



**RENKLİ HİSTOGRAM KULLANARAK İÇERİK TABANLI GÖRÜNTÜ
ERİŞİMİ**

Mahmut KILIÇASLAN

**DOKTORA TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

EYLÜL 2020

Mahmut KILIÇASLAN tarafından hazırlanan “RENKLİ HİSTOGRAM KULLANARAK İÇERİK TABANLI GÖRÜNTÜ ERİŞİMİ” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Gazi Üniversitesi Teknoloji Fakültesi Bilgisayar Mühendisliği Ana Bilim Dalında DOKTORA TEZİ olarak kabul edilmiştir.

Danışman: Prof. Dr. Recep DEMİRCİ

Bilgisayar Mühendisliği Ana Bilim Dalı, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum

.....

Başkan: Prof. Dr. Remzi YILDIRIM

Bilgisayar Mühendisliği Ana Bilim Dalı, Ankara Yıldırım Beyazıt Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum

.....

Üye: Prof. Dr. Nurettin TOPALOĞLU

Bilgisayar Mühendisliği Ana Bilim Dalı, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum

.....

Üye: Dr. Öğr. Üyesi Cemal KOÇAK

Bilgisayar Mühendisliği Ana Bilim Dalı, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum

.....

Üye: Dr. Öğr. Üyesi Hilal KAYA

Bilgisayar Mühendisliği Ana Bilim Dalı, Ankara Yıldırım Beyazıt Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum

.....

Tez Savunma Tarihi: 30/09/2020

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

Prof. Dr. Cevriye GENCER

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.

Mahmut KILIÇASLAN

30/09/2020

RENKLİ HİSTOGRAM KULLANARAK İÇERİK TABANLI GÖRÜNTÜ ERİŞİMİ

(Doktora Tezi)

Mahmut KILIÇASLAN

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Eylül 2020

ÖZET

Renk, doku veya şekil bilgilerinden faydalanılarak veri tabanında istenilen görüntüye ulaşma süreci içerik tabanlı görüntü erişimi (İTGE) olarak tanımlanır. İlgili sistemlerde görüntülerin benzerliklerinin değerlendirilmesi piksel seviyesinde değil, görüntüleri temsil eden özellik vektörleri aracılığıyla gerçekleştirilmektedir. Böylece özellik vektörleri farklı boyutlardaki görüntülerin karşılaştırılmalarına olanak sağlamaktadır. Bu nedenle sayısal görüntülerin vektörler ile temsil edilmesi içerik tabanlı görüntü erişiminin (İTGE) en önemli aşamasıdır. Gri ölçekli görüntülerin histogramları en tipik özellik vektörleridir. Diğer taraftan renkli görüntüyü temsil edebilecek histogram üç boyutlu bir dizi oluşturur ki bu durum sistemin hesapsal maliyetini oldukça artırmaktadır. Bundan dolayı araştırmacılar renkli görüntülerdeki renk sayılarını azaltmayı başka bir ifadeyle renk indirgeme yaklaşımını önermişlerdir. Diğer taraftan vektör kuantalama olarak bilinen renk indirgeme sürecinde ise her zaman aynı sonucu üretmek mümkün olmamıştır. Bunun nedeni ise önerilen algoritmaların başlangıçta rastgele üretilen renk vektörleri ile çözüm aramalarıdır. K-ortalamlar, Linde-Buzo-Gray (LBG) ve bulanık c-ortalamlar gibi algoritmalar bu tür çözüm yaklaşımlarına tipik örneklerdir. Bu çalışmada yeni bir İTGE sistemi geliştirilmiştir. Önerilen stratejide öncelikle tekrarlı ortalama veya histogramın ağırlık merkezi (HAM), Otsu ve Kapur yöntemleri ile çok seviyeli eşikler elde edilmiştir. Elde edilen eşikler kullanılarak RGB renk uzayı alt prizmalar şeklinde dilimlenmiştir. Oluşan alt prizmaların içinde kalan pikseller aynı sınıfa atanmış ve ilgili sınıftaki piksellerin ortalamları kullanılarak renk indirgemesi yapılmıştır. Sınıf indisleri ve ilgili sınıflara tahsis edilen piksel sayıları yardımıyla renkli görüntüleri temsil eden sınıf tabanlı tek boyutlu histogramlar elde edilmiştir. Son aşamada ise renkli görüntüler için üretilen tek boyutlu histogramlar özellik vektörü olarak kullanılmış ve içerik tabanlı görüntü erişimi gerçekleştirilmiştir. Önerilen algoritma ve LBG algoritması Corel1K (Wang) veri tabanında test edilmiş ve karşılaştırmalar yapılmıştır. Geliştirilen algoritmada renkli görüntüleri 8, 27 veya 64 renge indirmek mümkün olmuştur. Renk sayısı aynı zamanda özellik vektörünün eleman sayısını temsil etmektedir. 64 renkli HAM yöntemi geleneksel LBG yaklaşımından %22 daha başarılı olmuştur. Ayrıca Otsu ve Kapur tabanlı İTGE sistemi ise LBG tabanlı İTGE yaklaşımlarından %18 daha doğru sonuçlar üretmiştir.

Bilim Kodu : 92418
Anahtar Kelimeler : İçerik tabanlı görüntü erişimi, tek boyutlu histogram, renk indirgeme
Sayfa Adedi : 107
Danışman : Prof. Dr. Recep DEMİRCİ

CONTENT BASED IMAGE RETRIEVAL BY USING COLOR HISTOGRAM

(Ph. D. Thesis)

Mahmut KILIÇASLAN

GAZI UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

September 2020

ABSTRACT

The process in which any desired image in database is retrieved by using color, shape or texture information is called content-based retrieval (CBIR). In the related systems, the evaluation of similarities of images is carried out through feature vectors representing images, not at the pixel levels. Thus the feature vectors allow to compare similarities of images with different sizes. Therefore, the representation of images by vectors is called feature extraction process and it is the most significant stage of content-based image retrieval (CBIR). Histograms of gray-scale images are typical feature vectors. On the other hand, the histogram which represents any color image involves a three-dimensional array, which will increase the computational cost of CBIR system. Accordingly, researchers have proposed color reduction approaches that reduce number of colors in color images. The color reduction process is also known as vector quantization. Nevertheless, it was not always possible to produce the same results. The reason is that some algorithms search for solutions with randomly generated color vectors initially. Algorithms such as K-means, Linde-Buzo-Gray (LBG), and fuzzy c-means are typical solution techniques. In this study, a novel CBIR system has been developed. In the proposed strategy, multi-level thresholds were obtained from histogram of each color channel by using recursive mean or the center of gravity of histogram, Otsu and Kapur algorithms. By using the attained thresholds, the RGB color space was sliced into sub-prisms. The pixels remaining in the sub-prisms created were assigned to the same class and color reduction was performed by using the means of pixels in the related class. A cluster-based one-dimensional histogram representing color images was generated through class indices and the number of pixels allocated to the relevant clusters. Finally, one-dimensional histogram vectors were used as feature vectors and content based image retrieval was realized. The proposed algorithm and LBG algorithm have been tested with Core11K (Wang) database and comparisons have been completed. It is possible to reduce color images into 8,27 or 64 colors in the developed algorithm. The number of colors also represents the number of elements of feature vectors. The center of gravity of histogram algorithm with 64 colors has become %22 more successful than conventional LBG technique. Additionally, Otsu and Kapur based CBIR system produced 18% more accurate results than the LBG based CBIR system.

Science Code : 92418

Key Words : Content-based image retrieval, one dimensional color histogram, color quantization

Page Number : 107

Supervisor : Prof. Dr. Recep DEMİRCİ

TEŐEKKÜR

Bu tez alıőmasında ok byk emeđi olan ve alıőmalarımın her aőamasında engin bilgi ve tecrbesi ile bana yardımcı olan ynlendiren danıőman hocam Prof. Dr. Recep DEMİRĐİ'ye sonsuz teőekkrlerimi sunarım. Ayrıca desteklerini asla esirgemeyen alıőma arkadaőım Öğr. Gör. Dr. Ufuk TANYERĐ'ye, Haydar TUNA'ya, ok kıymetli unutulmaz dostum Öğr. Gör. Burcu YAKIŐIR GİRĐİN'e, deđerli abim Dr. Öğr. Üyesi Kürőat YILDIZ'a teőekkr ederim. Son olarak alıőmalarım sresince desteđi ve sabrıyla hibir zaman beni yalnız bırakmayan sevgili eőim Miray ELİK KILIASLAN'a, biricik ođlum Arden'e ve bugnlere gelmemde emeklerini hibir zaman unutamayacađım aileme teőekkr bor bilirim.



İÇİNDEKİLER

	Sayfa
ÖZET.....	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	x
SİMGELER VE KISALTMALAR.....	xiv
1. GİRİŞ	1
2. SAYISAL GÖRÜNTÜ İŞLEME.....	9
2.1. Sayısal Görüntü.....	9
2.2. Görüntü Türleri	9
2.3. Renk Uzayları	10
2.4. Görüntü Histogramı	11
2.4.1. Gri seviyeli görüntü histogramı	11
2.4.2. Renkli görüntülerin iki boyutlu histogramı.....	12
2.4.3. Renkli görüntülerin üç boyutlu histogramı.....	14
2.5. Vektör Nicemleme ve Renk İndirgeme	14
2.6. Görüntü Benzerlik Ölçümü	18
2.7. Histogram Tabanlı Benzerlik Ölçüm Metotları	19
2.8. İçerik Tabanlı Görüntü Erişimi Performans Ölçütleri	20
3. RENKLİ HİSTOGRAM TABANLI GÖRÜNTÜ ERİŞİMİ.....	27
3.1. Renk Uzayı Yardımıyla Görüntü Bölütleme.....	28
3.2. Renkli Görüntüler İçin Tek Boyutlu Histogram	49
4. DENEYSEL SONUÇLAR VE YORUMLAR.....	59
4.1. Corel1K Veritabanı.....	60

	Sayfa
4.2. Görüntü Erişimi ve Test Sonuçları.....	60
5. SONUÇ.....	95
KAYNAKLAR	99
ÖZGEÇMİŞ	106



ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1 G sınıflı bir veri kümesinin karmaşıklık matrisi.....	21
Çizelge 2.2 Sıralı erişim yöntemi.....	24
Çizelge 2.3 Standart 11 noktalı hassasiyet ve enterpole kesinlik değerleri	25
Çizelge 3.1 HAM yöntemiyle atanan eşik değerler ve sayıları	31
Çizelge 3.2. Renk uzayının bölütlenmesi	32
Çizelge 3.3. Eşik değerler: $n=1$	33
Çizelge 3.4. Ortalama PSNR (dB) sonuçları	48
Çizelge 4.1. Corel1K veritabanı sınıf isimleri ve etiketleri	60
Çizelge 4.2 LBG-Kosinüs (8 Renk): $P_m=0,3195$; $R_m=0,3211$; $A=0,3211$	64
Çizelge 4.3 LBG-Kosinüs (27 Renk): $P_m=0,3432$; $R_m=0,3340$; $A=0,3340$	64
Çizelge 4.4 LBG-Kosinüs (64 Renk): $P_m=0,3480$; $R_m=0,3346$; $A=0,3346$	64
Çizelge 4.5 Kapur-Kosinüs (8 Renk): $P_m=0,4111$; $R_m=0,4181$; $A=0,4181$	65
Çizelge 4.6 Kapur-Kosinüs (27 Renk): $P_m=0,3911$; $R_m=0,4287$; $A=0,4287$	65
Çizelge 4.7 Kapur-Kosinüs (64 Renk): $P_m=0,4407$; $R_m=0,4518$; $A=0,4518$	65
Çizelge 4.8 Otsu-Kosinüs (8 Renk): $P_m=0,4263$; $R_m=0,4238$; $A=0,4238$	66
Çizelge 4.9 Otsu-Kosinüs (27 Renk): $P_m=0,5025$; $R_m=0,5017$; $A=0,5017$	66
Çizelge 4.10 Otsu-Kosinüs (64 Renk): $P_m=0,5350$; $R_m=0,5244$; $A=0,5244$	66
Çizelge 4.11 HAM-Kosinüs (8 Renk): $P_m=0,4625$; $R_m=0,4537$; $A=0,4537$	67
Çizelge 4.12 HAM-Kosinüs (27 Renk): $P_m=0,5250$; $R_m=0,5222$; $A=0,5222$	67
Çizelge 4.13 HAM-Kosinüs (64 Renk): $P_m=0,5559$; $R_m=0,5525$; $A=0,5525$	67
Çizelge 4.14 Görüntü erişim yöntemleri (makro değerlendirme): P_m , R_m ve A	68

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Metin tabanlı görüntü erişim problemi	1
Şekil 1.2. İTGE mimarisinin blok diyagramı.....	2
Şekil 2.1. Sayısal görüntü örneği	9
Şekil 2.2. Biber görüntüsü a) renkli b) gri seviyeli c) ikili	10
Şekil 2.3. RGB renk uzayı	11
Şekil 2.4. Gri seviyeli biber görüntüsüne ait histogram.....	12
Şekil 2.5. Biber görüntüsünün iki boyutlu histogramı: RG	13
Şekil 2.6. Biber görüntüsünün iki boyutlu histogramı: RB	13
Şekil 2.7. Biber görüntüsünün iki boyutlu histogramı: GB	13
Şekil 2.8. Biber görüntüsünün renk dağılımı	14
Şekil 2.9. Medyan kesme yöntemi ile indirgenmiş Biber görüntüsü (8 renk)	15
Şekil 2.10. Sekizli ağaç algoritması.....	16
Şekil 2.11. Sekizli ağaç ile renk kodlarının oluşturulması.....	16
Şekil 2.12. Sekizli ağaç yöntemi ile indirgenmiş Biber görüntüsü (8 renk)	16
Şekil 2.13. LBG yöntemi ile indirgenmiş Biber görüntüsü (8 renk)	18
Şekil 2.14. Sıralı erişim P_i-R_i eğrisi	24
Şekil 2.15. Sıralı erişim enterpole P-R eğrisi.....	26
Şekil 3.1. İTGE sisteminin genel mimarisi	28
Şekil 3.2. Bölütlenmiş renk uzayı: $n=1, c=8$	32
Şekil 3.3. Lena a) orijinal b) renk dağılımı	34
Şekil 3.4. Biber a) orijinal b) renk dağılımı	34
Şekil 3.5. Mandrill a) orijinal b) renk dağılımı	34
Şekil 3.6. İndirgenmiş Lena (HAM:8 renk) a) algoritma çıktısı b) renk dağılımı.....	36
Şekil 3.7. İndirgenmiş Lena (HAM:27 renk) a) algoritma çıktısı b) renk dağılımı.....	36

Şekil	Sayfa
Şekil 3.8. İndirgenmiş Lena (HAM:64 renk) a) algoritma çıktısı b) renk dağılımı.....	36
Şekil 3.9. İndirgenmiş Biber (HAM:8 renk) a) algoritma çıktısı b) renk dağılımı	37
Şekil 3.10. İndirgenmiş Biber (HAM:27 renk) a) algoritma çıktısı b) renk dağılımı	37
Şekil 3.11. İndirgenmiş Biber (HAM:64 renk) a) algoritma çıktısı b) renk dağılımı	37
Şekil 3.12. İndirgenmiş Mandrill (HAM:8 renk) a) algoritma çıktısı b) renk dağılımı..	38
Şekil 3.13. İndirgenmiş Mandrill (HAM:27 renk) a) algoritma çıktısı b) renk dağılımı	38
Şekil 3.14. İndirgenmiş Mandrill (HAM:64 renk) a) algoritma çıktısı b) renk dağılımı	38
Şekil 3.15. İndirgenmiş Lena (Otsu:8 renk) a) algoritma çıktısı b) renk dağılımı.....	39
Şekil 3.16. İndirgenmiş Lena (Otsu:27 renk) a) algoritma çıktısı b) renk dağılımı.....	39
Şekil 3.17. İndirgenmiş Lena (Otsu:64 renk) a) algoritma çıktısı b) renk dağılımı.....	39
Şekil 3.18. İndirgenmiş Biber (Otsu:8 renk) a) algoritma çıktısı b) renk dağılımı.....	40
Şekil 3.19. İndirgenmiş Biber (Otsu:27 renk) a) algoritma çıktısı b) renk dağılımı.....	40
Şekil 3.20. İndirgenmiş Biber (Otsu:64 renk) a) algoritma çıktısı b) renk dağılımı.....	40
Şekil 3.21. İndirgenmiş Mandrill (Otsu:8 renk) a) algoritma çıktısı b) renk dağılımı....	41
Şekil 3.22. İndirgenmiş Mandrill (Otsu:27 renk) a) algoritma çıktısı b) renk dağılımı..	41
Şekil 3.23. İndirgenmiş Mandrill (Otsu:64 renk) a) algoritma çıktısı b) renk dağılımı..	41
Şekil 3.24. İndirgenmiş Lena (Kapur:8 renk) a) algoritma çıktısı b) renk dağılımı	42
Şekil 3.25. İndirgenmiş Lena (Kapur:27 renk) a) algoritma çıktısı b) renk dağılımı	42
Şekil 3.26. İndirgenmiş Lena (Kapur:64 renk) a) algoritma çıktısı b) renk dağılımı	42
Şekil 3.27. İndirgenmiş Biber (Kapur:8 renk) a) algoritma çıktısı b) renk dağılımı	43
Şekil 3.28. İndirgenmiş Biber (Kapur:27 renk) a) algoritma çıktısı b) renk dağılımı	43
Şekil 3.29. İndirgenmiş Biber (Kapur:64 renk) a) algoritma çıktısı b) renk dağılımı	43
Şekil 3.30. İndirgenmiş Mandrill (Kapur:8 renk) a) algoritma çıktısı b) renk dağılımı .	44
Şekil 3.31. İndirgenmiş Mandrill (Kapur:27 renk) a) algoritma çıktısı b) renk dağılımı	44
Şekil 3.32. İndirgenmiş Mandrill (Kapur:64 renk) a) algoritma çıktısı b) renk dağılımı	44
Şekil 3.33. İndirgenmiş Lena (LBG:8 renk) a) algoritma çıktısı b) renk dağılımı	45

Şekil	Sayfa
Şekil 3.34. İndirgenmiş Lena (LBG:27 renk) a) algoritma çıktısı b) renk dağılımı	45
Şekil 3.35. İndirgenmiş Lena (LBG:64 renk) a) algoritma çıktısı b) renk dağılımı	45
Şekil 3.36. İndirgenmiş Biber (LBG:8 renk) a) algoritma çıktısı b) renk dağılımı	46
Şekil 3.37. İndirgenmiş Biber (LBG:27 renk) a) algoritma çıktısı b) renk dağılımı	46
Şekil 3.38. İndirgenmiş Biber (LBG:64 renk) a) algoritma çıktısı b) renk dağılımı	46
Şekil 3.39. İndirgenmiş Mandrill (LBG:8 renk) a) algoritma çıktısı b) renk dağılımı ...	47
Şekil 3.40. İndirgenmiş Mandrill (LBG:27 renk) a) algoritma çıktısı b) renk dağılımı .	47
Şekil 3.41. İndirgenmiş Mandrill (LBG:64 renk) a) algoritma çıktısı b) renk dağılımı .	47
Şekil 3.42. Biber : Tek boyutlu histogram (HAM, 8 renk).....	50
Şekil 3.43. Biber: Tek boyutlu histogram (Otsu, 8 renk).....	50
Şekil 3.44. Biber: Tek boyutlu histogram (Kapur, 8 renk)	51
Şekil 3.45. Biber: Tek boyutlu histogram (LBG, 8 renk)	51
Şekil 3.46. Biber: Tek boyutlu histogram (HAM, 27 renk).....	52
Şekil 3.47. Biber: Tek boyutlu histogram (Otsu, 27 renk).....	52
Şekil 3.48. Biber: Tek boyutlu histogram (Kapur, 27 renk)	53
Şekil 3.49. Biber: Tek boyutlu histogram (LBG, 27 renk)	53
Şekil 3.50. Biber: Tek boyutlu histogram (HAM, 64 renk).....	54
Şekil 3.51. Biber: Tek boyutlu histogram (Otsu, 64 renk).....	55
Şekil 3.52. Biber: Tek boyutlu histogram (Kapur, 64 renk)	56
Şekil 3.53. Biber: Tek boyutlu histogram (LBG, 64 renk)	57
Şekil 4.1. Geliştirilen İTGE arayüzü.....	59
Şekil 4.2. Corel1K a) Afrikalılar b) Sahiller c) Yapıtlar d) Otobüsler e) Dinozorlar f) Filler g) Çiçekler h) Atlar ı) Dağlar i) Yiyecekler	60
Şekil 4.3. Afrikalılar ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk.....	72
Şekil 4.4. Afrikalılar ve kesişim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk.....	73
Şekil 4.5. Sahiller ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk	74

Şekil	Sayfa
Şekil 4.6. Sahiller ve kesişim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk	75
Şekil 4.7. Yapıtlar ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk	76
Şekil 4.8. Yapıtlar ve kesişim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk	77
Şekil 4.9. Otobüsler ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk.....	78
Şekil 4.10. Otobüsler ve kesişim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk.....	79
Şekil 4.11. Dinozorlar ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk	80
Şekil 4.12. Dinozorlar ve kesişim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk	81
Şekil 4.13. Filler ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk.....	82
Şekil 4.14. Filler ve kesişim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk.....	83
Şekil 4.15. Çiçekler ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk	84
Şekil 4.16. Çiçekler ve kesişim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk	85
Şekil 4.17. Atlar ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk	86
Şekil 4.18. Atlar ve kesişim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk	87
Şekil 4.19. Dağlar ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk.....	88
Şekil 4.20. Dağlar ve kesişim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk.....	89
Şekil 4.21. Yiyecekler ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk	90
Şekil 4.22. Yiyecekler ve kesişim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk	91
Şekil 4.23. Genel performans ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk..	93
Şekil 4.24. Genel performans ve kesişim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk..	94

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler Açıklama

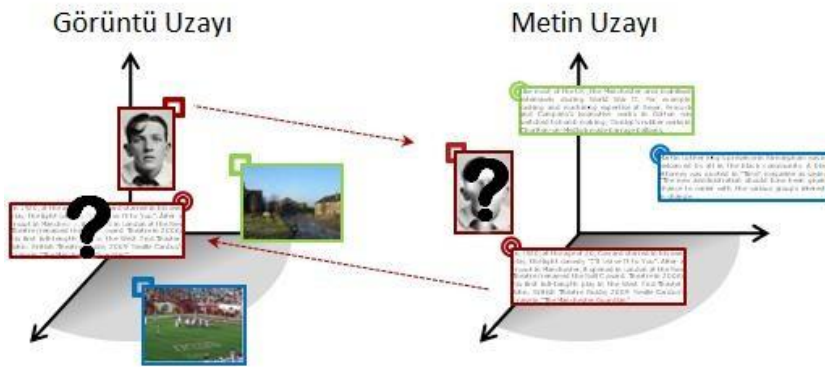
σ	Standart Sapma
ω	Ağırlıklı Ortalama
μ	Ortalama

Kısaltmalar Açıklama

A	Makro Doğruluk
CMY	Cyan Magenta Yellow
CMYK	Cyan Magenta Yellow Black
HSV	Hue Saturation Value
HAM	Histogramın Ağırlık Merkezi
İTGE	İçerik Tabanlı Görüntü Erişimi
LBG	Lindo Buzo Gray
MSE	Ortalama Kareler Hatası
P	Kesinlik
P_g	Sınıfsal Kesinlik
P_m	Makro Kesinlik
PSNR	Tepe Sinyal Gürültü Oranı
R	Duyarlılık
R_g	Sınıfsal Duyarlılık
R_m	Makro Duyarlılık
RGB	Kırmızı Yeşil Mavi

1. GİRİŞ


Teknolojinin gelişmesiyle görüntüleme cihazlarının kullanımı hayli artmıştır. Böylece sayısal görüntüler hızla yaygınlaşmış ve internet aracılığıyla pek çok kullanıcının erişilebileceği hale gelmiştir. Tıp, adli bilişim, ticari faaliyetler, yapay zekâ uygulamaları, güvenlik gibi birçok alanda sayısal görüntülerin kullanılması kaçınılmaz hale gelmiştir. Yüz tanıma, hareket algılama, medikal görüntüler üzerinden yapılan teşhisler, plaka tanıma, nesne belirleme gibi uygulamalar görüntüler üzerinde yapılan çalışmaların sadece birkaçıdır. Görüntü sayılarının ve uygulama alanlarının artması, büyük ölçekli görüntü veri yığınlarının oluşmasına sebep olmuştur. Böylece söz konusu yığınlar içerisinde istenilen görüntüleri erişmek önemli bir problem haline gelmiştir ve ilgili problemi çözmek için görüntü erişimi alanı doğmuştur. Söz konusu alanda yapılan çalışmalar büyük veritabanları içerisinde aranılan görüntüleri hızlı bir şekilde erişebilmeye odaklanmıştır. Görüntü erişimi ile ilgili yapılan ilk çalışmalar görüntülerin kelimelerle tanımlandığı metin tabanlı yaklaşımlardır. Ancak görüntülerin indekslenmesi için kullanılan anahtar kelimeler kişiden kişiye değişmekte olup, bir görüntünün çok fazla kelime ile ifade edilmesine gereksinim duyulmaktadır. İlâveten çalışmaların düzenli olarak yürütülebilmesi için büyük bir iş gücüne ihtiyaç vardır. Meta verilere dayalı bu tarz aramaların seçilen kelimelerin görüntüyü ne kadar ifade ettiğine bağlı olması, metin tabanlı yaklaşımların en büyük dezavantajıdır [1, 2]. Şekil 1.1’de metin tabanlı sistemlerin temel problemi şematik olarak ifade edilmiştir.



Şekil 1.1. Metin tabanlı görüntü erişim problemi [3]

Görüntü erişim yöntemleri metin tabanlı olduğu gibi içerik tabanlı da olabilmektedir. 1980’lerin başlarında ilgili sistemler için ilk adım atılmıştır. İçerik tabanlı arama da meta veriler yerine görüntüden çıkarılan renkler, şekiller, dokular veya bunların birleşiminden

oluşan vektörler kullanılmaktadır. İçerik tabanlı görüntü erişimi (İTGE) olarak ifade edilen söz konusu yaklaşım, sayısal görüntülerin oluşturduğu büyük veri tabanından istenilen görüntüye erişim probleminin çözümü için geliştirilmiş bilgisayarlı görme uygulamasıdır [4]. İTGE, web aramaları [5], sanat ve müze [6], medikal görüntüleme [7], ticari markalar [8] ve kriminal suçlar [9] gibi çeşitli alanlarda uygulanabilmektedir. Şekil 1.2’de, içerik tabanlı görüntü erişiminin blok diyagramı verilmiştir.



Şekil 1.2. İTGE mimarisinin blok diyagramı [9]

Şekil 1.2’de de görüldüğü üzere İTGE, özellik çıkarımı ve benzerlik hesaplama şeklinde iki temel aşamadan oluşmaktadır. Özellik çıkarımı aşaması öncelikle görüntü veritabanında yapılmaktadır. İlgili süreçte renk, doku ve şekil gibi tanımlayıcılar ile özellik veritabanı oluşturulmaktadır. Benzerlik hesaplama aşamasında ise sorgu görüntüden çıkarılan özellik, özellik veritabanındaki ile karşılaştırma işlemine tabi tutulmaktadır. Burada önemli olan husus karşılaştırmaya tabi tutulan özellik vektörlerinin eşit uzunlukta olmasıdır. Benzerlik hesaplama işlemi piksel düzeyinde yapılırsa farklı boyutlardaki görüntülerin karşılaştırılması bir problem haline dönüşmektedir. İlave renk uzayına bağlı olarak hesapsal karmaşıklık da artmaktadır. Bu sebeple İTGE’de sorgulama piksel düzeyinde değil görüntüyü temsil eden eşit uzunluktaki vektörler düzeyinde yapılmaktadır. Elde edilen vektörlerin görüntüyü temsil gücü, sayısı ve hesapsal karmaşıklığı ise metotların başarımını etkilemektedir. Kullanıcı geri bildirim, görüntü veritabanı ve performans değerlendirme ise İTGE’nin diğer unsurlarıdır [10]. Sonuç olarak özellik çıkarımı İTGE’nin en kritik basamağı olup, sistemin doğru ve hızlı çalışmasında önemli bir faktördür.

Günümüze kadar özellik çıkarımı için çeşitli İTGE yaklaşımları önerilmiştir. Literatür incelediğinde rengin çok zengin temsil yeteneğine sahip önemli bir özellik olarak kabul

edildiği görülmektedir. İnsanların renk duyarlılığı da onu güçlü bir içerik tanımlayıcısı yapmaktadır. Renk yapısı tanımlayıcısı [11], baskın renk tanımlayıcısı [12], renk düzen tanımlayıcısı [13], renk uyum vektörü [14], renk vektörü kuantalama [15] ve renk merkez momentleri [16] gibi yaklaşımlar etkili tanımlayıcılar olarak kullanılmaktadır. Özellik belirlemede renk tanımlayıcılarını tek başına kullanan çalışmalar olduğu kadar, doku ve şekil gibi diğer tanımlayıcıları kullanan teknikler de bulunmaktadır.

Zhang ve Tan doku tanımlayıcısının kullanıldığı ayrıntılı bir inceleme çalışması yapmışlardır [17]. Günümüzde doku analizi nesne tanıma, robot ile görüntüleme, endüstriyel muayene sistemleri, tıbbi görüntü analizi ve belge analizi gibi süreçlerde kullanılmaktadır. Literatürde bu amaç için çeşitli algoritmalar bulunmaktadır. Dalgacık katsayıları [18], çok ölçekli doku sınıflaması [19], yerel ikili desenler [20] ve çok ölçekli oransal analiz [21] gibi teknikler doku özelliğini kullanmaktadır. Ayrıca renk ve doku özelliklerini İTGE sistemleri için birleştiren teknikler de geliştirilmiştir. Bunlar çoklu texton histogram [22], dalgacık katsayıları ve sözlük ağacı [23], renk farkı histogramı [24], mikro-yapılar tanımlayıcısı [25] ve yapı elemanları tanımlayıcısı [26] şeklinde sıralanabilirler. Mikro-yapılar tanımlayıcısı düşük seviye özellikleri tek parça olarak temsil etmekte ve benzer kenar yönelimine sahip mikro yapılarda renkler kullanılarak oluşturulmaktadır. Düşük boyutlu bir tanımlayıcıdır ve daha önce Corel veri setine uygulanmıştır [27].

Swain ve Ballard renk bilgisinin görüntü erişimi için en etkili özellik olduğunu belirtmektedirler. Bu amaçla çalışmalarında büyük bir veritabanı üzerinde gerçek zamanlı ve histogram kesişim metriği ile görüntü erişimi yapan bir yaklaşım önermişlerdir. Önerdikleri teknik bilinen nesnelere yerlerini tanımlamada kullanılmıştır [28]. Söz konusu çalışma diğer araştırmacılara ilham kaynağı olmuş ve sonraki önerilerde, İTGE için renk özelliği yaygın bir şekilde kullanılmaya başlanmıştır.

Renk histogramı en sık kullanılan özellik vektörlerindedir [11, 29-35]. İlgili özelliğin kolay hesaplanması, döndürmeye ve ölçeklemeye dayanıklı olması onu güçlü bir tanımlayıcı yapmaktadır. Deselaers görüntüde renkleri birer bölge olarak kabul edip, ilgili özelliğin ayırt edici olarak kullanılabileceğini ancak 24 bit RGB (Kırmızı, Yeşil, Mavi) görüntülerde 2^{24} bölge olabileceğinden, renk sayısının düşürülmesi gerektiğinden bahsetmiştir [29]. Alamdar ve Keyvanpour [31], Finkel ve Bentley'in [36] dörtlü ağaç veri yapısını kullanarak görüntüde farklı boyutlarda elde ettikleri homojen bloklar üzerinden renk histogramına

bakan bir yaklaşım önermişlerdir. Pass ve Zabih'in görüntü histogramından ürettikleri uyum vektörünü kullanan farklı çalışmaları bulunmaktadır [37-41]. Ancak ilgili çalışmalarda uyum vektörlerinin normal renk histogramı hesaplamaya göre zaman maliyeti yüksek çıkmıştır [32]. Ayrıca bahsi geçen vektörün oluşturulmasında kullanıcı tarafından belirlenen bir parametre kullanılmıştır [41]. Renk uyum vektörü yönteminin kullanıcı bağımlı olması en büyük dezavantajıdır. Hafner, Sawhney, Equitz, Flickner ve Niblack'de, renk histogramları arasında mesafe ölçümünün hesapsal karmaşıklığının yüksek olduğunu göstermişlerdir [33]. Dolayısıyla renk indirgeme yaklaşımlarına ihtiyaç duyulmuştur. Yapılan çalışmalar histogramın İTGE'de etkili bir şekilde kullanılabileceğini ancak farklı kısıtları ya da zaman maliyeti açısından değerlendirilmesi gerektiğini göstermektedir.

Histogram görüntüdeki renk yoğunluk değerlerinin dağılımını göstermektedir. Geleneksel renk histogramları kullanan yaklaşımlar hesaplama, depolama ve eşleştirme konusunda sonuca hızla ulaşmaktadır. Ayrıca söz konusu sistemlerde yön ve ölçek bağımsızlığı önemli bir avantajdır [42]. Dolayısıyla histogram tabanlı İTGE sistemleri için renk uzayı, renk indirgeme tekniği ve uygun eşleştirme kriterlerinin belirlenmesi önem arz etmektedir [43]. Smith ve Chang histogramlar arasındaki mesafeyi kullanarak görüntü erişimi yaklaşımı geliştirmişlerdir. Çalışmalarında kullanılan benzerlik metrikleri Öklid uzaklığı, kuadratik mesafe ve histogram kesişimi olmuştur. Öklid mesafesinde karşılaştırılan histogramların renk dağılımlarındaki farklara bakılmaktadır. Bir diğer mesafe ölçüm yöntemi olan kuadratik metrikde, histogramların çapraz ilişkisi hesaplanarak algısal renk uyuşması ele alınmaktadır. Histogram kesişim mesafesinde ise histogramların ne kadar örtüştüğüne bakılmaktadır [44]. Ancak bahsi geçen çalışmada, bölgesel renk özelliği dikkate alındığından döndürülmüş imgelerde etkili olmayacaktır. İTGE sistemlerinde histogram yaklaşımı birçok çalışmada kullanılmıştır [30, 42, 45-48]. Zhang RGB renk uzayında renkler arasındaki uzaklığın aynı renge ait tonları belirlemede dezavantajlı olduğunu ifade etmiştir. Önerisini $L*u*v*$ renk uzayı ve doku özelliklerini bulan Gabor filtresi ile gerçekleştirmiştir [45]. Söz konusu yaklaşımda, $L*u*v*$ renk uzayında her kanalın sabit aralıklara bölünerek renk indirgemesi yapılması önemli bir dezavantajıdır. Küçüktunç ve Zamalieva ise $L*a*b*$ renk uzayında çalışan kural tabanlı bir İTGE yaklaşımı önermişlerdir. Çalışmalarında 26 adet kural tanımlamışlar ve görüntülerden 15 adet renk elde ederek histogram vektörünü oluşturmuşlardır [46].

Birçok histogram tabanlı İTGE çalışmaları histogramdan anlamlı sayıda bölgeye ayırmayı denemiştir. Dolayısıyla aynı bölge içerisindeki piksellerin önemsiz farkları olmuştur. Böylece aydınlatma değişiminden veya gürültüye bağlı değişikliklerden en az etkilenilecektir. Bölgelere ayırma çalışması ile bazı pikseller bir bölgeden diğer bölgeye taşınmış olabilirler. Ancak algısal olarak aynı ama aydınlatma ve gürültü gibi nedenlerle renk problemi olan iki benzer görüntünün farklı histogramlara sahip olacağı dikkate alınmalıdır. Ayrıca renk uzayını temsil eden üç farklı bileşene sahip olmak, üç boyutlu histogram kullanmayı gerektirmektedir. İlgili histogramlar üzerinde işlemler yürütmek zaman ve hesaplama maliyeti açısından yüksek olmaktadır. Söz konusu durumda bazı araştırmacılar 3B-histogramı bulanık sistemler ile tanımlı renk uzayına taşımışlardır. Konstantinidis, Gasteratos ve Andreadis, $L^*a^*b^*$ renk uzayında 27 kurala bağlı bulanık mantıkla çalışan ve histogram kesişim ölçütü ile benzerlik hesaplayan bir sistem önermişlerdir. Yaklaşımlarında 10 adet renk elde etmişlerdir [42]. Bulanık mantık birçok görüntü işleme uygulamasında kullanılmaktadır. Zadeh [49,50] tarafından ilk kez tanıtılan bulanık mantık yaklaşımından sonra, bulanık ilişkiler, bulanık integraller, K-ortalamlar, bulanık C-ortalamlar ve bulanık söz dizimsel yaklaşımlar gibi birçok yöntem geliştirilmiş ve farklı görüntü analizlerinde kullanılmıştır [43]. Han ve Ma bulanık renk histogramını piksellerin renk benzerliğini dikkate alarak geliştirmişlerdir [51]. Sugano'da renklerin kelimelerle ifade edilebileceği bulanık bir sistem önermiştir [52]. Yukarıda detayları verilen yaklaşımlarda renk indirgeme sonucu ulaşılan renk sayısının ve benzerlik ölçümünde kullanılan metriklerin İTGE'nin performansını önemli oranda etkileyeceğini göstermiştir.

Domke ve Aloimonos renk histogramının görüntü düzlemi ve görüntüleme açısı ile yakından ilişkili olduğunu bildirmişlerdir. Söz konusu çalışmada gradyan tabanlı renk histogramını önermişlerdir [53]. Renk histogramı görüntülerde ilgili renklerin global dağılımını göstermektedir ancak uzamsal bilgilerini içermemektedir. Söz konusu veriyi dâhil etmek için bölütleme, bölme, HSV dönüşümü gibi farklı yöntemlerle yerel veya sadece bölgelere ait histogram çıkarma gibi çeşitli çalışmalar yapılmıştır [54-60]. İlgili araştırmalarda en sık kullanılan yaklaşım görüntüleri indekslemeden önce bölümlere ayırmak olmuştur. Bahsi geçen uygulamalardan sabit bölütleme yaklaşımı en temel yöntemdir. Önerilen algoritmada görüntü ilk olarak sabit bölümlere ayrılmakta sonra elde edilen bölgeler dizine eklenmektedir. Ancak oluşturulan alanların her zaman görsel içeriği temsil etmemesi ihtimalinin olması bir dezavantajdır.

Renk kümeleme ve görüntüleri yerel bölümlere ayırma İTGE sistemlerinde yaygın olarak kullanılan diğer tekniklerdir. K-ortalama yaklaşımı yaygın kullanılan renk kümeleme yaklaşımlarından biridir [61,62]. Rasheed ve diğerlerinin çalışmaları ise görüntüyü bölümlere ayıran tekniğe bir örnektir. Çalışmalarında görüntüden yerel özellikleri çıkarılmakta ve histogram 16 eşit kutuya dönüştürülmektedir. Ancak ilgili teknik hız kazancı sağlamak için renkli görüntüleri gri seviye görüntülere dönüştürerek uygulandığından bilgi kaybı olmaktadır. Ayrıca çalışmada görüntü bölümlere ayrıldıktan sonra uzamsal bilgilerinin de alınabilmesi için maksimum frekans korelogram kullanılmıştır [57]. Görüntü türüne dayalı uyarlanabilir görüntü bölümlenmesi ise Song, Li ve Wang tarafından sunulmuştur [55]. Önerilen çalışmada Gauss karışım modeli tekniği kullanılmıştır. İlaveten renk histogramında boyut indirgemesi yapılmış ve isomap adı verilen doğrusal olmayan yaklaşımdan yararlanılmıştır. An, Riaz ve Park bölütleme için HSV renk uzayında ton ve doygunluk nicelemesi uygulamış ve her bir bölgede maksimum renk oluşumunu elde ederek İTGE sistemi geliştirmişlerdir [59].

İTGE’de farklı mesafelerde renk çiftlerinin mekânsal korelasyonunu elde eden yaklaşımlar da mevcuttur. İlgili çalışmalarda renklerin uzamsal bilgileri kullanılmıştır [63,64]. Ayrıca renk histogramında boyut indirgemeye yönelik dikkat çekici çalışmalar da bulunmaktadır. Söz konusu yöntemlerde marjinal renk histogramı adı verilen bir teknik ile renkli görüntülerin 3B histogramının, 2B veya 1B lu alt boyutlara yansıtılması sağlanmıştır [65, 66].

Renk uzayı ve uzaklık metriği histogram temelli görüntü erişiminde önem taşımaktadır [67]. HSV insanların renk tonunu ve doygunluğu algılayış biçimi dikkate alınarak oluşturululan bir renk uzayıdır. $L^*a^*b^*$ renk uzayı da insanların renk algılama biçimine dayalı olarak geliştirilen diğer bir modeldir [42, 45]. Uzaklık metrikleri için yapılan çalışmalar incelendiğinde ise Öklid, kuadratik, kosinüs ve histogram kesişim ölçümleri sık kullanılan metriklerdendir [44, 68].

Yukarıda verilen çalışmalardan da anlaşılacağı üzere, İTGE’nin temeli girdi görüntüyü bir özellikler kümesine ya da vektörlere dönüştüren öznelik çıkarma sürecine dayanmaktadır. Söz konusu vektörler görüntülerin indirgenmiş bir gösterimidir. Tanımlayıcılar uygun şekilde seçilirse karşılaştırmalarda yeterli bilgiye sahip olunmaktadır. Literatürde genellikle görüntü erişimi için yoğunluk temelli (renk ve doku) ve geometri tabanlı (şekil ve topoloji)

iki ana özellik grubu sunulmuştur [69]. Bahsedilen özelliklerin birleştirilmesinin tek başına kullanılmalarından daha iyi bir performans sağlayacağı açıktır [70,71]. Ancak özellik sayısı arttığında, İTGE sisteminin hesapsal karmaşıklığı da arttığı bilinen bir gerçektir.

Literatür çalışmaları genel olarak incelendiğinde renk histogramının İTGE çalışmalarında sıklıkla yararlanılan bir yaklaşım olduğu görülmektedir. Gri seviyeli görüntülerde histogram tek boyutlu bir vektör ile ifade edilirken, renkli görsellerde ise üç boyutlu bir matrisin çözümlenmesini gerektirmektedir. İlâveten her kanaldan alınan histogram bilgisinin birleştirilmesi de ayrı bir problemdir. RGB renk modelinde 2^{24} renk bilgisi bulunmakta ve geliştirilecek tekniklerin hesapsal karmaşıklığı artmaktadır. Bu nedenle etkili bir görüntü erişimi için renk indirgeme yaklaşımlarına ihtiyaç duyulmaktadır. Renk indirgeme işlemi benzer renklerin aynı grup altında toplanması olarak tanımlanabilir. LBG de renk indirgemesi için sık kullanılan bir yaklaşımdır. Bununla birlikte LBG algoritması kümeleme, hızlı arama, görüntü sıkıştırma ve İTGE sistemi gibi çeşitli işlemlerde de kullanılmaktadır. LBG algoritması başlangıç küme merkezlerini rastgele belirleyen iteratif bir yaklaşım olup, her seferinde aynı sonucun alınmasını garanti etmeyen bir yaklaşımdır.


Bu çalışmada yeni bir renk indirgeme algoritması önerilmiştir. Önerilen yöntem renkli görüntülerin Otsu, Kapur algoritmaları ve histogramın ağırlık merkezi (HAM) aracılığıyla çok seviyeli eşiklenmesini temel almaktadır. Geliştirilen stratejide öncelikle her bir renk kanalının histogramı üzerinden çok seviyeli eşikler elde edilmiştir. Elde edilen eşik değerleri aracılığıyla RGB renk uzayı prizmalara bölünmüştür. Oluşan kutucuklardaki pikseller ise aynı sınıfa atanarak sınıflandırma işlemi yapılmaktadır. İlâveten aynı kümedeki tüm piksellere ilgili sınıftaki piksellerin ortalama değerleri atanmış ve renk indirgemesi yapılmıştır. Aynı sınıfta bulunan piksellerin dağılımı ile de sınıfsal tabanlı tek boyutlu histogram (TBH) elde edilmiştir. Son aşamada ise sınıfsal tabanlı histogram bilgisi özellik vektörü olarak kullanılarak görüntü erişimi gerçekleştirilmiştir. Tüm deneysel sonuçlar Core11K veri seti üzerinden elde edilmiş ve geliştirilen yöntem LBG tabanlı görüntü erişimi ile karşılaştırılmıştır.

2. SAYISAL GÖRÜNTÜ İŞLEME

Sayısal görüntü işleme elektronik ortamlar üzerinde gözetilen amaç doğrultusunda erişim, sınıflandırma, bölütleme, filtreleme ve iyileştirme gibi süreçleri içeren bir araştırma alanıdır. Ayrıca tıp, coğrafya, savunma sanayi ve uzay bilimleri gibi birçok disiplinde etkin bir şekilde kullanılmaktadır.

2.1. Sayısal Görüntü

Görüntü $I(x,y)$ şeklinde gösterilen ışık yoğunluk fonksiyonu olarak tanımlanabilir. Burada x ve y uzamsal düzlemindeki koordinatları ifade etmektedir. Sayısal görüntü ise bahsi geçen düzlemde her birinin özel konumu ve değeri olan piksel diye adlandırılan sonlu elemanlı yapılardan oluşmaktadır. Bir başka ifade ile M satır ve N sütun sayısı olmak üzere $M \times N$ adet pikselden oluşan bir matris olarak tanımlanmaktadır [73, 74]. Şekil 2.1 tipik bir sayısal görüntüyü ve koordinatlarını göstermektedir.

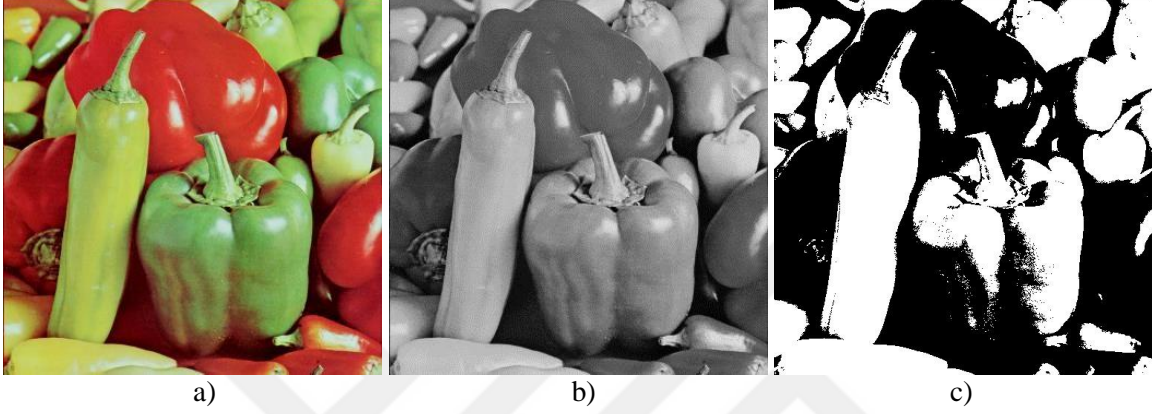


Şekil 2.1. Sayısal görüntü örneği

2.2. Görüntü Türleri

Sayısal görüntüler ikili, gri seviyeli ve renkli görüntüler şeklinde sınıflandırılmaktadır. Renkli görüntülerin her bir pikseli 8 bitlik kırmızı (R:red), yeşil (G:green) ve mavi (B:blue) bileşenlerinden oluşmaktadır. Her piksel üç farklı renk kanalının birleştirilmesi ile oluşan 24 bitlik bir sayıdan ibarettir. Sayısal görüntülerdeki pikseller elektromanyetik spektrumda 600-700 nm dalga boylu kırmızı, 500-600 nm dalga boylu yeşil ve 400-500 nm dalga boylu mavi

renği almaktadırlar ve bu renklerin birleşmesiyle renkli görüntüler elde edilmektedir. Gri seviyeli görüntülerin ise her pikseli farklı gri ton değerlerinden oluşmaktadır. Gri seviyeli görüntülerde pikseller $[0,255]$ aralığında 256 farklı değer almaktadır. Bir diğer tür olan ikili görüntülerde de pikseller siyah (0) ya da beyaz (255) değerini almaktadır [72]. Şekil 2.2' de üç görüntü türüne ait örnekler verilmiştir.




Şekil 2.2. Biber görüntüsü a) renkli b) gri seviyeli c) ikili

2.3. Renk Uzayları

Renkli görüntülerdeki her piksel genelde üç ayrı bileşenden oluşmaktadır. Piksellerin uzaysal koordinatlarına ilave olarak, aynı zamanda ilgili pikselin renk bileşenleride tanımlandığı renk uzayında bir noktaya tekabül etmektedir. Dolayısıyla sayısal görüntü işleme süreçleri sadece görüntülerin uzaysal koordinatlarında değil, aynı zamanda renk uzaylarında da yapılabilmektedir. Son yüz yılda çeşitli renk uzayları tanımlanmıştır. Ancak bunlardan yaygın kullanılanları: RGB, Lab, HSV, HSI, CMY ve CMYK'dır [75].

Lineer yapısından dolayı RGB renk uzayı pratik uygulamalarda tercih sebebi olmuştur. RGB renk uzayı her bir bileşeni $[0, 255]$ aralığında değer alan ve eksenleri renk seviyelerinden oluşan üç boyutlu bir küpten oluşmaktadır. RGB uzayı kırmızı (255,0,0), yeşil (0,255,0), mavi (0,0,255) birincil renkler ve camgöbeği (0,255,255), mor (255,0,255) ve sarı (255,255,0) ikincil renklere meydana gelmektedir. Şekil 2.3'te RGB renk küpü görülmektedir. İlgili uzayda tüm renkler üç temel rengin bir araya gelmesiyle oluşmaktadır ve her renk uzayda bir noktaya karşılık gelmektedir.



Şekil 2.3. RGB renk uzayı

2.4. Görüntü Histogramı


Histogram görüntülerin piksellerine ait renk bileşenlerinin bulunma olasılığını gösteren bir dağılım grafiğidir. Aynı zamanda döndürmeye, ölçeklemeye dayanıklı olmasından ve kolay hesaplanmasından dolayı görüntü işleme çalışmalarında sıklıkla tercih edilen bir özellik vektörüdür. Söz konusu olasılık dağılımını elde etmek için renkli görüntülerde iki veya üç boyutlu uzayda işlem yapılması gerekir iken, gri seviyeli görüntülerde ise tek boyut yeterli olmaktadır.

2.4.1. Gri seviyeli görüntü histogramı

Histogram her renk seviyesindeki piksel sayısını gösteren bir dağılımdır. Gri seviyeli görüntülerde tek bir kanal için oluşturulur iken renkli görüntülerde üç kanal için ayrı ayrı oluşturulması gereklidir. Başka bir ifade ile renkli görüntüler için üç ayrı tek boyutlu histogram hesaplanmalıdır. Herhangi bir görüntüde pikseller $\{0,1,\dots,L\}$ aralığında değer almaktadır. Bu durumda i . gri seviyenin olasılığı

$$p_i = \frac{r_i}{M \times N}, \quad 0 \leq i \leq L \quad (2.1)$$

şeklinde gösterilebilir. Burada $M \times N$ görüntünün boyutlarını, r_i i . yoğunluk seviyesine sahip piksellerin sayısını ve L maximum yoğunluk seviyesini ifade etmektedir. Şekil 2.4., Şekil 2.2. b'de verilen gri seviyeli biber görüntüsüne ait histogramı göstermektedir.



Şekil 2.4. Gri seviyeli biber görüntüsüne ait histogram


2.4.2. Renkli görüntülerin iki boyutlu histogramı

İki boyutlu renk histogramı RGB renk kanallarındaki renk bileşenlerinin RG, RB ve GB şeklindeki ikili kanalların olasılık dağılımlarını gösterir. (??) ikili renk bileşeninde tekrar sayısı ?? olmak üzere söz konusu dağılım


$$p_{i,j} = \frac{r_{i,j}}{M \times N}, \quad 0 \leq i \leq L, \quad 0 \leq j \leq L \quad (2.2)$$

$$\sum_{j=0}^L \sum_{i=0}^L p_{i,j} = 1 \quad (2.3)$$


şeklinde hesaplanmaktadır. Şekil 2.2 a'daki renkli Biber görüntüsünün Şekil 2.5.'de RG, Şekil 2.6.'da RB ve Şekil 2.7.'de ise GB bileşenlerine ait iki boyutlu renk dağılımları gösterilmiştir.



Şekil 2.5. Biber görüntüsünün iki boyutlu histogramı: RG



Şekil 2.6. Biber görüntüsünün iki boyutlu histogramı: RB



Şekil 2.7. Biber görüntüsünün iki boyutlu histogramı: GB


2.4.3. Renkli görüntülerin üç boyutlu histogramı

RGB renk uzayında tanımlanan sayısal görüntülerde her piksel bir noktaya karşılık gelmektedir. (RGB) renk bileşenlerinin sayısal görüntü içerisindeki tekrar sayısı $r_{i,j,k}$ olmak üzere, üç boyutlu histogram

$$p_{i,j,k} = \frac{r_{i,j,k}}{M \times N}, \quad 0 \leq i \leq L, \quad 0 \leq j \leq L, \quad 0 \leq k \leq L, \quad (2.4)$$

$$\sum_k \sum_j \sum_i p_{i,j,k} = 1 \quad (2.5)$$

gibi ifade edilmektedir. Şekil 2.8’de, Şekil 2.2 a’daki Biber görüntüsünün RGB uzayındaki renk dağılımı gösterilmiştir. Görüldüğü gibi renk uzayındaki bütün renkler kullanılmamıştır. Kartezyen koordinat sisteminde bir düzlemde tanımlı olan Biber görüntüsü, RGB uzayın noktalar bulutuna karşılık gelmektedir.



Şekil 2.8. Biber görüntüsünün renk dağılımı

2.5. Vektör Nicemleme ve Renk İndirgeme

Vektör nicemleme görüntü işleme çalışmalarında sıklıkla kullanılan önemli bir yaklaşımdır. Bahsi geçen yöntemin temel amacı birbirine yakın renkleri aynı grup altında toplayarak görüntüdeki renk çeşitliliğini azaltmaktır [76]. İndirgenen görüntünün orijinaline ne kadar benzediği ise indirgeme algoritmasının performansını göstermektedir.

RGB renk uzayında 16.777.216 farklı renk bulunmaktadır. İlgili uzayın büyüklüğünden kaynaklı renkli görüntülerde yapılacak işlemler karmaşık ve maliyetli olmaktadır. Bahsedilen karmaşıklık ve hesapsal maliyet probleminin üstesinden gelebilmek adına farklı renk indirgeme yaklaşımları önerilmiştir. Söz konusu tekniklerden bazıları octree (sekizli ağaç) [77], medyanCut (medyan kesme) [78] ve LBG [79] gibi algoritmalarıdır.


Medyan kesme yöntemi görüntüdeki renklerinin dağılımını temel almaktadır. İlk olarak görüntüdeki tüm renkleri içeren piksellerin bulunma olasılıkları hesaplanmaktadır. Ardından tüm kanallara ait renkler sıralanmaktadır. Son olarak sıralanmış listenin ortancasından iki bölgeye ayrılmaktadır. İşlem orijinal görüntüdeki farklı renk sayısının istenilen renk sayısına düşürülmesine kadar tekrarlanmaktadır [78]. Ayrılan her bölgenin ortalama renkleri renk paletini oluşturmaktadır. Şekil 2.9 medyan kesme algoritması ile Biber görüntüsünün 8 renge dönüştürülmüş halini göstermektedir.




Şekil 2.9. Medyan kesme yöntemi ile indirgenmiş Biber görüntüsü (8 renk)

Gervautz ve Purgathofer tarafından geliştirilen sekizli ağaç renk nicemeleme algoritması ise renk indirgeme işlemini 8 seviyeli ağaç veri yapısını temel alarak yürütmektedir. 8 seviyeli ağaç veri yapısındaki düğümler görüntüdeki kırmızı, yeşil ve mavi renk bileşenlerinin en önemli bitlerini değerlendirerek oluşturulmaktadır [77]. Öncelikle her renk değeri 8 bit seviyesine dönüştürülmektedir. Sonrasında renk kanallarının en önemli bitleri her seviyede birleştirilerek ikili kodlar oluşturulmaktadır. Görüntüdeki her piksele söz konusu işlemler uygulanarak piksellerin hangi kümeye dâhil olacağı belirlenmektedir. Son aşamada ise aynı kümeye giren piksellerin ortalamaları alınarak renk paleti oluşturulmaktadır. Şekil 2.10 sekizli ağaç indirgeme algoritmasının uygulama şemasını göstermektedir. R,G ve B değerleri sırasıyla 90, 148 ve 118 olan bir pikselin sekizli ağaç algoritmasına göre

kodlanması Şekil 2.11 de göstermiştir. Şekil 2.12 de ise Biber görüntüsünün bahsi geçen indirgeme tekniği ile sekiz renge indirgenmiş hali gösterilmiştir.



Şekil 2.10. Sekizli ağaç algoritması [80]

			7	6	5	4	3	2	1	0
 (R:90,G:148,B:118)	R	90	0	1	0	1	1	0	1	0
	G	148	1	0	0	1	0	1	0	0
	B	118	0	1	1	1	0	1	1	0
<i>Sınıf indisi</i>			$(010)_2$	$(101)_2$	$(001)_2$	$(111)_2$	$(100)_2$	$(011)_2$	$(101)_2$	$(000)_2$
			1. Seviye	2. Seviye	3. Seviye	4. Seviye	5. Seviye	6. Seviye	7. Seviye	8. Seviye

Şekil 2.11. Sekizli ağaç ile renk kodlarının oluşturulması



Şekil 2.12. Sekizli ağaç yöntemi ile indirgenmiş Biber görüntüsü (8 renk)

Görüntüler üzerindeki birbirine benzeyen piksellerin aynı sınıflara dâhil edilmesiyle, söz konusu görüntüler üzerindeki yürütülecek algoritmaların başarısı ve performansı arttırılmaktadır. Pikseller arasındaki benzerliklerden yararlanılarak aynı sınıfa dâhil etme işlemi vektör nicemleme ya da renk indirgeme algoritmalarıyla gerçekleştirilmektedir. 1980 yılında geliştirilmiş olan LBG algoritması vektör nicemleme ve veri sıkıştırma için kullanılan bir yaklaşımdır [79]. Öz yinmeli olan ilgili teknik GLA (Generalized Lloyd Algorithm) olarak da bilinmektedir. LBG algoritması bir girdi vektörünü rastgele belirlenen başlangıç merkez değerlerine olan uzaklıklarına göre sınıflara ayırmaktadır. Rastgele başlangıç değerlerinin atanması ve iteratif olmasıyla K-ortalamlar yöntemine benzeyen LBG tekniğinde iterasyon sayısı başlangıçta belirgin değildir ve bir durdurma eşliğine ihtiyacı vardır.

LBG algoritması $v_i = \{i = 1, 2, \dots, l\}$ olan bir girdi vektör kümesini alarak, $c_j = \{j = 1, 2, \dots, k\}$

olan temsili bir alt vektör kümesine indirgemektedir. Böylelikle $k < l$ olmak üzere l elemanlı bir vektör kümesi k elemanlı bir vektör kümesine indirgenmektedir. Başlangıçta rastgele belirlenen küme merkezleri pikselere olan uzaklıklarına göre güncellenmektedir. LBG algoritmasında aşağıdaki adımlar takip edilir [81]:

1. Girdi eğitim vektörünü al (v),
2. Başlangıç küme merkezlerini rasgele oluştur (c),
3. İterasyon sayısını (u) ve bozulum miktarını (D_u) sıfıra eşitle.
4. $j \neq q$ için eğer $\|v_i - c_q\| \leq \|v_i - c_j\|$ ise girdi elemanını ilgili sınıfa dâhil et $v_i \in c_q$

5. $c_j, j = 1, 2, \dots, k$ küme merkezlerini $c_j = \frac{1}{|S_j|} \sum_{v_i \in S_j} v_i$ aracılığıyla güncelle.

$$\| \quad \|$$

6. Bozulum miktarı hesapla $D_u = \sum_{j=1}^k \sum_{v_i \in S_j} \|v_i - c_j\|^2$

7. Eğer $(D_{u-1} - D_u) / D_u > \varepsilon$ ise 4. adıma dön.

8. Çıktı kod kitabı $c_j = \{j = 1, 2, \dots, k\}$ dır.

LBG algoritmasının sonlanması D_u bozulum miktarına ve ε durdurma eşik değerine

bağlıdır. Homojenliği sağlamak için maksimum sayıda iterasyon yapılmalıdır. Durdurma

eşığı olarak tanımlanan ϵ değeri kullanıcının belirlediği küçük bir sayıdır (0,005 tipik bir



değerdir). Şekil 2.14'te Biber görüntüsünün LBG nicemleme algoritması ile 8 renge dönüştürülmüş hali gösterilmiştir.



Şekil 2.13. LBG yöntemi ile indirgenmiş Biber görüntüsü (8 renk)

2.6. Görüntü Benzerlik Ölçümü

Görüntüler üzerinde yapılan renk indirgeme işlemi neticesinde bilgi kayıplarının olması beklenen muhtemel bir sonuçtur. Bilgi kayıplarının oranı herhangi bir işlemde geçen sayısal görüntünün orijinaline olan yakınlığına göre tespit edilmektedir. İki görüntünün birbirlerine ne kadar benzediğini hesaplamak için bazı ölçüm metriklerinden yararlanılmaktadır. Söz konusu kriterlerden yaygın olarak kullanılanlardan biri de ortalama kareler hatası (Mean Squared Error: MSE)'dir. Ortalama kareler hatası

$$MSE = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} (I_1(x, y) - I_2(x, y))^2 \quad (2.6)$$

şeklinde hesaplanmaktadır[72]. I_1 ve I_2 karşılaştırılan görüntüleri, x ve y ise ilgili görüntünün piksel konumlarını temsil etmektedirler. Eş. 2.6'dan da anlaşılacağı üzere karşılaştırılan her iki görüntünün boyutlarının aynı olması gerekmektedir. Tepe sinyal gürültü oranı (Peak Signal to Noise Ratio: PSNR) [72] ise sıklıkla kullanılan bir diğer karşılaştırma metriğidir.

İlgili metrik

$$PSNR = 10 \log \left(\frac{255 \times 255}{MSE} \right) \quad (2.7)$$

şeklinde hesaplanmaktadır. PSNR değeri ne kadar büyük çıkarsa karşılaştırılan görüntülerin birbirlerine o kadar yakın olduğu anlamına gelmektedir.

Performans değerlendirme adına diğer bir ölçüt olarak yapısal benzerlik indeksi (Structural Similarity Index: SSIM) kullanılmaktadır [82]. SSIM matematiksel olarak

$$SSIM = \frac{(2\mu_{I_1}\mu_{I_2} + c)(2\sigma_{I_1I_2} + a_2)}{(\mu_{I_1}^2 + \mu_{I_2}^2 + c)(\sigma_{I_1}^2 + \sigma_{I_2}^2 + a_1)} \quad (2.8)$$

olarak tanımlanmıştır. Eş. 2.8'deki μ_{I_1} ve μ_{I_2} girdi ve çıktı görüntünün ortalamasını, σ_{I_1} ve σ_{I_2} girdi ve çıktı görüntünün varyansını ve $\sigma_{I_1I_2}$ iki görüntünün kovaryansını göstermektedir. a_1 ve a_2 parametreleri $a_1 = (0.01xL)^2$ ve $a_2 = (0.03xL)^2$ olarak seçilen sabitleri ifade etmektedir. Burada L maksimum yoğunluk seviyesini göstermektedir ve gri seviyeli görüntüler için 255 değerini almaktadır.

2.7. Histogram Tabanlı Benzerlik Ölçüm Metotları

MSE, PSNR ve SSIM gibi yaklaşımlar görüntüleri piksel piksel işleme tabi tutmaktadırlar. Dolayısıyla karşılaştırılan görüntülerin aynı boyutlarda olması durumunda uygulanabilirler. Ancak farklı boyutlara sahip sayısal görüntülere ise bu metrikleri uygulamak mümkün olmamaktadır. Farklı boyutlardaki görüntülerden oluşan veri tabanları üzerinde gerçekleştirilen İTGE sistemlerinde görüntüleri piksel seviyesinde karşılaştırmak zaman ve karmaşıklık bakımından maliyetli olmaktadır. Bu sebeple farklı boyutlardaki görüntü karşılaştırma işlemlerini piksel seviyesinde yapmak yerine onları temsil eden eşit uzunluktaki özellik vektörleri üzerinde gerçekleştirmek gerekmektedir. Histogram ise görüntülerin boyutlarından bağımsız olan global bir temsil aracıdır ve görüntülerin benzerliğini hesaplamak için kullanılabilir bir özelliktir. Görüntüleri piksel seviyesine karşılaştırmak yerine onlara ait histogram vektörleri karşılaştırılabilir. Histogram vektörlerini karşılaştırmak adına geliştirilen birçok ölçüm tekniği bulunmaktadır. Öklit, Manhattan, kosinüs ve kesişim benzerlik metrikleri [83] histogram benzerlik yaklaşımlarından sadece birkaçıdır.

Öklit yaklaşımı benzerlik ölçümü için yaygın kullanılan yöntemlerden biridir. İki nokta arasındaki doğrusal uzaklığı ölçmek için kullanılmaktadır. Histogram benzerliği içinde etkin bir şekilde kullanılmakta olup Öklit mesafe ölçümü,

$$d_1(p_1, p_2) = \sqrt{\left(\sum_{i=0}^L p_{1,i}, p_{2,i} \right)^2} \quad (2.9)$$

gibi hesaplanmaktadır. Burada p_1 ve p_2 karşılaştırılan histogramları ifade etmektedir. Diğer taraftan Manhattan uzaklığı ile iki nokta arasındaki mesafe

$$d_2(p_1, p_2) = \sum_{i=0}^L |p_{1,i} - p_{2,i}| \quad (2.10)$$

şeklinde hesaplanmaktadır. Kosinüs benzerliği ise

$$d_3(p_1, p_2) = \frac{\sum_{i=0}^L p_{1,i} p_{2,i}}{\sqrt{\sum_{i=0}^L p_{1,i}^2} \sqrt{\sum_{i=0}^L p_{2,i}^2}} \quad (2.11)$$

olarak ifade edilmektedir. Ayrıca histogram kesişimi kısmi eşleşmeleri işleme kabiliyeti nedeniyle başarılı bir yöntemdir [29]. İlgili uzaklığın denklemi

$$d_4(p_1, p_2) = \sum_{i=0}^L \min(p_{1,i}, p_{2,i}) \quad (2.12)$$

şeklindedir.

2.8. İçerik Tabanlı Görüntü Erişimi Performans Ölçütleri

İTGE sistemlerinin amacı veri setindeki görüntüler arasından sorgu görüntüye en benzer görüntülere erişimi sağlamaktır. Bahsi geçen sistemlerin başarıları getirdikleri ilişkili görüntü sayısı ile doğru orantılıdır. Dolayısıyla sistemlerin erişebildiği ilişkili görüntü sayısının ölçümü önemli bir basamaktır. Bundan dolayı İTGE sistemlerinin başarımını tespit edebilmek için performans değerlendirme yöntemlerine ihtiyaç duyulmaktadır. İTGE sistemlerinin performans değerlendirmeleri için kullanılan yaklaşımlarından biri karmaşıklık matrisi adı verilen olasılık tablosudur [84]. Erişim sistemlerinde kullanılan veri tabanları çok sınıflı olmaktadır. Bu nedenle çok seviyeli karmaşıklık matrisinden yararlanılmaktadır. Çizelge 2.1 çok sınıflı genelleştirilmiş karmaşıklık matrisini

göstermektedir. Matristeki satırlar görüntülerin gerçekte ait olduğu sınıfları, sütunlar ise sorgulama sonrasında tahmin edilen sınıfları göstermektedir. Diyagonal eksen doğru sınıflandırılan görüntü sayılarını ifade ederken, köşegen dışında kalan diğer yerler yanlış sınıflandırılan görüntü sayısını temsil etmektedir. Bir veri setinde X örnek sayısını, G sınıf sayısını ve $g = \{1, 2, \dots, G\}$ sınıf indisini belirtmektedir. Matriste g indisli sınıfa ait fakat f indisli sınıfta tahmin edilen örnek sayısını z_{gf} , doğru sınıflandırılmış örnek sayısını ise z_{gg} göstermektedir [85, 86]. X tüm örneklerin sayısı olup,

$$X = \sum_{g=1}^G \sum_{f=1}^G z_{gf} \quad (2.13)$$

olarak hesaplanmaktadır. x_g sorgulanan görüntünün sınıfındaki örneklem sayısını gösterir ve

$$x_g = \sum_{f=1}^G z_{gf} \quad (2.14)$$

şeklinde ifade edilir. Tahmin edilen sınıflara ait örnek sayıları ise x'_g ile temsil edilmiştir ve

$$x'_g = \sum_{f=1}^G z_{fg} \quad (2.15)$$

olarak gösterilmiştir.

Çizelge 2.1 G sınıflı bir veri kümesinin karmaşıklık matrisi [85]

		Tahmin edilen sınıf					\mathbf{x}_g	\mathbf{R}_g
		1	2	3	...	G		
Gerçek sınıf	1	z_{11}	z_{12}	z_{13}	...	z_{1G}	x_1	\mathbf{R}_1
	2	z_{21}	z_{22}	z_{23}	...	z_{2G}	x_2	\mathbf{R}_2

	G	z_{G1}	z_{G2}	z_{G3}	...	z_{GG}	x_G	\mathbf{R}_G
	\mathbf{x}'_g	x'_1	x'_2	x'_3	...	x'_G		
	\mathbf{P}_g	P_1	P_2	P_3	...	P_G		

Sınıflandırma performansını değerlendirmek için kullanılan ölçütler kesinlik (Precision: P) ve hassasiyet (Recall: R) değerleridir [85]. g nolu sınıfı ait hassasiyet R_g ile gösterilir ve

$$R_g = \frac{z_{gg}}{x_g} \quad (2.16)$$

şeklinde ifade edilmektedir. Kesinlik değeri sınıfların saflığı olarak nitelendirilmektedir ve g sınıfına ait kesinlik değeri P_g olup,

$$P_g = \frac{z_{gg}}{x'_g} \quad (2.17)$$

şeklinde hesaplanmaktadır. Her sınıfın kesinlik ve hassasiyet değerleri ayrı ayrı hesaplanarak sınıfsal başarı değerleri elde edilmektedir. Ancak sınıflandırma işleminin genel başarısını değerlendirmek için yetersizdirler. Bu nedenle test edilen algoritmanın bir bütün olarak başarımı için makro kesinlik ve makro hassasiyet hesaplanması gereklidir. Makro hassasiyet (R_m) ve makro kesinlik (P_m) sırasıyla:

$$R_m = \frac{\sum_{g=1}^G R_g}{G} \quad (2.18)$$

ve

$$P_m = \frac{\sum_{g=1}^G P_g}{G} \quad (2.19)$$

olarak formüle edilmektedir. Sınıflandırma kalitesini analiz etmek için kullanılan bir başka ölçüt genel başarı oranı olarak bilinen doğruluktur (Accuracy: A) [85, 86]. İlgili parametre,

$$A = \frac{\sum_{g=1}^G z_{gg}}{X} \quad (2.20)$$

şeklinde tanımlanmaktadır.

Karmaşıklık matrisi getirilen doğru görüntülerin hangi sırada olduğunu önemsemeden sadece toplamda ne kadar doğru görüntünün getirildiğini dikkate alan performans değerlendirme ölçütüdür. Erişilen ilişkili görüntülerin hangi sırada getirildiğine bakan sistemler ise sıralı erişim sistemleri olarak adlandırılmaktadır. Sıralı erişim sistemlerinde performans ölçümleri için karmaşıklık matrisinde olduğu gibi kesinlik ve hassasiyet değerleri hesaplanmaktadır [87]. Genel anlamda kesinlik ve hassasiyet değerleri sırasıyla;

$$P = \frac{\text{getirilen ilişkili görüntü sayısı}}{\text{getirilen toplam görüntü sayısı}} \quad (2.21)$$

$$R = \frac{\text{getirilen ilişkili görüntü sayısı}}{\text{koleksiyondaki ilişkili görüntü sayısı}} \quad (2.22)$$

şeklinde hesaplanmaktadır. Çizelge 2.2 tipik bir sıralı erişim sistemini örneği gösterilmiştir. Söz konusu örnekte sorgu görüntünün veritabanındaki tüm görüntülerle karşılaştırılıp en çok benzeyene göre sıralanarak 10 tane görüntüye erişildiği varsayılmıştır. İlgili çizelgede sorgu görüntü temsili olarak sarı renk ile ifade edilmiştir. Erişilen ilişkili görüntüler yine sarı renkte gösterilmiş olup D (doğru) ile etiketlenmiştir. İlişkili olmayanlar ise siyah renk ile temsil edilerek Y (yanlış) ile etiketlenmiştir. *i*. sıradaki kesinlik ve hassasiyet değerleri sırasıyla

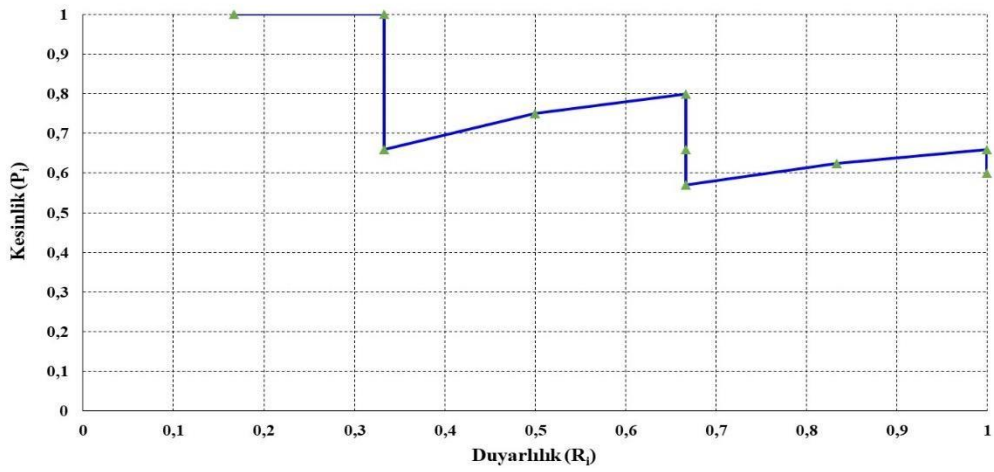
$$P = \frac{i. \text{ sıradaki ilişkili görüntü sayısı}}{i. \text{ sıradaki getirilen toplam görüntü sayısı}} \quad (2.23)$$

$$R_i = \frac{i. \text{ sıradaki ilişkili görüntü sayısı}}{\text{getirilen toplam ilişkili görüntü sayısı}} \quad (2.24)$$

gibi hesaplanmaktadır [88,89]. Sıralı erişim sistemlerinin performans değerlendirmeleri için yaygın olarak P-R eğrileri kullanılmaktadır. Çizelge 2.2 ait R_i ve P_i değerlerini gösteren grafik Şekil 2.14'te verilmiştir. İlgili şekil incelendiğinde bazı R_i seviyeleri için P_i değerlerinin hesaplanmadığı açıktır. Başka bir ifade ile karşılığı yoktur. Diğer taraftan algoritmaların performansları karşılaştırılırken aynı hassasiyet seviyelerindeki kesinlik değerleri dikkate alınmaktadır. Bundan dolayı Şekil 2.14'te verilen eğrinin standart hassasiyet değerlerine normalize edilmesi gerekmektedir. Literatürde kullanılan standart hassasiyet noktaları $\{0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1\}$ değerlerinden oluşmaktadır.

Çizelge 2.2 Sıralı erişim yöntemi

Sorgu görüntü	Sıra (i)	Getirilen görüntü	Hassasiyet (R_i)	Keskinlik (P_i)
■	1	■ D	0,17	1
	2	■ D	0,33	1
	3	■ Y	0,33	0,66
	4	■ D	0,50	0,75
	5	■ D	0,67	0,8
	6	■ Y	0,67	0,66
	7	■ Y	0,67	0,57
	8	■ D	0,83	0,625
	9	■ D	1	0,66
	10	■ Y	1	0,6

Şekil 2.14. Sıralı erişim P_i - R_i eğrisi


P-R eğrileri ile performans değerlendirilirken yukarıda bahsedildiği üzere aynı hassasiyet noktalarındaki kesinlik değerlerine bakılmaktadır. Dolayısıyla 11 standart hassasiyet noktalı P-R eğrisinin oluşturulması önemli hale gelmektedir. Bu nedenle söz konusu eğrilerden standart hassasiyet noktalarına karşılık gelen enterpole kesinlik değerlerinin hesaplanmasına ihtiyaç vardır [88]. Enterpole kesinlik değerleri

$$P_e(R) = \max_{R \Rightarrow R} (P(R')) \quad (2.25)$$

şeklinde ifade edilmektedir. Burada R' i . sıradaki standart hassasiyet değerine eşit ya da büyük olan $(i+1)$ değeri temsil etmektedir. Bir başka ifade ile herhangi bir R seviyesindeki P değeri, kendinden sonraki sıralardaki P değerlerinin en büyük olanına eşittir. Böylelikle standart hassasiyet seviyelerindeki enterpole kesinlik değerleri hesaplanmaktadır. Çizelge 2.3 11 standart hassasiyet noktalarına karşılık gelen enterpole kesinlik (P) değerlerini göstermektedir. Çizelge 2.2'de görüldüğü gibi bazı R_i değerleri elde edilememiştir. Tespit edilemeyen hassasiyet noktaları için bir sonraki hassasiyet seviyesindeki maksimum kesinlik değeri atanmaktadır. Böylelikle algoritmaların performansları aynı hassasiyet seviyelerindeki kesinlik değerlerine bakılarak yapılmakta ve sonuçta tutarlılık sağlanmaktadır. Şekil 2.15'te Çizelge 2.3'de hesaplanan standart 11 noktalı R seviyelerini ve ilgili seviyelere karşılık gelen enterpole P değerlerini temsil eden grafik bulunmaktadır.

Çizelge 2.3 Standart 11 noktalı hassasiyet ve enterpole kesinlik değerleri

Standart Hassasiyet (R)	Enterpole Kesinlik (P _e)
0	1
0,1	1
0,2	1
0,3	1
0,4	0,8
0,5	0,8
0,6	0,8
0,7	0,66
0,8	0,66
0,9	0,66
1	0,66



Şekil 2.15. Sıralı erişim enterpole P-R eğrisi


3. RENKLİ HİSTOGRAM TABANLI GÖRÜNTÜ ERİŞİMİ

Teknolojinin hızla gelişmesiyle sayısal görüntü kullanımı fazlasıyla artmıştır. Böylece elde edilen görüntülerin depolanmasıyla çok büyük veri tabanları oluşmaktadır. Veri yığını haline dönüşen görüntülerin dizinlenmesi ve arzu edilen görüntülere erişilmesi önemli bir sorun haline dönüşmüştür. 1970 li yıllarda bahsi geçen problemin üstesinden gelmek adına metin tabanlı görüntü erişim sistemleri geliştirilmiştir. Ancak görüntülerin kelime ya da kelime gruplarıyla indekslendiği ilgili erişim sistemleri 1980 yıllardan itibaren yerini görüntülerin özelliklerini kullanan İTGE sistemlerine bırakmıştır. İTGE mimarisi görüntülerin renk, doku veya şekil gibi özelliklerini kullanarak istenilen görüntüleri elde etmek amacıyla geliştirilen bir süreçtir [89]. IBM şirketi tarafından hazırlanan QBIC isimli yazılım veritabanındaki görüntülerin özellikleriyle sorgu görüntüsüne ait özellik vektörlerini karşılaştırılarak benzerlerin çağrıldığı ilk ticari yazılım olmuştur [90, 91]. Photobook, Virage, VisualSEEK, Netra, SIMPLicity gibi yazılımlarda İTGE sistemlerine örnek gösterilebilecek diğer uygulamalardır.

İTGE sistemlerinin çalışma prensibi veri tabanındaki görüntülerin içeriklerine dayalı özelliklerin çıkartılıp vektörel büyüklüklere dönüştürülmesi ve devamında veritabanına kaydedilmesi ile başlamaktadır. Akabinde aynı yöntemlerle çıkarılan sorgu görüntü özellik vektörünün veri tabanındaki özellik vektörlerine olan uzaklıkları hesaplanarak en benzerlerinin getirilmesi ile sonlanır. Özellik çıkarımı erişilmesi istenen görüntülerin elde edilmesinde en önemli basamaktır. Tüm sistemin doğru ve hızlı çalışmasını etkilemektedir. Özellik görüntülerin renk, doku veya şekil gibi bilgilerini temsil eden vektörlerdir. Özellik çıkarımı aşamasında elde edilen vektörler benzerlik ölçüm metrikleri aracılığıyla karşılaştırılarak görüntülerin benzerlikleri sayısal değerlerle ifade edilmektedir.

Histogram İTGE sistemlerinde sıklıkla kullanılan global bir temsil vektörüdür. Gri seviyeli görüntülerde tek renk kanalının işlenmesini gerektirmektedir. Ancak renkli görüntülerde histogram bilgisini kullanarak işlem yapmak 3 boyutlu bir matrisin çözülmesini gerektirmektedir. Söz konusu analizin ise hesapsal maliyeti oldukça yüksektir. RGB renk uzayındaki her bir kanaldan elde edilen histogramların birleştirilmesi de ayrıca bir problemdir. Söz konusu problemin üstesinden gelmek için bu çalışmada sınıf temelli tek boyutlu histogram vektörü önerilmiştir. Geliştirilen yaklaşımda çıkarılan histogram, özellik

vektörü olarak kullanılarak bir İTGE yapısı oluşturulmuştur. Şekil 3.1’de önerilen İTGE yapısının genel mimarisi verilmiştir.



Şekil 3.1. İTGE sisteminin genel mimarisi

3.1. Renk Uzayı Yardımıyla Görüntü Bölütleme

Görüntü bölütleme farklı bölgelerdeki piksellerin homojen bir şekilde tasnif edilmesi olarak tanımlanmaktadır ve önemli bir süreçtir. Görüntü bölütleme nesne tanıma, görüntü erişimi, veri sıkıştırma gibi birçok uygulamada kullanılmaktadır [92]. Söz konusu süreçte bölge büyütme yaklaşımı, yapay sinir ağları tabanlı teknikler, olasılık ve bulanık mantık tabanlı çözümler gibi metotlar uygulanmaktadır.

Gri seviyeli görüntülerde histogram üzerinden seçilen eşik noktaları yardımıyla görüntü ayrıştırma yapılabilmektedir. Söz konusu işlem için yaygın olarak Kapur [93], Otsu [94] ve histogramın ağırlık merkezi (HAM) [95] gibi algoritmalar kullanılmaktadır. Otsu optimizasyon yaklaşımında sınıflar arası varyansı maksimum veya sınıf içi varyansları minimum yapan amaç fonksiyonu dikkate alınmaktadır. Böylece oluşturulan sınıflardaki homejenlik sağlanmış olacaktır. Başka bir ifade ile aynı kümeye atanan pikseller benzer olacaktır. Diğer taraftan Kapur’un entropi metodu sınıflar arası entropi toplamını maksimum yapan noktaları tespit etmeyi amaçlamaktadır. Sınıflandırmada tek eşik kullanılması durumunda farklı tonlardaki renkler ancak iki sınıfın birinde yer bulacaktır ve homejenlik düşük olacaktır. Bu nedenle bilgi kaybının yaşanması beklenen bir durumdur. Muhtemel olan bilgi kayıplarını azaltmak için çok seviyeli eşikleme yapmak ve böylece sınıf sayısını artırarak sınıfların homejenliği sağlanmak mümkündür[96]. Gri seviyeli görüntüler için n

tane eşik değeri seçilmesiyle $c_{max}=n+1$ adet küme oluşacaktır ve ilgili kümeler $c_0 = \{0, \dots, t_1 - 1\}$, $c_1 = \{t_1, \dots, t_2 - 1\}$ ve $c_n = \{t_n, \dots, L\}$ şeklinde atanacaktır. Renkli görüntülerde ise üç kanaldan hesaplanan n tane eşik değeri için $c_{max}=(n+1)^3$ tane küme oluşacaktır. Gri seviyeli görüntülerde başarılı sonuçlar veren ve Kapur tarafından önerilen yaklaşımın çok seviyeli amaç fonksiyonu,

$$J(t_1, t_2, \dots, t_n) = H_0 + H_1 + H_2 + \dots + H_n \quad (3.1)$$

şeklinde ifade edilmiştir. Eş. 3.1 de verilen t eşik değerleri temsil etmektedir. H_0, H_1, \dots, H_n değişkenleri histogramın yerel entropilerini temsil etmekte olup,

$$\begin{aligned} H_0 &= - \sum_{i=0}^{t_1-1} \frac{p_i}{\omega_0} \ln \frac{p_i}{\omega_0}, & \omega_0 &= \sum_{i=0}^{t_1-1} p_i \\ H_1 &= - \sum_{i=t_1}^{t_2-1} \frac{p_i}{\omega_1} \ln \frac{p_i}{\omega_1}, & \omega_1 &= \sum_{i=t_1}^{t_2-1} p_i \\ H_2 &= - \sum_{i=t_2}^{t_3-1} \frac{p_i}{\omega_2} \ln \frac{p_i}{\omega_2}, & \omega_2 &= \sum_{i=t_2}^{t_3-1} p_i \\ & \vdots \\ H_n &= - \sum_{i=t_n}^L \frac{p_i}{\omega_n} \ln \frac{p_i}{\omega_n}, & \omega_n &= \sum_{i=t_n}^L p_i \end{aligned} \quad (3.2)$$

gibi hesaplanmaktadır. Burada p_i i . seviyede pikselin bulunma olasılığıdır. L ise 255 olup maksimum gri seviye değerini ifade etmektedir. Diğer taraftan Otsu yaklaşımının çok seviyeli amaç fonksiyonu

$$J(t_1, t_2, \dots, t_n) = \sigma_0 + \sigma_1 + \sigma_2 + \dots + \sigma_n \quad (3.3)$$

şeklinde tanımlanmıştır. İlgili eşitlikte verilen $\sigma_0, \sigma_1, \dots, \sigma_n$ parametreleri sınıflar arası varyansı temsil etmekte olup;

$$\begin{aligned}
\sigma_0 &= \omega_0 (\mu_0 - \mu_T)^2 \\
\sigma_1 &= \omega_1 (\mu_1 - \mu_T)^2 \\
\sigma_2 &= \omega_2 (\mu_2 - \mu_T)^2 \\
&\vdots \\
\sigma_n &= \omega_n (\mu_n - \mu_T)^2
\end{aligned} \tag{3.4}$$

ifadeleri ile hesaplanmaktadır. Burada sınıf ortalamaları μ ve kısmi olasılıklar ω

$$\begin{aligned}
\omega_0 &= \sum_{i=0}^{t_1-1} p_i, & \mu_0 &= \sum_{i=0}^{t_1-1} \frac{ip_i}{\omega_0} \\
\omega_1 &= \sum_{i=t_1}^{t_2-1} p_i, & \mu_1 &= \sum_{i=t_1}^{t_2-1} \frac{ip_i}{\omega_1} \\
\omega_2 &= \sum_{i=t_2}^{t_3-1} p_i, & \mu_2 &= \sum_{i=t_2}^{t_3-1} \frac{ip_i}{\omega_2} \\
&\vdots \\
\omega_n &= \sum_{i=t_n}^L p_i, & \mu_n &= \sum_{i=t_n}^L \frac{ip_i}{\omega_n}
\end{aligned} \tag{3.5}$$

şeklinde tanımlanmıştır. Ayrıca görüntünün gri seviye ortalaması μ_T ise

$$\mu_T = \sum_{i=0}^{L-1} ip_i \tag{3.6}$$

ifadesi ile bulunmaktadır. Diğer taraftan tekrarlı ortalamalar yaklaşımında histogram ağırlık merkezi (HAM) kullanılmıştır. Tekrarlı ortalamalar yönteminde kullanılan kısmi olasılık toplamları ve kısmi ortalamalar:

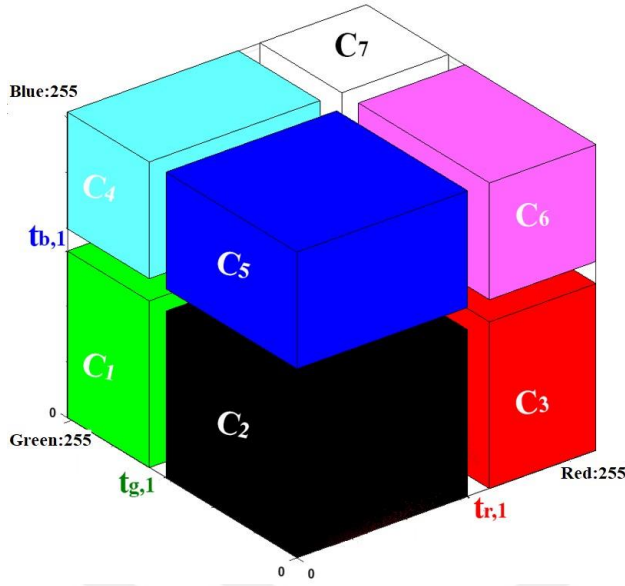
$$\begin{aligned}
\omega_0 &= \sum_{i=0}^{\mu_r-1} p_i, & \mu_0 &= \sum_{i=0}^{\mu_r-1} \frac{ip_i}{\omega_0} \\
\omega_1 &= \sum_{i=\mu_r}^{255} p_i, & \mu_1 &= \sum_{i=\mu_r}^{255} \frac{ip_i}{\omega_1} \\
\omega_{00} &= \sum_{i=0}^{\mu_0-1} p_i, & \mu_{00} &= \sum_{i=0}^{\mu_0-1} \frac{ip_i}{\omega_{00}} \\
\omega_{01} &= \sum_{i=\mu_0}^{\mu_r-1} p_i, & \mu_{01} &= \sum_{i=\mu_0}^{\mu_r-1} \frac{ip_i}{\omega_{01}} \\
\omega_{10} &= \sum_{i=\mu_r}^{\mu_1-1} p_i, & \mu_{10} &= \sum_{i=\mu_r}^{\mu_1-1} \frac{ip_i}{\omega_{10}} \\
\omega_{11} &= \sum_{i=\mu_1}^{255} p_i, & \mu_{11} &= \sum_{i=\mu_1}^{255} \frac{ip_i}{\omega_{11}}
\end{aligned} \tag{3.7}$$

şeklinde hesaplanmaktadır. HAM tekniği histogram üzerinden bulduğu her eşik değerini bir sonraki adımda tekrar kullanan bir yaklaşımdır. Bulunan ilk eşik ile histogram 2 kümeye bölünmektedir, sonraki adımda ise bulunan ilk eşik sınır noktasını oluşturmaktadır. Bu şekilde tekrarlı bir süreç ile çok seviyeli eşikleme gerçekleştirilmektedir. Çizelge 3.1 HAM yöntemi ile bulunan eşik sayılarını ve eşik değerlerini göstermektedir.

Çizelge 3.1 HAM yöntemiyle atanan eşik değerler ve sayıları

Eşik sayısı	Atanan değerleri
t_1	μ_T
$t_1 \quad t_2$	μ_0, μ_1
$t_1 \quad t_2 \quad t_3$	μ_0, μ_T, μ_1
$t_1 \quad t_2 \quad t_3 \quad t_4$	$\mu_{00}, \mu_{01}, \mu_{10}, \mu_{11}$
$t_1 \quad t_2 \quad t_3 \quad t_4 \quad t_5$	$\mu_{00}, \mu_{01}, \mu_T, \mu_{10}, \mu_{11}$

Yukarıda bahsedilen eşik belirleme teknikleri gri seviyeli görüntülerde başarılı sonuçlar verirken, renkli görüntülerde ise üç farklı kanal olduğundan her renk kanalı için eşik değerlerinin hesaplanması gereklidir. Ancak kanallardan alınan bilgilerin birleştirilerek anlamlı kümelerin oluşturulması bir problemdir. Diğer taraftan söz konusu problem, üç renk kanalından alınan eşik değerleri ile Şekil 3.2.'de gösterilen renk uzayı alt parçalara ayrılarak çözülmüştür. Böylece, her bir prizma içerisinde kalan pikseller aynı kümeye atanmıştır [97].



Şekil 3.2. Bölütlenmiş renk uzayı: $n=1$, $c=8$ [97]

Renk uzayı yardımıyla yapılan bölütleme işlemi görüntünün boyutundan bağımsızdır. Geleneksel yöntemler gibi hesaplama sürecinde görüntüdeki tüm pikseller defalarca kullanılmamaktadır. Yani hızlı ve iteratif olmayan bir süreçtir. Görüntüler çok büyük boyutlarda olsalar bile ayrıştırma süreci için harcanan süre değişmemektedir. Çizelge 3.2.'de ilgili teknik ile renk uzayındaki alt kümelerinin kural tabanlı nasıl belirlendiği görülmektedir [97]. Böylece piksellerin ait olduğu sınıflar ve sınıfların toplam piksel sayıları eş zamanlı olarak bulunabilmektedir.

Çizelge 3.2. Renk uzayının bölütlenmesi

Sınıf etiketi	Kurallar	Sınıf piksel sayısı
c_0	Eğer ($R <= t_{r,1}$ & $G <= t_{g,1}$ & $B <= t_{b,1}$)	r_0
c_1	Eğer ($R <= t_{r,1}$ & $G <= t_{g,1}$ & $B >= t_{b,1}$)	r_1
c_2	Eğer ($R <= t_{r,1}$ & $G >= t_{g,1}$ & $B <= t_{b,1}$)	r_2
c_3	Eğer ($R <= t_{r,1}$ & $G >= t_{g,1}$ & $B >= t_{b,1}$)	r_3
c_4	Eğer ($R >= t_{r,1}$ & $G <= t_{g,1}$ & $B <= t_{b,1}$)	r_4
c_5	Eğer ($R >= t_{r,1}$ & $G <= t_{g,1}$ & $B >= t_{b,1}$)	r_5
c_6	Eğer ($R >= t_{r,1}$ & $G >= t_{g,1}$ & $B <= t_{b,1}$)	r_6
c_7	Eğer ($R >= t_{r,1}$ & $G >= t_{g,1}$ & $B >= t_{b,1}$)	r_7

Çizelge 3.2 incelendiğinde her bir sınıfa ait piksel sayıları verilmiş olup, görüntünün toplam piksel sayısı bütün sınıfların piksel sayısının toplamına eşit olduğundan

$$MxN = \sum_{i=0}^7 r_i \quad (3.8)$$

ifadesi yazılabilir ve böylece herhangi bir pikselin i nolu sınıfta olma olasılığı

$$p_i = \frac{r_i}{MxN} \quad (3.9)$$

şeklinde tanımlanabilir. Böylece elde edilen dağılım fonksiyonu p_i tek boyutlu bir dağılım olup, üç farklı histograma ihtiyaç duyulmadan renkli görüntüleri temsil edilebilme imkânı sağlanmaktadır. t_r , t_g ve t_b eşikleri aracılığıyla 8 adet kural tanımlandığı görülmektedir. Söz konusu işlem büyük bir renk uzayını daha küçük bir kümeye indirgemektedir. Dolayısıyla elde edilen kümeler üzerinde daha hızlı işlem yapılabilmektedir. Eşikleme yöntemleri olarak Otsu, Kapur ve HAM algoritmalarından yararlanılmıştır. Bahsi geçen teknikler ile her bir referans görüntüler için elde edilecek eşik değerleri Çizelge 3.3’de görülmektedir.


Çizelge 3.3. Eşik değerler: $n=1$

	HAM			Otsu			Kapur		
	$t_{r,1}$	$t_{g,1}$	$t_{b,1}$	$t_{r,1}$	$t_{g,1}$	$t_{b,1}$	$t_{r,1}$	$t_{g,1}$	$t_{b,1}$
Lena	180	99	105	162	102	112	171	140	131
Biber	149	115	66	145	110	72	98	129	116
Mandrill	137	128	113	144	128	130	145	120	132

Çizelge 3.3 incelendiğinde eşikleme tekniklerinin aynı görüntüler için bulduğu eşik değerlerinin farklı olduğu görülmektedir. Bu durum Şekil 3.2 de gösterilen her bir sınıfa (c_i) dâhil olacak piksel sayılarının ve çıktı görüntülerin birbirinden farklı olacağını açık göstergesidir. İndirgeme sonucunda yaşanan bilgi kayıplarını test etmek için Lena, Biber ve Mandrill görüntüleri kullanılmıştır. Bu kapsamda orijinal hali Şekil 3.3 (a)’da verilen Lena’nın renk dağılımı Şekil 3.3 (b)’de, aynı şekilde orijinal hali Şekil 3.4 (a)’da verilen Biber’in renk dağılımı Şekil 3.4 (b)’de gösterilmiştir. Tipik bir örnek olan Mandrill’in orijinali Şekil 3.5 (a)’da, renk dağılımı ise Şekil 3.5 (b)’de gösterilmiştir.



a)




b)

Şekil 3.3. Lena a) orijinal b) renk dağılımı




a)




b)

Şekil 3.4. Biber a) orijinal b) renk dağılımı



a)




b)


Şekil 3.5. Mandrill a) orijinal b) renk dağılımı

Önerilen stratejide sınıflandırma, renk indirgeme ve tek boyutlu histogram aynı anda gerçekleştirilmektedir. Referanslar görüntüler üzerinde HAM, Otsu, Kapur ve geleneksel

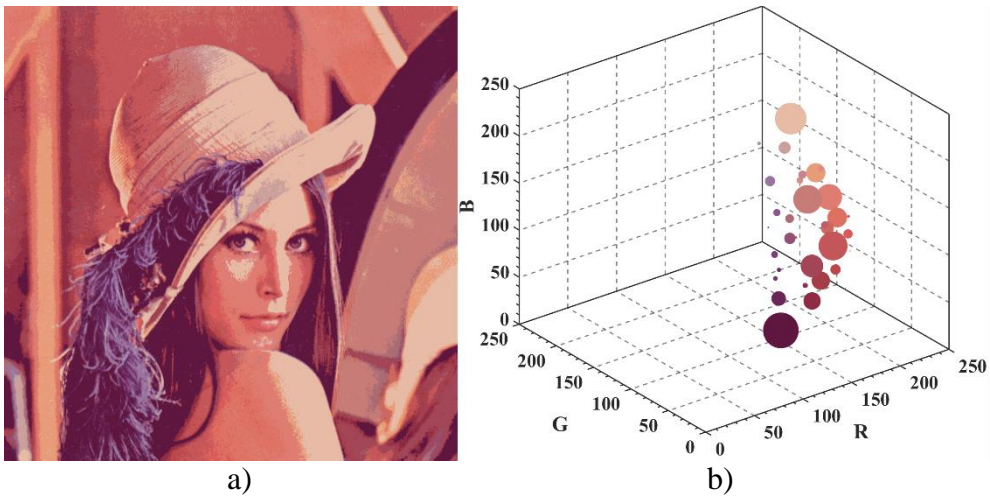
LBG yöntemleri ile indirgeme işlemi uygulanmıştır. HAM ile 8 renge indirgenmiş Lena görüntüsü Şekil 3.6 (a) da verilmiştir. 8 renkli indirgenmiş Lena görüntüsünün renk dağılımı ise Şekil 3.6 (b) de görülmektedir. Yine aynı şekilde 2 ve 3 eşik kullanılarak 27 ve 64 renge indirgenmiş Lena görüntüleri sırasıyla Şekil 3.7 (a) ve Şekil 3.8 (a)' da verilirken, görüntülerin renk dağılımları Şekil 3.7 (b) ve Şekil 3.8 (b)' de görülmektedir. 1, 2 ve 3 eşik ve HAM tekniği ile bir başka referans görüntü olan Biber'e ait indirgenen görüntüler, sırasıyla Şekil 3.9 (a), Şekil 3.10 (a) ve Şekil 3.11 (a)'da bulunurken, söz konusu görüntülerin renk dağılımları Şekil 3.9 (b), Şekil 3.10 (b) ve Şekil 3.11 (b)' de verilmiştir. Aynı şekilde 8, 27 ve 64 renkli indirgenmiş Mandril görüntüleri ve renk dağılımları Şekil 3.12, Şekil 3.13 ve Şekil 3.14'te bulunmaktadır. Otsu optimizasyon tekniği ile Lena'ya ait indirgenmiş görüntüler Şekil 3.15 (a), Şekil 3.16 (a) ve Şekil 3.17 (a) gösterilmiştir. Şekil 3.18, Şekil 3.19 ve Şekil 3.20'da ise Biber görüntüsünün 8, 27 ve 64 renk ile indirgenmiş halleri ve bahsi geçen görüntülerin renk dağılımı bulunmaktadır. Otsu tekniğinin Mandrill ile olan indirgeme sonuçları ve renk dağılımları Şekil 3.21, Şekil 3.22 ve Şekil 3.23'te verilmiştir. Aynı şekilde Kapur yaklaşımı ile 1, 2 ve 3 eşik kullanarak Lena'nın 8, 27 ve 64 renge dönüştürülmüş görüntüleri sırasıyla Şekil 3.24 (a), Şekil 3.25 (a) ve Şekil 3.26 (a)' da verilmiştir. Aynı şekilde ilgili görüntülerin renk dağılımlarını ise Şekil 3.24 (b), Şekil 3.25 (b) ve Şekil 3.26 (b) göstermektedir. Biber görüntüsünün Kapur entropi yaklaşımı ve tek eşik ile elde edilen 8 renkli durumu Şekil 3.27 (a)' da ve indirgenen görüntünün renk dağılımı Şekil 3.27 (b)' de verilmiştir. Aynı görüntünün entropi yaklaşımı ile elde edilen 27 ve 64 renkli halleri sırasıyla Şekil 3.28 (a) ve Şekil 3.29 (a)' da bulunurken, ilgili görüntülerin renk dağılımları Şekil 3.28 (b) ve Şekil 3.29 (b)' deki gibidir. Aynı eşikleme tekniği ile Mandrill'e ait görüntüler ve renk dağılımları Şekil 3.30, Şekil 3.31 ve Şekil 3.32 de gösterilmiştir. Kullanıcı bağımlı ve iteratif bir yaklaşım olan geleneksel LBG yaklaşımı ile elde edilen 8, 27 ve 64 indirgenmiş renkli Lena görüntüleri Şekil 3.33 (a), Şekil 3.34 (a) ve Şekil 3.35 (a)'da gösterilirken, renk dağılımları sırasıyla Şekil 3.33 (b), Şekil 3.34 (b) ve Şekil 3.35 (b)'de gösterilmiştir. Aynı şekilde biber görüntüsünün söz konusu yöntem ile indirgenmiş hallerini ve renk dağılımlarını Şekil 3.36, Şekil 3.37 ve Şekil 3.38 göstermektedir. Mandrill'in LBG ile renk indirgemesi yapılarak sonuçları Şekil 3.39 (a), Şekil 3.40 (a) ve Şekil 3.41 (a)'da gösterilmiştir. Mandrill'in indirgenmiş hallerinin renk dağılımları ise Şekil 3.39 (b), Şekil 3.40 (b) ve Şekil 3.41 (b)'de verilmiştir.



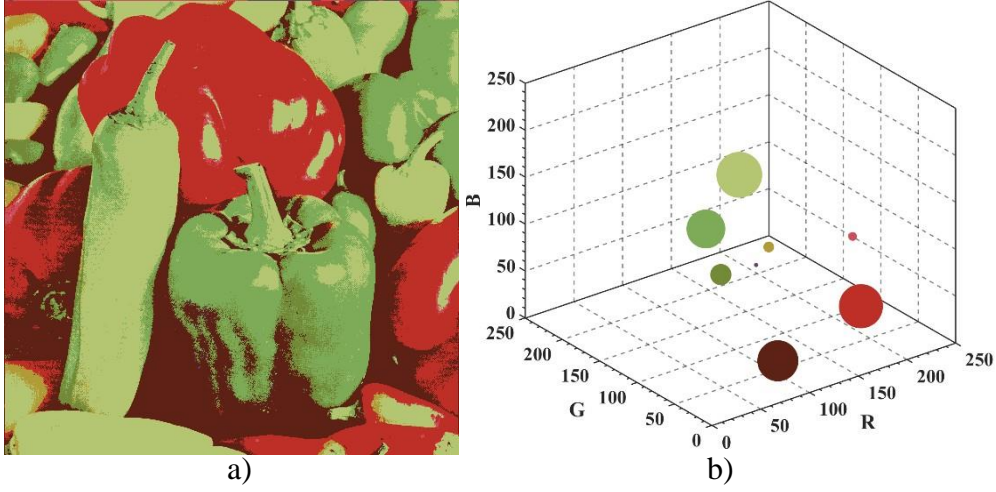
Şekil 3.6. İndirgenmiş Lena (HAM:8 renk) a) algoritma çıktısı b) renk dağılımı



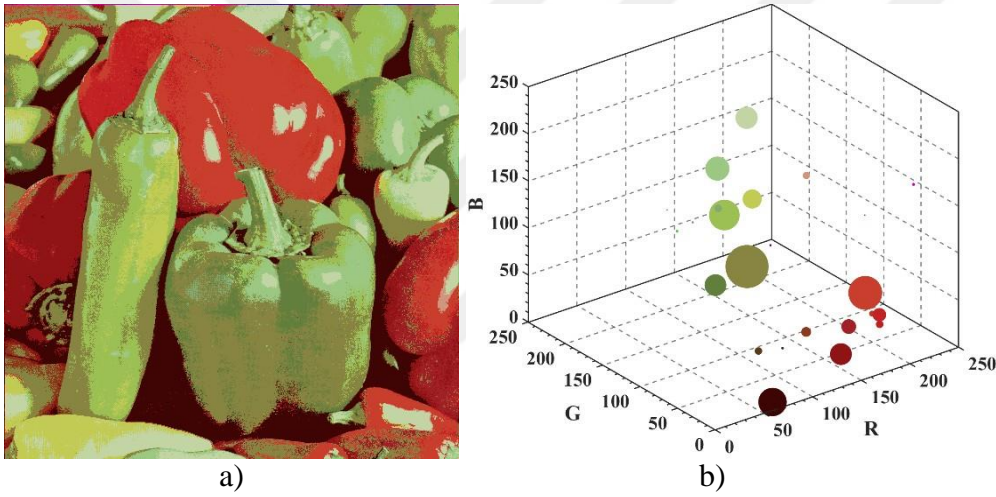
Şekil 3.7. İndirgenmiş Lena (HAM:27 renk) a) algoritma çıktısı b) renk dağılımı



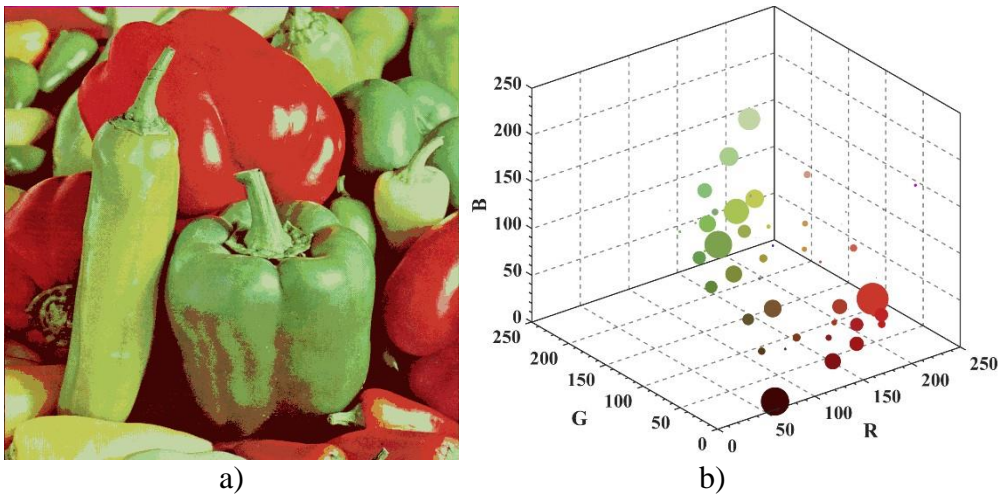
Şekil 3.8. İndirgenmiş Lena (HAM:64 renk) a) algoritma çıktısı b) renk dağılımı



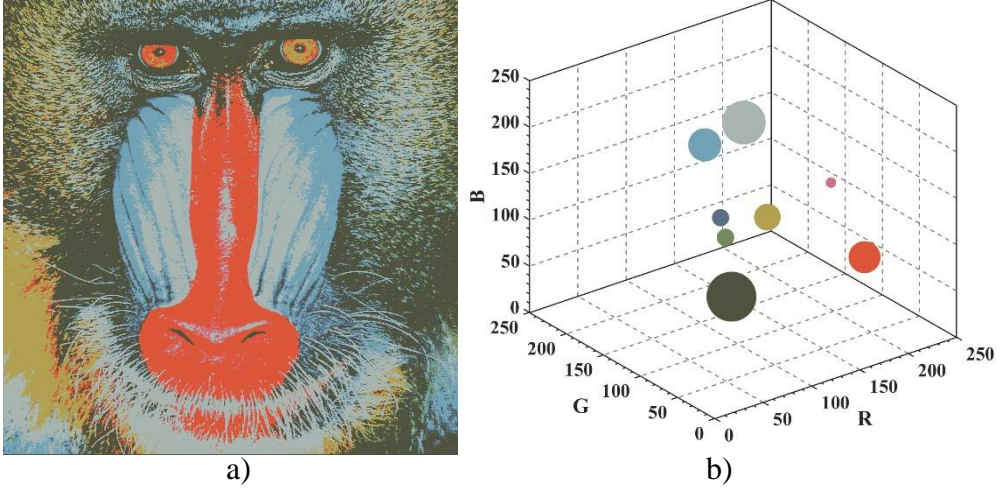
Şekil 3.9. İndirgenmiş Biber (HAM:8 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.10. İndirgenmiş Biber (HAM:27 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.11. İndirgenmiş Biber (HAM:64 renk) a) algoritma çıktısı b) renk dağılımı



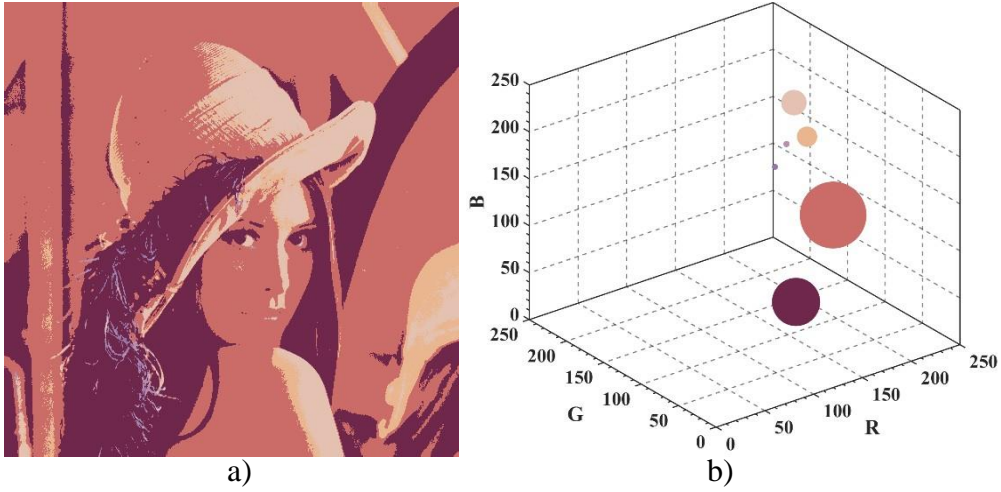
Şekil 3.12. İndirgenmiş Mandrill (HAM:8 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.13. İndirgenmiş Mandrill (HAM:27 renk) a) algoritma çıktısı b) renk dağılımı



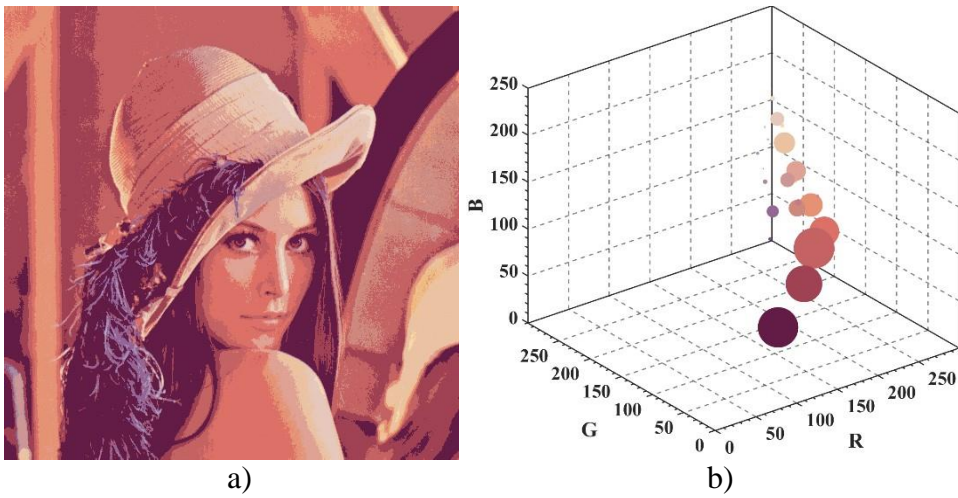
Şekil 3.14. İndirgenmiş Mandrill (HAM:64 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.15. İndirgenmiş Lena (Otsu:8 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.16. İndirgenmiş Lena (Otsu:27 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.17. İndirgenmiş Lena (Otsu:64 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.18. İndirgenmiş Biber (Otsu:8 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.19. İndirgenmiş Biber (Otsu:27 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.20. İndirgenmiş Biber (Otsu:64 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.21. İndirgenmiş Mandrill (Otsu:8 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.22. İndirgenmiş Mandrill (Otsu:27 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.23. İndirgenmiş Mandrill (Otsu:64 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.24. İndirgenmiş Lena (Kapur:8 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.25. İndirgenmiş Lena (Kapur:27 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.26. İndirgenmiş Lena (Kapur:64 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.27. İndirgenmiş Biber (Kapur:8 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.28. İndirgenmiş Biber (Kapur:27 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.29. İndirgenmiş Biber (Kapur:64 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.30. İndirgenmiş Mandrill (Kapur:8 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.31. İndirgenmiş Mandrill (Kapur:27 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.32. İndirgenmiş Mandrill (Kapur:64 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.33. İndirgenmiş Lena (LBG:8 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.34. İndirgenmiş Lena (LBG:27 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.35. İndirgenmiş Lena (LBG:64 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.36. İndirgenmiş Biber (LBG:8 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.37. İndirgenmiş Biber (LBG:27 renk) a) algoritma çıktısı b) renk dağılımı




Şekil 3.38. İndirgenmiş Biber (LBG:64 renk) a) algoritma çıktısı b) renk dağılımı



Şekil 3.39. İndirgenmiş Mandrill (LBG:8 renk) a) algoritma çıktısı b) renk dağılımı



Şekil 3.40. İndirgenmiş Mandrill (LBG:27 renk) a) algoritma çıktısı b) renk dağılımı



Şekil 3.41. İndirgenmiş Mandrill (LBG:64 renk) a) algoritma çıktısı b) renk dağılımı

İndirgenmiş görüntüler incelendiğinde tüm metotlarda eşik sayısı artmasıyla görüntünün homejenliğinin arttığı görülmektedir. Bir başka ifade ile eşik sayısının artması bilgi kaybını azaltmaktadır. HAM ile elde edilen 64 renkli Lena görüntüsünde şapka ve yüzdeki detayların diğer yöntemlere göre daha iyi korunduğu görülmektedir. Benzer şekilde diğer bölgelerde daha net bir şekilde çıkmıştır. Bu durumda HAM yönteminin orijinal görüntüye daha benzer sonuçlar ürettiği söylenebilir. Biber görüntüsünün 8 renkli hallerinde ise HAM, Otsu ve LBG birbirine yakın sonuçlar verdiği görülürken, Kapur optimizasyon yaklaşımının detayları koruyamadığı görülmektedir. 64 renkli görüntülerin sınıf sayısı artmasından dolayı görüntüdeki detayları daha belirgin olması beklenen bir durumdur. Refereans görüntülerin indirgenmesi sonucu yaşanan bilgi kayıpları ortalama PSNR cinsinden Çizelge 3.4'te verilmiştir. Deneyle elde edilen PSNR değerleri R,G ve B renk kanallarının hepsinde ayrı ayrı hesaplanmış ve ortalama değerleri çizelgede gösterilmiştir.

Çizelge 3.4. Ortalama PSNR (dB) sonuçları


	Lena			Biber			Mandrill		
	Renk sayısı			Renk sayısı			Renk sayısı		
	8	27	64	8	27	64	8	27	64
HAM	21,52	26,75	28,28	20,67	22,48	26,32	20,13	22,53	26,05
Otsu	22,47	24,47	25,75	20,87	23,01	24,48	20,37	23,81	24,53
Kapur	22,55	24,43	25,70	20,58	23,20	24,35	20,58	23,55	24,45
LBG	21,23	22,75	26,52	20,72	22,35	24,42	19,92	21,57	22,15

Çizelge 3.4' e bakıldığında Lena görüntüsünde HAM yöntemi ile 27 ve 64 renkte daha az bilgi kaybının olduğu gözlemlenmektedir. Biber ve Mandrill görüntülerinde ise 64 renkte yine aynı şekilde söz konusu yöntem daha başarılıdır. Ancak Biberde 8 renk te Otsu tekniğinin performansı daha üstün olduğu izlenirken, 27 renkte Kapur algoritmasının bilgi kaybı daha azdır. Eşik sayısında artış ile tüm yöntemlerde başarı artsada, HAM yönteminin performansındaki artışın diğer tekniklere göre daha fazla olduğu açıkça görülmektedir. Mandrill görüntüsünde ki durum ise tek eşik ile Kapur daha başarılı bir performans sergilerken, 27 renkte Otsu yaklaşımı orijinaline daha benzer görüntü üretmiştir.


3.2. Renkli Görüntüler İçin Tek Boyutlu Histogram

Görüntü histogramı İTGE sistemlerinde sıklıkla kullanılan bir tekniktir ve renkli görüntülerde elde edilmesi RGB kanallarından oluşan 3 boyutlu bir matrisin analizini gerektirmektedir. Mevcut işlemin hesapsal karmaşıklığı yüksektir. Ayrıca renk kanallarından gelen bilgilerin birleştirilmesi de bir problemdir. Söz konusu sorunun giderilmesi için, her bir renk kanalından elde edilen histogramdan öncelikle yukarıda tanımlanan eşikleme tekniklerinden yararlanılarak t_r , t_g ve t_b olmak üzere 3 eşik değeri elde edilmektedir. Akabinde ilgili değerler Çizelge 3.2’de verilen kurallar ile birleştirilmektedir. Bu durumda görüntüden 8 adet renk kümesi meydana gelir. Son olarak, görüntüdeki her bir piksel ait olduğu kümedeki piksellerin ortalama değeri ile temsil edilerek çıktı görüntü oluşturulur. Böylece 256^3 renge sahip renk uzayı 8 renkle temsil edilebilen bir hale dönüştürülür. Dolayısıyla renkli görüntülerin pikselleri elde edilen 8 kümeden birine dahil olacaktır. Kümelerdeki piksellere, ilgili kümenin ortalama değerlerinin atanmasıyla pikseller tek renk değeri ile temsil edilerek renk çeşitliliği azaltılmaktadır. Bir başka ifade ile renk indirgeme yapılmaktadır. Önerilen sınıfsal tabanlı tek boyutlu histogram ise Eş. 3.9’daki ifade ile hesaplanmaktadır. [98,99]. Böylelikle renkli görüntüler için 3 renk kanalının bilgilerini içeren bir özellik vektörü oluşturulmuştur. Şekil 3.42 biber görüntüsünün HAM tekniği ile elde edilen 8 renkli tek boyutlu histogramını göstermektedir. Şekil 3.43, Şekil 3.44 ve Şekil 3.45’te ise sırasıyla Otsu, Kapur ve LBG yaklaşımları ile oluşturulan 8 sınıflı özellik vektörleri bulunmaktadır. Biber görüntüsünün 27 elemanlı histogramları Şekil 3.46, Şekil 3.47, Şekil 3.48, Şekil 3.49’da görülmektedir. Şekil 3.50 ve Şekil 3.51 64 renkli biber görüntüsünün HAM ve Otsu yaklaşımı ile elde edilen histogramlarını gösterirken, Şekil 3.52 ve Şekil 3.53 sırasıyla Kapur ve LBG ile üretilen sınıfsal tabanlı tek boyutlu özellik vektörünü göstermektedir.

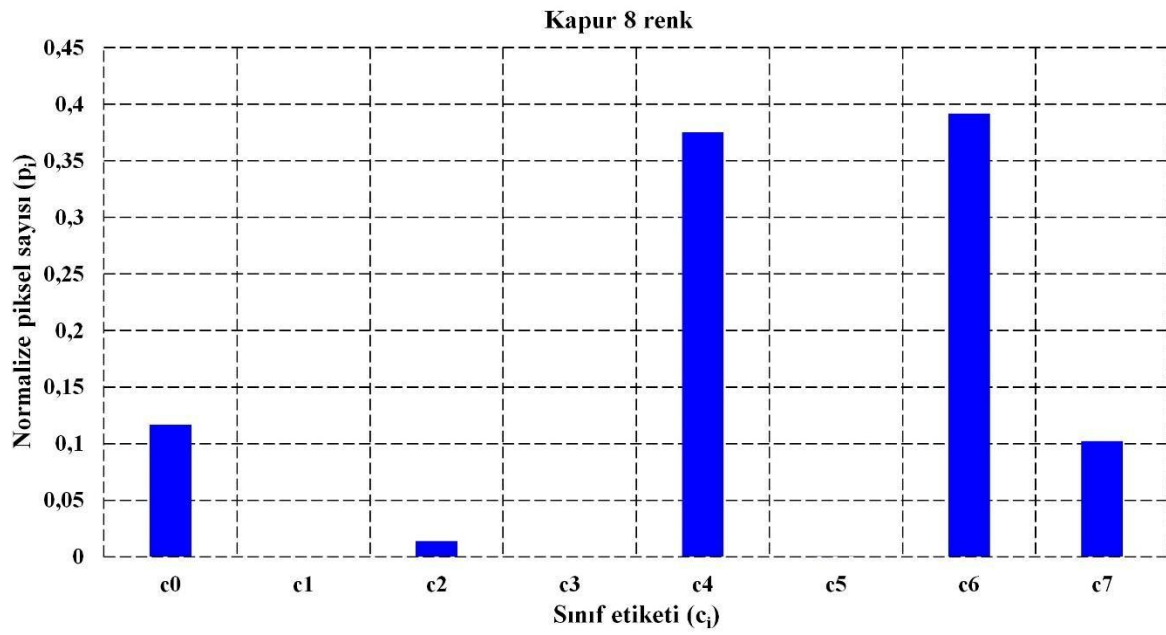
Geliştirilen renk uzayı tabanlı bölütleme ile oluşturulan tek boyutlu vektörler incelendiğinde bazı sınıflara ait piksel sayısının sıfır veya sıfıra yakın olduğu gözlemlenmiştir. İndirgenmiş görüntülerin renk dağılımlarına bakıldığında ise bazı renk değerlerinin çok küçük olduğu görülmektedir. Bu durum indirgenen görüntü ile onu temsil eden özellik vektörünün uyumlu olduğunun göstergesidir. Böylece sınıflandırma ve önerilen tek boyutlu histogram yaklaşımının birbirlerini desteklediği açıktır. Bu durumda geliştirilen sınıfsal tabanlı tek boyutlu histogramın renkli bir görüntüyü temsil etme kapasitesinin olduğu söylenebilir.




Şekil 3.42. Biber: Tek boyutlu histogram (HAM, 8 renk)




Şekil 3.43. Biber: Tek boyutlu histogram (Otsu, 8 renk)




Şekil 3.44. Biber: Tek boyutlu histogram (Kapur, 8 renk)




Şekil 3.45. Biber: Tek boyutlu histogram (LBG, 8 renk)




Şekil 3.46. Biber: Tek boyutlu histogram (HAM, 27 renk)




Şekil 3.47. Biber: Tek boyutlu histogram (Otsu, 27 renk)




Şekil 3.48. Biber: Tek boyutlu histogram (Kapur, 27 renk)




Şekil 3.49. Biber: Tek boyutlu histogram (LBG, 27 renk)




Şekil 3.50. Biber: Tek boyutlu histogram (HAM, 64 renk)



Şekil 3.51. Biber: Tek boyutlu histogram (Otsu, 64 renk)



Şekil 3.52. Biber: Tek boyutlu histogram (Kapur, 64 renk)



Şekil 3.53. Biber: Tek boyutlu histogram (LBG, 64 renk)



4. DENEYSEL SONUÇLAR VE YORUMLAR

Bu çalışmada renkli görüntüler için tek boyutlu histogram vektörü çıkararak yaklaşımlar geliştirilmiştir. Otsu, Kapur ve HAM yaklaşımları ile geliştirilen İTGE algoritması, çok bilinen vektör nicemeleme yaklaşımı olan LBG metodu tabanlı İTGE ile karşılaştırılmıştır. Önerilen yaklaşımların başarısı karmaşıklık matrisi ve P-R eğrileri olmak üzere iki farklı performans değerlendirme kriteri ile değerlendirilmiştir. İlâveten geliştirilen algoritmayı test etmek için visual studio 2015 ortamında C# programlama dili ile bir ara yüz tasarlanmıştır. Şekil 4.1 geliştirilen arayüzü göstermektedir.

ImageSimilarityForm

RENKLİ HİSTOGRAM KULLANARAK İÇERİK TABANLI GÖRÜNTÜ ERİŞİMİ

Adım 1: Sorgu Görüntü Seçiniz

Dosya Seç

Seçilen Görüntü: 616.jpg

Seçilen Görüntünün Kategorisi: Flowers

0 seconds

Score: 17/20

Adım 2: Metot Seç

ÖZELLİK ÇIKARIM YÖNEMİ

OTSU KAPUR

HAM LBG

Eşik Değer Sayısı: 3

BENZERLİK ÖLÇÜM KRİTERİ

Kosinüs

Histogram Kesişimi

Ara


Veritabanı Oluştur

1	0,9142	0,9050	0,8801	0,8717
616 True	650 True	643 True	657 True	669 True
0,8622	0,8473	0,8423	0,8330	0,8063
602 True	634 True	317 False	624 True	620 True
0,7973	0,7910	0,7844	0,7671	0,7669
626 True	673 True	603 True	667 True	674 True
0,7552	0,7506	0,7466	0,7463	0,7439
608 True	678 True	994 False	601 True	376 False

Şekil 4.1. Geliştirilen İTGE arayüzü

4.1. Corel1K Veritabanı

Deneysel sonuçlar için kullanılan Corel1K veri tabanında 10 kategori ve her kategoride 100 görüntü olmak üzere toplam 1000 adet görüntü bulunmaktadır. Söz konusu görüntüler 256x384 ve 384x256 olmak üzere 2 farklı boyuttadır. Veri tabanındaki kategoriler Afrikalılar, Sahiller, Yapıtlar, Otobüsler, Dinozorlar, Filler, Çiçekler, Atlar, Dağlar ve Yiyeceklerdir. Şekil 4.2’de her kategoriden rastgele seçilen görüntülere ve Çizelge 4.1.’de ise kategorilere ait sınıf numaralarına yer verilmiştir.



Şekil 4.2. Corel1K a) Afrikalılar b) Sahiller c) Yapıtlar d) Otobüsler e) Dinozorlar
f) Filler g) Çiçekler h) Atlar i) Dağlar j) Yiyecekler

Çizelge 4.1. Corel1K veritabanı sınıf isimleri ve etiketleri

Sınıf etiketleri	1	2	3	4	5	6	7	8	9	10
Sınıf ismi	Afrikalılar	Sahiller	Yapıtlar	Otobüsler	Dinozorlar	Filler	Çiçekler	Atlar	Dağlar	Yiyecekler

4.2. Görüntü Erişimi ve Test Sonuçları

Deneysel sonuçlar gerçekleştirilirken Corel1K veri tabanındaki görüntülere ait eşik değerler Eş. 3.1, Eş. 3.3 ve Eş. 3.7’deki denklemler aracılığıyla hesaplanmıştır. Bahsi geçen eşik değerler ile Çizelge 3.2’de verilen kurallar bir başka deyişle renk tablosu oluşturulmuştur. İlgili tablo renk indirgeme için kod kitabı olarak kullanılmıştır. Sonuç olarak veri tabanındaki 1000 adet görüntü tek eşik değeri için 8 renge, iki ve üç eşik değeri için sırasıyla 27 ve 64 renge indirgenmiştir. Dolayısıyla HAM, Otsu ve Kapur yaklaşımları ile 8, 27 ve 64 renkli olmak üzere 9000, LBG vektör nicemleme metoduyla da 8, 27 ve 64 renkli 3000, toplamda 12 000

adet indirgenmiş görüntüye ait özellik vektörleri çıkarılmıştır. Böylelikle veri tabanındaki her bir görüntü vektörel olarak temsil edilmiştir. Görüntü erişiminin en önemli basamağı olan özellik çıkarımı (feature extraction) ile elde edilen temsil vektörleri veri tabanına kaydedilerek özellik veri tabanı oluşturulmuştur. Yukarıda ifade edilen her bir aşama sorgu görüntüler için de uygulanmış olup eşit uzunluklarda özellik vektörü çıkarılmıştır. Sorgu görüntü ise Corel1K'dan sırayla seçilerek işleme tabi tutulmuştur. Sorgu görüntünün özellik vektörü, veri tabanındaki her bir eşit uzunlukta vektörler ile Eş. 2.11 ve Eş. 2.12'deki kosinüs ve histogram kesişimi benzerlik denklemleri aracılığıyla karşılaştırılmıştır. Bu aşamada sorgu görüntüyü temsil eden özellik vektörü, veri tabanındaki 1000 adet görüntüye ait özellik vektörü ile karşılaştırılmış ve benzerlik değerleri elde edilmiştir. İlgili değerler en yüksek değerden küçüğe doğru sıralanmıştır. Yapılan sıralama sonucunda en benzer ilk 20 görüntü dikkate alınarak deneysel bulgular elde edilmiştir. Deneysel bulgularda erişilen 20 görüntünün hangi sınıfta olduğu tasniflenerek çok sınıflı karmaşıklık matrisleri oluşturulmuştur. Elde edilen matrislerde aynı gruba ait satır ve sütunların kesiştiği hücreler getirilen doğru görüntü sayısını z_{gg} 'yi temsil etmektedir. Her bir sınıfta 100 adet görüntü olduğundan ve benzer ilk 20 görüntü kullanıldığından sınıflara ait toplam 2000 adet erişilen görüntü bulunmaktadır. Geliştirilen İTGE yöntemlerinin Corel1K kategorilerinde ki performansını göstermek adına Eş. 2.16 ve Eş. 2.17'de gösterilen hassasiyet (R_g) ve kesinlik (P_g) değerlerinden yararlanılmıştır. Yaklaşımların genel performansı ise Eş. 2.18 ile makro hassasiyet (R_m), Eş. 2.19 ile makro kesinlik (P_m) ve Eş. 2.20 ile de doğruluk (A) değerleri ile gösterilmiştir.

Çizelge 4.2, Çizelge 4.3 ve Çizelge 4.4 sırasıyla LBG yaklaşımının 8, 27 ve 64 elemanlı özellik vektörleri ile uygulanan İTGE'nin karmaşıklık matrislerini göstermektedir. Matrisler incelendiğinde LBG'nin 8 renkteki global doğruluk A değeri 0,3211iken, bu parametre 27 renkte 0,3340 ve 64 renkte 0,3346 olmuştur. LBG yaklaşımı ile en çok ilişkili görüntüye 8, 27 ve 64 renk sayılarında sırasıyla $R_g=0.9550$, $R_g=0.9295$ ve $R_g=0.8695$ değerleri ile Dinozorlar kategorisinde erişilmiştir. İlâveten 8 renkte diğer başarılı kategoriler $R_g=0,3810$ ile Atlar ve $R_g=0,3230$ ile Afrikalılar olmuştur. 27 renkte Afrikalılar $R_g=0,4210$ ve 64 renkte Yiyecekler $R_g=0,3855$ değerlerini alarak yöntemin başarımını arttıran diğer kategorilerdir. LBG'nin performansının en düşük olduğu kategoriler ise Sahiller ve Dağlar olduğu görülmektedir. Kapur algoritmasının İTGE bulguları ise 8 renk için Çizelge 4.5, 27 ve 64 renk için ise Çizelge 4.6 ve Çizelge 4.7'de verilmiştir. Bahsi geçen eşikleme tekniğinin İTGE

performansına doğruluk parametresi açısından bakıldığında 8 renk için $A=0,4181$, 27 renk için $A=0,4287$ ve 64 renk için $A=0,4518$ olmuştur. Kapur yaklaşımının 64 renkli özellik vektörü 8 renge göre %4 daha fazla ilişkili görüntüye erişmiştir. Sınıfsal performansı incelendiğinde en başarılı olduğu kategorilerin Dinozorlar, Çiçekler, Yiyeceklerdir. Başarımın düşük olduğu kategorilerin ise Sahiller, Dağlar ve Yapıtlar olduğu görülmektedir. Tipik bir kategori olan Atlar kategorisinde 8 renk özellik vektörü ile 1248 tane ilişkili görüntü getirdiği görülmektedir. Aynı kategoride 27 ve 64 renk özelliği ile sırasıyla 830 ve 954 adet doğru görüntü getirilmiştir. Bu durum 8 rengin Atlar kategorisinde daha anlamlı indirgeme yaptığını göstermektedir. Çiçeklerde ise renk sayısı arttıkça özellik vektörlerinin ilgili kategorideki görüntüleri daha iyi temsil ettiği görülmüştür. Renk sayısının artmasının genel olarak başarıyı arttırdığı görülse de kategorilerdeki görüntülerin renk çeşitliği veya sadeliği bu durumu değiştirebilmektedir. Bir diğer optimizasyon algoritması olan Otsu tekniğinin LBG ve Kapur'dan daha başarılı olduğu açıkça görülmektedir. Çizelge 4.8, Çizelge 4.9 ve Çizelge 4.10 Otsu ile gerçekleştirilen İTGE'ye ait karmaşıklık matrisleridir. Otsu'nun 8, 27 ve 64 renkteki doğruluk değerleri sırasıyla $A=0,4238$, $A=0,5017$ ve $A=0,5244$ 'dir. Yaklaşımın eşik sayısındaki artışının performansı yaklaşık %10 arttırdığı görülmektedir. Ayrıca genel olarak tüm yöntemlerin en başarılı olduğu Dinozorlarda Otsu $R_g=0,9890$ değeri ile en yüksek başarıyı elde etmiştir. Otsu yaklaşımının başarılı olduğu diğer kategoriler ise Atlar ve Çiçekler olmuştur. 64 renkte Atlar $R_g=0,7875$, 27 renkte ise Çiçekler $R_g=0,6625$ değerleri ile genel başarıyı olumlu etkilemişlerdir. Kapur ile benzer şekilde Otsu yaklaşımında da renk sayısının artmasından olumsuz etkilenen kategori Sahiller olmuştur. 8 renk ile ilgili kategoride 634 adet doğru görüntüye erişilirken, 64 renk ile 519 doğru görüntüye erişilmektedir. Otsu tabanlı İTGE'nin performansının düşük olduğu kategoriler ise 8 renkte Dağlar, 27 ve 64 renkte ise Sahillerdir. Bahsi geçen her iki kategori diğer algoritmalarında zorlandığı kategorilerdir. HAM yönteminin performansı ise 8 renk için Çizelge 4.11, 27 ve 64 renk için Çizelge 4.12 ve Çizelge 4.13'te yer verilmiştir. HAM 64 renkli özellik vektörünün doğruluk değeri $A=0,5525$ olmuştur. HAM tekniği diğer yöntemlerle 64 renk temelinde kıyaslandığında LBG ile %22, Kapur ile %10, Otsu ile yaklaşık %3 farkla daha daha üstün performans sergilediği görülmektedir. Bahsi geçen yaklaşımın en başarılı olduğu kategoriler ise hassasiyet açısından Dinozorlar ve Atlardır. Dağlar ise performansın en düşük olduğu kategori olmakla birlikte, başarı oranları 8 renkte $R_g=0,2435$, 27 renkte $R_g=0,3160$ ve 64 renkte ise $R_g=0,2875$ olduğu görülmektedir. Dağlar ise CorellK'daki zorlanılan bir kategoridir. Bu kategoride ki ışık yoğunluk farkı gün ışığı

veya karanlık çekimler gibi kıstaslar performansı etkileyen diğer hususlardır. Bütün yaklaşımların ayırt edicilik bakımından genel performansı olumsuz etkileyen bir diğer kategori ise Yapıtlardır. İlgili kategoriye ait görüntülerde renk çeşitliliğinin ayırt ediciliği diğer kategorilere göre daha azdır. Ancak Yapıtlar 64 renkte yaklaşımların hassasiyet değerleri incelendiğinde LBG $R_g=0,2495$, Kapur $R_g=0,2525$, Otsu $R_g=0,3295$, HAM ise $R_g=0,3965$ değerlerini almıştır. HAM söz konusu kategoride daha anlamlı renk indirgeme yaparak özellik vektörleri çıkarmıştır. Başka bir ifade ile çıkarılan özellikler görüntüleri daha iyi temsil etmiştir denilebilir. Dinozorlar ise genel olarak yaklaşımların başarılı olduğu bir yapıya sahiptir. Bu durumun nedeni Dinozorlara ait görüntülerin ayırt edici bir arka planı olması ve tek nesneli olmasından kaynaklanmaktadır. Afrikalılar ve Yiyecekler ise renk çeşitliliğinin fazla olduğu gruplardır. Bu gruplarda Otsu ve HAM renk sayısı arttıkça yüksek ayırteçicilik sağlamışlardır. Afrikalılarda Otsu 8 renk özelliği ile 708 ilişkili görüntüye erişip $R_g=0,3540$ hassasiyet değerini alırken, 64 renkte 1232 görüntüyü doğru sınıflandırarak $R_g=0,6160$ hassasiyet değerine ulaşmıştır. Aynı kategoride HAM yaklaşımı ise 8 renk sayısı ile 0,449, 64 renk ile 0,657 hassasiyet değeri sağlamışlardır. Afrikalılar grubunda renk sayısının artmasıyla Otsu ve HAM yöntemleri performanslarını sırasıyla yaklaşık %26 ve %20 arttırdığı görülmektedir. Sahiller kategorisinde LBG hariç diğer tüm teknikler 8 renkte daha üstün performans sergilemişlerdir. Kapur 8 renk ile ilgili kategoride 585 doğru görüntü elde ederken, 64 renkte 457 doğru görüntüye ulaşmıştır. Benzer şekilde Otsu 8 ve 64 renkte sırasıyla 634 ve 519 ilişki görüntü sınıflandırmışlardır. HAM ile gerçekleştirilen İTGE ise aynı kategoride 8 renkte 660, 64 renkte ise 632 doğru görüntü bulmuştur. Dolayısıyla söz konusu kategorinin daha az renk sayısı ile temsil edilmesi gerektiği aşikârdır. Ancak genel olarak renk sayısının artması performansı arttırdığı görülmektedir.

Elde edilen karmaşıklık matrisleri kosinüs benzerlik metriği ile elde edilen bulguları göstermektedir. Ancak İTGE'nin son aşaması olan benzerlik ölçümü erişim sistemlerinin performansı etkileyen diğer bir unsurdur ve farklı ölçüm metrikleri geliştirilen tekniklerin başarımlarını değiştirebilmektedir. Bundan dolayı farklı benzerlik teknikleri ile testlerin yapılması önemli bir konudur. Geliştirilen İTGE yaklaşımında kosinüs benzerliğinin yanında histogram benzerliği için sık kullanılan histogram kesişimi yöntemi de uygulanmıştır. Farklı renk sayılarındaki kosinüs ve histogram kesişimi benzerliklerinin genel performansı Çizelge 4.14'te gösterilmiştir. Böylelikle farklı renk gruplarındaki farklı ölçüm metriklerinin başarımları değerlendirilmiştir.

Çizelge 4.2 LBG-Kosinüs (8 Renk): $P_m=0,3195$; $R_m=0,3211$; $A=0,3211$

		Tahmin Edilen Sınıf										m_g	R_g
		1	2	3	4	5	6	7	8	9	10		
Gerçek Sınıf	1	646	114	180	202	18	166	181	107	112	274	2000	0,3230
	2	183	360	252	127	14	310	137	215	229	173	2000	0,1800
	3	247	184	377	176	22	235	125	146	241	247	2000	0,1885
	4	312	129	207	446	11	128	145	80	169	373	2000	0,2230
	5	0	7	6	21	1910	33	10	3	3	7	2000	0,9550
	6	262	167	232	72	48	636	72	91	221	199	2000	0,3180
	7	298	164	184	175	7	138	417	178	166	273	2000	0,2085
	8	185	187	191	83	6	164	138	762	211	73	2000	0,3810
	9	217	180	267	150	23	304	129	184	308	238	2000	0,1540
	10	272	121	222	210	46	211	162	41	155	560	2000	0,2800
m'_g		2622	1613	2118	1662	2105	2325	1516	1807	1815	2417		
P_g		0,2464	0,2232	0,1780	0,2684	0,9074	0,2735	0,2751	0,4217	0,1697	0,2317		

Çizelge 4.3 LBG-Kosinüs (27 Renk): $P_m=0,3432$; $R_m=0,3340$; $A=0,3340$

		Tahmin Edilen Sınıf										m_g	R_g
		1	2	3	4	5	6	7	8	9	10		
Gerçek Sınıf	1	842	100	163	95	18	199	75	69	165	274	2000	0,4210
	2	197	363	314	85	3	337	88	214	221	178	2000	0,1815
	3	219	221	439	69	28	380	128	108	249	159	2000	0,2195
	4	464	135	130	388	9	183	83	131	132	345	2000	0,1940
	5	0	11	10	19	1859	57	9	3	11	21	2000	0,9295
	6	203	198	328	47	93	583	32	40	261	215	2000	0,2915
	7	353	148	219	130	6	126	530	162	193	133	2000	0,2650
	8	222	259	195	79	5	178	114	666	171	111	2000	0,3330
	9	260	209	282	72	22	374	104	110	339	228	2000	0,1695
	10	386	101	117	166	75	192	88	53	152	670	2000	0,3350
m'_g		3146	1745	2197	1150	2118	2609	1251	1556	1894	2334		
P_g		0,2676	0,2080	0,1998	0,3374	0,8777	0,2235	0,4237	0,428	0,1790	0,2871		

Çizelge 4.4 LBG-Kosinüs (64 Renk): $P_m=0,3480$; $R_m=0,3346$; $A=0,3346$

		Tahmin Edilen Sınıf										m_g	R_g
		1	2	3	4	5	6	7	8	9	10		
Gerçek Sınıf	1	745	70	118	141	39	181	66	100	121	419	2000	0,3725
	2	170	361	239	48	14	328	77	280	226	257	2000	0,1805
	3	192	182	499	42	25	327	120	163	267	183	2000	0,2495
	4	584	92	88	343	15	134	65	90	94	495	2000	0,1715
	5	10	5	24	66	1739	89	27	7	7	26	2000	0,8695
	6	197	177	230	34	80	594	58	119	230	281	2000	0,2970
	7	297	119	278	85	8	147	503	160	209	194	2000	0,2515
	8	169	190	158	29	9	243	93	748	189	172	2000	0,3740
	9	228	182	323	63	26	333	89	146	389	221	2000	0,1945
	10	429	84	81	112	36	223	69	92	103	771	2000	0,3855
m'_g		3021	1462	2038	963	1991	2599	1167	1905	1835	3019		
P_g		0,2466	0,2469	0,2448	0,3562	0,8734	0,2285	0,4310	0,3927	0,2120	0,2554		

Çizelge 4.5 Kapur-Kosinüs (8 Renk): $P_m=0,4111$; $R_m=0,4181$; $A=0,4181$

		Tahmin Edilen Sınıf										m_g	R_g
		1	2	3	4	5	6	7	8	9	10		
Gerçek Sınıf	1	699	91	162	214	28	72	186	150	78	320	2000	0,3495
	2	94	585	294	103	137	148	71	219	308	41	2000	0,2925
	3	146	230	531	208	23	210	96	96	345	115	2000	0,2655
	4	321	112	247	571	4	76	133	50	275	211	2000	0,2855
	5	17	30	13	0	1813	106	0	0	2	19	2000	0,9065
	6	104	113	240	90	274	689	99	101	118	172	2000	0,3445
	7	248	86	109	157	0	50	835	222	54	239	2000	0,4175
	8	115	174	93	38	0	114	98	1248	77	43	2000	0,6240
	9	90	280	376	264	31	145	61	115	597	41	2000	0,2985
	10	421	57	125	171	34	160	186	28	25	793	2000	0,3965
m'_g		2255	1758	2190	1816	2344	1770	1765	2229	1879	1994		
P_g		0,3100	0,3328	0,2425	0,3144	0,7735	0,3893	0,4731	0,5599	0,3177	0,3977		

Çizelge 4.6 Kapur-Kosinüs (27 Renk): $P_m=0,3911$; $R_m=0,4287$; $A=0,4287$

		Tahmin Edilen Sınıf										m_g	R_g
		1	2	3	4	5	6	7	8	9	10		
Gerçek Sınıf	1	673	48	193	84	38	75	156	139	40	554	2000	0,3365
	2	105	370	206	127	72	167	77	485	260	131	2000	0,1850
	3	299	183	444	192	1	109	177	165	273	157	2000	0,2220
	4	349	97	237	457	0	57	231	59	239	274	2000	0,2285
	5	0	0	0	0	1951	16	0	0	0	33	2000	0,9755
	6	124	142	152	104	268	557	21	260	188	184	2000	0,2785
	7	74	16	53	73	0	0	1252	41	32	459	2000	0,6260
	8	23	81	45	47	0	106	659	830	64	145	2000	0,4150
	9	145	290	313	194	48	110	181	191	417	111	2000	0,2085
	10	227	30	51	39	85	77	228	16	24	1223	2000	0,6115
m'_g		2019	1257	1694	1317	2463	1274	2982	2186	1537	3271		
P_g		0,3333	0,2944	0,2621	0,3470	0,7921	0,4372	0,4199	0,3797	0,2713	0,3739		

Çizelge 4.7 Kapur-Kosinüs (64 Renk): $P_m=0,4407$; $R_m=0,4518$; $A=0,4518$

		Tahmin Edilen Sınıf										m_g	R_g
		1	2	3	4	5	6	7	8	9	10		
Gerçek Sınıf	1	975	26	137	60	35	91	45	98	58	475	2000	0,4875
	2	139	457	246	178	33	176	46	254	358	113	2000	0,2285
	3	349	184	505	232	2	115	158	45	245	165	2000	0,2525
	4	374	78	250	498	5	49	226	28	184	308	2000	0,2490
	5	0	0	1	0	1936	0	0	0	0	63	2000	0,9680
	6	183	134	155	101	196	654	24	193	142	218	2000	0,3270
	7	38	10	67	67	0	3	1376	58	14	367	2000	0,6880
	8	53	63	92	13	0	59	507	954	78	181	2000	0,4770
	9	142	232	292	236	55	126	146	177	477	117	2000	0,2385
	10	244	27	92	43	110	60	185	11	24	1204	2000	0,6020
m'_g		2497	1211	1837	1428	2372	1333	2713	1818	1580	3211		
P_g		0,3905	0,3774	0,2749	0,3487	0,8162	0,4906	0,5072	0,5248	0,3019	0,3750		

Çizelge 4.8 Otsu-Kosinüs (8 Renk): $P_m=0,4263$; $R_m=0,4238$; $A=0,4238$

		Tahmin Edilen Sınıf										m_g	R_g
		1	2	3	4	5	6	7	8	9	10		
Gerçek Sınıf	1	708	127	185	248	29	101	158	44	108	292	2000	0,3540
	2	142	634	306	143	144	95	50	84	333	69	2000	0,3170
	3	151	271	544	155	19	233	130	64	309	124	2000	0,2720
	4	379	135	189	598	0	127	124	16	219	213	2000	0,2990
	5	0	40	26	0	1845	42	0	0	28	19	2000	0,9225
	6	149	75	241	134	40	721	58	67	211	304	2000	0,3605
	7	268	48	158	183	0	66	788	231	95	163	2000	0,3940
	8	91	102	87	59	12	90	162	1278	68	51	2000	0,6390
	9	130	286	345	218	32	216	119	48	539	67	2000	0,2695
	10	364	44	140	149	29	289	85	16	63	821	2000	0,4105
m'_g		2382	1762	2221	1887	2150	1980	1674	1848	1973	2123		
P_g		0,2972	0,3598	0,2449	0,3169	0,8581	0,3641	0,4707	0,6916	0,2732	0,3867		

Çizelge 4.9 Otsu-Kosinüs (27 Renk): $P_m=0,5025$; $R_m=0,5017$; $A=0,5017$

		Tahmin Edilen Sınıf										m_g	R_g
		1	2	3	4	5	6	7	8	9	10		
Gerçek Sınıf	1	1092	42	222	169	10	101	11	63	83	207	2000	0,5460
	2	130	484	272	171	35	281	19	141	361	106	2000	0,2420
	3	305	187	602	241	1	144	57	58	290	115	2000	0,3010
	4	433	113	276	680	0	109	64	45	176	104	2000	0,3400
	5	1	1	1	0	1978	6	0	0	3	10	2000	0,9890
	6	168	160	222	114	30	874	8	91	151	182	2000	0,4370
	7	46	28	60	104	0	10	1325	148	39	240	2000	0,6625
	8	184	78	83	80	1	114	67	1291	70	32	2000	0,6455
	9	151	280	343	208	16	205	39	82	584	92	2000	0,2920
	10	313	55	98	68	66	91	116	16	53	1124	2000	0,5620
m'_g		2823	1428	2179	1835	2137	1935	1706	1935	1810	2212		
P_g		0,3868	0,3389	0,2763	0,3706	0,9256	0,4517	0,7767	0,6672	0,3227	0,5081		

Çizelge 4.10 Otsu-Kosinüs (64 Renk): $P_m=0,5350$; $R_m=0,5244$; $A=0,5244$

		Tahmin Edilen Sınıf										m_g	R_g
		1	2	3	4	5	6	7	8	9	10		
Gerçek Sınıf	1	1232	41	226	95	3	81	6	16	79	221	2000	0,6160
	2	144	519	329	159	47	256	6	67	362	111	2000	0,2595
	3	294	177	659	216	15	135	63	14	296	131	2000	0,3295
	4	361	130	299	698	0	89	69	13	255	86	2000	0,3490
	5	0	1	5	0	1970	1	0	0	0	23	2000	0,9850
	6	232	140	241	112	36	894	4	60	145	136	2000	0,4470
	7	51	5	61	77	0	2	1327	226	26	225	2000	0,6635
	8	106	37	38	47	0	46	72	1575	57	22	2000	0,7875
	9	167	251	362	269	42	164	42	54	557	92	2000	0,2785
	10	407	28	98	62	96	77	116	18	42	1056	2000	0,5280
m'_g		2994	1329	2318	1735	2209	1745	1705	2043	1819	2103		
P_g		0,4115	0,3905	0,2843	0,4023	0,8918	0,5123	0,7783	0,7709	0,3062	0,5021		

Çizelge 4.11 HAM-Kosinüs (8 Renk): $P_m=0,4625$; $R_m=0,4537$; $A=0,4537$

		Tahmin Edilen Sınıf											
		1	2	3	4	5	6	7	8	9	10	m_g	R_g
Gerçek Sınıf	1	898	91	163	231	18	88	73	24	126	288	2000	0,4490
	2	113	660	395	119	43	170	24	88	291	97	2000	0,3300
	3	154	309	609	154	5	223	111	46	278	111	2000	0,3045
	4	392	104	167	744	7	139	66	22	172	187	2000	0,3720
	5	2	11	4	14	1910	26	2	0	13	18	2000	0,9550
	6	113	106	255	137	11	679	31	115	215	338	2000	0,3395
	7	132	40	169	179	1	45	984	174	111	165	2000	0,4920
	8	112	90	71	45	2	140	73	1343	58	66	2000	0,6715
	9	170	300	370	179	17	235	84	48	487	110	2000	0,2435
	10	376	48	116	186	16	289	71	36	103	759	2000	0,3795
m'_g		2462	1759	2319	1988	2030	2034	1519	1896	1854	2139		
P_g		0,3647	0,3752	0,2626	0,3742	0,9409	0,3338	0,6478	0,7083	0,2627	0,3548		

Çizelge 4.12 HAM-Kosinüs (27 Renk): $P_m=0,5250$; $R_m=0,5222$; $A=0,5222$

		Tahmin Edilen Sınıf											
		1	2	3	4	5	6	7	8	9	10	m_g	R_g
Gerçek Sınıf	1	1166	51	267	140	3	111	26	29	61	146	2000	0,5830
	2	126	639	283	142	2	243	23	98	384	60	2000	0,3195
	3	257	182	777	153	5	176	75	33	269	73	2000	0,3885
	4	391	126	262	727	6	93	37	31	220	107	2000	0,3635
	5	0	0	0	8	1962	18	0	3	0	9	2000	0,9810
	6	156	133	315	100	6	823	6	129	164	168	2000	0,4115
	7	86	41	101	110	0	17	1102	179	43	321	2000	0,5510
	8	91	64	29	34	3	82	27	1586	54	30	2000	0,7930
	9	141	368	356	203	5	148	33	40	632	74	2000	0,3160
	10	280	53	107	84	31	103	211	22	80	1029	2000	0,5145
m'_g		2694	1657	2497	1701	2023	1814	1540	2150	1907	2017		
P_g		0,4328	0,3856	0,3112	0,4274	0,9698	0,4537	0,7156	0,7377	0,3314	0,5102		

Çizelge 4.13 HAM-Kosinüs (64 Renk): $P_m=0,5559$; $R_m=0,5525$; $A=0,5525$

		Tahmin Edilen Sınıf											
		1	2	3	4	5	6	7	8	9	10	m_g	R_g
Gerçek Sınıf	1	1321	55	225	73	3	83	13	16	65	146	2000	0,6570
	2	150	632	345	88	3	234	20	82	328	118	2000	0,3135
	3	307	220	794	113	5	162	67	22	212	98	2000	0,3965
	4	375	102	232	793	17	99	54	23	182	123	2000	0,3960
	5	0	1	0	13	1948	17	4	1	0	16	2000	0,9760
	6	203	104	305	91	13	879	7	90	148	160	2000	0,4405
	7	96	26	95	89	3	25	1218	159	52	237	2000	0,6135
	8	46	29	15	26	2	59	37	1725	36	25	2000	0,8605
	9	168	321	333	175	10	188	33	46	581	145	2000	0,2875
	10	271	42	97	47	47	66	143	32	97	1158	2000	0,5775
m'_g		2937	1532	2441	1508	2051	1812	1596	2196	1701	2226		
P_g		0,4498	0,4125	0,3253	0,5259	0,9498	0,4851	0,7632	0,7855	0,3416	0,5202		

Çizelge 4.14 Görüntü erişim yöntemleri (makro değerlendirme): P_m , R_m ve A

Vektör nicemleme yöntemi	Renk sayısı	Histogram benzerlik yöntemi	P_m	R_m	A
LBG	8	Kosinüs	0,3195	0,3221	0,3221
		Kesişim	0,3201	0,3293	0,3293
	27	Kosinüs	0,3432	0,3340	0,3340
		Kesişim	0,3528	0,3363	0,3363
	64	Kosinüs	0,3480	0,3346	0,3346
		Kesişim	0,3578	0,3526	0,3526
Kapur	8	Kosinüs	0,4111	0,4181	0,4181
		Kesişim	0,4047	0,4079	0,4079
	27	Kosinüs	0,4110	0,4145	0,4145
		Kesişim	0,4884	0,4783	0,4783
	64	Kosinüs	0,4407	0,4518	0,4518
		Kesişim	0,5447	0,5369	0,5369
Otsu	8	Kosinüs	0,4263	0,4238	0,4238
		Kesişim	0,4280	0,4250	0,4250
	27	Kosinüs	0,5025	0,5017	0,5017
		Kesişim	0,5093	0,5164	0,5164
	64	Kosinüs	0,5350	0,5244	0,5244
		Kesişim	0,5421	0,5352	0,5352
HAM	8	Kosinüs	0,4625	0,4537	0,4537
		Kesişim	0,4608	0,4548	0,4548
	27	Kosinüs	0,5250	0,5222	0,5222
		Kesişim	0,5370	0,5315	0,5315
	64	Kosinüs	0,5559	0,5525	0,5525
		Kesişim	0,5818	0,5714	0,5714

Çizelge 4.14'e genel doğruluk (A) bilgisine bakıldığında geliştirilen tüm yaklaşımların kesişim metriği ile daha başarılı olduğu görülebilir. LBG ile geliştirilen İTGE sisteminde benzerlik metriği başarıyı arttırsada çok fazla değişkenlik göstermektedir. En belirgin farklılığın 64 renkte yaklaşık %2 lik farkla kesişim metriğinde olduğu görülmektedir. 8 ve 27 renkte ise %1'in altında kalmıştır. Kapur tabanlı İTGE sistemi incelendiğinde ise, ilgili eşikleme tekniği ile elde edilen 8 renk vektörü kosinüs ile daha başarılı sonuçlar vermiştir. Ancak 27 ve 64 renkteki başarısına bakıldığında benzerlik metriğinin önemi açıkça görülmektedir. Kapur temelli İTGE'nin 27 renkte kosinüs benzerlik metriği ile doğruluk parametresi $A=0,4145$ iken, kesişim metriği ile olan doğruluk değeri $A=0,4783$ 'tür. 64 renkte ise kosinüs ve kesişim metriği ile olan doğruluk değerleri sırasıyla $A=0,4518$ ve $A=0,5369$ olduğu görülmektedir. Kapur yöntemi 27 ve 64 renkte kesişim metriği ile kosinüs benzerlik

metriğine göre daha fazla sayıda ilişkili görüntüye erişmiştir. 27 ve 64 renkte kesişim benzerliği sırasıyla yaklaşık %6 ve %8 daha üstün başarı göstermiştir. Otsu ve HAM metotları ise diğer yaklaşımlarda olduğu gibi kesişim metriği ile daha başarılı sonuçlar vermiştir. Otsu yaklaşımında ilgili benzerlik teknikleri arasındaki doğruluk değerleri farkı 8 renkte %0,12 iken, 27 ve 64 renkte sırasıyla %1,47 ve %1,08 olmuştur. Benzer şekilde HAM yöntemi de kesişim metriği ile daha başarılı sonuçlar elde etmiş ve kosinüs ile olan doğruluk değeri farkı 8 renkte yaklaşık %0,12 iken 27 renkte bu değer yaklaşık %1 olmuştur. 64 renkte ise doğruluk değerleri arasındaki fark yaklaşık %2 olmuştur.


Renkli görüntüler için sınıfsal tabanlı tek boyutlu özellik vektörü çıkaran yaklaşımların başarılarına kendi aralarında bakıldığında ise HAM yönteminin kesişim benzerlik metriği ile en başarılı sonuçları verdiği açıkça görülmektedir. LBG ise en düşük performansa sahip olmuştur. LBG'nin başlangıç küme merkezlerini rastgele ataması yöntemin en önemli dezavantajıdır. İlaveten iteratif olması ve durdurma eşiğine ihtiyaç duyması diğer problemidir. LBG tekniğinin başarısının düşük olmasının sebebi başlangıç küme merkezlerini 0-255 değer aralığında rastgele ataması dolayısıyla her bir sorgulamada aynı görüntü için farklı özellik vektörü üretmesinden kaynaklanmaktadır. Otsu ve Kapur optimizasyon teknikleri ise LBG yöntemine göre daha iyi bir başarı sergilemesine rağmen HAM yaklaşımının gerisinde kalmışlardır. Bu durum HAM yaklaşımının diğerlerine göre daha anlamlı renk indirgeme yaptığının ve dolayısıyla daha az bilgi kaybının olduğunu göstermektedir. Ayrıca söz konusu yaklaşım ile indirgeme sonucunda elde edilen özellik vektörleri görüntüleri daha iyi temsil etmiştir. Sistemlerin genel doğruluk değerleri dikkate alındığında HAM yaklaşımı 64 renk ve kesişim metriğinde $A=0,5714$ ile en başarılı sonucu vermiştir. Otsu yaklaşımı her iki metriktede 8 ve 27 renkte Kapur yaklaşımından daha üstün olsada, 64 renkte Kapur yaklaşımı kesişim metriği ile $A=0,5369$ değeri ile daha üstün bir sonuç elde etmiştir. HAM tekniğinin tüm renk sayılarındaki genel doğruluk ortalama değeri 0,51 iken LBG tekniğinde ise bu değer 0,33 olmaktadır.

Karmaşıklık matrisleri erişilen görüntülerin sıralaması dikkate alınmadan sadece doğru sınıfta olup olmadığını kontrol eden performans değerlendirme yöntemidir. Ancak sıralı erişim olarak adlandırılan sistemlerde erişilen görüntünün sıralamasıda önemli olmaktadır. Bu tür erişim sistemlerinde standart 11 noktalı P-R grafikleri ile değerlendirmeler yapılmaktadır. Şekil 4.3 (a), Şekil 4.3 (b) ve Şekil 4.3 (c) geliştirilen İTGE sistemlerinin


kosinüs benzerlik metriği ve 8, 27 ve 64 renk ile Afrikalılar kategorisine ait performanslarını gösteren P-R eğrileridir. Benzer şekilde kullanılan algortimaların kesişim metriği ve 8 renk için P-R değerlendirmeleri Şekil 4.4 (a)'da bulunmaktadır. Kesişim metriğinin 27 ve 64 renkteki Afrikalılardaki durumları ise Şekil 4.5 (b) ve Şekil 4.5 (c)' de verilmiştir. Söz konusu eğriler incelendiğinde HAM, Otsu ve Kapur tekniklerinin LBG yaklaşımlarına göre başarıları açıkça görülmektedir. HAM yaklaşımı ile her hassasiyet seviyesinde diğer yöntemlere göre daha yüksek kesinlik değerleri elde edilmiştir. Ancak kesişim metriği ile 27 renkte Otsu yaklaşımının daha başarılı olduğu görülmektedir. Erişim sistemlerinin genel olarak zorlandığı kategori olan Sahillerdeki başarı durumları ise Şekil 4.5 ve Şekil 4.6'da verilmiştir. HAM yönteminin benzerlik metriğine göre performansı karşılaştırıldığında histogram kesişim ile daha başarılı sonuçlar üretmiştir. LBG yaklaşımı ise benzerlik metriklerine göre herhangi bir ilerleme göstermemiştir. Şekil 4.5 (c) ve Şekil 4.6 (c) ise sırasıyla kosinüs ve kesişim metriklerinin 64 renkteki performanslarını temsil eden grafiklerdir. Söz konusu eğrilere bakıldığında zor bir kategori olan Sahillerde Kapur eşikleme tekniğinin daha üstün performans gösterdiği görülmektedir. Yapıtlar ise bir diğer tipik Core1K kategorisidir. Bahsi geçen gruptaki kosinüs metriği ile 8, 27 ve 64 renkteki P-R eğrileri Şekil 4.7 (a), Şekil 4.7 (b) ve Şekil 4.7 (c) verilmiştir. Kesişim yaklaşımı ile tekniklerin başarımları ise 8 renk için Şekil 4.8 (a)'da 27 ve 64 renk için sırasıyla Şekil 4.8 (b) ve Şekil 4.8 (c)'de gösterilmiştir. Bu kategoride renk sayısının artmasıyla HAM yönteminin ayırt ediciliğinin arttığı görülmektedir. Yapıtlarda Otsu ve Kapur her iki benzerlik metriği ile yapılan deneylerde birbirine yakın performans göstermişlerdir. LBG ise bu kategoride de en düşük performansa sahiptir. Şekil 4.9 (a), Şekil 4.9 (b) ve Şekil 4.9 (c)

'da verilen grafiklerde Otobüsler kategorisinin 8,27 ve 64 renklerdeki kosinüs benzerlik metriğiyle performansları bulunmaktadır. Şekil 4.10 (a), Şekil 4.10 (b) ve Şekil 4.10 (c) ise aynı kategorideki kesişim metriğinin başarımlarını gösteren deneysel bulgulardır. 8 renk ve kosinüs benzerliğinde $R=0,2$ seviyelerinde kadar yöntemlerin hepsi yakın kesinlik değerlerine ulaşmıştır. Ancak gelen görüntü sayısı arttıkça HAM yönteminin dayanıklılığının arttığı gözlemlenmiştir. Yine 8 renkte Otsu ve Kapur çok yakın performans göstermiştir. Ancak renk sayısı arttıkça Otsu eşikleme tekniğinin seçiciliğinin arttığı söylenebilir. Bu durum Otsu'nun Kapur yaklaşımına göre görüntüleri daha iyi temsil eden özellik vektörleri çıkarttığı anlamına gelmektedir. Şekil 4.9 (c)'ye bakıldığında ise $R=0,3$ seviyelerine kadar HAM ve Otsu yaklaşımları birbirine yakın kesinlik değerlerine ulaşmaktadır. Ancak yine erişilen görüntü sayısı arttıkça HAM yönetiminin dayanıklılığı


başka bir deyişle eriştiği doğru görüntü sayısının arttığı bulgulara izlenmektedir. Tüm yaklaşımların en başarılı olduğu kategori Dinozorlardır. Dinozorlar kategorisine ait bulgular ise kosinüs için Şekil 4.11, kesişim için Şekil 4.12’de verilmiştir. HAM yöntemi genel olarak birçok kategoride diğer metotlara göre daha başarılıdır. Ancak Filler kategorisine bakılırsa Otsu tekniğinin daha ayırt edici olduğu görülebilir. Bahsi geçen kategoriye ait 8, 27 ve 64 renk ve kosinüs metriği erişim sonuçları Şekil 4.13 (a), Şekil 4.13 (b) ve Şekil 4.13 (c)’de bulunmaktadır. Aynı şekilde kesişim benzerliği ile 8,27 ve 64 renk başarıları Şekil 4.14 (a), Şekil 4.14 (b) ve Şekil 4.14 (c) ile gösterilmiştir. HAM, Otsu ve Kapur yaklaşımlarının ortalamanın üzerinde başarı gösterdiği kategori Çiçeklerdir. Şekil 4.15 Çiçekler kategorisinin kosinüs benzerliği ile olan performansını gösterirken, Şekil 4.16 ise aynı kategorideki kesişim ile elde edilen bulguları göstermektedir. Şekil 4.15 (a)’ya bakıldığında HAM 8 renkte aynı hassasiyet seviyelerinde en iyi kesinlik değerlerine ulaştığı görülebilir. Ancak renk sayısının artmasıyla bu durum değişmiştir. Şekil 4.15 (b) ve Şekil 4.15 (c)’de ise Otsu algoritmasının ortalamanın üzerinde başarı gösterdiği ifade edilebilir. LBG temelli İTGE ise diğer yöntemlerin gerisinde kalmıştır. Atlar ise HAM, Otsu ve Kapur tekniklerinin ortalama başarısını olumlu etkileyen diğer bir kategori olmuştur. Şekil 4.17 ve Şekil 4.18’de geliştirilen erişim sistemlerinin söz konusu kategorideki başarımları gösterilmiştir. Dağlar ise kategoriler arasındaki en az ilişkili görüntüye erişilen grup olmuştur. Şekil 4.19 ve Şekil 4.20 Dağlardaki performansını gösteren grafiklerdir. Şekil 4.19 (a) ve Şekil 4.20 (a) incelendiğinde Kapur yaklaşımı aynı hassasiyet seviyelerinde daha başarılı sonuçlar ürettiği görülmüştür. Ancak renk sayısı arttıkça söz konusu eşikleme tekniği ile gerçekleştirilen erişim sisteminin başarısının düştüğü görülmektedir. Şekil 4.21 (a), Şekil 4.21 (b) ve Şekil 4.21 (c) ise Yiyecekler kategorisindeki yaklaşımların sırasıyla 8,27 ve 64 renklerdeki kosinüs metriği ile olan durumlarını göstermektedir. Aynı kategoride kesişim benzerlik ölçümü ile elde edilen sonuçları ise 8 renk için Şekil 4.22 (a), 27 renk için Şekil 4.22 (b) ve 64 renk için ise Şekil 4.22 (c)’de gösterilmiştir. Renk çeşitliliğinin fazla olduğu ilgili kategoride 64 renkte ve kosinüs metriği ile en iyi performansı HAM gösterirken, kesişim metriği ile Otsu ve Kapur yaklaşımlarının başarısı artarak HAM’dan daha iyi performans göstermişleridir. Bu durum benzerlik metriğinin erişim sistemleri için önemli bir aşama olduğunun göstergesidir. Böylece geliştirilen erişim sistemleri için farklı ölçümler kullanmak geçerlilik için önem arz etmektedir.



a)




b)




c)


Şekil 4.3. Afrikalılar ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk



a)






b)




c)


Şekil 4.4. Afrikalılar ve kesişim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk




Şekil 4.5. Sahiller ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk



a)






b)






c)




Şekil 4.6. Sahiller ve kesişim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk






Şekil 4.7. Yapıtlar ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk






Şekil 4.8. Yapıtlar ve kesişim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk




Şekil 4.9. Otobüsler ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk




Şekil 4.10. Otobüsler ve kesişim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk




Şekil 4.11. Dinozorlar ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk



a)






b)






c)


Şekil 4.12. Dinozorlar ve kesimlik: P-R grafiği a) 8 renk b) 27 renk c) 64 renk




Şekil 4.13. Filler ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk




Şekil 4.14. Filler ve kesişim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk



a)




b)




c)


Şekil 4.15. Çiçekler ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk



a)




b)




c)


Şekil 4.16. Çiçekler ve kesişim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk



a)






b)






c)


Şekil 4.17. Atlar ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk




Şekil 4.18. Atlar ve kesimim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk




Şekil 4.19. Dağlar ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk



a)




b)




c)


Şekil 4.20. Dağlar ve kesişim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk



a)




b)




c)


Şekil 4.21. Yiyecekler ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk



a)






b)




c)

Şekil 4.22. Yiyecekler ve kesimim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk


Kategorilerdeki performanslar incelendiğinde en başarılı yaklaşımın HAM yöntemi olduğu görülmektedir. Bahsi geçen yaklaşım tüm kategorilerde genellikle kesişim benzerlik metriği ile başarılı sonuçlar verdiği gözlemlenmiştir. Test edilen algortimaların kategorilerdeki performansları da aynı şekilde benzerlik metriklerinden etkilenmiştir. LBG-İTGE Dinozorlar dışındaki diğer gruplarda ortalamasının altında düşük performans göstermektedir. Otsu ve Kapur yaklaşımları ile geliştirilen İTGE'nin performanslarına bakıldığında ise tüm gruplarda LBG-İTGE'den daha üstündür. Geliştirilen İTGE yaklaşımlarının genel performansı kosinüs benzerliği ile 8, 27 ve 64 renkte sırasıyla Şekil 4.23 (a), Şekil 4.23 (b) ve Şekil 4.23 (c)'de gösterilmiştir. Kesişim metriği ile olan genel durum ise aynı renk sayılarında sırasıyla Şekil 4.24 (a), Şekil 4.24 (b), Şekil 4.24 (c) ile verilmiştir. Otsu ve Kapur yaklaşımları 8 renk için her iki metrikte birbirine çok yakın sonuçlar üretmiştir. 27 renkte ise kosinüs ile Kapur daha başarılı iken, kesişim metriğinde ise Otsu daha iyi performans göstermiştir. HAM yaklaşımı tüm renk sayılarında ve her iki benzerlik metriğinde daha fazla sayıda ilişkili görüntüye erişmiştir. Genel performanslar incelendiğinde HAM yönteminin ürettiği özellik vektörlerinin İTGE sistemleri için daha ayırt edici olduğu söylenebilir. LBG yaklaşımının genel performansı ise diğer yöntemlerin gerisinde kalmıştır. Bu durum her defasında farklı başlangıç küme merkezleri üretmesinden kaynaklanmaktadır. Dolayısıyla aynı görüntüyü farklı vektörlerle temsil etmektedir.




Şekil 4.23. Genel performans ve kosinüs: P-R grafiği a) 8 renk b) 27 renk c) 64 renk



a)



b)



c)

Şekil 4.24. Genel performans ve kesişim: P-R grafiği a) 8 renk b) 27 renk c) 64 renk

5. SONUÇ

İçerik tabanlı görüntü erişimi görüntülerin renk, şekil, doku gibi özniteliklerinden yararlanarak veritabanındaki istenilen görüntülere erişme sürecidir. Söz konusu süreç özellik çıkarım aşamasıyla başlar ve çıkarılan özelliklerin karşılaştırılmasıyla devam eder. İçerik tabanlı erişim sistemlerinde görüntülerin kendisi yerine onları temsil eden özellik vektörleri kullanılmaktadır. Görüntülerin benzerlik karşılaştırmaları ise piksel seviyesi yerine eşit uzunluktaki özellik vektörleri üzerinden yapılmaktadır. Dolayısıyla görüntüleri temsil eden özellik vektörleri sistem mimarisinin en önemli unsuru olmaktadır. Görüntülerin boyutlarından bağımsız olmaları ve farklı boyutlardaki görüntülerin karşılaştırılmasına imkân sağlamalarından dolayı tek boyutlu histogramlar içerik tabanlı sistemlerde sıklıkla kullanılan bir özellik vektörüdür. Döndürmeye ve ölçeklemeye dayanıklı olmaları histogramları erişim sistemleri için güçlü bir tanımlayıcı yapmaktadır. Histogramlar görüntülerdeki piksellerin bulunma olasılığını gösteren dağılım grafikleridir. Bahsi geçen olasılık dağılımı gri seviyeli görüntülerde tek kanaldan gelen bilgileri temsil etmektedir. Diğer taraftan renkli görüntülerde üç kanaldan gelen bilgilerin ayrı ayrı işlenmeleri gerekir. Ayrıca bu kanallardan gelen bilgilerin birleştirilmeside diğer bir problemdir. RGB renk uzayı 2^{24} farklı renkten oluşmaktadır. Erişim sistemlerinde görüntülerin birbirine yakın renklerini bir araya toplayarak ifade etmek algoritmaların işlem hızını artıracaktır. Dolayısıyla görüntülerdeki renk sayılarının azaltılması önemli hale gelmektedir.

Bu çalışmada renkli görüntüler için sınıf tabanlı tek boyutlu histogram kullanan yeni bir görüntü erişimi yaklaşımı önerilmiştir. Başlangıçta Otsu, Kapur ve HAM yaklaşımları ile renkli görüntülerin her bir kanalı için eşik değerleri hesaplanmıştır. Akabinde elde edilen eşik değerler ile RGB renk uzayı dilimlenmiştir. Başka bir ifade ile RGB renk uzayı bölütlenmiştir. Renk uzayında oluşan her bir küp veya prizma bir renk sınıfını temsil etmektedir. İlgili prizmaların içinde kalan piksellerin ortalamaları aynı etiketli piksellere atanmıştır. Böylelikle renkli görüntüler için renk indirgemesi yapılmıştır. Renk kanalları için tek eşik ile 8, iki eşik ile 27 ve üç eşik ile 64 alt küme oluşmaktadır. Her renk kanalının eşik sayısı n olmak üzere, $c_{max}=(n+1)^3$ adet sınıf oluşturmak mümkündür. Görüldüğü gibi eşik sayısı ile renk sayısı birbiri ile ilişkilidir ancak oluşan her kümeye piksel ataması yapılamayabilir. Bu durum görüntüdeki piksellerin RGB renk uzayındaki dağılımı ile ilgilidir.

Renk uzayının bölütlenmesi ile görüntüdeki herhangi bir piksel RGB renk uzayında oluşan herhangi bir kümeye dahil olacaktır. Kümelerin bulunma olasılıkları renkli görüntüleri temsil eden sınıf tabanlı tek boyutlu histogramların bileşenleridir. Elde edilen tek boyutlu histogramlar ise İTGE sistemleri için özellik vektörü olarak kullanılmıştır.

Önerilen yaklaşımların performansı bilinen renk indirgeme algoritması olan LBG ile karşılaştırılmıştır. LBG algoritması küme merkezlerinin başlangıç değerlerine bağlıdır. Bu nedenle aynı görüntü için farklı özellik vektörleri üretebilmektedir. İlâveten iteratif bir algoritma olan LBG tekniğinde, iterasyonların bitmesini sağlayan ve kullanıcı tarafından belirlenen parametreye ihtiyaç vardır. Diğer taraftan geliştirilen stratejiler iteratif değildir ve herhangi bir sonlandırma eşiğine ihtiyaç duymazlar.

Geliştirilen içerik tabanlı görüntü erişim sisteminde görüntü benzerliği hesaplaması aşamasında kosinüs ve kesişim metriklerinden faydalanılmıştır. Önerilen algoritma 64 renk ile en başarılı sonuçları üretmiştir. 64 renkte LBG yaklaşımı ve histogramların kesişim metriği ile sistemin genel doğruluk değeri %35,26 iken, ilgili parametre Kapur ve Otsu yaklaşımlarında sırasıyla %53,69 ve %53,52 olmuştur. Diğer taraftan HAM yaklaşımında ise 64 renk ve kesişim benzerlik metriği ile global doğruluk değeri %57,14 seviyelerine ulaşmıştır. Dolayısıyla HAM indirgeme yaklaşımı ile gerçekleştirilen erişim sistemi, LBG temelli erişim sistemine göre yaklaşık %22 oranında daha ilişkili görüntülere erişmiştir. Benzer şekilde HAM metodu Kapur ve Otsu yaklaşımdan yaklaşık %4 daha başarılı olmuştur.

Yaklaşımların 27 renk sayısındaki performansına bakıldığında ise HAM tekniği LBG'ye göre yaklaşık %20 daha başarılı olmuştur. Otsu ve Kapur optimizasyon teknikleri ile gerçekleştirilen İTGE mimarileri LBG'den sırasıyla %6 ve %8 daha fazla sayıda benzer görüntülere erişse de, HAM algoritmasının gerisinde kalmışlardır.

İlâveten 8 renk ile yapılan deneylerde elde edilen başarımlar en düşük seviyede kalmıştır. Bunun nedeni 8 sınıflı renk indirgemesinde bilgi kayıplarının fazla olmasıdır. Diğer taraftan 64 renk kümesi olan histogram vektörleri, 8 ve 27 renk kümesi olan vektörlere göre görüntüleri daha iyi temsil etmektedir. Bu durum sınıf sayısının artmasıyla bilgi kaybını azalmasının göstergesidir.

İlave olarak İTGE sistemlerinde histogramların kesişim algoritmasının kosinüs benzerlik metriğinden daha etkili bir sonuç ürettiği görülmüştür. Ayrıca renkli görüntülerin benzerlik değerlendirmesinde sınıfsal tabanlı histogramlar ile histogram kesişim benzerlik metriğinin daha uyumlu olduğu gözlenmiştir.

Önerilen yöntemde her bir renk kanalı için aynı sayıda eşik değerleri kullanılmıştır. Bu durum renk dağılımlarının karakteristiğine göre dezavantajlar yaratabilmektedir. Bazı sınıflara atanan piksel sayıları sıfır olabilmektedir. Başka bir ifade ile bazı sınıflara hiçbir piksel ataması yapılamayabilmektedir. Söz konusu problemin çözümü için farklı sayılarda eşiklerin kullanılması muhtemel ilerki çalışma alanıdır. Geliştirilen erişim sistemlerinde sadece renk özelliği kullanılmıştır. Sınıfsal tabanlı tek boyutlu histograma kenar, şekil ve örüntü gibi diğer tanımlayıcıların dâhil edilmesi muhtemel çalışma alanlarıdır.



KAYNAKLAR

1. Song, W., Zhang, Y., Liu, F., Chai, Z., Ding, F., Qian, X., ve Park, S. C. (2018). Taking advantage of multi-regions-based diagonal texture structure descriptor for image retrieval. *Expert Systems with Applications*, 96, 347-357.
2. Sethi, I. K., Coman, I. L. ve Stan, D. (2001). Mining association rules between low-level image features and high-level concepts. In *Data Mining and Knowledge Discovery: Theory, Tools, and Technology*, 4384, 279-290.
3. İnternet: URL: <http://www.svcl.ucsd.edu/projects/crossmodal/>, Son Erişim Tarihi: 10.10.2019.
4. Lew, M. S., Sebe, N., Djeraba, C. ve Jain, R. (2006). Content-based multimedia information retrieval: State of the art and challenges. *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, 2(1), 1-19.
5. Lumini, A. ve Maio, D. (2000). *Haruspex: an image database system for query-by-examples*. In *Pattern Recognition, 2000. Proceedings. 15th International Conference, Spain, 4*, 258-261.
6. Müller, H., Michoux, N., Bandon, D. ve Geissbuhler, A. (2004). A review of content-based image retrieval systems in medical applications clinical benefits and future directions. *International journal of medical informatics*, 73(1), 1-23.
7. Qi, H., Li, K., Shen, Y. ve Qu, W. (2010). An effective solution for trademark image retrieval by combining shape description and feature matching. *Pattern Recognition*, 43(6), 2017-2027.
8. Lee, Y. B., Park, U., Jain, A. K. ve Lee, S. W. (2012). Pill-ID: Matching and retrieval of drug pill images. *Pattern Recognition Letters*, 33(7), 904-910.
9. Bosilj, P., Aptoula, E., Lefèvre, S. ve Kijak, E. (2016). Retrieval of remote sensing images with pattern spectra descriptors. *International Journal of Geo-Information*, 5(12), 228-244.
10. Smeulders, A. W., Worring, M., Santini, S., Gupta, A. ve Jain, R. (2000). Content-based image retrieval at the end of the early years. *IEEE Transactions on pattern analysis and machine intelligence*, 22(12), 1349-1380.
11. Messing, D. S., Van Beek, P., Errico, J. H. (2001). The mpeg-7 colour structure descriptor: image description using colour and local spatial information. In: *Proceedings of the International Conference on Image Processing*, 670-673.
12. Manjunath, B. S., Ohm, J-R., Vasudevan, V. V., ve Yamada, A. (2001). Color and texture descriptors. *IEEE Transactions on Circuits and Systems for Video Technology*, 11(6), 703-715.
13. Kasutani, E. ve Yamada, A. (2001, Ekim). The MPEG-7 color layout descriptor: a compact image feature description for high-speed image/video segment retrieval. In: *Proceedings of IEEE International Conference on Image Processing*, 674-677.

14. Pass, G., Zabih, R., ve Miller, J. (1997). Comparing images using color coherence vectors. *In: Proceedings of the fourth ACM international conference on Multimedia*, 65–73.
15. Lu, G. ve Teng, S. (1999). A novel image retrieval technique based on vector quantization. *In: Proceedings of International Conference on Computational Intelligence for Modeling, Control and Automation*, 36–41.
16. Jing, J., Li, Q., Li, P., ve Zhang, L. (2016). A new method of printed fabric image retrieval based on color moments and gist feature description. *Textile Research Journal*, 86(11), 1137-1150.
17. Zhang, J. ve Tan, T. (2002). Brief review of invariant texture analysis methods. *Pattern recognition*, 35(3), 735–747.
18. Portilla, J. ve Simoncelli, E. P. (2000). A parametric texture model based on joint statistics of complex wavelet coefficients. *International Journal of Computer Vision*, 40(1), 49–70.
19. van Ginneken, B. ve ter Haar Romeny, B. M. (2003). Multi-scale texture classification from generalized locally orderless images. *Pattern Recognition*, 36(4), 899–911.
20. Ojala, T., Pietikäinen, M. ve Mäenpää, T. (2002). Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7), 971–987.
21. Emerson, C. W., Siu-Ngan Lam, N. ve Ouattrochi, D. (1999). Multi-scale fractal analysis of image texture and patterns. *Photogrammetric Engineering and Remote Sensing*, 65, 51–62.
22. Liu, G-H., Zhang, L., Hou, Y-K., Li, Z-Y. ve Yang, J-Y. (2010). Image retrieval based on multi-texton histogram. *Pattern Recognition*, 43(7), 2380–2389.
23. Subrahmanyam, M., Maheshwari, R. ve Balasubramanian, R. (2012). Expert system design using wavelet and color vocabulary trees for image retrieval. *Expert Systems with Applications*, 39(5), 5104–5114.
24. Liu, G-H. ve Yang, J-Y. (2013). Content-based image retrieval using color difference histogram. *Pattern Recognition*, 46(1), 188–198.
25. Liu, G-H., Li, Z-Y., Zhang, L. ve Xu, Y. (2011). Image retrieval based on micro-structure descriptor. *Pattern Recognition*, 44(9), 2123–2133.
26. Wang, X. ve Wang, Z. (2013). A novel method for image retrieval based on structure elements' descriptor. *Journal of Visual Communication and Image Representation*, 24(1), 63–74.
27. Ortega, M., Rui, Y., Chakrabarti, K., Porkaew, K., Mehrotra, S. ve Huang, T. S. (1998). Supporting ranked boolean similarity queries in MARS. *IEEE Transactions on Knowledge and Data Engineering*, 10(6), 905–925.

28. Swain, M. J. ve Ballard, D. H. (1991). Color indexing. *International Journal of Computer Vision*, 7(1), 11-32.
29. Deselaers, T. (2003). Features for image retrieval. Master Thesis, Human Language Technology and Pattern Recognition Group, RWTH Aachen University, Aachen, Germany.
30. Long, F., Zhang, H. ve Feng, D. D. (2003). *Fundamentals of content-based image retrieval*, in Multimedia Information Retrieval and Management, Berlin, 1–26.
31. Alamdar, F. ve Keyvanpour, M. (2011). A new color feature extraction method based on quadhistogram. *Procedia Environmental Sciences*, 10(Part A), 777-783.
32. Pass, G. ve Zabih, R. (1996). Histogram refinement for content-based image retrieval. *In Applications of Computer Vision, 1996. WACV'96, Proceedings 3rd IEEE Workshop on*, 96-102.
33. Hafner, J., Sawhney, H. S., Equitz, W., Flickner, M. ve Niblack, W. (1995). Efficient color histogram indexing for quadratic form distance functions. *IEEE transactions on pattern analysis and machine intelligence*, 17(7), 729-736.
34. Datta, R., Joshi, D., Li, J. ve Wang, J. Z. (2008). Image retrieval: Ideas, influences, and trends of the new age. *ACM Computing Surveys (Csur)*, 40(2), 5: 1-60.
35. Rui, Y., Huang, T. S. ve Chang, S. F. (1999). Image retrieval: Current techniques, promising directions, and open issues. *Journal of visual communication and image representation*, 10(1), 39-62.
36. Finkel, R. A. ve Bentley, J. L. (1974). Quad trees a data structure for retrieval on composite keys. *Acta informatica*, 4(1), 1-9.
37. Salmi, M. ve Boucheham, B. (2014). Content based image retrieval based on cell color coherence vector (Cell-CCV). *ISKO-Maghreb: Concepts and Tools for knowledge Management (ISKO-Maghreb), 2014 4th International Symposium*, 1-5.
38. Patil, S. M. ve Patil, V. K. (2015). CCV based image retrieval for FMIQ with confined histogram refinement. *International of Journal of Innovative Research in Electrical*, 3(1), 64-68.
39. Ravani, R., Mirali, M. R. ve Baniyasi, M. (2010). Parallel CBIR system based on color coherence vector. *17th International Conference on Systems, Signals and Image Processing*, 518-521.
40. Al-Hamami, A. ve Al-Rashdan, H. (2010). Improving the effectiveness of the color coherence vector. *International Arab Journal Information Technology*, 7(3), 324-332.
41. Ayan, M. (2016). *Genetik algoritma kullanılarak renk ve doku özelliklerine dayalı içerik tabanlı görüntü erişim sistemi tasarımı ve uygulaması*. Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara,105.

42. Konstantinidis, K., Gasteratos, A. ve Andreadis, I. (2005). Image retrieval based on fuzzy color histogram processing. *Optics Communications*, 248(4), 375-386.
43. Grabisch, M. (2000). New pattern recognition tools based on fuzzy logic for image understanding. In *Soft Computing for Image Processing, Physica-Verlag HD*, 299-317.
44. Smith, J. R. ve Chang, S. F. (1996). Tools and techniques for color image retrieval. In *Storage and Retrieval for Image and Video Databases (SPIE)*, 2670, 2-7.
45. Zhang, D. (2004). Improving image retrieval performance by using both color and texture features. In *Image and Graphics (ICIG'04), Third International Conference on*, 172-175.
46. Kucuktunc, O. ve Zamalieva, D. (2009). Fuzzy color histogram-based CBIR system. In *Proceedings of 1st International Fuzzy Systems Symposium*.
47. Veltkamp, R. C. ve Tanase, M. (2001). *Content-based image retrieval systems: A survey*, Technical Report, The Netherlands, Utrecht University, Information and Computing Sciences, 1-49.
48. Niblack, C. W., Barber, R., Equitz, W., Flickner, M. D., Glasman, E. H., Petkovic, D., Yanker, P.; Faloutsos, C. ve Taubin, G. (1993). QBIC project: querying images by content, using color, texture, and shape. In *IS&T/SPIE's Symposium on Electronic Imaging: Science and Technology, International Society for Optics and Photonics*, 173-187.
49. Zadeh, L. A. (1979). Approximate reasoning based on fuzzy logic. In *Proceedings of the 6th international joint conference on Artificial intelligence 2*, 1004-1010.
50. Zadeh, L.A. (1984). Fuzzy probabilities. *Information Processing and Management*, 20(3), 363-372.
51. Han, J. ve Ma, K. K. (2002). Fuzzy color histogram and its use in color image retrieval. *IEEE Transactions on image Processing*, 11(8), 944-952.
52. Sugano, N. (2001). Color-naming system using fuzzy set theoretical approach. In *Fuzzy Systems, The 10th IEEE International Conference on*. 1, 81-84.
53. Domke, J. ve Aloimonos, Y. (2006). Deformation and viewpoint invariant color histograms. In *BMVC*, 509-518.
54. Felzenszwalb, P. F., & Huttenlocher, D. P. (2004). Efficient graph-based image segmentation. *International Journal of Computer Vision*, 59(2), 167-181.
55. Song, H., Li, X. ve Wang, P. (2010). Adaptive feature selection and extraction approaches for image retrieval based on region. *Journal of Multimedia*, 5(1), 85-92.
56. Rasheed, W., An, Y., Pan, S., Jeong, I., Park, J. ve Kang, J. (2008). Image retrieval using maximum frequency of local histogram based color correlogram. In *Multimedia and Ubiquitous Engineering*, 62-66.

57. . Rasheed, W., Kang, G., Kang, J., Chun, J., ve Park, J. (2008). Sum of values of local histograms for image retrieval. *In 2008 Fourth International Conference on Networked Computing and Advanced Information Management*. 690-694.
58. An, Y., Rasheed, W., Park, S. ve Park, J. (2011). Feature extraction through generalization of histogram refinement technique for local region-based object attributes. *International Journal of Imaging Systems and Technology*, 21(3), 298-306.
59. An, Y., Riaz, M. ve Park, J. (2010). CBIR based on adaptive segmentation of HSV color space. *In Computer Modelling and Simulation (UKSim), 2010 12th International Conference on*, 248-251.
60. Suhasini, P.S., Krishna, K.S.R. ve Krishna, I.V.M. (2008). Graph based segmentation in content based image retrieval, *Journal of Computer Science*, 4 (8): 699-705.
61. Datta, R., Li, J. ve Wang, J. Z., (2005). Content-Based image retrieval approaches and trends of the new age, *in Proceedings of International Workshop on Multimedia Information Retrieval, in conjunction with ACM International Conference on Multimedia*, 253-262.
62. Shi, J. ve Malik, J. (2000). Normalized cuts and image segmentation. *IEEE Transactions on pattern analysis and machine intelligence*, 22(8), 888-905.
63. Huang, J., Kumar, S. R., Mitra, M., Zhu, W. J. ve Zabih, R. (1997, June). Image indexing using color correlograms. *In Computer Vision and Pattern Recognition, 1997. Proceedings, 1997 IEEE Computer Society Conference on*, 762-768.
64. Huang, J. ve Zabih, R. (1998). Combining color and spatial information for content-based image retrieval. *In Proceedings of ECDL*.
65. González, E., Bianconi, F. ve Fernández, A. (2010). A comparative review of colour features for content-based image retrieval. *Anales de Ingeniería Gráfica*, 21, 7-14.
66. Bianconi, F., Harvey, R., Southam, P. ve Fernández, A. (2011). Theoretical and experimental comparison of different approaches for color texture classification. *Journal of Electronic Imaging*, 20(4), 1-20.
67. Mathias, E. ve Conci, A. (1998). Comparing the influence of color spaces and metrics in content-based image retrieval. *In Computer Graphics, Image Processing, and Vision, 1998. Proceedings. SIBGRAP'98. International Symposium on*, 371-378.
68. Suhasini, P. S., Krishna, K. ve Krishna, I. M. (2009). CBIR using color histogram processing. *Journal of Theoretical & Applied Information Technology*, 6(1), 116-122.
69. Alajlan, N., Kamel, M. S. ve Freeman, G. H. (2008). Geometry-based image retrieval in binary image databases. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 30(6), 1003-1013.
70. Mäenpää, T. ve Pietikäinen, M. (2004). Classification with color and texture: jointly or separately. *Pattern recognition*, 37(8), 1629-1640.

71. Sharif, U., Mehmood, Z., Mahmood, T., Javid, M. A., Rehman, A., ve Saba, T. (2019). Scene analysis and search using local features and support vector machine for effective content-based image retrieval. *Artificial Intelligence Review*, 52(2), 901-925.
72. Gonzalez, R.C. ve Woods, R.E. (2002). *Digital Image Processing* (2nd Edition). New Jersey: Prentice Hall, 1-100.
73. Tanyeri, U. (2014). *Dalgacık Dönüşümüne Dayalı Yayınım Filtresi Tasarımı*, Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 79-91.
74. Jne, B. (1997). *Digital image processing: concepts, algorithms, and scientific applications*. Springer, 41-45.
75. Tyagi, V. (2017). Content-Based Image Retrieval: Ideas, Influences, and Current Trends. Springer, Singapore, 133-158.
76. Pérez-Delgado, M. L. (2019). The color quantization problem solved by swarm-based operations. *Applied Intelligence*, 49(7), 2482-2514..
77. Gervautz, M., ve Purgathofer, W. (1988). A simple method for color quantization: Octree quantization. *In New trends in computer graphics*. Springer, Berlin, Heidelberg, 219-231.
78. Kruger, A. (1994). Median-cut color quantization. *Dr Dobb's Journal-Software Tools for the Professional Programmer*, 19(10), 46-55.
79. Linde, Y., Buzo, A., ve Gray, R. (1980). An algorithm for vector quantizer design. *IEEE Transactions on communications*, 28(1), 84-95.
80. Sandor, J. (1985). Octree data structures and perspective imagery. *Computers and Graphics*, 9(4), 393-405.
81. Patané, G., ve Russo, M. (2001). The enhanced LBG algorithm. *Neural Networks*, 14(9), 1219-1237.
82. Wang, Z., Bovik, A. C., Sheikh, H. R., ve Simoncelli, E. P. (2004). Image quality assessment: from error visibility to structural similarity. *IEEE transactions on image processing*, 13(4), 600-612.
83. Vadivel, A., Majumdar, A. K., ve Sural, S. (2003). Performance comparison of distance metrics in content-based image retrieval applications. *In International Conference on Information Technology (CIT), Bhubaneswar, India*, 159-164.
84. Tuna, H. (2019). *Kabuk zincir koduyla şekil tanıma*. Doktora Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 57.
85. Ballabio, D., Grisoni, F., Todeschini, R. (2018). Multivariate comparison of classification performance measures. *Chemometrics and Intelligent Laboratory Systems*, 174, 33-44.

86. Sokolova, M. ve Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing and Management*, 45(4), 427-437.
87. Müller, H., Müller, W., Squire, D. M., Marchand-Maillet, S., ve Pun, T. (2001). Performance evaluation in content-based image retrieval: overview and proposals. *Pattern Recognition Letters*, 22(5), 593-601.
88. Manning, C. D., Raghavan, P., ve Schütze, H. (2009) *Introduction to Information Retrieval*. Cambridge University Press, 151-175.
89. Ioannakis, G., Koutsoudis, A., Pratikakis, I., ve Chamzas, C. (2017). Retrieval an Online Performance Evaluation Tool for Information Retrieval Methods. *IEEE Transactions on Multimedia*, 20(1), 119-127
90. Flickner, M., Sawhney, H., Niblack, W., Ashley, J., Huang, Q., Dom, B., ve Steele, D. (1995). Query by image and video content: The QBIC system. *Computer*, 28(9), 23-32.
91. Shapiro, L. G. (2020). Computer vision: the last 50 years. *International Journal of Parallel, Emergent and Distributed Systems*, 35(2), 112-117..
92. Cheng, H. D., Jiang, X. H., Sun, Y., ve Wang, J. (2001). Color image segmentation: advances and prospects. *Pattern recognition*, 34(12), 2259-2281.
93. Kapur, J. N., Sahoo, P. K., ve Wong, A. K. (1985). A new method for gray-level picture thresholding using the entropy of the histogram. *Computer vision, graphics, and image processing*, 29(3), 273-285.
94. Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1), 62-66.
95. Demirci, R. (2010). Fuzzy adaptive anisotropic filter for medical images, *Expert Systems*, 27(3), 219–229.
96. Rahkar Farshi, T., Demirci, R., ve Feizi-Derakhshi, M. R. (2018). Image clustering with optimization algorithms and color space. *Entropy*, 20(4), 296.
97. Demirci, R., Güvenç, U., ve Kahraman, H. T. (2014). Görüntülerin Renk Uzayı Yardımıyla Ayırıştırılması. *İleri Teknoloji Bilimleri Dergisi*, 3(1), 1-8.
98. Kılıçaslan, M., Tanyeri, U., ve Demirci, R. (2018). Renkli Görüntüler İçin Tek Boyutlu Histogram. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 6(4), 1094-1107.
99. Kılıçaslan, M., Tanyeri, U., ve Demirci, R. (2020). Image Retrieval using One-Dimensional Color Histogram Created with Entropy. *Advances in Electrical and Computer Engineering*, 20(2), 79-88

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : KILIÇASLAN, Mahmut
 Uyruğu : T.C.
 Doğum tarihi ve yeri : 18.08.1986, Kayseri
 Medeni hali : Evli

Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Doktora	Gazi Üniversitesi / Bilgisayar Mühendisliği	Devam ediyor
Yüksek lisans	SDÜ / Elektronik Bilgisayar Eğitimi	2013
Lisans	SDÜ / Elektronik Bilgisayar Eğitimi	2009
Lise	Aydınlıkevler Anadolu Lisesi	2004

İş Deneyimi

Yıl	Yer	Görev
2011-Halen	Ankara Üniversitesi	Öğretim Görevlisi

Yabancı Dil

İngilizce

Yayımlar

- Uluslararası hakemli dergilerde yayımlanan makaleler

1. Kılıçaslan, M., Tanyeri, U., ve Demirci, R. (2020). Image Retrieval using One-Dimensional Color Histogram Created with Entropy. *Advances in Electrical and Computer Engineering*, 20(2), 79-88
2. Kılıçaslan, M., Tanyeri, U., ve Demirci, R. (2020) Tekrarlı Ortalama Yardımıyla Renk İndirgeme ve Görüntü Erişimi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 8(1), 1042-1057.
3. Kılıçaslan, M., Tanyeri, U., ve Demirci, R. (2018). Renkli Görüntüler İçin Tek Boyutlu Histogram. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 6(4), 1094-1107.

4. Kılıçaslan Mahmut, Tanyeri Ufuk, İncetaş Mürsel Ozan, Yakışır Girgin Burcu, Demirci Recep, Atakan Cemal (2017). Farklı Boyutlarda Görüntülerde Uyarlamalı Yerel Pencere İle Benzerlik Ölçümü. *Mühendislik Bilimleri ve Tasarım Dergisi*, 5(3), 609-614., doi:10.21923/jesd.328160 (Yayın No: 3770692)

- **Uluslararası bilimsel toplantılarda sunulan ve bildiri kitaplarında (proceedings) basılan bildiriler**

1. Tanyeri, U., İncetaş, M. O., Kılıçaslan, M., and Atakan, C. (2019) *Quantification of the Effects of Noise and Noise Filters on Edge Detection Algorithms in Images with F Score Technique*, Presented at the 4th International Symposium on Innovative Approaches in Engineering and Natural Sciences, Samsun, 2019.
2. Tanyeri, U., Kılıçaslan, M., and Demirci, R. (2019, October). *Canny Edge Detector with Half Entropy*. In 2019 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT) (pp. 1-4). IEEE.
3. Kılıçaslan Mahmut, Tanyeri Ufuk, İncetaş Mürsel Ozan, Yakışır Girgin Burcu, Demirci Recep (2017). *Eşikleme Tekniklerinin Renk Uzayı Tabanlı Kümeleme Yönteminin Başarısına Etkisi*. Uluslararası Multidisipliner Çalışmalar ve Yenilikçi Teknolojiler Sempozyumu ISMSIT 2017, 107- 110.
4. İncetaş Mürsel Ozan, Tanyeri Ufuk, Kılıçaslan Mahmut, Yakışır Girgin Burcu, Demirci Recep (2017). *Eşik Seçiminin Benzerliğe Dayalı Kenar Belirlemeye Etkisi*. Uluslararası Multidisipliner Çalışmalar ve Yenilikçi Teknolojiler Sempozyumu Ismsit 2017, 102-106. (tam metin bildiri/sözlü sunum)(yayın no:3610479)
5. İncetaş Mürsel Ozan, Kılıçaslan Mahmut, Tanyeri Ufuk, Yakışır Girgin Burcu, Aydemir Zübeyr (2017). *Gürültünün Tohumlu Alan Genişletme Tabanlı Bölütleme Sonucuna Etkisinin Nicemsel Olarak Belirlenmesi*. Uluslararası Multidisipliner Çalışmalar ve Yenilikçi Teknolojiler Sempozyumu ISMSIT 2017, 98-101
6. Yakışır Girgin Burcu, Kılıçaslan Mahmut, Tanyeri Ufuk, İncetaş Mürsel Ozan (2017). *Yönlendirilmiş Hoparlör Tasarımı*. Uluslararası Multidisipliner Çalışmalar ve Yenilikçi Teknolojiler Sempozyumu ISMSIT 2017, 80-80.
7. Yakışır Girgin, B., Kılıçaslan, M., Tanyeri, U. ve İncetaş, M.O., (2017), *Meslek Yüksekokulu Öğrencilerinin Yerleştirilme Türlerinin Ders Geçme Başarısına Etkisi: Nallıhan Meslek Yüksekokulu Örneği*, 2. Uluslararası Yükseköğretimde Mesleki Eğitim ve Öğretim Sempozyumu (ISVET2017),10-10.

Hobiler

Yüzme, Voleybol



GAZİ GELECEKTİR..