ki kare uzaklık* % 73,2 ile en iyi sonucu verdi.

HSV (16, 4, 4) için renk histogramı hassasiyet oranı Çizelge 4.5' de görülmektedir. *Afrika*, *Dinozor* ve *Fil* kategorilerinde en iyi sonuç *Ki Kare Uzaklık* kullanılarak alındı. *Sahil* ve *Dağ* kategorilerinde *Histogram Kesişim Uzaklık* ve *Cityblock Uzaklık* en iyi sonucu verdi. *Bina*, *Çiçek* ve *Yemek* kategorilerinde *Spearman Uzaklık*, *Otobüs* ve *At* kategorilerinde *Histogram Kesişim Uzaklık* *Ki Kare Uzaklık* ve *Cityblok Uzaklık* en iyi sonucu verdi. Sistemin genel ortalamasına baktığımızda *Ki Kare Uzaklık* % 73,1 ile en iyi sonucu verdi.

Çizelge 4.4. HSV (10, 4, 4) renk histogramı hassasiyet oranı

Kategori	N=10										
	Afrika	Sahil	Bina	Otobüs	Dinozor	Fil	Çiçek	At	Dağ	Yemek	Ortalama
Öklit	0,77	0,33	0,45	0,72	0,95	0,45	0,61	0,91	0,32	0,64	0,614
Histogram	0,78	0,44	0,63	<b>0,82</b>	<b>0,99</b>	0,62	0,79	<b>0,97</b>	0,40	0,75	0,718
Chebychev	0,65	0,30	0,36	0,50	0,91	0,34	0,52	0,84	0,32	0,47	0,520
Korelasyon	0,70	0,40	0,49	0,43	0,97	0,50	0,73	0,94	0,35	0,61	0,612
Kosinüs	0,72	0,39	0,49	0,50	0,97	0,49	0,73	0,94	0,35	0,63	0,622
Spearman	0,76	0,38	<b>0,75</b>	0,73	0,77	0,62	<b>0,81</b>	0,93	0,35	<b>0,83</b>	0,694
Ki Kare	<b>0,82</b>	<b>0,45</b>	0,65	<b>0,82</b>	<b>0,99</b>	<b>0,64</b>	<b>0,81</b>	<b>0,97</b>	<b>0,41</b>	0,77	<b>0,732</b>
City block	0,78	0,44	0,63	<b>0,82</b>	<b>0,99</b>	0,62	0,79	<b>0,97</b>	0,40	0,75	0,718

Çizelge 4.5. HSV (16, 4, 4) renk histogramı hassasiyet oranı

Kategori	N=10										
	Afrika	Sahil	Bina	Otobüs	Dinozor	Fil	Çiçek	At	Dağ	Yemek	Ortalama
Öklit	0,82	0,31	0,49	0,68	0,93	0,43	0,55	0,91	0,28	0,67	0,606
Histogram	0,83	<b>0,41</b>	0,70	<b>0,80</b>	0,98	0,60	0,79	<b>0,97</b>	<b>0,39</b>	0,78	0,725
Chebychev	0,67	0,28	0,34	0,45	0,91	0,38	0,50	0,83	0,31	0,48	0,515
Korelasyon	0,74	0,35	0,56	0,41	0,96	0,51	0,68	0,94	0,35	0,65	0,614
Kosinüs	0,75	0,35	0,56	0,46	0,96	0,51	0,67	0,94	0,34	0,67	0,620
Spearman	0,77	0,38	<b>0,79</b>	0,72	0,79	0,60	<b>0,82</b>	0,92	0,34	<b>0,82</b>	0,695
Ki Kare	<b>0,84</b>	0,42	0,71	<b>0,80</b>	<b>0,99</b>	<b>0,62</b>	0,80	<b>0,97</b>	0,38	0,79	<b>0,731</b>
City block	0,83	<b>0,41</b>	0,70	<b>0,80</b>	0,98	0,60	0,79	<b>0,97</b>	<b>0,39</b>	0,78	0,725



Test edilen renk histogramlarının kıyası Çizelge 4.6' da görülmektedir. Test edilen farklı renk histogramlarında en yüksek hassasiyet oranını *Ki Kare Uzaklık* verdi. Bu oranlar farklı renk sayısı 32 olduğunda %65,0, 72 olduğunda %70,6, 160 olduğunda %73,2, ve 256 olduğunda %73,1 olarak alındı. Nicelenen farklı renk sayısı belli bir sayıya kadar arttıkça renk histogramı hassasiyet oranının da arttığı gözlemlendi. Sonraki artışların hassasiyet oranının da benzer sonuçlar verdiği, bazı durumlarda ise bu sonucun düştüğü gözlemlendi. Kullanılan *Histogram Kesişim Uzaklık*, *Spearman Uzaklık* ve *Cityblok Uzaklık* da renk histogramı için iyi sonuçlar verdi. Fakat *Öklit Uzaklık*, *Chebychev Uzaklık*, *Korelasyon Uzaklık* ve *Kosinüs Uzaklık* düşük sonuçlar verdi.

Bu çalışmada birbirine yakın ve en yüksek sonuçları verdiği için önerilen yöntemde RH (10, 4, 4) ve RH (16, 4, 4) yöntemleri ayrı ayrı kullanılarak test edildi.

Çizelge 4.6. Renk histogramlarının birbirleriyle kıyası

	RH (8, 2, 2)	RH (8, 3, 3)	RH (10, 4, 4)	RH (16, 4, 4)
Öklit	0,571	0,607	0,614	0,606
Histogram	0,621	0,684	0,718	0,725
Chebychev	0,512	0,526	0,520	0,515
Korelasyon	0,557	0,597	0,612	0,614
Kosinüs	0,570	0,608	0,622	0,620
Spearman	0,643	0,683	0,694	0,695
Ki Kare	0,650	0,706	<b>0,732</b>	<b>0,731</b>
Cityblock	0,621	0,675	0,718	0,725

Resim 4.2' de RH (10, 4, 4) yönteminde *Ki Kare Uzaklık* kullanılarak *Sahil* içerikli sorgu görüntüsü için erişilen benzer 10 görüntü görülmektedir. Bu sorgu görüntüsü için 5 tane *Sahil* içerikli görüntü, 2 tane *Otobüs* içerikli görüntü ve 3 tane *Dağ* içerikli görüntüye erişildi. Sorgu görüntüsü ağırlıklı olarak mavi ve yeşil renkten oluştuğu için erişilen görüntülerde de bu renklerin hakim olduğu görüldü. Erişilen ilişkisiz görüntülerin de sorgu görüntüsünün hakim olduğu renklere sahip olduğu görüldü.



Resim 4.2 Sahil kategorisine ait 112 numaralı görüntünün erişim sonuçları (RH (10, 4, 4)-Ki Kare Uzaklık)

Renk histogramı yöntemi görüntüdeki renklerin dağılımına baktığı için aynı renk dağılımına sahip görüntüleri benzer olarak getirecektir. Resim 4.3' de *Dağ* kategorisine ait sorgu görüntüsünün erişim sonuçları görülmektedir. Sorgu görüntüsünde beyaz ve mavi renklerin dağılımı fazla olduğu için erişilen görüntülerde de bu renklerin dağılımı fazla olacaktır. Bu yüzden bu sorgu görüntüsü için ilişkili olarak adlandıracağımız sadece 1 görüntüye erişildi. *Sahil* kategorisine ait 7 görüntüye erişildi. Çünkü renk dağılımında *Sahil* ve *Dağ* kategorileri birbirine oldukça benzer. Bu yüzden sadece görüntülerin rengine bakarak yapılacak olan erişimler görüntüleri tanımlamada yeterli olmaz.



Resim 4.3. Dağ kategorisine ait 812 numaralı görüntünün erişim sonuçları (RH (10, 4, 4) – Ki Kare Uzaklık)

### 4.3.2. Renk momenti test sonuçları

Bu çalışmada RGB ve HSV renk uzaylarındaki görüntülerin renk momentleri test edildi. Her iki renk uzayında da tüm görüntünün renk momenti, yatay olarak üç eşit parçaya ayrılmış olan görüntünün renk momenti ve dikey olarak üç eşit parçaya ayrılmış olan görüntünün renk momenti hesaplandı ve test edildi.

RGB renk uzayındaki tüm görüntü için renk momenti hassasiyet oranı Çizelge 4.7' de görülmektedir. Kategori bazında incelendiğinde *Spearman Uzaklık*, *Afrika* ve *Sahil* kategorilerinde iyi sonuç verirken diğer kategorilerde başarısız sonuç verdi. Aynı şekilde *Histogram Kesişim Uzaklık*, *Dinazor* ve *Dağ* kategorilerinde iyi sonuç verirken ortalama hassasiyet oranında kötü sonuç verdi. Ortalama hassasiyet oranına bakıldığında *Histogram Kesişim Uzaklık* ve *Spearman Uzaklık* dışındaki uzaklık metrikleri benzer sonuç verdi. En iyi sonuç ise *Ki Kare Uzaklık* hesap edildiğinde elde edildi.

Çizelge 4.7. Tüm görüntünün renk momenti hassasiyet oranı (RGB-RMT)

Kategori	N=10										
	Afrika	Sahil	Bina	Otobüs	Dinazor	Fil	Çiçek	At	Dağ	Yemek	Ortalama
Öklit	0,42	0,48	0,25	0,45	0,99	<b>0,50</b>	0,65	<b>0,85</b>	0,33	<b>0,54</b>	0,546
Histogram	0,41	0,08	0,21	0,29	<b>1,00</b>	0,35	0,21	0,44	<b>0,36</b>	0,30	0,364
Chebychev	0,44	0,46	0,27	0,43	0,99	<b>0,50</b>	0,62	0,84	0,33	0,53	0,541
Korelasyon	0,48	0,41	0,30	0,44	0,95	0,42	0,68	0,83	0,35	0,53	0,538
Kosinüs	0,48	0,41	<b>0,31</b>	0,43	0,96	0,42	<b>0,67</b>	0,83	0,34	0,52	0,537
Spearman	<b>0,64</b>	<b>0,60</b>	0,21	0,30	0,07	0,21	0,63	0,63	0,11	0,17	0,358
Ki Kare	0,44	0,51	0,25	<b>0,46</b>	0,99	<b>0,50</b>	<b>0,67</b>	<b>0,85</b>	0,32	<b>0,54</b>	<b>0,551</b>
Cityblock	0,42	0,47	0,25	0,45	0,99	<b>0,50</b>	0,66	0,84	0,31	0,53	0,542

RGB renk uzayındaki görüntüleri yatay olarak üç eşit parçaya böldükten sonra hesaplanan renk momenti hassasiyet oranı Çizelge 4.8' de görülmektedir. Ortalama hassasiyet oranı

Öklit Uzaklık, Korelasyon Uzaklık, Kosinüs Uzaklık, Ki Kare Uzaklık ve Cityblock Uzaklık' larında benzer sonuçlar verdi. Fakat diğerlerinde kötü sonuçlar verdi. En yüksek hassasiyet oranını %58,4 ile *Kosinüs Uzaklık* kullanılarak elde edildi.

Çizelge 4.8. RGB-RMY hassasiyet oranı

Kategori	N=10										
	Afrika	Sahil	Bina	Otobüs	Dinozor	Fil	Çiçek	At	Dağ	Yemek	Ortalama
Öklit	0,39	<b>0,49</b>	0,29	0,48	0,99	0,55	0,76	0,92	<b>0,41</b>	0,50	0,577
Histogram	0,18	0,03	0,15	0,33	<b>1,00</b>	0,18	0,18	0,18	0,21	0,50	0,293
Chebychev	0,37	0,45	0,28	0,44	0,99	0,49	0,71	0,88	0,40	0,47	0,548
Korelasyon	0,41	0,45	0,30	0,48	0,99	0,52	<b>0,77</b>	0,91	<b>0,41</b>	0,53	0,576
Kosinüs	<b>0,44</b>	0,46	<b>0,31</b>	0,49	0,98	0,54	0,76	<b>0,93</b>	0,40	<b>0,54</b>	<b>0,584</b>
Spearman	0,35	0,39	0,30	0,29	0,95	0,49	0,73	0,90	0,36	0,47	0,522
Ki Kare	0,39	<b>0,49</b>	0,30	0,49	0,99	<b>0,56</b>	<b>0,77</b>	0,92	0,40	0,51	0,581
Cityblock	0,41	0,47	<b>0,31</b>	<b>0,50</b>	0,99	<b>0,56</b>	<b>0,77</b>	0,91	<b>0,41</b>	0,49	0,582

RGB renk uzayındaki görüntüleri dikey olarak üç eşit parçaya böldükten sonra hesaplanan renk momenti hassasiyet oranı Çizelge 4.9' da görülmektedir. Ortalama hassasiyet oranı %55,1 ile en yüksek *Kosinüs Uzaklık* kullanılarak alındı. RGB-RMD ve RGB-RMT hassasiyet oranı benzer sonuçlar verdi. Fakat RGB-RMY bu yöntemlerden %3,3 oranında daha iyi sonuç verdi.

HSV renk uzayındaki tüm görüntü (HSV-RMT), yatay olarak bölünmüş görüntü (HSV-RMY) ve dikey olarak bölünmüş görüntü (HSV-RMD) için renk momenti hassasiyet oranları sırasıyla Çizelge 4.10, Çizelge 4.11. ve Çizelge 4.12' de görülmektedir. En yüksek hassasiyet oranı HSV-RMT için %44,8 ile *Spearman Uzaklık*, HSV-RMY için %54,0 ile *Cityblock Uzaklık* ve HSV-RMD için %49,6 ile *Cityblock Uzaklık* kullanıldığında alındı.

Çizelge 4.9. RGB-RMD hassasiyet oranı

Kategori	N=10										
	Afrika	Sahil	Bina	Otobüs	Dinozor	Fil	Çiçek	At	Dağ	Yemek	Ortalama
Öklit	0,41	0,47	0,25	0,45	0,99	<b>0,55</b>	<b>0,72</b>	<b>0,86</b>	0,33	0,47	0,550
Histogram	0,24	0,05	0,18	0,27	<b>1,00</b>	0,30	0,08	0,12	0,32	0,27	0,282
Chebychev	0,41	0,42	0,25	0,37	<b>1,00</b>	0,54	0,65	0,84	0,33	0,42	0,519
Korelasyon	<b>0,42</b>	0,44	<b>0,26</b>	<b>0,47</b>	0,99	0,48	0,71	0,81	<b>0,39</b>	0,50	0,548
Kosinüs	<b>0,42</b>	0,43	<b>0,26</b>	<b>0,47</b>	0,99	0,52	0,70	0,84	<b>0,39</b>	<b>0,51</b>	<b>0,551</b>
Spearman	0,35	0,44	0,24	0,30	0,99	0,39	0,64	0,83	0,34	0,42	0,493
Ki Kare	<b>0,42</b>	<b>0,48</b>	<b>0,26</b>	0,45	0,99	0,52	0,69	0,85	0,32	0,46	0,545
Cityblock	<b>0,42</b>	0,47	0,25	<b>0,47</b>	0,99	0,52	0,70	0,84	0,32	0,47	0,546

Çizelge 4.10. HSV-RMT hassasiyet oranı

Kategori	N=10										
	Afrika	Sahil	Bina	Otobüs	Dinozor	Fil	Çiçek	At	Dağ	Yemek	Ortalama
Öklit	0,35	0,23	0,26	0,39	0,95	0,38	0,33	0,44	0,32	0,33	0,398
Histogram	0,40	0,07	0,27	<b>0,58</b>	0,76	0,39	<b>0,49</b>	<b>0,59</b>	0,10	0,30	0,396
Chebychev	0,31	0,22	0,24	0,32	0,93	0,38	0,31	0,40	0,31	0,30	0,371
Korelasyon	0,30	0,23	0,26	0,25	0,89	0,34	0,36	0,48	0,35	0,35	0,379
Kosinüs	0,35	0,22	0,25	0,37	0,94	0,39	0,33	0,45	0,31	0,32	0,392
Spearman	<b>0,41</b>	<b>0,36</b>	0,29	0,35	0,97	0,40	0,41	0,58	0,32	<b>0,40</b>	<b>0,448</b>
Ki Kare	0,36	0,24	0,26	0,39	0,94	0,38	0,33	0,46	0,33	0,33	0,401
Cityblock	<b>0,41</b>	0,28	<b>0,30</b>	0,49	<b>0,96</b>	<b>0,42</b>	0,36	0,54	<b>0,35</b>	0,37	0,447

Çizelge 4.11. HSV-RMY hassasiyet oranı

Kategori	N=10										
	Afrika	Sahil	Bina	Otobüs	Dinozor	Fil	Çiçek	At	Dağ	Yemek	Ortalama
Öklit	0,39	0,24	0,32	0,63	0,95	0,39	0,63	0,47	0,37	0,44	0,481
Histogram	<b>0,49</b>	0,11	<b>0,49</b>	0,41	0,81	0,40	0,64	0,36	0,08	0,24	0,404
Chebychev	0,36	0,22	0,28	0,57	0,95	0,34	0,59	0,36	0,32	0,36	0,434
Korelasyon	0,28	0,27	0,33	0,42	<b>0,96</b>	<b>0,46</b>	<b>0,65</b>	0,51	0,38	0,47	0,472
Kosinüs	0,40	0,25	0,31	0,63	0,95	0,38	0,63	0,47	0,36	0,44	0,482
Spearman	0,37	0,31	0,37	0,44	0,94	0,47	0,64	<b>0,68</b>	0,34	<b>0,52</b>	0,509
Ki Kare	0,40	0,24	0,32	0,63	0,95	0,39	0,63	0,47	0,37	0,44	0,482
Cityblock	<b>0,49</b>	<b>0,30</b>	0,36	<b>0,68</b>	<b>0,96</b>	0,45	0,64	0,61	<b>0,40</b>	0,51	<b>0,540</b>

Çizelge 4.12. HSV-RMD hassasiyet oranı

Kategori	N=10										
	Afrika	Sahil	Bina	Otobüs	Dinozor	Fil	Çiçek	At	Dağ	Yemek	Ortalama
Öklit	0,40	0,25	0,22	0,45	0,97	0,42	0,61	0,38	0,32	0,34	0,435
Histogram	0,44	0,06	<b>0,32</b>	0,51	0,75	0,41	0,61	0,51	0,09	0,22	0,393
Chebychev	0,36	0,23	0,21	0,40	0,96	0,38	0,56	0,31	0,29	0,28	0,398
Korelasyon	0,29	0,24	0,20	0,32	<b>0,98</b>	0,41	<b>0,66</b>	0,43	<b>0,38</b>	0,35	0,424
Kosinüs	0,41	0,23	0,22	0,43	<b>0,98</b>	0,42	0,61	0,37	0,31	0,34	0,431
Spearman	0,33	0,29	0,22	0,37	0,96	<b>0,48</b>	0,67	<b>0,66</b>	0,30	<b>0,41</b>	0,469
Ki Kare	0,40	0,25	0,23	0,45	0,97	0,42	0,61	0,38	0,32	0,34	0,437
Cityblock	<b>0,49</b>	<b>0,30</b>	0,27	<b>0,56</b>	<b>0,98</b>	0,46	0,63	0,52	0,34	0,39	<b>0,496</b>

Test edilen renk momentlerinin birbirleriyle kıyası Çizelge 4.13’ de görülmektedir. Renk momenti RGB renk uzayında HSV renk uzayına göre daha iyi sonuç verdi. RGB renk uzayında da yatay olarak bölünmüş görüntülerin hassasiyet oranı diğerlerine göre daha iyi sonuç verdi. En iyi sonuç RGB-RMY de *Kosinüs Uzaklık* kullanılarak alınmasına rağmen *Ki Kare Uzaklık* ve *Cityblock Uzaklık* da bu uzaklığa benzer sonuçlar verdi. Bu sonuçlara göre çalışmada en yüksek sonucu verdiği için önerilen yöntemde RGB-RMY yöntemi kullanılarak test edildi.


Çizelge 4.13. Renk momentlerinin birbirleriyle kıyası

	RGB			HSV		
	RMT	RMY	RMD	RMT	RMY	RMD
Öklit	0,546	0,577	0,550	0,398	0,481	0,435
Histogram	0,364	0,293	0,282	0,396	0,404	0,393
Chebychev	0,541	0,548	0,519	0,371	0,434	0,398
Korelasyon	0,538	0,576	0,548	0,379	0,472	0,424
Kosinüs	0,537	<b>0,584</b>	0,551	0,392	0,482	0,431
Spearman	0,358	0,522	0,493	0,448	0,509	0,469
Ki Kare	0,551	0,581	0,545	0,401	0,482	0,437
Cityblock	0,542	0,582	0,546	0,447	0,540	0,496

Resim 4.4’ de *Yemek* kategorisine ait sorgu görüntüsünün erişim sonuçları görülmektedir. Erişilen 10 görüntünün hepsi *Yemek* kategorisine ait olarak gelmiştir. Fakat Resim 4.5’ de *Otobüs* kategorisine ait olan sorgu görüntüsünün erişim sonuçlarında 5’ i *Otobüs*, 2’ si *Bina*, diğerleri ise *Afrika*, *Sahil* ve *Dağ* kategorilerine ait olarak geldi. *Otobüs* sorgu görüntüsünü incelediğimizde görüntüde yeşil renkte otobüs, koyu renkte zemin ve arka planda bina ve ağaç görülmektedir. İlişkisiz gelen görüntülere baktığımızda bina ve arka planlarında ağaç olan veya koyu zemine sahip görüntüler olduğu anlaşılır.



Resim 4.4. Yemek kategorisine ait 995 numaralı görüntünün erişim sonuçları (RGB-RMY-Kosinüs Uzaklık)



Resim 4.5. Otobüs kategorisine ait 354 numaralı görüntünün erişim sonuçları (RGB-RMY-Kosinüs Uzaklık)

### 4.3.3. Renk uyum vektörü test sonuçları


CCV hassasiyet oranı Çizelge 4.14' de görülmektedir. *Histogram Kesişim Uzaklığı*, *Sahil*, *Çiçek* ve *Yemek* kategorilerinde en iyi sonucu verdi. *Bina* kategorisinde en iyi sonucu *Spearman Uzaklık* verdi. Diğer kategorilerde ise *Ki Kare Uzaklık* en iyi sonucu verdi. En iyi ortalama hassasiyet oranını ise % 63,9 ile *Ki Kare Uzaklık* verdi.



Çizelge 4.14. CCV hassasiyet oranı

	Afrika	Sahil	Bina	Otobüs	Dinozor	Fil	Çiçek	At	Dağ	Yemek	Ortalama
Öklit	0,55	0,32	0,26	0,50	0,98	0,59	0,67	0,83	0,30	0,60	0,559
Histogram	0,57	<b>0,40</b>	0,37	0,50	0,04	0,42	0,69	<b>0,89</b>	0,28	<b>0,67</b>	0,482
Chebychev	0,47	0,32	0,22	0,45	0,97	0,49	0,60	0,79	0,27	0,58	0,517
Korelasyon	0,53	0,32	0,26	0,42	0,61	0,50	0,71	0,86	0,28	0,49	0,496
Kosinüs	0,53	0,31	0,25	0,45	0,61	0,50	0,70	0,85	0,28	0,52	0,500
Spearman	0,49	0,28	<b>0,47</b>	0,60	0,59	0,47	0,73	0,77	0,40	0,65	0,546
Ki Kare	<b>0,68</b>	0,35	0,40	<b>0,63</b>	<b>1,00</b>	<b>0,66</b>	<b>0,74</b>	<b>0,89</b>	<b>0,40</b>	0,65	<b>0,639</b>
Cityblock	0,61	0,30	0,32	0,51	0,99	0,63	0,72	0,85	0,36	0,59	0,589

Resim 4.6' da *Fil* kategorisine ait sorgu görüntüsünün erişim sonuçları görülmektedir. Benzerlik ölçümü için *Ki Kare Uzaklık* kullanılarak erişilen görüntülerin 9 tanesi ilişkili ve 1 tanesi ilişkisiz olarak geldi. İlişkisiz olarak gelen görüntü *Bina* kategorisine aittir. CCV yöntemi renklerin oluşturduğu bağlı bileşenleri hesap eder. Sorgu görüntüsünde görüldüğü üzere fil rengi olan koyu kahverengi ve yer rengi olan açık kahverengi rengi bağlı bileşen oluşturmaktadır. Bu yüzden Bina görüntüsü her iki bağlı bileşeni içerdiği için erişildi.



Resim 4.6. *Fil* kategorisine ait 577 numaralı görüntü için erişim sonuçları (CCV-Ki Kare Uzaklık)

Resim 4.7' de *At* kategorisine ait sorgu görüntüsü için erişim sonuçları görülmektedir. Resim 4.6' da hassasiyet oranı %90,0 iken bu sorgu görüntüsü için hassasiyet oranı %50,0' dir. Sorgu görüntüsünü incelediğimizde açık ve koyu yeşil renginin büyük bağlı bileşenler oluşturduğu görülmektedir. Aynı zamanda atın rengi de kahverengi bağlı bileşen oluşturmaktadır. Bu yüzden erişilen resimlerde yeşil renginin ağırlıklı olduğu ve resmin bir yerinde kahverengi renginin oluşturduğu bağlı bileşen olması beklenir. Sonuçlara baktığımızda görüntülerin 5 tanesi ilişkili, 5 tanesi ilişkisiz olarak geldi. İlişkisiz gelen resimlerde sorgu görüntüsünü tanımlayan yeşil ve kahverengi bağlı bileşenlerin olduğu görülür.



Resim 4.7. At kategorisine ait 756 numaralı görüntü için erişim sonuçları (CCV-Ki Kare Uzaklık)

#### 4.3.4. Birleştirilen renk yönteminin test sonuçları

Renk histogramı, renk momenti ve CCV yöntemleri tek başlarına kullanıldıklarında ortaya çıkan hassasiyet oranı gözlemlendi. Renk histogramı görüntünün renk dağılımı hakkında bilgi verirken, renk momenti renk dağılımının istatistiksel özellikleri hakkında bilgi verdi. CCV yöntemi ise görüntüdeki renklerin oluşturduğu bağlı bileşenleri hesap ederek görüntüyü tanımladı. Her biri görüntüdeki farklı bir özelliği bulmaya çalıştı. Bu yöntemler tek başlarına kullanıldıklarında belli ölçüde başarılı olmalarına rağmen görüntüyü tanımlamada tam olarak yeterli olmadıkları anlaşıldı. Bu yüzden çalışmada test edilen bu üç

yöntem birleştirerek görüntünün renk özelliğini daha iyi tanımlayan BRY (Birleştirilmiş Renk Yöntemi) önerildi. Çizelge 4.15’ de RH (10, 4, 4), RGB-RMY ve CCV yöntemlerinin birleşmesi ile elde edilen BRY-1’ in hassasiyet oranı görülmektedir. BRY-1 yönteminde *Histogram Kesişim Uzaklık* ve *Cityblock Uzaklık* hariç bütün uzaklıklarda hassasiyet oranında artış gerçekleşti. *Öklit Uzaklık* ile %3,8, *Chebychev Uzaklık* ile %5,9, *Korelasyon Uzaklık* ile %5,1, *Kosinüs Uzaklık* ile %2,9, *Spearman Uzaklık* ile %0,03 ve *Ki Kare Uzaklık* ile %0,02 oranında artış gözlemlendi.

Çizelge 4.15. BRY-1 hassasiyet oranı

Kategori	N=10			
	RH (10, 4, 4)	RGB-RMY	CCV	BRY-1
Öklit	0,614	0,577	0,559	0,652
Histogram	0,718	0,293	0,482	0,703
Chebychev	0,520	0,548	0,517	0,607
Korelasyon	0,612	0,576	0,496	0,663
Kosinüs	0,622	0,584	0,500	0,651
Spearman	0,694	0,522	0,546	0,697
Ki Kare	0,732	0,581	0,639	<b>0,734</b>
Cityblock	0,718	0,582	0,589	0,706

Çizelge 4.16’ da RH (16, 4, 4), RGB-RMY ve CCV yöntemlerinin birleşmesi ile elde edilen BRY-2’ nin hassasiyet oranı görülmektedir. *Histogram Kesişim Uzaklık* ve *Cityblock Uzaklık* hariç tüm uzaklıklarda hassasiyet oranı arttı. *Öklit Uzaklık* ile %4,4, *Chebychev Uzaklık* ile %8,7, *Korelasyon Uzaklık* ile %5,6, *Kosinüs Uzaklık* ile %3,6, *Spearman Uzaklık* ile %0,05 ve *Ki Kare Uzaklık* ile %1,2 oranında artış gözlemlendi. BRY-2 ile en yüksek hassasiyet oranı %74,2 ile *Ki Kare Uzaklık* kullanılarak alındı. Bu sonuç tüm renk yöntemlerinin ayrı ayrı kullanıldığında ortaya çıkan hassasiyet oranından daha yüksektir.

Çizelge 4.16. BRY-2 hassasiyet oranı


Kategori	N=10			
	RH (16, 4, 4)	RGB-RMY	CCV	BRY-2
Öklit	0,606	0,577	0,559	0,650
Histogram	0,725	0,293	0,482	0,706
Chebychev	0,515	0,548	0,517	0,602
Korelasyon	0,614	0,576	0,496	0,670
Kosinüs	0,620	0,584	0,500	0,656
Spearman	0,695	0,522	0,546	0,700
Ki Kare	0,731	0,581	0,639	<b>0,742</b>
City block	0,725	0,582	0,589	0,711

Çizelge 4.17. BRY-2' nin kategori bazında hassasiyet oranı


Kategori	N=10										
	Afrika	Sahil	Bina	Otobüs	Dinozor	Fil	Çiçek	At	Dağ	Yemek	Ortalama
Öklit	0,62	0,41	0,39	0,63	0,99	0,64	0,79	0,95	0,38	0,69	0,650
Histogram	0,78	0,41	0,65	0,78	0,88	0,63	0,80	0,96	0,39	0,77	0,706
Chebychev	0,55	0,38	0,33	0,53	0,99	0,57	0,73	0,91	0,36	0,68	0,602
Korelasyon	0,75	0,38	0,56	0,60	0,97	0,61	0,81	0,97	0,38	0,67	0,670
Kosinüs	0,76	0,37	0,56	0,58	0,97	0,58	0,77	0,95	0,35	0,67	0,656
Spearman	0,71	0,40	<b>0,66</b>	0,68	0,87	0,68	<b>0,85</b>	0,95	0,40	<b>0,80</b>	0,700
Ki Kare	<b>0,81</b>	0,45	0,65	<b>0,79</b>	<b>1,00</b>	<b>0,71</b>	0,84	0,97	<b>0,44</b>	0,77	<b>0,742</b>
Cityblock	0,72	<b>0,47</b>	0,55	0,71	1,00	0,68	0,86	<b>0,98</b>	0,43	0,71	0,711

BRY-2 BRY-1' den %0,8 oranında daha iyi sonuç verdi. Bu yüzden çalışmada önerilen yöntemde BRY-2 yöntemi kullanıldı ve test edildi. Çizelge 4.17' de BRY-2' nin kategori bazında hassasiyet oranı görülmektedir.

Resim 4.8' de Fil kategorisine ait sorgu görüntüsünün farklı renk yöntemlerine göre erişim sonuçları görülmektedir. Sorgu görüntüsüne RH(16, 4, 4) uygulandığında 7 görüntü ilişkili, 3 görüntü ilişkisiz olarak geldi. RGB-RMY yöntemi ile elde edilen erişim sonuçlarında 8 görüntü ilişkili, 2 görüntü ilişkisiz olarak elde edildi. Aynı sorgu görüntüsüne CCV yöntemi uygulandığında 6 görüntü ilişkili, 4 görüntü ilişkisiz olarak elde edildi. En son olarak BRY-2 uygulandığında ise tüm erişilen görüntüler ilişkili olarak elde edildi. Böylece bu sorgu görüntü için yöntemler tek başına kullanıldığında en yüksek %80 olarak elde edilen hassasiyet oranı BRY-2 ile %100' e çıkmış oldu. Bu durum renk yöntemlerinin birleştirilmesinin başarımı arttırdığını gösterdi.




a)



b)

Resim 4.8. a) RM (16, 4, 4) erişim sonuçları b) RGB-RMY erişim sonuçları c) CCV erişim sonuçları d) BRY-2 erişim sonuçları (Ki Kare Uzaklık)



c)



d)

Resim 4.8. (devam) a) RM (16, 4, 4) erişim sonuçları b) RGB-RMY erişim sonuçları c) CCV erişim sonuçları d) BRY-2 erişim sonuçları (Ki Kare Uzaklık)

#### 4.4. Doku Yöntemlerinin Test Sonuçları

Bu çalışmada görüntülerin doku özelliklerini çıkarmak GLCM ve dalgacık dönüşümü yöntemleri test edildi.

##### 4.4.1. GLCM test sonuçları

GLCM hassasiyet oranı Çizelge 4.18' de görülmektedir. Ortalama hassasiyet oranı %48,4 ile en yüksek *Öklit Uzaklık* kullanıldığında alındı. GLCM doku analizi hassasiyet oranı kategori bazında incelendiğinde *Otobüs*, *Dinazor*, *At* ve *Çiçek* kategorilerinde iyi sonuç verirken diğer kategorilerde %35,0' in altında kalmıştır.

Çizelge 4.18. GLCM hassasiyet oranı

	Afrika	Sahil	Bina	Otobüs	Dinozor	Fil	Çiçek	At	Dağ	Yemek	Ortalama
Öklit	0,31	<b>0,35</b>	0,26	0,70	0,94	<b>0,31</b>	0,81	<b>0,58</b>	<b>0,24</b>	<b>0,34</b>	<b>0,484</b>
Histogram	0,08	0,03	0,20	<b>0,81</b>	<b>0,99</b>	0,08	0,60	0,04	0,11	0,28	0,321
Chebychev	0,26	0,33	0,24	0,66	0,91	<b>0,31</b>	<b>0,83</b>	0,56	0,23	0,32	0,463
Korelasyon	0,27	0,29	0,29	0,71	0,60	0,30	0,80	0,52	0,23	0,31	0,431
Kosinüs	0,29	0,32	0,27	0,70	0,92	0,29	0,82	0,53	<b>0,24</b>	0,30	0,468
Spearman	<b>0,33</b>	0,31	0,23	0,52	0,48	0,27	0,57	0,31	0,15	0,22	0,339
Ki Kare	0,31	0,34	0,27	0,67	0,94	0,28	0,81	0,55	<b>0,24</b>	0,32	0,473
City block	0,32	0,34	<b>0,28</b>	0,70	0,95	0,30	0,80	0,57	0,22	<b>0,34</b>	0,481

Resim 4.9' da Fil kategorisine ait sorgu görüntüsünün erişim sonuçları görülmektedir. GLCM yönteminde *Öklit Uzaklık* kullandığında bu sorgu görüntü için 9 tane ilişkili, 1 tane *Dağ* kategorisine ait ilişkisiz görüntüye erişildi. Sorgu görüntüsüne baktığımızda yeşilin hakim olduğu arka plan üzerinde beyaz ve kahverengiden oluşan 3 tane at görülmektedir. Hedef görüntülere baktığımızda 7' sinde kahverengi ve beyaz atların olduğu görüntülere ve 2' sinde beyaz atların olduğu görüntülere erişildi.



Resim 4.9. At kategorisine ait 719 numaralı görüntü için erişim sonuçları (GLCM-Öklit)

Resim 4.10' da *Afrika* kategorisine ait sorgu görüntüsünün erişim sonuçları görülmektedir. GLCM yönteminde *Öklit Uzaklık* kullandığında bu sorgu görüntü için 5 tane ilişkili, 5 tane ilişkisiz görüntüye erişildi. *Afrika* kategorisinde kendine has bir doku özelliği olmadığından bu kategoride hassasiyet oranı genel olarak düşük çıktı.



Resim 4.10. Afrika kategorisine ait 6 numaralı görüntü için erişim sonuçları (GLCM-Öklit Uzaklık)

#### 4.4.2. Dalgacık dönüşümü test sonuçları


Dalgacık doku analizi hassasiyet oranı Çizelge 4.19' da görülmektedir. Bu yöntemde de GLCM' de olduğu gibi *Histogram Kesişim Uzaklık* ve *Spearman Uzaklık* iyi sonuç vermedi. Diğer uzaklıklar birbirlerine yakın sonuçlar verdi. *Afrika* kategorisinde en yüksek hassasiyet oranını %70 ile *Histogram Kesişim Uzaklık* kullanılarak elde edildi. *Sahil* kategorisinde dört farklı uzaklık %42 ile aynı sonucu verdi. *Bina* kategorisinde en yüksek oran %27 oldu. Bu kategoriler arasındaki en düşük orandır. *Otobüs* kategorisinde en yüksek oran %39 oldu. *Dinozor* kategorisinde %99 oranında hassasiyet elde edildi. En iyi ortalama hassasiyet oranı %52,0 ile *Öklit Uzaklık* ile alındı. Kategori bazında incelendiğinde *Afrika*, *Dinazor*, *At*, ve *Çiçek* kategorilerinde diğer kategorilere göre iyi sonuç alınmıştır. Çünkü bu kategorilerin kendilerine has karakteristik doku özelliklerine sahiptirler.



Çizelge 4.19. Dalgacık doku analizi hassasiyet oranı

Kategori	N=10										
	Afrika	Sahil	Bina	Otobüs	Dinozor	Fil	Çiçek	At	Dağ	Yemek	Ortalama
Öklit	0,42	<b>0,42</b>	0,24	<b>0,39</b>	<b>0,99</b>	0,47	0,64	0,87	0,31	0,45	<b>0,520</b>
Histogram	<b>0,70</b>	0,23	<b>0,27</b>	0,13	<b>0,99</b>	0,25	0,09	0,00	0,14	0,09	0,290
Chebychev	0,43	0,40	0,23	<b>0,39</b>	<b>0,99</b>	<b>0,48</b>	0,63	0,86	0,31	0,43	0,514
Korelasyon	0,40	<b>0,42</b>	0,23	0,28	0,95	0,33	<b>0,70</b>	<b>0,88</b>	<b>0,35</b>	0,41	0,495
Kosinüs	0,50	0,38	<b>0,27</b>	<b>0,39</b>	0,97	0,42	0,67	0,87	0,34	<b>0,46</b>	0,527
Spearman	0,68	0,74	0,14	0,33	0,02	0,09	0,66	0,35	0,04	0,10	0,314
Ki Kare	0,44	<b>0,42</b>	0,23	0,37	0,98	0,46	0,64	0,86	0,31	0,44	0,516
Cityblock	0,42	<b>0,42</b>	0,22	0,38	0,98	0,47	0,63	0,87	0,32	0,45	0,517

Resim 4.11 ve Resim 4.12’ de *Dinozor* ve *Çiçek* kategorilerine ait sorgu görüntülerinin erişim sonuçları görülmektedir. *Dinozor* sorgu görüntüsü için hassasiyet oranı %100 iken *Çiçek* sorgu görüntüsü için %90 olarak alındı. *Dinozor* ve *Çiçek* kategorilerinin doku özellikleri belirgin olduğu için hassasiyet oranı yüksek çıktı.



Resim 4.11. Dinozor kategorisine ait 490 numaralı görüntü için erişim sonuçları (Dalgacık-Öklit Uzaklık)



Resim 4.12. Çiçek kategorisine ait 632 numaralı görüntü için erişim sonuçları (Dalgacık-Öklit Uzaklık)

#### 4.4.3. Birleştirilen doku yönteminin test sonuçları

GLCM ve dalgacık dönüşümü yöntemlerinin ayrı ayrı test edildiğinde *Otobüs*, *Dinozor*, *At* ve *Çiçek* kategorilerinde başarılı sonuç verdiği gözlemlendi. Fakat diğer kategorilerde hassasiyet oranı düşük kaldı. Bu yüzden çalışmada test edilen iki farklı doku özellik çıkarım yöntemi birleştirilerek görüntünün doku özelliğini daha iyi tanımlayan BDY (Birleştirilen Doku Yöntemi) önerildi. BDY ile sistemin hassasiyet oranı artırıldı.

Çizelge 4.20' de BDY' nin ortalama hassasiyet oranı ve Çizelge 4.21' de BDY 'nin kategori bazında hassasiyet oranı görülmektedir. *Öklit Uzaklık'* ta %7,7, *Chebychev Uzaklık'* ta %8,0, *Korelasyon Uzaklık'* ta %9,7, *Kosinüs Uzaklık'* ta %10,5, *Spearman Uzaklık'* ta %16,9, *Ki Kare Uzaklık'* ta %8,6 ve *Cityblock Uzaklık'* ta %6,2 oranında artış oldu. Sadece *Histogram Kesişim Uzaklık'* ta artış olmadı. Sonuç olarak BDY ile en yüksek hassasiyet oranını %52,7' den %63,3' e çıkarıldı.


Resim 4.13' de *Yemek* kategorisine ait olan sorgu görüntüsüne GLCM, dalgacık ve önerilen doku yöntemleri uygulandığında erişilen görüntüler görülmektedir. GLCM ve dalgacık yöntemi ayrı ayrı uygulandığında 2 ilişkili, 8 ilişkisiz görüntüye erişildi. Bu iki yöntem birleştirilerek geliştirilen önerilen doku yöntemi uygulandığında ise görüntülerin tamamı ilişkili olarak erişildi.

Çizelge 4.20. BDY hassasiyet oranı

Kategori	GLCM	Dalgacık Dönüşümü	BDY
Öklit	0,484	0,520	0,597
Histogram	0,321	0,290	0,316
Chebychev	0,463	0,514	0,594
Korelasyon	0,431	0,495	0,592
Kosinüs	0,468	0,527	<b>0,633</b>
Spearman	0,339	0,314	0,507
Ki Kare	0,473	0,516	0,602
Cityblock	0,481	0,517	0,578

Çizelge 4.21. BDY' nin kategori bazında hassasiyet oranı

Kategori	N=10										
	Afrika	Sahil	Bina	Otobüs	Dinozor	Fil	Çiçek	At	Dağ	Yemek	Ortalama
Öklit	0,44	0,46	0,29	0,70	0,99	<b>0,58</b>	<b>0,91</b>	0,77	0,38	0,44	0,597
Histogram	0,09	0,02	0,25	0,69	<b>1,00</b>	0,17	0,45	0,06	0,18	0,24	0,316
Chebychev	0,42	0,47	0,31	0,69	0,99	<b>0,58</b>	<b>0,91</b>	0,77	0,40	0,41	0,594
Korelasyon	0,45	0,44	<b>0,36</b>	0,60	0,89	0,45	0,89	<b>0,87</b>	0,40	0,56	0,592
Kosinüs	<b>0,55</b>	0,43	<b>0,36</b>	<b>0,71</b>	0,99	0,54	0,89	0,85	<b>0,46</b>	<b>0,55</b>	<b>0,633</b>
Spearman	0,40	0,47	0,27	0,56	0,75	0,26	0,83	0,65	0,42	0,46	0,507
Ki Kare	0,46	<b>0,48</b>	0,29	0,69	0,99	0,57	<b>0,91</b>	0,80	0,36	0,46	0,602
City block	0,44	0,45	0,28	0,70	0,99	0,53	<b>0,91</b>	0,73	0,34	0,43	0,578



a)



b)



c)

Resim 4.13. Yemek kategorisine ait 944 numaralı görüntü için erişim sonuçları a) GLCM erişim sonuçları b) Dalgacık dönüşümü erişim sonuçları c) BDY erişim sonuçları (Kosinüs Uzaklık)

#### 4.5. Önerilen Yöntemin Test Sonuçları

Çizelge 4.22' de BRY-1 ve BDY' nin birleştirilmesi sonucu elde edilen önerilen sistem 1' in hassasiyet oranı görülmektedir. Renk ve doku özellikleri birleştiğinde sistemin hassasiyet oranında artış gözlemlendi. Sistemin en yüksek hassasiyet oranı bu yöntemle %2,4 artarak %75,8 oranına ulaştı.

Çizelge 4.22 Önerilen yöntem 1' in hassasiyet oranı

	BRY-1	BDY	Önerilen yöntem 1
Öklit	0,652	0,597	0,682
Histogram	0,703	0,316	0,717
Chebychev	0,607	0,594	0,662
Korelasyon	0,663	0,592	0,709
Kosinüs	0,651	0,633	0,692
Spearman	0,697	0,507	0,710
Ki Kare	0,734	0,602	<b>0,758</b>
City block	0,706	0,578	0,712

Çizelge 4.23' de BDY-2 ve BDY' nin birleştirilmesi sonucu elde edilen önerilen sistem 2' in hassasiyet oranı görülmektedir. Bu yöntemde *Ki Kare Uzaklık* kullanılarak elde edilen ortalama hassasiyet oranı %2,0 artarak %76,2' ye ulaştı. Önerilen sistem 2' nin hassasiyet oranı önerilen sistem 1' e göre %0,4 ile daha iyi sonuç verdi.

Çizelge 4.23. Önerilen yöntem 2' nin hassasiyet oranı

	BRY-2	BDY	Önerilen yöntem 2
Öklit	0,650	0,597	0,679
Histogram	0,706	0,316	0,720
Chebychev	0,602	0,594	0,660
Korelasyon	0,670	0,592	0,715
Kosinüs	0,656	0,633	0,694
Spearman	0,700	0,507	0,708
Ki Kare	0,742	0,602	<b>0,762</b>
City block	0,711	0,578	0,715

Resim 4.14' de *Dağ* kategorisine ait sorgu görüntüsünün erişim sonuçları görülmektedir. BRY- 2 ile 6 ilişkili görüntü, BDY ile 5 ilişkili görüntü ve bu iki yöntem birleştirilerek oluşturulan önerilen yöntem 2 ile 10 ilişkili görüntü geldi.



a)



b)

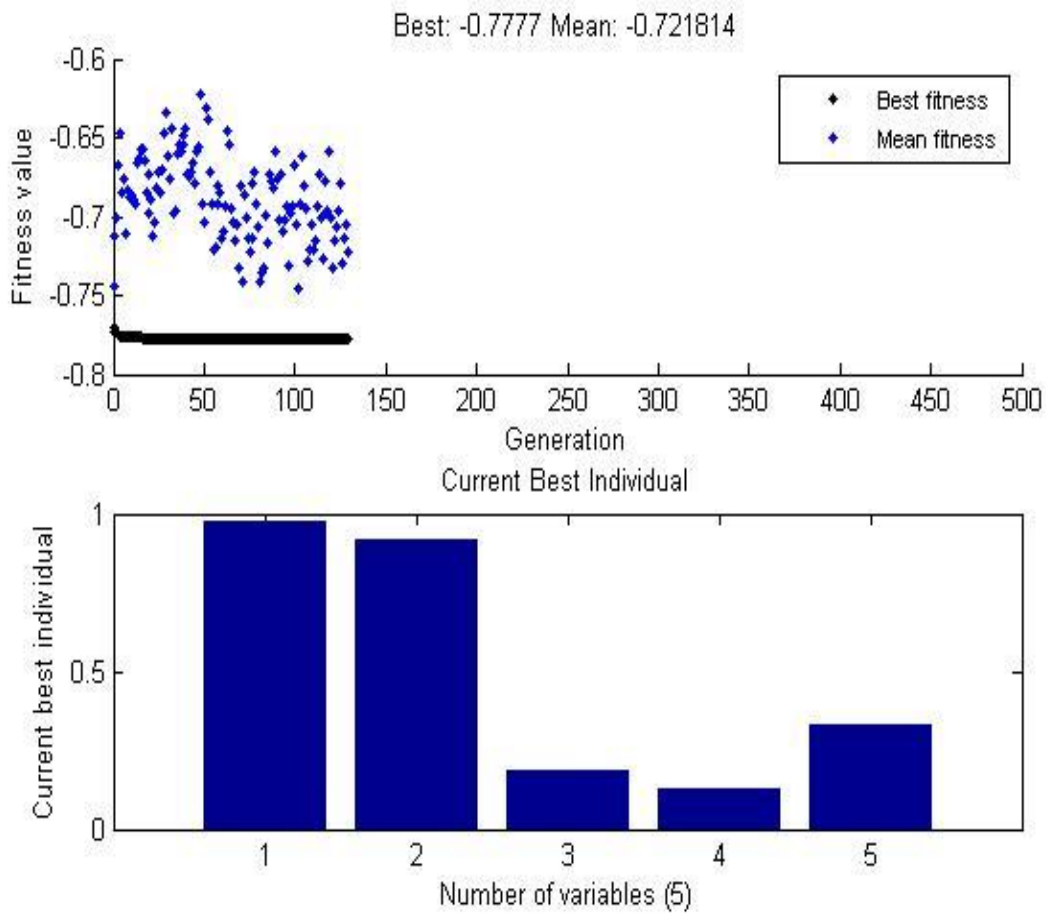


c)

Resim 4.14. Dağ kategorisine ait 891 numaralı görüntü için erişim sonuçları a) BRY-2 erişim sonuçları b) BDY erişim sonuçları c) Önerilen sistem 2 erişim sonuçları (Ki Kare Uzaklık)

#### 4.6. Ağırlıklı Önerilen Yöntemin Test Sonuçları

Şekil 4.1' de önerilen yöntem 2' de *Ki Kare Uzaklık*' da genetik algoritma kullanarak elde edilen ağırlıklandırma sonuçları görülmektedir. Yaklaşık 130 iterasyon sonucunda elde edilen en yüksek uygunluk değeri %77,77 olarak elde edildi. Aynı zamanda yöntemlerin ağırlıkları renk histogramı için %38, renk momenti için %36, CCV için %7, Dalgacık dönüşümü için %5 ve GLCM için %13 olarak hesap edildi.



Şekil 4.1. GA kullanılarak elde edilen yöntemlerin ağırlıkları

Çizelge 4.24' de GA kullanılarak ağırlıklandırılan önerilen yöntem 2' nin hassasiyet oranı görülmektedir. GA kullanıldığında kategori bazında hassasiyet oranı *Afrika* için %4, *Bina* için %8, *At* için %1, *Dağ* için %1 ve *Yemek* için %5 oranında arttı. Diğer kategorilerde hassasiyet oranı değişmedi. Sistemin genel ortalaması %1,6 oranında arttı.

Çizelge 4.24. Ağırlıklı önerilen yöntemin hassasiyet oranı (Ki Kare Uzaklık)

	Önerilen Yöntem 2	Ağırlıklı önerilen yöntem
Afrika	0,77	0,81
Sahil	0,52	0,52
Bina	0,59	0,67
Otobüs	0,84	0,84
Dinozor	1,00	1,00
Fil	0,73	0,73
Çiçek	0,96	0,96
At	0,97	0,98
Dağ	0,49	0,50
Yemek	0,74	0,79
Ortalama	0,762	<b>0,778</b>


Çizelge 4.25' de GA kullanılarak elde edilen ağırlıklı önerilen yöntemin *Ki Kare Uzaklık* kullanılarak farklı sayılarda görüntülere erişildiğine elde edilen kategori bazında ortalama hassasiyet oranı görülmektedir.

Çizelge 4.25. Ağırlıklı önerilen yöntemin farklı erişim sayılarındaki hassasiyet oranı (Ki Kare Uzaklık)

Kategori	Erişilen görüntü sayısı					
	L=10	L=20	L=30	L=40	L=50	L=100
Afrika	0,81	0,77	0,73	0,70	0,66	0,51
Sahil	0,52	0,47	0,43	0,41	0,39	0,32
Bina	0,67	0,60	0,55	0,50	0,47	0,36
Otobüs	0,84	0,81	0,78	0,76	0,73	0,60
Dinozor	1,00	1,00	1,00	0,99	0,99	0,94
Fil	0,73	0,61	0,55	0,51	0,48	0,38
Çiçek	0,96	0,93	0,92	0,91	0,89	0,77
At	0,98	0,96	0,94	0,92	0,89	0,68
Dağ	0,49	0,45	0,42	0,40	0,37	0,31
Yemek	0,79	0,72	0,68	0,63	0,60	0,47
Ortalama	0,778	0,731	0,699	0,673	0,648	0,535



Resim 4.15’ de *Afrika* kategorisine ait sorgu görüntüsü için erişim sonuçları görülmektedir. GA kullanılmadan eşit ağırlıklarla birleştirilen önerilen yöntem 2’ de 5 tane ilişkili görüntüye erişildi. GA ile ağırlıklar optimize edildikten sonra aynı sorgu görüntüsü için erişilen görüntü sayısı 8’ e çıktı. Böylece bu sorgu görüntüsü için hassasiyet oranını %30 oranında artarak %80’ e çıktı.



Resim 4.15. Afrika kategorisine ait 50 numaralı görüntü için erişim sonuçları a) Önerilen yöntem 2 b) Ağırlıklı önerilen yöntem (Ki Kare Uzaklık)

Resim 4.16’ da *Yemek* kategorisine ait sorgu görüntüsü için erişim sonuçları görülmektedir. Önerilen yöntem 2 kullanıldığında 7 görüntü ilişkili, 3 görüntü ilişkisiz olarak geldi. İlişkisiz gelen görüntülerin 2’ si *Afrika* 1’ i *Bina* kategorisine aittir. Yöntemler GA ile ağırlıklandırıldıktan sonra aynı sorgu görüntüsü için tekrar 10 farklı görüntüye erişildi. Bu sefer 9 görüntü ilişkili, 1 görüntü ilişkisiz olarak geldi. Böylece GA ile bu sorgu görüntüsünün hassasiyet oranı %20 arttı.



a)



b)

Resim 4.16. Yemek kategorisine ait 903 numaralı görüntü için erişim sonuçları a) Önerilen yöntem 2 b) Ağırlıklı önerilen yöntem (Ki Kare Uzaklık)

Resim 4.17' de *Bina* kategorisine ait sorgu görüntüsü için erişim sonuçları görülmektedir. Önerilen yöntem 2 kullanıldığında 6 görüntü ilişkili, 4 görüntü ilişkisiz olarak geldi. İlişkisiz görüntülerin hepsi *Otobüs* kategorisine aittir. Yöntemler GA ile ağırlıklandırıldıktan sonra aynı sorgu görüntüsü için tekrar 10 farklı görüntüye erişildi. Bu sefer tüm görüntüler ilişkili olarak geldi. Böylece GA ile bu sorgu görüntüsünün hassasiyet oranı %40 arttı.



a)



b)

Resim 4.17. Bina kategorisine ait 217 numaralı görüntü için erişim sonuçları a) Önerilen yöntem 2 b) Ağırlıklı önerilen yöntem (Ki Kare Uzaklık)

#### 4.7. Ağırlıklı Önerilen Yöntemin Diğer Yöntemlerle Kıyaslanması

Çizelge 4.26' da N=10 için ağırlıklı önerilen yöntemin yapılmış çalışmalarla olan kıyası görülmektedir. Salmi ve Boucheham [13] %62,0, Singh ve Hemachandran [19] %58,1, Subrahmanyam ve arkadaşları [31] %74,0, Vimina ve Jacob [35] %70,3, Gonde ve arkadaşları [42] %66,0 ve Gali ve arkadaşları [72] %76,5 hassasiyet oranı elde etmiştir. Çalışmada ağırlıklı önerilen yöntemle %77,8 hassasiyet oranıyla yukarıda anlatılan çalışmalardan daha iyi sonuç alınmıştır.

Çizelge 4.27' de N=20 için ağırlıklı önerilen yöntemin yapılmış çalışmalarla olan kıyası görülmektedir. Vimina ve Jacob [35] %64,6, Thakkar ve Kale [43] %61,4, Lin ve arkadaşları [73] %72,7 ve Banerjee ve arkadaşları [74] %72,9 hassasiyet oranı elde etmiştir. Çalışmada

ağırlıklı önerilen yöntemle %73,1 hassasiyet oranıyla yukarıda anlatılan çalışmalardan daha iyi sonuç alınmıştır.

Çizelge 4.28' de N=30 ve N=40 için ağırlıklı önerilen yapılmış çalışmalarla olan kıyası görülmektedir. N=30 için Chaudhary ve Pithadia [75] ortalama hassasiyet oranını %69,5 olarak elde etmişlerdir. Çalışmada bu oran %0,04 artırılarak %69,9 olarak elde edildi. N=40 için Banerjee ve arkadaşları [74] %65,9 ve Tajeripour ve arkadaşları %67,2 hassasiyet oranı elde etmiştir. Çalışmada hassasiyet oranı %67,3 ile önceki çalışmalardan daha iyi sonuç verdi.

Çizelge 4.29' da N=50 ve N=100 için ağırlıklı önerilen yöntemin yapılmış çalışmalarla olan kıyası görülmektedir. N=50 için Vimina ve Jacob [35] ortalama hassasiyet oranını %57,6 elde etmiştir. Çalışmada bu oran %7,2 artırılarak %64,8 olarak elde edildi. N=100 için Kavitha ve arkadaşları [54] %44,5 ve Vimina ve Jacob [35] %45,4 hassasiyet oranı elde etmiştir. Çalışmada hassasiyet oranı %53,5 ile önceki çalışmalardan daha iyi sonuç verdi.

Çizelge 4.26. Ağırlıklı önerilen yöntemin diğer yöntemlerle kıyası (N=10)

Kategori	Erişilen görüntü sayısı (N=10)						Ağırlıklı önerilen yöntem
	[19]	[13]	[42]	[35]	[31]	[72]	
Afrika	0,61	0,68	0,64	0,72	0,78	0,72	0,81
Sahil	0,45	0,45	0,50	0,45	0,49	0,59	0,52
Bina	0,29	0,40	0,47	0,54	0,59	0,63	0,67
Otobüs	0,65	0,62	0,73	0,86	0,91	0,97	0,84
Dinozor	0,89	0,98	1,00	1,00	0,99	1,00	1,00
Fil	0,32	0,63	0,58	0,66	0,61	0,77	0,73
Çiçek	0,6	0,86	0,91	0,91	0,91	0,94	0,96
At	0,84	0,64	0,89	0,89	0,92	0,93	0,98
Dağ	0,56	0,46	0,33	0,35	0,46	0,41	0,49
Yemek	0,6	0,58	0,55	0,65	0,73	0,70	0,79
Ortalama	0,581	0,620	0,660	0,703	0,740	0,765	<b>0,778</b>

Çizelge 4.27. Ağırlıklı önerilen yöntemin diğer yöntemlerle kıyası (N=20)

Kategori	Erişilen görüntü sayısı (N=20)				Ağırlıklı önerilen yöntem
	[43]	[35]	[73]	[74]	
Afrika	0,71	0,65	0,68	0,61	0,77
Sahil	0,77	0,40	0,54	0,56	0,47
Bina	0,91	0,46	0,56	0,64	0,60
Otobüs	0,79	0,83	0,89	0,73	0,81
Dinozor	0,03	1,00	0,99	0,95	1,00
Fil	0,54	0,56	0,66	0,77	0,61
Çiçek	0,76	0,86	0,89	0,83	0,93
At	0,62	0,85	0,80	0,95	0,96
Dağ	0,58	0,29	0,52	0,68	0,45
Yemek	0,43	0,57	0,73	0,57	0,72
Ortalama	0,614	0,646	0,727	0,729	<b>0,731</b>

Çizelge 4.28. Ağırlıklı önerilen yöntemin diğer yöntemlerle kıyası (N=30 ve N=40)

Kategori	N=30		N=40		
	[75]	Ağırlıklı Önerilen Yöntem	[74]	[76]	Ağırlıklı Önerilen Yöntem
Afrika	0,59	0,73	0,58	0,57	0,70
Sahil	0,62	0,43	0,53	0,54	0,41
Bina	0,70	0,55	0,56	0,61	0,50
Otobüs	0,94	0,78	0,63	0,72	0,76
Dinozor	0,97	1,00	0,92	0,95	0,99
Fil	0,57	0,55	0,66	0,62	0,51
Çiçek	0,92	0,92	0,71	0,74	0,91
At	0,55	0,94	0,83	0,80	0,92
Dağ	0,67	0,42	0,62	0,63	0,40
Yemek	0,42	0,68	0,55.2	0,56	0,63
Ortalama	0,695	<b>0,699</b>	0,659	0,672	<b>0,673</b>

Çizelge 4.29. Ağırlıklı önerilen yöntemin diğer yöntemlerle kıyası (N=50 ve N=100)

Kategori	N=50		N=100		
	[35]	Ağırlıklı Önerilen Yöntem	[54]	[35]	Ağırlıklı Önerilen Yöntem
Afrika	0,52	0,66	0,41	0,41	0,51
Sahil	0,33	0,39	0,32	0,28	0,32
Bina	0,36	0,47	0,37	0,29	0,36
Otobüs	0,76	0,73	0,66	0,61	0,60
Dinozor	0,99	0,99	0,43	0,95	0,94
Fil	0,44	0,48	0,39	0,35	0,38
Çiçek	0,74	0,89	0,87	0,57	0,77
At	0,74	0,89	0,35	0,50	0,68
Dağ	0,43	0,37	0,34	0,21	0,31
Yemek	0,46	0,60	0,31	0,37	0,47
Ortalama	0,576	<b>0,648</b>	0,445	0,454	<b>0,535</b>

## 5. SONUÇ VE ÖNERİLER

MTGE sistemlerinin olumsuzluklarını gidermek için ortaya çıkan İTGE sistemleri 1980'lerden bu yana aktif bir akademik çalışma alanı olmuştur. İTGE sistemlerinin amacı büyük görüntü veritabanı arasından doğru görüntüleri getirmesidir. Bu amacı gerçekleştirmek için yapılmış çalışmalarda insanın görsel algısını taklit eden birçok yöntem geliştirilmiştir. Fakat hiçbir yöntem doğru görüntülere erişimde tam olarak insanın görsel algısı gibi başarıya ulaşmamıştır.

Çalışmada probleme katkıda bulunmak için bir İTGE sistemi tasarlandı. Görüntülerin renk ve doku görsel özellikleri kullanılarak doğru görüntülere erişim başarıları artırıldı. Görüntülerin renk görsel özellikleri için renk histogramı, renk momenti ve renk uyum vektörü kullanıldı. Bu yöntemler görüntünün farklı renk özelliklerini tanımladığı için birleştirildi. Böylece görüntülerin renk özelliğini daha kapsamlı inceleyen, daha etkin ve daha gelişmiş bir birleşmiş renk yöntemi önerildi. Görüntülerin doku görsel özelliklerini çıkarmak için GLCM ve dalgacık dönüşümü yöntemleri kullanıldı. Bu yöntemler görüntünün farklı doku bilgisini hesap ettiğinden dolayı birleştirilerek görüntülerin doku özelliğini daha ayrıntılı hesap eden birleşmiş doku yöntemi önerildi. Birleşmiş renk ve doku yöntemi beraber kullanılarak görüntülerin renk ve doku özelliklerini hesap eden bir yöntem geliştirildi. Genetik algoritma kullanılarak önerilen yöntemde kullanılan yöntemlerin ağırlıkları optimize edilerek ağırlıklı önerilen yöntem geliştirildi.

Tasarlanan İTGE sisteminde ağırlık önerilen yöntemin performansını test etmek için WANG veritabanı kullanıldı. Ayrıca mevcut diğer İTGE sistemleriyle karşılaştırıldı. Elde edilen sonuçlar tasarlanan İTGE sisteminin güzel ve etkin performans ortaya koyduğunu gösterdi. *Afrika* kategorisinde %81, *Sahil* kategorisinde %52, *Bina* kategorisinde %67, *Otobüs* kategorisinde %84, *Dinozor* kategorisinde %100, *Fil* kategorisinde %73, *Çiçek* kategorisinde %96, *At* kategorisinde %98, *Dağ* kategorisinde %49, *Yemek* kategorisinde %79 ve ortalamada %77,8 hassasiyet oranı elde edildi.

Gelecekte renk ve doku görsel özelliklerinin yanında şekil gibi başka görsel özellikler eklenerek, kullanıcı geri bildirimini oluşturularak, farklı optimizasyon teknikleri ile

yöntemlerin ağırlıklandırılması yapılarak, semantik ve görsel içerik birleştirilerek ve farklı veritabanları kullanılarak sistemin performansı üzerinde çalışılabilir.





## KAYNAKLAR

1. Sethi, I. K., Coman, I. L. and Stan, D. (2001). Mining association rules between low-level image features and high-level concepts. *Aerospace/Defense Sensing, Simulation, and Controls*, 434, 279-290.
2. Faloutsos, C., Barber, R., Flickner, M., Hafner, J., Niblack, W., Petkovic, D. and Equitz, W. (1994). Efficient and effective querying by image content. *Journal of intelligent information systems*, 3(3-4), 231-262.
3. Pentland, A., Picard, R. W. and Sclaroff, S. (1996). Photobook: Content-based manipulation of image databases. *International journal of computer vision*, 18(3), 233-254.
4. Smith, J. R. and Chang, S. F. (1997, Şubat). VisualSEEK: a fully automated content-based image query system. *Proceedings of the fourth ACM international conference on Multimedia*, 87-98.
5. Ma, W. Y. and Manjunath, B. S. (1999). Netra: A toolbox for navigating large image databases. *Multimedia systems*, 7(3), 184-198.
6. Wang, J. Z., Li, J. and Wiederhold, G. (2001). SIMPLIcity: Semantics-sensitive integrated matching for picture libraries. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 23(9), 947-963.
7. Gonzalez, R. C. ve Woods, R. E. (2014). *Sayısal Görüntü İşleme*. Ankara: Palme Yayıncılık
8. Yılmaz, İ., Güllü, M., Baybura, T. ve Erdoğan, A. O. (2002). Renk Uzayları ve Renk Dönüşüm Programı (RDP). *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 2(2), 19-35.
9. Riaz, F., Hassan, A., Rehman, S. and Qamar, U. (2013). Texture classification using rotation-and scale-invariant gabor texture features. *Signal Processing Letters, IEEE*, 20(6), 607-610.
10. Swain, M. J. and Ballard, D. H. (1991). Color indexing. *International journal of computer vision*, 7(1), 11-32.
11. Zhang, L., Wang, L. and Lin, W. (2012). Generalized biased discriminant analysis for content-based image retrieval. *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on*, 42(1), 282-290.
12. Alata, O., Burie, J. C., Moussa, A. and Fernandez-Maloigne, C. (2011). Choice of a pertinent color space for color texture characterization using parametric spectral analysis. *Pattern Recognition*, 44(1), 16-31.
13. Salmi, M. and Boucheham, B. (2014). Content Based Image Retrieval Based on Cell Color Coherence Vector (Cell-Ccv). *ISKO-Maghreb: Concepts and Tools for knowledge Management*, 1-5.

14. Wan, S., Jin, P. and Yue, L. (2011). An Effective Image Retrieval Technique Based on Color Perception. *Image and Graphics (ICIG), 2011 Sixth International Conference on*, 1017-1022.
15. Stehling, R. O., Nascimento, M. A. and Falcão, A. X. (2003). Cell histograms versus color histograms for image representation and retrieval. *Knowledge and Information Systems*, 5(3), 315-336.
16. Manjunath, B. S., Ohm, J. R., Vasudevan, V. V. and Yamada, A. (2001). Color and texture descriptors. *Circuits and Systems for Video Technology, IEEE Transactions on*, 11(6), 703-715.
17. Liu, Y., Zhang, D. and Lu, G. (2008). Region-based image retrieval with high-level semantics using decision tree learning. *Pattern Recognition*, 41(8), 2554-2570.
18. Stricker, M. A. and Orengo, M. (1995). Similarity of color images. *ISveT/SPIE's Symposium on Electronic Imaging: Science ve Technology*, 381-392.
19. Singh, S. M. and Hemachandran, K. (2012). Image Retrieval based on the combination of Color Histogram and Color Moment. *International Journal of Computer Applications*, 58(3), 27-34.
20. Patil, S. M. and Patil, V. K. (2015). CCV based image retrieval for FMIQ with confined histogram refinement. *International of Journal of Innovative Research in Electirical*, 3(1).
21. Ravani, R., Mirali, M. R. and Baniasadi, M. (2010). Parallel CBIR system based on color coherence vector. *17th International Conference on Systems, Signals and Image Processing*, 518-521.
22. Al-Hamami, A. and Al-Rashdan, H. (2010). Improving the Effectiveness of the Color Coherence Vector. *International Arab Journal Information Technology*, 7(3), 324-332.
23. Ojala, T., Pietikainen, M. and Harwood, D. (1994). Performance evaluation of texture measures with classification based on Kullback discrimination of distributions. *Pattern Recognition, Proceedings of the 12th IAPR International Conference on*, 1, 582-585.
24. Rao, L. K. and Rao, D. V. (2015). Local quantized extrema patterns for content-based natural and texture image retrieval. *Human-centric Computing and Information Sciences*, 5(1), 1-24.
25. Ahonen, T., Hadid, A. and Pietikainen, M. (2006). Face description with local binary patterns: Application to face recognition. *Pattern Analysis and Machine Intelligence*, 28(12), 2037-2041.
26. Tan, X. and Triggs, B. (2010). Enhanced local texture feature sets for face recognition under difficult lighting conditions. *Image Processing*, 19(6), 1635-1650.

27. Takala, V., Ahonen, T. and Pietikäinen, M. (2005). Block-based methods for image retrieval using local binary patterns. *Image analysis*, 882-891.
28. Heikkilä, M., Pietikäinen, M. and Schmid, C. (2009). Description of interest regions with local binary patterns. *Pattern recognition*, 42(3), 425-436.
29. ul Hussain, S. and Triggs, B. (2012). Visual recognition using local quantized patterns. *Computer Vision*, 716-729.
30. Murala, S., Maheshwari, R. P. and Balasubramanian, R. (2012). Directional local extrema patterns: a new descriptor for content based image retrieval. *International Journal of Multimedia Information Retrieval*, 1(3), 191-203.
31. Subrahmanyam, M., Maheshwari, R. P. and Balasubramanian, R. (2012). Local maximum edge binary patterns: a new descriptor for image retrieval and object tracking. *Signal Processing*, 92(6), 1467-1479.
32. Murala, S., Maheshwari, R. P. and Balasubramanian, R. (2012). Local tetra patterns: a new feature descriptor for content-based image retrieval. *Image Processing*, 21(5), 2874-2886.
33. Reddy, A. H. and Chandra, N. S. (2015). Local opponent color space extrema patterns for content based natural and texture image retrieval. *AEU-International Journal of Electronics and Communications*, 69(1), 290-298.
34. Haralick, R. M., Shanmugam, K. and Dinstein, I. H. (1973). Textural features for image classification. *Systems, Man and Cybernetics*, (6), 610-621.
35. Vimina, E. R. and Jacob, K. P. (2013). Content based image retrieval using low level features of automatically extracted regions of interest. *Journal of Image and Graphics*, 1(1), 7-11.
36. Tamura, H., Mori, S. and Yamawaki, T. (1978). Textural features corresponding to visual perception. *Systems, Man and Cybernetics*, 8(6), 460-473.
37. Puviarasan, N., Bhavani, R. and Vasanthi, A. (2014). Image Retrieval Using Combination of Texture and Shape Features. *Image*, 3(3), 5873-5877.
38. Verma, M., Raman, B. and Murala, S. (2015, May). Wavelet Based Directional Local Extrema Patterns for Image Retrieval on Large Image Database. *Advances in Computing and Communication Engineering (ICACCE), 2015 Second International Conference on*, 649-654.
39. Wang, J. Z., Wiederhold, G., Firschein, O. and Wei, S. X. (1998). Content-based image indexing and searching using Daubechies' wavelets. *International Journal on Digital Libraries*, 1(4), 311-328.
40. Giveki, D., Soltanshahi, A. and Tarrah, F. S. H. (2015). A New Content Based Image Retrieval Model Based on Wavelet Transform. *Journal of Computer and Communications*, 3, 66-73.

41. Arai, K. and Rahmad, C. (2012). Wavelet based image retrieval method. *International Journal Advanced Computer Scine Application (IJACSA)*, 3(4), 6-11.
42. Gonde, A. B., Maheshwari, R. P. and Balasubramanian, R. (2010, Aralık). Complex wavelet transform with vocabulary tree for content based image retrieval. *Proceedings of the Seventh Indian Conference on Computer Vision, Graphics and Image Processing*, 359-366.
43. Thakkar, M. R. and Kale, M. O. (2014). Get High Precision in Content-Based Image Retrieval using Combination of Color, Texture and Shape Features. *International Journal of Engineering Development and Research*, 2(2), 1988-1993.
44. Afifi, A. J. and Ashour, W. M. (2012). Content-based image retrieval using invariant color and texture features. In *Digital Image Computing Techniques and Applications (DICTA), 2012 International Conference on*, 1-6.
45. Irtaza, A., Jaffar, M. A. and Mahmood, M. T. (2013). Semantic image retrieval in a grid computing environment using support vector machines. *The Computer Journal*, 57(2), 205-216.
46. Anusha, M. V., Reddy, M. V. U. and Ramashri, T. (2014). Content Based Image Retrieval Using Color Moments and Texture. *International Journal of Engineering Research and Technology*, 3(2), 2812-2815.
47. Malik, F. and Baharudin, B. (2013). Analysis of distance metrics in content-based image retrieval using statistical quantized histogram texture features in the DCT domain. *Journal of King Saud University-Computer and Information Sciences*, 25(2), 207-218.
48. Thepade, S. D. and Shinde, Y. D. (2015). Improvisation of Content Based Image retrieval using Color Edge Detection with various Gradient Filters and Slope Magnitude Method. *Computing Communication Control and Automation (ICCUBEA), 2015 International Conference on*, 625-628.
49. Chaudhry, A., Ullah, J., Jaffar, M. A., Kim, J. Y. and Tuan, T. A. (2012). Human Activity Recognition System: Using Improved Crossbreed Features and Artificial Neural Network. *Life Science Journal*, 9(4), 5351-5356.
50. Nugroho, S. and Utomo, D. (2013). Rotation Invariant Indexing For Image Using Zernike Moments and RTree. *Telecommunication Computing Electronics and Control*, 9(2), 335-340.
51. Rao, C., Kumar, S. S. and Mohan, B. C. (2010). Content based image retrieval using exact legendre moments and support vector machine. *The International Journal of Multimedia and its applications (IJMA)*, 2(2), 69-79.
52. Mohammadi, S. M., Helfroush, M. S. and Kazemi, K. (2012). Novel shape-texture feature extraction for medical X-ray image classification. *International Journal of Innovative Computing, Information and Control*, 8, 659-76.

- 53.** Kaur, S. and Banga, D. V. K. (2013). Content based image retrieval: Survey and comparison between rgb and hsv model. *International Journal of Engineering Trends and Technology*, 4(4), 575-579.
- 54.** Kavitha, C., Rao, D. B. P. and Govardhan, D. A. (2011). Image retrieval based on color and texture features of the image sub-blocks. *International Journal of Computer Applications*, 15(7), 0975–8887.
- 55.** Huang, Z. C., Chan, P. P., Ng, W. W. and Yeung, D. S. (2010, Temmuz). Content-based image retrieval using color moment and Gabor texture feature. In *Machine Learning and Cybernetics (ICMLC), 2010 International Conference on*, 2, 719-724.
- 56.** Huang, M., Shu, H., Ma, Y. and Gong, Q. (2015). Content-based image retrieval technology using multi-feature fusion. *Optik-International Journal for Light and Electron Optics*, 126(19), 2144-2148.
- 57.** Soh, L. K. and Tsatsoulis, C. (1999). Texture analysis of SAR sea ice imagery using gray level co-occurrence matrices. *Geoscience and Remote Sensing*, 37(2), 780-795.
- 58.** Altun, A. A. ve Allahverdi, N. (2007). Filtreleme teknikleri ile iyileştirilmiş parmak izlerini yapay sinir ağları ile tanımadada yeni bir yaklaşım. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 22(2), 227-236.
- 59.** Übeyli, E. D. ve Güler, İ. Dalgacık dönüşümü ile EGG işaretlerinden çıkarılan öznelik vektörleri üzerinde istatistiksel işlemlerin gerçekleştirilmesi. *Elektrik-Elektronik-Bilgisayar Mühendisliği Sempozyumu ELECO*, 230-234.
- 60.** Jain, A., Nandakumar, K., & Ross, A. (2005). Score normalization in multimodal biometric systems. *Pattern recognition*, 38(12), 2270-2285.
- 61.** Nixon, M., Nixon, M. S. and Aguado, A. S. (2012). *Feature extraction ve image processing for computer vision*. Southampton: Academic Press.
- 62.** Rubner, Y., Tomasi, C. and Guibas, L. J. (2000). The earth mover's distance as a metric for image retrieval. *International journal of computer vision*, 40(2), 99-121.
- 63.** Kaur, S. and Aggarwal, D. (2013). Image Content Based Retrieval System using Cosine Similarity for Skin Disease Images. *Advances in Computer Science: an International Journal*, 2(4), 89-95.
- 64.** Pedronette, D. C. G. and Torres, R. D. S. (2010). Distances correlation for re-ranking in content-based image retrieval. *2010 23rd SIBGRAPI-Conference on Graphics, Patterns and Images*, 1-8.
- 65.** Holland, J. H. (1975). *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*. Cambridge: Michigan Press.

66. Lin, C. H., Chen, H. Y. and Wu, Y. S. (2014). Study of image retrieval and classification based on adaptive features using genetic algorithm feature selection. *Expert Systems with Applications*, 41(15), 6611-6621.
67. Ligade, A. N. and Patil, M. R. (2013). Optimized content based image retrieval using genetic algorithm with relevance feedback technique. *International journal of computer science engineering and information technology research*, 3(4), 49-54.
68. Güçlü, A. (2015). *Yüksek Gerilim Tekniğinde Genetik Algoritma Uygulamaları*. Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
69. Li, J. and Wang, J. Z. (2003). Automatic linguistic indexing of pictures by a statistical modeling approach. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 25(9), 1075-1088.
70. Wang, J. Z., Li, J. and Wiederhold, G. (2001). SIMPLicity: Semantics-sensitive integrated matching for picture libraries. *Pattern Analysis and Machine Intelligence*, 23(9), 947-963.
71. Müller, H., Müller, W., Squire, D. M., Martand-Maillet, S. and Pun, T. (2001). Performance evaluation in content-based image retrieval: overview and proposals. *Pattern Recognition Letters*, 22(5), 593-601.
72. Gali, R., Dewal, M. L. and Anand, R. S. (2012). Genetic algorithm for content based image retrieval. In *Computational Intelligence, Communication Systems and Networks (CICSyN), 2012 Fourth International Conference on*, 243-247.
73. Lin, C. H., Chen, R. T. and Chan, Y. K. (2009). A smart content-based image retrieval system based on color and texture feature. *Image and Vision Computing*, 27(6), 658-665.
74. Banerjee, M., Kundu, M. K. and Maji, P. (2009). Content-based image retrieval using visually significant point features. *Fuzzy Sets and Systems*, 160(23), 3323-3341.
75. Chaudhary, M. D. and Pithadia, P. V. (2014). Multi-feature histogram intersection for Efficient Content Based Image Retrieval. *Circuit, Power and Computing Technologies (ICCPCT), 2014 International Conference on*, 1366-1371.
76. Tajeripour, F., Saberi, M. and Fekri-Ershad, S. (2015). Developing a Novel Approach for Content Based Image Retrieval Using Modified Local Binary Patterns and Morphological Transform. *International Arab Journal of Information Technology (IAJIT)*, 12(6), 574-581.

## ÖZGEÇMİŞ

### Kişisel Bilgiler

Soyadı, adı : AYAN, Mehmet  
 Uyuğu : T.C.  
 Doğum tarihi ve yeri : 01.08.1989, Çanakkale  
 Medeni hali : Evli  
 Telefon : 0 (533) 642 57 01  
 e-mail : mehmetayan@gazi.edu.tr



### Eğitim

Derece	Eğitim Birimi	Mezuniyet tarihi
Yüksek lisans	Gazi Üniversitesi /Bilgisayar Mühendisliği	Devam Ediyor
Lisans	TOBB Üniversitesi /Bilgisayar Mühendisliği	2013

### İş Deneyimi

Yıl	Yer	Görev
2014-Halen	Gazi Üniversitesi	Araştırma Görevlisi

### Yabancı Dil

İngilizce

### Yayınlar

Ayan, M., Erdem, O. A. ve Bilge H. Ş. (2016). Multi-Featured Content-Based Image Retrieval using Color and Texture Features, *3rd International Conference on Electrical and Electronics Engineering (ICEEE 2016)*.







*GAZİ GELECEKTİR..*