



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



**RENKLİ GÖRÜNTÜLERİN UZAMSAL
ALANDA ZENGİNLEŞTİRİLMESİ**

Aybüke BABADAĞ

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalını

Mayıs-2019
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

AYBÜKE BABADAĞ tarafından hazırlanan “RENKLİ GÖRÜNTÜLERİN UZAMSAL ALANDA ZENGİNLEŞTİRİLMESİ” adlı tez çalışması 28/05/2019 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü BİLGİSAYAR MÜHENDİSLİĞİ Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Doç. Dr. Mesut GÜNDÜZ

Danışman

Dr. Öğr. Üyesi Ömer Kaan BAYKAN

Üye

Dr. Öğr. Üyesi Ahmet ÖZKIŞ

İmza







Yukarıdaki sonucu onaylarım.

Prof. Dr. Yakup KARA
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.



Aybüke BABADAĞ

Tarih: 28/05/2019

ÖZET

YÜKSEK LİSANS TEZİ

RENKLİ GÖRÜNTÜLERİN UZAMSAL ALANDA ZENGİNLEŞTİRİLMESİ

Aybüke BABADAĞ

Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Ömer Kaan BAYKAN

2019, 90 Sayfa

Jüri

Dr. Öğr. Üyesi Ömer Kaan BAYKAN
Doç. Dr. Mesut GÜNDÜZ
Dr. Öğr. Üyesi Ahmet ÖZKİŞ

Sayısal görüntü işleme uygulamalarında, görüntülerdeki belirsiz detayların daha açık hale getirilmesi ve istenilen özelliklerin vurgulanması amacıyla görüntü zenginleştirme algoritmaları sıklıkla kullanılmaktadır. Bu tez çalışmasında düşük kontrasta sahip renkli görüntülerin kontrastlarının, görüntüde herhangi bir yapay görünüme sebep olmadan zenginleştirilmesi hedeflenmiştir.

Çalışmada görüntü zenginleştirme, bir optimizasyon problemi olarak ele alınmıştır. Günlük hayatta karşılaşılan optimizasyon problemlerinin çözümünde başarılı sonuçlar vermesi sebebiyle, metasezgisel algoritmalar tercih edilmiştir. Ayrıca, gerçek hayat problemlerinde genellikle birden fazla amacın olması sebebiyle, çok amaçlı optimizasyon algoritmalarından da faydalanılmıştır.

Bu çalışmada düşük kontrastlı renkli görüntülerin kontrastları, tek ve çok amaçlı yapay arı kolonisi algoritması, parçacık sürü optimizasyonu algoritması ve genetik algorithmadan faydalanılarak zenginleştirilmiştir. Çalışmada sekiz adet renkli standart test görüntüsü kullanılmıştır. Çalışmada kullanılan algoritmalar test görüntülerine uygulandıktan sonra elde edilen sonuçlar; pik sinyal gürültü oranı, yapısal benzerlik indeksi, kontrast geliştirme indeksi ve renk zenginleştirme faktörü kalite metrikleriyle değerlendirilmiştir. Böylece görüntü zenginleştirme işleminde tek ve çok amaçlı optimizasyon uygulamalarının etkisi gözlemlenmiştir. Elde edilen sonuçların sayısal ve görsel değerlendirilmeleri neticesinde, çalışmada kullanılan tek ve çok amaçlı algoritmalarla, görüntülerde yapay görünüme sebebiyet vermeden kontrastlarının zenginleştirildiği gözlemlenmiştir.

Anahtar Kelimeler: Görüntü Zenginleştirme, Metasezgisel Algoritmalar, Çok Amaçlı Optimizasyon

ABSTRACT

MS THESIS

COLOR IMAGES ENHANCEMENT IN SPATIAL DOMAIN

Aybüke BABADAĞ

**Konya Technical University
Institute of Graduate Studies
Department of Computer Engineering**

Advisor: Asst. Prof. Dr. Ömer Kaan BAYKAN

2019, 90 Pages

Jury

**Asst. Prof. Dr. Ömer Kaan BAYKAN
Assoc. Prof. Dr. Mesut GÜNDÜZ
Asst. Prof. Dr. Ahmet ÖZKIŞ**

In digital image processing applications, image enhancement algorithms are often used to bring out details that is vague and emphasize certain features in an image. The aim of this thesis is to enhance the contrast of low contrast color images without causing any artificial effect on images.

In this study, image enhancement is considered as an optimization problem. Due to the effective performance in reel world optimization problems metaheuristic algorithms are preferred in this study. Also because the reel world problems generally have multiple objectives multi objective optimization algorithms are utilized.

In this study, contrasts of low contrast color images are enhanced by utilizing single and multi objective genetic algorithm, particle swarm optimization algorithm and artificial bee colony algorithm. In this study, eight standard color test images are used. After the algorithms used in this study are applied to the test images the obtained results are evaluated based on the quality metrics; peak signal to noise ratio, structural similarity index metric, contrast improvement index and color enhancement factor. Thus the effect of both single and multi objective optimization techniques on image enhancement is observed. As a result of both visual and objective evaluations of obtained results, it is observed that contrasts of images have improved by applying single and multi objective image enhancement algorithms that used in this study without causing any artificial appearance.

Keywords: Image Enhancement, Metaheuristic Algorithms, Multi Objective Optimization

ÖNSÖZ

Her Őeyden önce, beni her zaman maddi ve manevi açıdan destekleyen sevgilerinde hep moral ve güç bulduğum aileme sonsuz teşekkür ediyorum. Bu tez çalışmasında değerli bilgileriyle bana yol gösteren danışman hocam Dr. Öğr. Üyesi Ömer Kaan BAYKAN'a teşekkür ediyorum.

Aybüke BABADAĞ
KONYA-2019



İÇİNDEKİLER

ÖZET	iv
ABSTRACT	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	ix
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	5
2.1. Evrimsel Algoritma Tabanlı Optimizasyon Teknikleri	6
2.1.1. Genetik algoritma ile ilgili kaynak araştırması.....	6
2.2. Sürü Zekâsı Tabanlı Optimizasyon Teknikleri	10
2.2.1. Parçacık sürü optimizasyonu ile ilgili kaynak araştırması.....	10
2.2.2. Yapay arı kolonisi algoritması ile ilgili kaynak araştırması	12
2.2.3. Melez yaklaşımlar ile ilgili kaynak araştırması	14
3. MATERYAL VE YÖNTEM	15
3.1. Optimizasyon	15
3.2. Genetik Algoritma	16
3.3. Parçacık Sürü Optimizasyonu.....	18
3.4. Yapay Arı Kolonisi	20
3.5. Çok Amaçlı Optimizasyon.....	22
3.5.1. Bastırılmamış Sınıflandırılmalı Genetik Algoritma II	22
3.5.2. Çok amaçlı parçacık sürü optimizasyonu	25
3.5.3. Çok amaçlı yapay arı kolonisi	26
3.6. Çalışmada Gerçekleştirilen Görüntü Zenginleştirme Yöntemleri	27
3.6.1. Genetik algoritma tabanlı tek amaçlı yöntem ile görüntü zenginleştirme ...	29
3.6.2. Genetik algoritma tabanlı çok amaçlı yöntem ile görüntü zenginleştirme ...	30
3.6.3. Parçacık sürü optimizasyonu tabanlı tek amaçlı yöntem ile görüntü zenginleştirme	31
3.6.4. Parçacık sürü optimizasyonu tabanlı çok amaçlı yöntem ile görüntü zenginleştirme	32
3.6.5. Yapay arı kolonisi tabanlı tek amaçlı yöntem ile görüntü zenginleştirme ...	33
3.6.6. Yapay arı kolonisi tabanlı çok amaçlı yöntem ile görüntü zenginleştirme...	34
3.7. Çalışmada Kullanılan Kalite Metrikleri.....	35
3.7.1. Pik sinyal gürültü oranı.....	35
3.7.2. Yapısal benzerlik indeksi.....	35
3.7.3. Kontrast geliştirme indeksi	36
3.7.4. Renk zenginleştirme faktörü	36
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA	38

5. SONUÇLAR VE ÖNERİLER.....	83
5.1 Sonuçlar	83
5.2 Öneriler	84
KAYNAKLAR	85
ÖZGEÇMİŞ	90



SİMGELER VE KISALTMALAR

Simgeler

a	:	Orijinal görüntü
a_x	:	a görüntüsündeki piksel değeri
b	:	Zenginleştirilmiş görüntü
b_x	:	b görüntüsündeki piksel değeri
B	:	Mavi renk kanalı
Baskınlık	:	i . yiyecek kaynağının bastırıldığı yiyecek kaynaklarının sayısı
C	:	İçerikten bağımsız kontrast
C_m	:	Ortalama kontrast
c_1	:	Yerel öğrenme katsayısı
C_1	:	Sabit değer
c_2	:	Global öğrenme katsayısı
C_2	:	Sabit değer
C_0	:	Orijinal görüntünün ortalama kontrastı
C_Z	:	Zenginleştirilmiş görüntünün ortalama kontrastı
$D(s)$:	Ton bozulması
fit_i	:	i . çözümün uygunluk değeri
G	:	Yeşil renk kanalı
$G(s)$:	Kontrast kazancı
K	:	Görüntüde bulunan gri seviye sayısı
\bar{L}	:	Dönüştürülmüş histogramdaki gri seviye değerlerinin sayısı
L_i	:	Alt sınır
N	:	Görüntü boyutu
P	:	Görüntüde bulunan piksellerin alabileceği en büyük değer
p_k	:	k . gri seviye değerinin görüntüde bulunma olasılığı
R	:	Kırmızı renk kanalı
r_1	:	(0,1) aralığında rastsal değerli parametre
r_2	:	(0,1) aralığında rastsal değerli parametre
s_j	:	j piksel değerinin içerikten bağımsız kontrast değeri
SN	:	Yiyecek kaynaklarının sayısı
t	:	Mevcut iterasyon
T	:	Dönüşüm fonksiyonu
t_{max}	:	Maksimum iterasyon sayısı
U_i	:	Üst sınır
$v_{i,j}$:	i . aday yiyecek kaynağının j . bileşeni
$v_{i,j}^k$:	k . iterasyonda i . parçacığın hızının j bileşeni
V_{max}	:	Maksimum hız parametresi
w	:	Eylemsizlik ağırlığı
w_{max}	:	Maksimum eylemsizlik değeri
w_{min}	:	Minimum eylemsizlik değeri
X	:	Girdi görüntüsü
x_{besti}	:	i . parçacığın o ana kadar eriştiği en iyi konum
x_{gbest}	:	Tüm popülasyonun o ana kadar eriştiği en iyi konum
$x_{i,j}$:	i . yiyecek kaynağının j . bileşeni
$x_{i,j}^k$:	k . iterasyonda i . parçacığın konumunun j bileşeni
X_{max}	:	Penceredeki en büyük piksel değeri
X_{min}	:	Penceredeki en küçük piksel değeri

Y	:	Çıktı görüntüsü
λ	:	Amaçlar arasındaki önem dengesini belirleyen çarpan
μ	:	Popülasyonda bulunan birey sayısı
μ_a	:	a görüntüsünün ortalaması
μ_b	:	b görüntüsünün ortalaması
σ_a	:	a görüntüsündeki standart sapma
σ_{ab}	:	a ve b görüntülerinin kovaryansı
σ_b	:	b görüntüsündeki standart sapma
Φ_{ij}	:	i. konumun j. bileşeni için [-1,1] aralığında rastgele değer

Kısaltmalar

ABC	:	Yapay Arı Kolonisi
AMBE	:	Mutlak Ortalama Parlaklık Hatası
BBHE	:	Parlaklık Muhafazalı Bi-Histogram Eşitleme
BV	:	Arkaplan Varyansı
CEF	:	Renk Zenginleştirme Faktörü
CHE	:	Klasik Histogram Eşitleme
CIE	:	Uluslararası Aydınlatma Komisyonu
CII	:	Kontrast Geliştirme İndeksi
CLAHE	:	Kontrast Sınırlı Adaptif Histogram Eşitleme
CM	:	Renklilik Metriği
CS	:	Kontrast Germe
DV	:	Detay Varyansı
DSIHE	:	İkili Alt Görüntü Histogram Eşitleme
FSIM	:	Özellik Benzerlik İndeksi Metriği
GA	:	Genetik Algoritma
GACIE	:	Genetik Algoritma ile Renkli Görüntü Zenginleştirme
HE	:	Histogram Eşitleme
HPCIE	:	Renk özü Muhafazalı Renkli Görüntü Zenginleştirme
HSI	:	Renk özü Doymunluk Gri seviye
HSV	:	Renk özü Doymunluk Değer
IFC	:	Bilgi Uygunluk Kriteri
LHS	:	Parlaklık Renk özü Doymunluk
LUT	:	Başvuru Çizelgesi - Look Up Table
MSE	:	Ortalama Karesel Hata
MOABC	:	Çok Amaçlı Yapay Arı Kolonisi
MOPSO	:	Çok Amaçlı Parçacık Sürü Optimizasyonu
NSGA-II	:	Bastırılmamış Sınıflandırılmalı Genetik Algoritma
PCA	:	Temel Bileşenler Analizi
POF	:	Pareto Optimal Cephe
PSNR	:	Pik Sinyal Gürültü Oranı
PSO	:	Parçacık Sürü Optimizasyonu
RGB	:	Kırmızı Yeşil Mavi
SIFT	:	Ölçekten Bağımsız Özellik Dönüşümü
SSIM	:	Yapısal Benzerlik İndeksi Metriği
VIF	:	Görsel Bilgi Uygunluğu
VSNR	:	Görsel Sinyal Gürültü Oranı

1. GİRİŞ

Görüntü, $f(x,y)$ şeklinde iki boyutlu bir fonksiyon olarak düşünülebilir. (x,y) görüntü düzlemindeki koordinatlar, fonksiyonun çıktısı ise bu koordinatlarda bulunan elemanların değerleridir. Eğer f , x ve y değerleri ayrık ve sonlu ise bu görüntülere *sayısal görüntü* denir. Sayısal görüntüler sonlu sayıda eleman içerirler ve her bir eleman belli bir konum ve değere sahiptir. Bu elemanlar *piksel* yani görüntü elemanı olarak adlandırılırlar (Gonzalez ve Woods, 2006).

Sayısal görüntülerin bilgisayar ortamında işlendiği alan *sayısal görüntü işleme* alanıdır. Sayısal görüntü işleme; görüntü zenginleştirme, görüntü restorasyonu, görüntü sıkıştırma, morfolojik görüntü işleme ve görüntü segmentasyonu gibi alt alanlara ayrılabilir (Gonzalez ve Woods, 2006).

Geniş uygulama alanına sahip görüntü zenginleştirme, görüntü üzerinde bir takım değişikliklerin yapılmasıyla görüntünün belli bir amaç için daha uygun hale getirilmesi işlemidir. Belli bir amaca yönelik modifikasyonların yapılması sebebiyle zenginleştirme yöntemleri, probleme göre farklılık göstermektedir. Örneğin, X-ray görüntüsünü zenginleştirirken kullanılan yöntem uydu görüntüsü için uygun olmayabilir (Gonzalez ve Woods, 2006).

Uzamsal alan ve frekans alanı olmak üzere iki ana başlık altında görüntü zenginleştirme yöntemleri incelenebilir. Frekans alanı yöntemlerinde görüntü, uzamsal alandan frekans alanına dönüştürülür ve bu alanda işlemler uygulanır. Uzamsal alanda ise işlemler doğrudan görüntüdeki pikseller üzerinde gerçekleştirilir (Gonzalez ve Woods, 2006).

Ayrıca görüntü zenginleştirme işlemleri, uygulandığı görüntü tipine göre de farklılık gösterebilir. Temel olarak dört tip sayısal görüntü vardır: İkili (binary) görüntü, her bir pikselin 1 bit ile ifade edildiği ve yalnızca siyah veya beyaz değer alabildiği görüntü tipidir. Gri seviye görüntü, her bir pikselin 8 bitle ifade edildiği ve 256 farklı değer alabildiği görüntü tipidir. Gerçek renk veya RGB (Red, Green, Blue - Kırmızı, Yeşil, Mavi) görüntü, üç renk kanalından oluşur: kırmızı, yeşil ve mavi. Renkli görüntülerde, her bir piksele üç farklı kanalın değeri karşılık gelir. İndeksli görüntü, renkli görüntülerde bulunan tüm renklerin listelendiği renk haritalarının kullanıldığı görüntü tipidir. Her bir pikselin, renk haritasında bir indeks değeri vardır (McAndrew, 2004).

İnsan görme sistemi, gri seviye resimlerdeki küçük parlaklık değişimlerini, renk tonlarında olduğu gibi kolaylıkla fark edemez. İnsanlar için renk, çevrenin algılanması açısından oldukça önemli bilgiler sağlar. İnsanlar renkleri, temel renkler olarak adlandırılan mavi, kırmızı ve yeşil'in çeşitli miktarda bileşimleriyle algırlar. Temel renklerin dalga boyu değerleri, 1931 yılında CIE (Commision Internationale d'Eclairage) organizasyonu tarafından tanımlanmıştır (McAndrew, 2004). Renk, insanların çevrelerindeki nesnelere arasındaki farklılıkları ayırt etmelerinde, bu nesnelere tanımlarında önemli bir etkidir. Bu sebeple insan algısı açısından renkli görüntülerin yorumlanabilirliğinin artırılması önemlidir.

Renk, nesne tespiti ve nesnenin sahnedan çıkarılması işlemlerini kolaylaştırması açısından önemli bir tanımlayıcıdır (Gonzalez ve Woods, 2006). Bu özelliğiyle de renk, makine algısına yönelik; segmentasyon, nesne tespiti ve sınıflandırma gibi pek çok uygulamada kullanılır. Dolayısıyla, renkli görüntülerin belli uygulamalar için daha uygun hale getirilmesi önemlidir.

Renk modelleri, her bir rengin koordinat düzleminde bir nokta ile gösterildiği sistemlerdir. Belli bir standardın getirilmesiyle, renklerin tanımının kolaylaştırılması ve evrensel bir gösterim amaçlanmıştır. Sayısal görüntü işlemede yaygın olarak kullanılan RGB renk modeli, kırmızı, yeşil ve mavi renk bileşeninden oluşur. Her bir renk bileşenini oluşturan görüntülerde, 8 bitle ifade edilen pikseller bulunur. Dolayısıyla, bir RGB görüntüyü oluşturan pikseller 24 bitle ifade edilir (Gonzalez ve Woods, 2006). RGB renk uzayıyla kıyaslandığında HSV (Hue, Saturation, Value - Renk özü, Doygunluk, Değer) renk uzayı, insan renk algısına daha yakındır (Gonzalez ve ark., 2009). HSV renk uzayında; hue (renk özü) gerçek rengi, saturation (doygunluk) rengin içerdiği beyaz ışık miktarını, value (değer) ise parlaklık derecesini ifade etmektedir (McAndrew, 2004). HSI (Hue, Saturation, Intensity – Renk özü, Doygunluk, Gri seviye) renk modeli, renk bilgisi içeren renk özü ve doygunluk ve gri seviye bileşenlerinden oluşur. HSI renk modeli, kromatik bilginin akromatik bilgiden ayrılması sebebiyle, insan renk algısına yönelik görüntü işleme uygulamaları için elverişli bir modeldir (Gonzalez ve Woods, 2006). İnsanlar, belli bir rengi elde etmek için hangi oranlarda kırmızı, yeşil ve mavi kullanacaklarını kestiremeyebilirler. Bunu kolaylaştırmak için parlaklık, renk özü ve doygunluğun kullanıldığı LHS (Luminance, Hue, Saturation – Parlaklık, Renk Özü, Doygunluk) renk modeli geliştirilmiştir (Levkowitz, 1988).

Renkli görüntü işleme temelde iki alternatif yöntem içerir: Her bir R, G ve B bileşenin ayrı ayrı işlenmesi veya gri seviye değerinin renk bilgisinden ayrıldığı bir başka renk modeline dönüştürülerek işlemlerin gri seviye bileşeni üzerinde gerçekleştirilmesi (McAndrew, 2004).

Görüntü zenginleştirme, görüntü işlemenin oldukça subjektif bir alanıdır. Görsel yorumlanabilirliğin artırılması amacıyla gerçekleştirilen zenginleştirme işlemi sonucunda elde edilen sonuç görüntülerinin kalitelerinin değerlendirilmesi öznedir. Buna karşın makine algısına yönelik zenginleştirme işlemleri neticesinde elde edilen sonuç görüntülerinin kaliteleri objektif metotlarla değerlendirilir ve bu işlem nispeten daha kolaydır (Gonzalez ve Woods, 2002).

Optimizasyon, bir probleme ait fonksiyonun değişkenleri için, o probleme uygun değer kümesinden fonksiyonu minimize veya maksimize edecek en uygun değerlerin seçilmesidir. Geniş uygulama alanına sahip optimizasyonda, sınırlı kaynakların varsa belli kısıtlamalar altında etkin kullanımı amaçlanır (Kaveh, 2014). Optimizasyon problemlerini temsil eden fonksiyonlar, genellikle amaç fonksiyonu olarak adlandırılır. Tek amaçlı optimizasyonda optimize edilecek bir tek amaç fonksiyonu olurken çok amaçlı optimizasyonda eşzamanlı olarak birden fazla amaç fonksiyonunun optimizasyonu hedeflenmektedir. Birden fazla amacın optimal çözümlerine Pareto optimal çözümler denir (Arora, 2015). Gerçek hayat problemleri genellikle birbiriyle çelişen birden fazla amaç barındırırlar. Bu tip problemlerin çözümünde bir tek çözüm olmadığı için çok amaçlı optimizasyondan faydalanılır. Çok amaçlı optimizasyonda, birbiriyle çelişen amaç fonksiyonları arasında dengenin sağlandığı optimal çözüm kümesi oluşturulur (Deb, 2014).

Bu tez çalışmasında görüntü zenginleştirme işlemleri, uzamsal alanda gerçekleştirilmiştir. Düşük kontrasta sahip renkli görüntüler, tek ve çok amaçlı optimizasyon yöntemlerinden faydalanılarak zenginleştirilmiştir. Çalışmada kullanılan tek amaçlı yöntemler; genetik algoritma (GA) (Holland, 1992), parçacık sürü optimizasyonu (PSO) (Kennedy ve Eberhart, 1995) ve yapay arı kolonisi (ABC) (Karaboga, 2005) yöntemleridir. Çok amaçlı yöntemler ise bastırılmamış sınıflandırılmalı genetik algoritma (NSGA-II) (Deb ve ark., 2002), çok amaçlı parçacık sürü optimizasyonu (MOPSO) (Bejinariu ve ark., 2017) ve çok amaçlı yapay arı kolonisi (MOABC) (Akbari ve ark., 2012) yöntemleridir. Hem tek amaçlı hem de çok amaçlı optimizasyon yöntemleri kullanılarak, görüntü zenginleştirmede tek ve çok amaçlı yöntemlerin etkisi görülmüştür.

RGB renk modelindeki girdi görüntüleri, insan renk algısına daha yakın olması sebebiyle HSV renk modeline dönüştürülmüştür. Dönüşüm işleminin ardından V bileşeni ayrılarak işlemler V bileşenine uygulanmıştır. Problem çözümünün tanımı, [0,1] aralığında sıralı gri seviye değerleri kullanılarak yapılmıştır. Problem boyutu, girdi görüntüsünde bulunan gri seviye değeri sayısı kadardır. Girdi görüntüsünün V bileşenine, çalışmada gerçekleştirilen tek ve çok amaçlı yöntemler uygulandıktan sonra elde edilen zenginleştirilmiş V bileşeni, girdi görüntüsünün H ve S bileşenleriyle birleştirilerek zenginleştirilmiş HSV görüntüsü oluşturulmuştur. Ardından elde edilen HSV görüntüsü tekrar RGB modeline dönüştürülerek zenginleştirilmiş sonuç görüntüsü elde edilmiştir.

Tüm yöntemlerden elde edilen sonuçlar için hem subjektif hem de objektif değerlendirme yapılmıştır. Objektif değerlendirme; pik sinyal gürültü oranı (PSNR), yapısal benzerlik indeksi (SSIM), kontrast geliştirme indeksi (CII) ve renk zenginleştirme faktörü (CEF) kalite metrikleri kullanılarak gerçekleştirilmiştir. Gerçekleştirilen tek ve çok amaçlı görüntü zenginleştirme yöntemleri, histogram eşitleme (HE), kontrast sınırlı adaptif histogram eşitleme (CLAHE) ve kontrast germe (CS) klasik görüntü zenginleştirme yöntemlerinin yanı sıra literatürde önerilen çok amaçlı parçacık sürü optimizasyonu tabanlı görüntü zenginleştirme (Bejinariu ve ark., 2017) yöntemiyle de karşılaştırılmıştır.

Tez metninin devamı şu şekilde düzenlenmiştir; 2. Bölümde konuyla ilgili literatürde yapılmış çalışmalara değinilmiştir. 3. Bölümde çalışmada gerçekleştirilen tek ve çok amaçlı yöntemler detaylı olarak aktarılmıştır. 4. Bölümde, elde edilen sonuçlar paylaşılmıştır. Son olarak 5. Bölümde sonuçların değerlendirilmesi yapılmıştır.

2. KAYNAK ARAŞTIRMASI

Görüntü zenginleştirme işlemlerinde; makine algısı açısından, görüntünün belli bir uygulamada kullanılmak üzere daha uygun bir hale getirilmesi ve insan algısı açısından ise görsel yorumlanabilirliğinin artırılması hedeflenmektedir. Bu amaçlar doğrultusunda gerçekleştirilen görüntü zenginleştirme işleminin temelinde, görüntülerdeki belirsiz detayların daha açık hale getirilmesi ve kontrast, renk veya kenar bilgisi gibi istenilen belli bazı özelliklerin vurgulanması vardır (Gonzalez ve Woods, 2002). Görüntü zenginleştirme, özellikle ileri seviye görüntü işleme uygulamalarından önce bir ön işlem olarak uygulandığında daha iyi nihai sonuçlar elde edildiği için görüntü işleminin önemli bir alanıdır.

Görüntü zenginleştirmeye dair literatürde çok çeşitli yöntemler mevcuttur. Bunlar arasında, görüntü zenginleştirmenin bir optimizasyon problemi olarak görüldüğü çalışmalar da bulunmaktadır.

Son yıllarda optimizasyon problemlerinin çözümünde metasezgisel yöntemler sıklıkla kullanılmaktadır.

Metasezgisel yöntemler, problemler için en iyi çözümleri bulmayı hedefler ve bunu yaparken de probleme ait tüm kısıtlamalara uymalıdır. Tüm problemler için optimal çözümler hızla bulunamayabilir ancak, hayli geniş uygulama alanına sahip olması ve gerçek hayat problemlerinin çoğunda optimale yakın çözümlerin bulunabilir olması açısından oldukça önemlidir. Metasezgisel yöntemlerin temelinde keşif ve sömürü prensibi vardır. Keşif ile arama uzayı global ölçekte aranır. Sömürü ile ise mevcut bölgede bulunan en iyi çözümden elde edilen bilgi kullanılarak yerel arama gerçekleştirilir. Böylece, tüm arama uzayı kapsamında optimal çözümün bulunabilmesi sağlanır (Gonzalez, 2007; Yang, 2010).

Kaynak araştırması bölümünün devamı şu şekilde organize edilmiştir; Bölüm 2.1’de evrimsel algoritma tabanlı optimizasyon teknikleri kullanılarak gerçekleştirilmiş görüntü zenginleştirme çalışmaları kısaca anlatılmıştır. Bu bölümde, genetik algoritma tabanlı tek ve çok amaçlı optimizasyon yöntemlerinin kullanıldığı farklı görüntü zenginleştirme yaklaşımları ana hatlarıyla verilmiştir. Bölüm 2.2’de sürü zekası tabanlı optimizasyon teknikleri kullanılarak gerçekleştirilen görüntü zenginleştirme çalışmaları kısaca anlatılmıştır. Bu bölümde ise tek ve çok amaçlı parçacık sürü optimizasyonu, yapay arı kolonisi ve bu iki algoritmanın ortak kullanıldığı bir melez yaklaşımla gerçekleştirilen görüntü zenginleştirme yöntemleri ana hatlarıyla verilmiştir.

Bu tez çalışmasında gerçekleştirilen görüntü zenginleştirme işleminde, genetik algoritma, parçacık sürü optimizasyonu ve yapay arı kolonisi algoritmalarının kullanılması sebebiyle literatürde yalnızca bu yöntemlerin kullanıldığı görüntü zenginleştirme çalışmaları incelenmiştir.

2.1. Evrimsel Algoritma Tabanlı Optimizasyon Teknikleri

2.1.1. Genetik algoritma ile ilgili kaynak araştırması

Hashemi ve ark. (2010) kontrast zenginleştirme için GA tabanlı bir yaklaşım önermişlerdir. Önerdikleri yöntemde kullandıkları kromozom yapısı, girdi görüntüsündeki gri seviye sayısı kadar sıralı genden oluşmaktadır. Çalışmalarında, kenar piksellerini temel alan bir uygunluk fonksiyonu kullanmışlardır. Çaprazlama yöntemi olarak iki noktalı çaprazlama yöntemini seçmişlerdir. Mutasyon işleminde ise; kromozomda bulunan genlerin %5'i rastgele seçilmiş ve her bir seçilen gen için bir önceki genden küçük ve bir sonraki genden büyük olmamak kaydıyla rastgele bir gen değeri belirlenip mevcut değerle değiştirilmiştir. Çalışmalarında gri seviye görüntüler kullanmışlar ancak sonuçlarını gözlemlemek için 3 adet renkli standart test görüntüsüne de önerdikleri yöntemi uygulayıp iyi sonuçlar elde ettiklerinden bahsetmişlerdir. Önerdikleri yöntemi; HE, Gri Seviye Gruplama, Adaptif Gri Seviye Gruplama ve Saitoh'un (1999) önerdiği GA tabanlı yöntemle karşılaştırmışlardır. Sayısal değerlendirme için sonuç görüntüsünde bulunan kenar sayısını ve PSNR kalite metriğini kullanmışlardır. Sayısal değerlendirmeler sonucunda, 5 test görüntüsünden 4'ünde en yüksek PSNR değerini önerdikleri yöntemle, kenar sayısında ise tüm test görüntülerinde en yüksek değeri elde etmişlerdir. Yaptıkları görsel değerlendirme neticesinde diğer yöntemlere kıyasla önerdikleri yöntemle doğal görünümlü sonuçlar elde ettiklerini ve ayrıca diğer yöntemlerin gürültüyü arttırdığını fakat önerdikleri yöntemde böyle bir problemin olmadığını da belirtmişlerdir.

Munteanu ve Rosa (2004) gri seviye görüntülerin zenginleştirilmesi için Gerçek Kodlu GA'dan faydalanmışlardır. Kullandıkları dönüşüm fonksiyonunu, $n \times n$ boyutlu pencerede, yerel olarak uygulamışlardır. Çalışmalarında, 4 parametresini optimize etmeyi hedefledikleri bir dönüşüm fonksiyonu ve bu dönüşüm fonksiyonundan elde edilen sonucu; kenar piksellerinin sayısı, kenar piksellerinin keskinliği ve histogram değerine göre ölçen bir değerlendirme fonksiyonu kullanmışlardır. Optimize edilecek

parametrelerin reel değerli oluşu sebebiyle gerçek kodlu GA tercih etmişlerdir. Çalışmalarında, her biri dönüşüm fonksiyonunun bir parametresini ifade eden 4 genden oluşan bir kromozom yapısı kullanmışlardır. Seçim işlemi ikili (binary) turnuva ile K-elitist şemayı (Bäck ve Hoffmeister, 1991) birleştiren bir yaklaşımı benimsemişlerdir. Çaprazlama yöntemi olarak aritmetik çaprazlamayı, mutasyon için ise Temel Bileşenler Analizi (PCA) mutasyonu (Munteanu ve Lazarescu, 1999) seçmişlerdir. Önerdikleri yöntemi, 12 görüntü üzerinde Doğrusal Kontrast Germe ve Histogram Eşitleme yöntemleriyle karşılaştırmışlardır. Önerdikleri yöntemi, hem objektif hem de subjektif açıdan değerlendirmişlerdir. Subjektif değerlendirme için ikisi görüntü işleme alanında uzman 6 kişinin yorumunu almışlardır. Tüm görüntülere verilen puanların, ortalamalarının toplamına bakıldığında önerdikleri yöntemin en iyi sonucu verdiği görülmektedir. Objektif değerlendirme için Ramponi ve ark. (1996) 'nın çalışmalarındaki Detay Varyansını (DV) ve Arkaplan Varyansını (BV) değerlendirme kriteri olarak seçmişlerdir. Test görüntülerinin çoğunda önerdikleri yöntemle daha iyi sonuçlar elde ettiklerini belirtmişlerdir. Ayrıca objektif değerlendirmeye sonuç görüntüsünde bulunan kenar pikselleri sayısını da dâhil ederek, test görüntülerinden ikisinin bu değerlerini makalelerinde paylaşmışlar ve sonuçların diğer yöntemlerden daha iyi olduğunu vurgulamışlardır.

Singh ve Khare (2013) gri seviye görüntülerin zenginleştirilmesi için çok amaçlı GA tabanlı bir yöntem önermişlerdir. Yöntemde zenginleştirme için Munteanu ve Rosa (2004) 'nın çalışmalarında önerdikleri dönüşüm fonksiyonuna benzer bir dönüşüm fonksiyonu uygulamış ardından elde edilen zenginleştirilmiş görüntüyü değerlendirmek için piksel değeri, entropi ve kenar sayısı olmak üzere üç farklı amaç fonksiyonu kullanmışlardır. Çalışmada kullandıkları seçim yöntemi turnuva seçimi, çaprazlama yöntemi aritmetik çaprazlama (Michalewicz, 1996) ve mutasyon yöntemi ise basit mutasyondur. NSGA-II yöntemini, yeni popülasyonun seçimi için uygulayarak Pareto Optimal Cephe'yi (POF) oluşturmuşlardır. POF'tan en iyi bireyleri seçmişlerdir. Ardından NSGA-II algoritması ile elde ettikleri popülasyona çaprazlama ve mutasyon uygulayarak yeni popülasyon elde etmişlerdir. Son olarak en iyi bireyleri kullanarak zenginleştirilmiş görüntü elde etmişlerdir. GA'da 40-50 nesilde daha iyi sonuç aldıklarını, popülasyon sayısının 48 olarak seçildiğini ve problem boyutunun 4 olduğunu belirtmişlerdir. Önerdikleri yöntemi; histogram eşitleme (Pratt, 2006), Munteanu ve Rosa (2004) tarafından önerilen yöntem, Sobel yöntemi (Davis, 1975), 2B medyan filtresi (Lim, 1990) ve parlaklık muhafazalı dinamik bulanık (BPDF) histogram

eşitleme yöntemleriyle (Sheet ve ark., 2010) karşılaştırmışlardır. Önerdikleri yöntemi 4 standart test görüntüsüne uygulamışlar ve uygunluk, piksel değeri, kenar sayısı ve entropi değerlerini vermişlerdir. Uygunluk değerini yalnızca Munteanu ve Rosa (2004) tarafından önerilen yöntemle karşılaştırmışlardır. Bu değerler incelendiğinde, çoğunda önerdikleri yöntemin daha iyi sonuç verdiği görülmektedir.

Prabha ve Kumar (2017) kontrastında farklı düzeylerde bozulma meydana gelen görüntülerin optimal parametre değerleri kullanılarak zenginleştirildiği bir yaklaşım önermişlerdir. Öncelikle RGB renk uzayındaki girdi görüntüsünü, HSV renk uzayına dönüştürmüşlerdir. İşlemleri değer (V) bileşeni üzerinde gerçekleştirmiş, renk özü (H) ve doygunluk (S) bileşenlerini korumuşlardır. Ardından görüntüdeki piksel değerlerinin görülme sıklıklarının tespiti için V bileşeninin histogramını hesaplamışlardır. Bir sonraki aşamada, her bir pikselin değerini zenginleştirilmiş değerlere dönüştürecek bir dönüşüm fonksiyonu uygulamışlardır. Bu dönüşüm fonksiyonundaki parametrelerin optimal değerlerinin belirlenmesi için GA kullanmışlardır.

Shyu ve Leou (1998) çalışmalarında, GA kullanarak renkli görüntülerin zenginleştirilmesini hedeflemişlerdir. İlk olarak girdi görüntüsünü, RGB renk modelinden LHS renk modeline dönüştürmüşlerdir. Girdi görüntülerinde farklı türde bozulmaların olabileceğini düşünerek farklı doğrusal olmayan dönüşüm fonksiyonları kullanmışlardır. Bu fonksiyonlardan 4 tanesini birleştirerek, Parlaklık (L) bileşenine ve Tubbs'un (1987) tamamlanmamış beta fonksiyonunu ise Doymunluk (S) bileşenine uygulamış ve Renk Özü (H) bileşenini değiştirmemişlerdir. Dönüşüm fonksiyonlarında bulunan toplam 11 parametreyi, optimize edilmek üzere GA'da kromozomları oluşturan, her bir parametrenin 8 bitle ifade edildiği genler olarak kodlamışlardır. Popülasyondaki birey sayısını 66, maksimum nesil sayısını ise 50 olarak belirlemişlerdir. Uygunluk fonksiyonu olarak; AC güç, kompaktlık, the Branner's ve bilgi-gürültü değişimi (Tubbs, 1987; Pratt, 1991) ölçütünden oluşan bir fonksiyon kullanmışlardır. AC güç, kompaktlık ve bilgi-gürültü değişimi ölçütlerini birlikte L bileşenine ve the Branner's ölçütünü ise S bileşenine uygulamışlardır. Çalışmalarında çaprazlama için hem çok noktalı çaprazlama hem de aritmetik çaprazlamayı kullanmışlardır. Mutasyon işleminde rastgele seçilen bir genin değerini değiştirmişlerdir. Elde ettikleri zenginleştirilmiş LHS renk modelindeki görüntüyü, RGB renk modeline dönüştürmüşlerdir. Bu dönüşümün ardından, görüntüdeki piksellerin değer aralığının dışına çıkmaları ihtimaline karşı her bir pikseli kontrol ederek sınır değerlerine çekmişlerdir. Önerdikleri yöntemi 4 test görüntüsü üzerinde

denemişler ve Uniform 3-B Histogram Spesifikasyon (Uniform 3-D Histogram Specification) (Trahanias ve Venetsanopoulos, 1992), Bireysel 3-B Eşitleme (the Individual 3-D Equalization) (Niblack, 1986) ve L ve S bileşenlerinin ayrı ayrı eşitlendiği H bileşeninin değiştirilmediği, Bireysel En Küçük Kareler Eşitleme (the Individual LS Equalization) yaklaşımlarını önerdikleri yöntemle karşılaştırmışlardır. Objektif değerlendirmeyi, GA'da kullandıkları uygunluk fonksiyonu ile gerçekleştirmişlerdir. Önerdikleri yöntem, karşılaştırma yaptıkları diğer 3 yöntemden daha iyi uygunluk değerine sahiptir ancak yürütme süresi diğer yöntemlere göre daha uzundur.

Gri seviye görüntülerin zenginleştirilmesi için Saitoh (1999) çalışmasında GA'dan yararlanmıştır. Girdi ve çıktı görüntülerinin gri seviye değerleri arasındaki ilişkiyi Look-Up Table (LUT) kullanarak göstermiştir. Girdi ve çıktı görüntülerinin değer aralıklarını [0-255] olarak kabul etmiştir. LUT'ta bulunan, girdi ve çıktı görüntülerine ait gri seviye değerleri arasındaki optimal ilişkiyi bulmak için GA kullanmıştır. Görüntünün kontrastını zenginleştirmek için görüntüde bulunan en küçük gri seviye değerini 0'a en büyük gri seviye değerini ise 255'e haritalamıştır. Girdi ve çıktı görüntülerindeki gri seviye değerleri arasındaki ilişkiyi bir eğride göstermiş ve GA'nın kromozom yapısını bu eğriyi temsil edecek şekilde oluşturmuştur. Uygunluk fonksiyonu olarak, çıktı görüntüsündeki kenar piksellerinin değerleri toplamını kullanmıştır. Kenar piksellerini Prewitt (Ballard ve Brown, 1982) operatörü kullanarak hesaplamıştır. Seçim işlemi, bireylerin uygunlukları büyükten küçüğe sıralandıktan sonra bireylerin ilk yarısının diğer nesle aktarılmasıyla gerçekleştirmiştir. Çaprazlama işlemi, iki noktalı çaprazlama ile mutasyonu ise seçilen bir bitin değiştirilmesiyle gerçekleştirmiştir. Saitoh (1999) önerdiği yöntemi, gri seviye doğrusal dönüşüm ve histogram eşitleme yöntemleriyle karşılaştırmıştır. Çalışmasında, elde edilen tüm sonuç görüntülerin 8 kişi tarafından görsel olarak değerlendirildiğini ve önerdiği yöntemin, en yüksek ortalama derecelendirmeye sahip olduğunu belirtmiştir. Objektif değerlendirmede ise Detay Varyansı ve Arkaplan Varyansı (Vanzo ve ark., 1994; Ramponi ve ark., 1996) kullanmıştır. Orijinal görüntüye göre sonuç görüntüsünün DV değerinin artması, BV değerinin ise değişmemesi başarılı sonuç elde edildiğini göstermektedir (Vanzo ve ark., 1994; Ramponi ve ark., 1996). Önerdiği yöntemde diğer yöntemlere kıyasla görüntülerin çoğunda BV orijinal görüntülere göre fazla değişiklik göstermemiş ve DV tüm görüntülerde en yüksek artışı göstermiştir. Ayrıca önerdiği

yöntemin, karşılaştırdığı diğer yöntemlere göre daha uzun yürütme süresine sahip olduğunu da vurgulamıştır.

2.2. Sürü Zekâsı Tabanlı Optimizasyon Teknikleri

2.2.1. Parçacık sürü optimizasyonu ile ilgili kaynak araştırması

Gorai ve Ghosh (2011) renkli görüntülerin zenginleştirilmeleri için Parçacık Sürü Optimizasyonu (PSO) tabanlı renk özü değerlerinin muhafaza edildiği bir yaklaşım önermişlerdir. Önerdikleri yöntemde öncelikle, renkli görüntüden HSI renk uzayının Gri seviye (I) bileşenini kullanarak gri seviye görüntü elde etmişler ve işlemleri bu görüntü üzerinde gerçekleştirmişlerdir. Girdi görüntüsündeki tüm piksellerin değerlerine karşılık yeni değerler üreterek görüntüyü zenginleştiren, görüntünün hem yerel hem de global bilgisinden faydalanan bir dönüşüm fonksiyonu ve bu üretilen zenginleştirilmiş görüntünün kalitesini değerlendirmesi için; entropi, kenar piksellerinin değerleri toplamı ve kenar piksellerinin sayısının kullanıldığı bir değerlendirme fonksiyonu oluşturmuşlardır. Kullandıkları dönüşüm fonksiyonunun 4 parametresi olup, en iyi sonucu üretmesi için optimal parametre değerlerini PSO yöntemiyle bulmayı amaçlamışlardır. Zenginleştirilmiş görüntü elde edildiğinde istenmeyen renk değişimlerine karşı ölçeklendirme uygulamışlardır. Önerdikleri yöntemi test ettikleri renkli görüntülerden üç tanesini makalelerinde vermişlerdir. Çalışmalarını, aralık problemi olmadan, renk özü muhafazalı renkli görüntü zenginleştirme (HPCIE) ve renkli görüntü zenginleştirme için genetik algoritma yaklaşımı (GACIE) ile karşılaştırmışlardır. Objektif değerlendirme için Ramponi ve ark. (1996) tarafından önerilen DV ve BV metriklerini ve değerlendirme fonksiyonunu kullanmışlardır. Bir görüntünün BV değeri hariç 3 görüntüde de en iyi değerleri önerdikleri yöntemle elde etmişlerdir. Yaptıkları görsel değerlendirmede ise diğer yöntemlere kıyasla önerdikleri yöntemde görüntülerdeki detayların daha belirgin olduğunu belirtmişlerdir.

Bejinariu ve ark. (2017) çok amaçlı parçacık sürü optimizasyonu ile görüntü kontrastı zenginleştirme yöntemi önermişlerdir. Çalışmalarında, girdi görüntülerindeki kontrastı arttırmak ve bu işlemi gerçekleştirirken de görüntüde yapay bir görünüme sebebiyet vermemek için Wu (2011) tarafından önerilen kontrast kazancı ve ton bozulması amaç fonksiyonlarını kullanmışlardır. Kontrast kazancını maksimize etmeyi

ve ton bozulmasını minimize etmeyi hedeflemişlerdir. PSO'daki konum vektörünü, girdi görüntüsünde bulunan pikseller arasındaki farklarla tanımlamışlardır. Çalışmalarında uyguladıkları çok amaçlı yöntemde global en iyi değerini elde ettikleri çözüm kümesinden rastgele seçmişlerdir. Yerel en iyinin tespiti içinse başlangıçta her bir parçacık için rastgele üretilen konumları yerel en iyi olarak belirlemişlerdir. Ardından yeni olası bir çözümün üretildiği her sefer önceki yerel en iyiyle kıyaslamışlardır. Eğer yeni çözüm, yerel en iyiyi bastırırsa yeni yerel en iyi olmuş ve eğer mevcut yerel en iyi, yeni çözümü bastırırsa yerel en iyi değişmemiş ve eğer herhangi baskınlık söz konusu değilse yeni yerel en iyi, mevcut ve yeni çözüm arasından rastgele seçilmiştir. Her iterasyonda bastırılmamış çözümler kümesini güncellemiş, yeni üretilen olası çözümleri kümeye ekleyip ardından her bir çözüm çiftini herhangi baskınlık ilişkisi olmasına karşın kontrol etmişlerdir. İterasyonlar sonunda, tüm bastırılmış çözümleri kümeden çıkarıp Pareto optimal çözümleri elde etmişlerdir. Önerdikleri yaklaşımı test görüntülerine uygulamış ve 'Brainix' test görüntüsünden elde ettikleri sonuçları makalelerinde vermişlerdir. Önerdikleri çok amaçlı optimizasyon modelinin yüksek oranda genelliğe sahip olduğu ve aynı zamanda biyomedikal görüntü işleme alanında da kullanılabileceğini belirtmişlerdir. Ayrıca yöntemlerini, yalnızca gri seviye görüntüler üzerine uygulamış olsalar da renkli görüntülerde de farklı renk modellerine dönüştürülüp parlaklık bileşenine uygulanabileceğini belirtmişlerdir.

Venkatalakshmi ve Shalinie (2010) çalışmalarında, PSO ile görüntü zenginleştirmeyi hedeflemişlerdir. Önerdikleri yöntemde, Munteanu ve Rosa (2000) tarafından önerilen dönüşüm ve uygunluk fonksiyonlarını kullanmışlardır. PSO ile dönüşüm fonksiyonunda bulunan dört parametrenin optimal değerlerinin bulunmasını hedeflemişlerdir. PSO algoritmasında parçacıkların hızlarını güncellerken, Eberhart ve Kennedy (1995) ve Zheng ve ark. (2003) 'ın çalışmalarında da olduğu gibi global en iyi ile mevcut en iyi değerlerinin farklarını almak yerine yalnızca global en iyi değerini kullanmışlardır. Önerdikleri PSO yaklaşımını, klasik PSO yaklaşımıyla, kenar pikselleri sayısı ve uygunluk değerine göre 'cameraman' test görüntüsü üzerinde karşılaştırmışlardır. Önerdikleri yöntem klasik PSO'ya göre daha iyi değerler vermiştir.

2.2.2. Yapay arı kolonisi algoritması ile ilgili kaynak araştırması

Görüntülerdeki kontrastın zenginleştirilmesi için Draa ve Bouaziz (2014) Yapay Arı Kolonisi (ABC) yöntemini önermişlerdir. Problem temsilini, Hashemi ve ark. (2010) çalışmalarında yaptıkları gibi; $[0,255]$ aralığında, sıralı olası gri seviye değerlerinin tutulduğu, girdi görüntüsünde bulunan gri seviye değerleri boyutunda bir vektör şeklinde gerçekleştirmişlerdir. Amaç fonksiyonu olarak; kenar piksellerinin sayısını, kenar piksellerinin değerini ve tüm görüntünün entropi değerini birleştiren fonksiyonu kullanmışlardır (Munteanu ve Rosa, 2004; Braik ve ark., 2007a; Coelho ve ark., 2009; Gorai ve Ghosh, 2009). Önerilen yöntem, Hashemi ve ark. (2010) tarafından önerilen GA tabanlı yöntem ve Guguk Kuşu Arama (Agrawal ve Panda, 2012) algoritması sonuçları ile karşılaştırılmıştır. Test görüntülerinin zenginleştirilmiş sonuçlarını ve zenginleştirilmiş görüntüye ait histogram grafiklerini makalelerinde vererek önerdikleri yöntem sayesinde gri seviyelerin daha fazla gerildiğini böylece yöntemin etkinliğinin kanıtlandığını belirtmişlerdir. Görsel değerlendirmeye göre, sonuçların Hashemi ve ark. (2010)'nın çalışmasından elde edilenlerle benzerlik gösterdiğini, sayısal değerlendirme için PSNR kalite metriğini kullandıklarını ifade etmişlerdir. 5 görüntüden 4'ünde daha iyi PSNR değeri elde ettiklerini ve bunun yöntemlerinin üstünlüğünü gösterdiğini vurgulamışlardır. Ayrıca gri seviye görüntüleri uyguladıkları yöntemlerini RGB görüntüleri de uygulamışlardır. Her bir renk kanalını gri seviye olarak ele alıp ayrı ayrı yöntemlerini uyguladıktan sonra renk kanallarını birleştirerek zenginleştirilmiş sonuç görüntüsü elde etmişlerdir. Elde edilen sonuçlar Agrawal ve Panda (2012) tarafından önerilen guguk kuşu arama algoritması tabanlı yaklaşımla karşılaştırılmıştır. Objektif değerlendirme için amaç fonksiyonu değeri, entropi, Özellik Benzerlik İndeksi Metriği (FSIM), PSNR ve kenar pikselleri sayısını kullanmışlardır. Önerdikleri ABC tabanlı yaklaşımın, 5 durumun 4'ünde GA tabanlı yaklaşıma (Hashemi ve ark., 2010) göre daha iyi performansa sahip olduğunu belirtmişlerdir. Ayrıca önerdikleri yöntemin renkli görüntülerin zenginleştirilmesinde de etkili olduğunu ifade etmişlerdir.

Chen ve ark. (2018) çalışmalarında ABC yöntemi kullanarak görüntülerin kontrastını zenginleştirmeyi hedeflemişlerdir. Görüntü zenginleştirmeyi bir optimizasyon problemi olarak ele almışlardır. Dönüşüm fonksiyonu olarak Tubbs (1987) 'un önerdiği Tamamlanmamış Beta Fonksiyonu'nu kullanmışlar ve bu fonksiyonun iki parametresinin optimal değerlerini, ABC algoritmasıyla tespit etmeyi

hedeflemişlerdir. ABC algoritmasında uygunluk fonksiyonu olarak; kenar piksellerinin değerleri toplamı, kenar pikselleri sayısı, görüntü entropisi ve görüntü kontrastından oluşan bir fonksiyon kullanmışlardır. Önerdikleri yöntemi, renkli test görüntülerini gri seviyeye dönüştürüp gri seviye üzerinde uygulamışlardır. Önerdikleri yöntemi, konvansiyonel histogram tabanlı kontrast zenginleştirme yaklaşımlarıyla (Kim ve ark., 2006; Poddar ve ark., 2013; Santhi ve Banu, 2015), evrimsel tabanlı kontrast zenginleştirme yaklaşımlarıyla (Hashemi ve ark., 2010; Qinqing ve ark., 2011; Agrawal ve Panda, 2012) ve ABC tabanlı yaklaşımlarla (Draa ve Bouaziz, 2014; Joshi ve Prakash, 2015) karşılaştırmışlardır. Önerdikleri yöntemin performansını; PSNR, SSIM (Wang ve ark., 2004), Bilgi Uygunluk Kriteri (IFC) (Sheikh ve ark., 2005), Görsel Bilgi Uygunluğu (VIF) (Sheikh ve Bovik, 2006) ve Görsel Sinyal Gürültü Oranı (VSNR) (Chandler ve Hemami, 2007) metrikleriyle değerlendirmişlerdir. Önerdikleri yöntem karşılaştırdıkları yöntemlere göre, tüm test görüntülerinde tüm metriklerde en iyi sonuçları vermiştir.

Joshi ve Prakash (2015) çalışmalarında zayıf kontrastlı görüntülerin kontrastını zenginleştirmek için ABC tabanlı bir yaklaşım önermişlerdir. Önerdikleri yöntemde gri seviye görüntülerin kontrastının zenginleştirilmesini hedefledikleri için problem tanımını, gri seviye görüntülerdeki piksellerin değer aralığı olan $[0,255]$ aralığındaki sıralı değerlerden oluşan bir vektör şeklinde yapmışlardır. Amaç fonksiyonunu, yerel bant kısıtlamalı kontrast (Peli, 1990) 'tan faydalanarak oluşturmuşlardır. Önerilen yöntemi uygulamadan önce girdi görüntüsünün kontrast kalitesini analiz etmişler ve zayıf kontrasta sahip olduğunu tespit ettikleri görüntülere önerdikleri yöntemi uygulamışlardır. ABC algoritmasında da önerdikleri kalite tespit yönteminden faydalanmışlardır. Zenginleştirilmiş görüntüyü, hem görsel olarak hem de zenginleştirdikleri görüntülerden elde edilen özellikleri ele alarak değerlendirmişlerdir. Görsel değerlendirme için zenginleştirilen görüntülerle birlikte histogramlarını makalelerinde vermişlerdir. Önerdikleri yöntemle zenginleştirilen görüntülerin histogramlarının gerildiği görülmektedir. Ölçekten Bağımsız Özellik Dönüşümü (SIFT) (Lowe, 2004) ile önerdikleri yöntemi değerlendirmişlerdir. Orijinal görüntü ile bozulmuş görüntü arasındaki eşleşmeye oranla orijinal görüntü ile zenginleştirilmiş görüntü arasındaki eşleşmenin daha iyi olduğunu belirtmişler ve sonuçları paylaşmışlardır. Ayrıca önerdikleri yöntemi GA tabanlı (Hashemi ve ark., 2010) ve ABC tabanlı (Draa ve Bouaziz, 2014) yöntemlerle PSNR kalite metriği ile

karşılaştırmışlardır. Tüm test görüntülerinde önerdikleri yöntemle en iyi sonuçları elde etmişlerdir.

Yimit ve ark. (2013) çalışmalarında ABC algoritmasını, görüntü zenginleştirme işlemi için kullandıkları dönüşüm fonksiyonunun parametrelerinin optimal değerlerini tespit etmek için kullanmışlardır. Önerdikleri otomatik görüntü zenginleştirme metodunda, Munteanu ve Rosa (2004) tarafından önerilen dönüşüm ve amaç fonksiyonundan faydalanmışlardır. Önerdikleri yöntemi gri seviye test görüntülerine uygulayarak, PSO tabanlı (Braik ve ark., 2007b) ve GA tabanlı (Munteanu ve Rosa, 2004) iki yöntemle, DV ve BV kalite metriklerini dikkate alarak karşılaştırmışlardır. Önerdikleri yöntemin daha iyi zenginleştirme elde edebileceğini belirtmişlerdir.

2.2.3. Melez yaklaşımlar ile ilgili kaynak araştırması

Mondal ve ark. (2018) çalışmalarında PSO ve ABC algoritmalarını birleştiren melez bir kontrast zenginleştirme tekniği önermişlerdir. Önerdikleri yöntemde, rastgele konum ve hız değerleriyle başlattıkları PSO algoritmasında, her iterasyonda bu değerleri güncelleyip son iterasyonda üretilen sonuçları, ABC algoritmasında başlangıç popülasyonu olarak kullanmışlardır. ABC algoritmasıyla elde ettikleri çözümü kullanarak zenginleştirilmiş görüntü elde etmişlerdir. Çalışmalarında, 3 görüntü kalite metriğinin birleşiminden oluşan bir amaç fonksiyonu kullanmışlardır. Mutlak Ortalama Parlaklık Hatası (AMBE) (Raju, 2013), PSNR (Kaur, 2012) ve Entropi (Wang ve Ye, 2005) kalite metriklerini birleştirmişlerdir. Önerdikleri yöntemi, gri seviye test görüntüleri üzerinde uygulamış ve amaç fonksiyonunda kullandıkları kalite metrikleriyle değerlendirmişlerdir. Klasik Histogram Eşitleme (CHE), Parlaklık Muhafazalı Bi-Histogram Eşitleme (BBHE) ve İkili Alt Görüntü Histogram Eşitleme (DSIHE) yöntemleriyle önerdikleri yöntemi karşılaştırmışlardır. Test görüntülerinin ortalamalarına bakmışlar ve en yüksek değerleri önerdikleri yöntemle elde etmişlerdir.

3. MATERYAL VE YÖNTEM

3.1. Optimizasyon

Optimizasyon, herhangi bir problem için, o problemle ilgili tüm kısıtlamaları sağlayan çözümler arasından en iyisinin bulunmasıdır. Problemler genellikle, amaç fonksiyonu adı verilen fonksiyonlar kullanılarak matematiksel olarak ifade edilir. Bir probleme ait optimize edilmesi gereken sadece bir amaç fonksiyonu varsa bu problem Tek Amaçlı Optimizasyon, birden fazla amaç fonksiyonu varsa Çok Amaçlı Optimizasyon problemidir. Tek amaçlı optimizasyonda, amaç fonksiyonunun minimize edilmesi veya maksimize edilmesi hedeflenir. Optimizasyon sonucunda tek bir çözüm elde edilir. Örneğin minimum maliyet, maksimum kazanç gibi problemler tek amaçlı optimizasyon problemleridir. Olası çözümler içinden minimum maliyeti veren veya maksimum kazancı sağlayan çözüm seçilir (Arora, 2015).

Günlük hayatta karşılaştığımız problemlerin çoğunun çok amaçlı olduğu söylenebilir. Bu amaçlar çoğunlukla birbiriyle çelişirler (Deb, 2014). Örneğin görüntülerde hem doğal görünüm hem de yüksek kontrast istenir. Ancak görüntülerin kontrastları yükseltildiğinde, abartılı kontrast dolayısıyla yapay bir görünüm meydana gelebilir. Burada görüntü kontrastı ve doğal görünüm optimize edilmek istenen amaçlardır. Bu iki amaç arasında dengenin sağlanarak en uygun görüntünün elde edilmesi bir optimizasyon problemi olarak düşünülebilir.

Çok amaçlı optimizasyon probleminde amaç fonksiyonları eş zamanlı olarak optimize edilir. Optimizasyon neticesinde tek bir çözüm değil, bir çözüm kümesi elde edilir. Bu çözüm kümesine Pareto Optimal Çözümler denir (Arora, 2015). Çözüm uzayında, Pareto optimal çözüm kümesine ait tüm amaç fonksiyonlarının tüm değerlerine Pareto Optimal Yüzeyi veya Pareto Yüzeyi denir (Amouzgar, 2012). Pareto optimal yüzey, çözümler arasındaki baskınlık ilişkisi kullanılarak oluşturulur. Her bir amaç fonksiyonu için her bir çözümün bir diğer çözümü bastırıp bastırmadığına bakılır. Eğer bir x çözümü, tüm amaç fonksiyonlarında başka bir y çözümünden daha kötü değilse ve en az bir amaç için y çözümünden iyiyse y çözümünü bastırır. Pareto yüzeyinde bulunan çözümlere Bastırılmayan Çözümler denir (Arora, 2015).

3.2. Genetik Algoritma

Evrimsel algoritmaların temelinde, bir popülasyondaki bireylerin çevresel baskılar sebebiyle doğal seçime uğraması ve bunun neticesinde popülasyonun uygunluğunun artması vardır. Pek çok çeşidi bulunan evrimsel algoritmaların genel yapısı şöyledir; Başlangıçta rastgele aday çözümlerle popülasyon oluşturulur. Ardından her bir aday çözüm uygunluğu ölçülerek değerlendirilir. Değerlendirme işlemine göre, daha iyi olan aday bireylerin bazıları bir sonraki nesli oluşturmak üzere ebeveyn olarak seçilir. Seçilen ebeveynlere rekombinasyon uygulanır ve çocuk bireyler elde edilir. Rekombinasyon, seçilen iki veya daha fazla aday bireye (ebeveyn) uygulanan ve bir veya daha fazla yeni aday birey (çocuk) oluşturan işlemdir. Rekombinasyonla elde edilen çocuk bireyler, belli bir ihtimale göre mutasyona uğratılır. Mutasyon, bir aday bireye (çocuk) uygulanan ve yeni bir aday bireyin (çocuk) elde edildiği bir işlemdir. Rekombinasyon ve mutasyonla yeni bireyler oluşturularak çeşitlilik sağlanır. Bu şekilde oluşturulan yeni popülasyon değerlendirilerek yeni nesil için bireyler seçilir. Bu işlemler yeterli kaliteye sahip bir nesil elde edene kadar veya daha önceden belirlenmiş nesil sayısına erişilene kadar sürdürülebilir (Eiben ve Smith, 2003).

Evrimsel algoritmaların en bilineni Genetik Algoritmadır. GA, ilk olarak Holland (1992) tarafından geliştirilmiştir.

GA'da optimize edilecek problemin olası çözümleri kromozomlarla ifade edilir. Çözümlerin kodlanması GA'nın ilk aşamasıdır. Probleme uygun kodlama tipinin belirlenmesi, GA'nın ileriki aşamalarını da etkileyeceği için oldukça önemlidir (Sivanandam ve Deepa, 2007). En sık kullanılan kodlama teknikleri; ikili kodlama, tamsayı kodlama ve reel değerli kodlamadır. Tez çalışmasında reel değerli kodlama yöntemi kullanılmıştır.

Genlerle temsil edilecek değerler sürekli ise reel değerli kodlama yöntemi tercih edilir. k gene sahip bir çözüm, $\langle x_1, \dots, x_k \rangle$ $x_i \in R$ vektörü ile kodlanır (Eiben ve Smith, 2003).


Mutasyonla seçilen bireylerin, rastgele belirlenen gen değerleri değiştirilir (Mitchell, 1998). Çalışmada bireyler reel değerler kullanılarak kodlandığı için buna uygun bir mutasyon yöntemi seçilmiştir.

Seçilen her bir genin değeri, rastgele kendi değer aralığında değiştirilir. Denklem 3.1'de mutasyon işlemi gösterilmiştir. Denklem 3.1'de L_i alt sınırı, U_i üst sınırı ifade eder.

$$\langle x_1, \dots, x_n \rangle \rightarrow \langle x_1', \dots, x_n' \rangle \quad x_i, x_i' \in [L_i, U_i] \quad (3.1)$$

Rekombinasyon, iki veya daha fazla ebeveynden elde edilen bilgilerden yararlanılarak yeni bir bireyin oluşturulması işlemidir (Eiben ve Smith, 2003). Genellikle rekombinasyon uygulanacak bireyler içerisinde ikisi rastgele seçilir ve yine rastgele belirlenen bir veya daha fazla nokta referans alınarak iki birey arasında takas işlemi gerçekleştirilir. Böylece iki yeni birey elde edilir (Deb, 1999). Çalışmada bireyler reel değerler kullanılarak kodlandığı için buna uygun bir rekombinasyon yöntemi olan tekli aritmetik rekombinasyon seçilmiştir.

Tekli aritmetik rekombinasyonda, rastgele bir k geni seçilir ve o konumda iki ebeveyn bireyin aritmetik ortalaması alınır. Diğer genlere ebeveynlerin gen değerleri yazılır. Birinci çocuk, $\langle x_1, \dots, x_{k-1}, \alpha \times y_k + (1 - \alpha) \times x_k, x_{k+1}, \dots, x_n \rangle$ şeklinde, ikinci çocuk ise benzer şekilde ancak x ve y 'lerin yeri değiştirilerek elde edilir (Eiben ve Smith, 2003). Şekil 3.1.'de tekli aritmetik rekombinasyon örneği verilmiştir. Örnekte P1 ve P2 ebeveyn bireyleri, O1 ve O2 çocuk bireyleri ifade ederken $k = 3$ ve $\alpha = 1/2$ 'dir.



Şekil 3.1. Tekli aritmetik rekombinasyon

Seçim işlemiyle rekombinasyon uygulanacak bireyler belirlenir. Bu işlemde, uygunluk değeri daha iyi olan bireylerin seçilme olasılıkları daha yüksektir (Mitchell, 1998). Çalışmada, uygunluk orantılı bir seçim yöntemi olan turnuva seçim yöntemi kullanılmıştır.

Turnuva seçim yönteminde öncelikle popülasyondan, rastgele belli sayıda birey seçilir. Bu bireyler bir sonraki seçimden önce popülasyondan çıkarılabileceği gibi tekrar seçilmelerine izin de verilebilir. Seçilen bireyler içerisinde en iyi uygunluk değerine sahip olan birey seçilir. Bu işlem, rekombinasyon uygulanacak birey sayısına ulaşılan

kadar devam ettirilir. Eđer başlangıçta popülasyondan rastgele seçilen birey sayısı 2 olarak belirlenirse bu seçim yöntemine İkili Turnuva Seçimi denir (Goldberg ve Deb, 1991).

Genetik algoritmanın sözde kodu Şekil 3.2’de verilmiştir.

```

procedure GA
begin
  Çözümleri kromozomlara kodla
  Uygunluk fonksiyonunu tanımla
  Başlangıç popülasyonunu oluştur
  Çaprazlama ( $p_c$ ) ve mutasyon ( $p_m$ ) oranlarını belirle
    while ( $t <$  maksimum nesil sayısı)
      çaprazlama ve mutasyonla yeni çözümler oluştur
      if  $p_c >$ rand
        Çaprazlama();
      end
      if  $p_m >$ rand
        Mutasyon();
      end
      Uygunluğu artarsa yeni çözümleri kabul et
      Mevcut en iyiyi bir sonraki nesil için seç
    (elitizm)
  end
  Sonucun kodunu çöz ve göster
end

```

Şekil 3.2. GA sözde kod (Yang, 2010)

3.3. Parçacık Sürü Optimizasyonu

Parçacık sürü optimizasyonu algoritması ilk olarak, Kennedy ve Eberhart (1995) tarafından geliştirilmiştir. PSO algoritması, kuş ve balık sürülerinin davranışlarından esinlenilerek oluşturulmuş popülasyon tabanlı, metasezgisel bir algoritmadır. Optimize edilmek istenen problemin aday çözümleri, rastsal olarak dağıtılmış parçacıklarla ifade edilir. Bu çözümler, uygunluk fonksiyonu ile değerlendirilir ve değerlendirme sonucuna göre geliştirilir. Çözümler, çözüm uzayında hareket ettirilerek geliştirilir. Hareket ettirme işlemi, her bir parçacığın o ana kadar en iyi uygunluk değerini verdiği konum ve popülasyonun o ana kadar en iyi uygunluk değerini elde ettiği konuma göre gerçekleştirilir. Parçacıkların konumlarının güncellenmesi Denklem 3.2 ve Denklem 3.3’te verilen formüllerle gerçekleştirilir (Eberhart ve Kennedy, 1995).

$$v_{i,j}^{k+1} = v_{i,j}^k + c_1 r_1 (x_{best\ i,j}^k - x_{i,j}^k) + c_2 r_2 (x_{gbest\ j}^k - x_{i,j}^k) \quad (3.2)$$

$$x_{i,j}^{k+1} = x_{i,j}^k + v_{i,j}^{k+1} \quad (3.3)$$

Denklem 3.2’de $x_{i,j}^k$ ve $v_{i,j}^k$ sırasıyla k . iterasyondaki, i . parçacığın konumunun ve hızının j . bileşenidir. r_1 ve r_2 parametreleri, (0,1) aralığında rastgele değer alırlar. $x_{best\ i}$ ve x_{gbest} sırasıyla, i . parçacık tarafından o ana kadar erişilen en iyi konum ve tüm popülasyon tarafından o ana kadar erişilen en iyi konumu ifade eder. c_1 ve c_2 parametreleri sırasıyla, parçacığın kendine ve sürüye güvenini ifade eder. Bu parametrelere, Kennedy ve Eberhart (1995) tarafından 2 değeri verilmiştir. Bu parametreler, keşif ve sömürü arasındaki dengenin oluşturulmasında oldukça önemlidir. c_1 parametresinin daha büyük değer alması parçacıkları, yerel en iyi konuma yönlendirirken c_2 parametresinin daha büyük olması global en iyi konuma daha hızlı ulaşmalarını sağlar. Parçacıkların arama uzayından çıkmaması için Eberhart ve ark. (1996), maksimum hız parametresi V_{max} ’ı önermişlerdir. Shi ve Eberhart (1998), Denklem 3.2’de verilen formülde, parçacığın önceki hızının, global ve yerel arama dengesi üzerinde önemli bir etkisi olduğunu belirtmişlerdir. Denklemden parçacığın önceki hızı çıkarılırsa, parçacık başlangıçtaki bölgesinden çıkamaz ve arama uzayı küçülür. Eğer parçacığın önceki hızının denklemdeki etkinliği arttırılırsa o zaman da parçacık, bilinen iyi konuma yakınsamaktan kaçınacak ve arama uzayında bilinmeyen alanları keşfedecektir. Bu sebeple Denklem 3.2’ye eylemsizlik ağırlığı w eklenmiştir. Eylemsizlik ağırlıklı formül Denklem 3.4’te verilmiştir (Kaveh, 2014).

$$v_{i,j}^{k+1} = wv_{i,j}^k + c_1 r_1 (x_{best\ i,j}^k - x_{i,j}^k) + c_2 r_2 (x_{gbest\ j}^k - x_{i,j}^k) \quad (3.4)$$

PSO algoritmasının sözde kodu Şekil 3.3’de verilmiştir.

```

procedure PSO
begin
  Her bir  $i$  parçacığı için  $x_i, v_i, x_{best_i}$  parametrelerine ilk değer ata
  while (sonlandırma şartı sağlanmadığı sürece) do
    begin
      for her bir parçacık  $i$ 
        amaç fonksiyonunu hesapla
         $x_{best_i}$ 'yi güncelle
      end
      for her bir  $i$ 
         $g'$ ye en iyi  $x_{best_i}$  değerli komşusunun indisini ata
         $v_i$ 'yi hesaplamak için  $g'$ 'yi kullan
         $x_i = x_i + v_i$ 'i güncelle
        amaç fonksiyonunu hesapla
         $x_{best_i}$ 'yi güncelle
      end
    end
  end
end

```

Şekil 3.3. PSO sözde kod (Kaveh, 2014)

3.4. Yapay Arı Kolonisi

Yapay Arı Kolonisi, Karaboga (2005) tarafından önerilen sürü zekâsı tabanlı bir yaklaşımdır. Doğadaki bal arılarının yiyecek arama davranışından esinlenen yapay arı kolonisinde, işçi, gözcü ve kâşif olmak üzere üç grup arı bulunur (Akbari ve ark., 2012). Koloninin yarısı işçi diğer yarısı gözcü arıdır. Yiyecek kaynağı sayısı işçi arı sayısına eşittir. Yiyecek kaynağı, optimizasyon probleminin çözümünü temsil eder. İşçi arılar yiyecek kaynaklarına giden, gözcü arılar yiyecek kaynağını seçmek için bekleyen, kâşif arılar ise rastgele arama yapan ve yiyecek kaynağı, işçi veya gözcü arılarca tüketilmiş olan işçi arılardır. Algoritmada her iterasyonda üç temel aşama vardır: İşçi arı, gözcü arı ve kâşif arı aşaması. İşçi arı aşamasında işçi arılar yiyecek kaynaklarına gönderilir ve nektar miktarı ölçülür. Nektar miktarlarının ölçülmesi optimizasyon probleminde uygunluk fonksiyonunun hesaplanmasına karşılık gelir. Gözcü arı aşamasında, işçi arılardan edinilen bilgiyle gözcü arılar, yiyecek kaynağı seçer ve yiyeceğin nektar miktarını ölçer. Kâşif arı aşamasında kâşif arılar belirlenerek potansiyel yiyecek kaynaklarına gönderilir (Karaboga ve Basturk, 2007).

Algoritmanın ilk adımında, yiyecek kaynaklarına rastgele başlangıç değerleri verilir. Yiyecek kaynakları, x_i ($i = 1,2,3, \dots, SN$) vektörüyle temsil edilir. Burada SN,

yiyecek kaynaklarının (çözümlerin) sayısıdır. Problemin boyutu (optimizasyon parametrelerinin sayısı) ise D ile gösterilir (Karaboga ve Basturk, 2007).

İşçi arı aşamasında, her bir işçi arı kendisiyle ilişkili x_i yiyecek kaynağı dışında rastgele bir x_k yiyecek kaynağı seçer. Ardından bu yiyecek kaynağının rastgele bir j konumunu seçip Denklem 3.5'e göre günceller (Karaboga ve Basturk, 2007).

$$v_{ij} = x_{ij} + \Phi_{ij} (x_{ij} - x_{kj}) \quad (3.5)$$

Denklem 3.5'te, $k \in \{1,2, \dots, SN\}$ rastgele seçilen yiyecek kaynağının indisi, $j \in \{1,2, \dots, D\}$ rastgele seçilen konum indisidir. Φ_{ij} , $[-1,1]$ aralığında rastgele bir sayıdır. Böylece yeni bir aday yiyecek kaynağı v_i oluşturulur. Eğer v_i aday yiyecek kaynağının nektar miktarı, mevcut x_{ij} yiyecek kaynağınınkinden daha fazlaysa v_i hafızaya alınır ve x_{ij} yiyecek kaynağı unutulur. Aksi halde mevcut kaynak hafızada kalır (Karaboga ve Basturk, 2007).

Gözcü arı aşamasında, bir önceki aşamada elde edilen bilgilerden faydalanılır. Tüm gözcü arılar olasılıksal olarak, nektar miktarına göre bir yiyecek kaynağı seçer ve Denklem 3.5'e göre güncelleme işlemini gerçekleştirir. Mevcut yiyecek kaynağı ve yeni oluşturulan kaynak arasında seçim işlemi, işçi arı aşamasında bahsedildiği gibi gerçekleştirilir. Gözcü arıyla ilişkili olan i yiyecek kaynağının olasılığı, Denklem 3.6'da gösterildiği gibi hesaplanır. Denklem 3.6'da, fit_i , i . çözümün uygunluk değeridir (Karaboga ve Basturk, 2007).

$$p_i = \frac{fit_i}{\sum_{n=1}^{SN} fit_n} \quad (3.6)$$

Kâşif arı aşamasında ise terk edilen yiyecek kaynaklarının yerine yenileri getirilir. İşçi ve gözcü arı aşamalarında geliştirilmeyen yiyecek kaynakları terk edilir. Bunun için bir limit belirlenmiştir ve genellikle problem boyutu ile yiyecek kaynağı sayısının çarpımı kadardır. Bu limiti aşan yiyecek kaynakları, rastgele oluşturulan yeni değerleriyle değiştirilir. Bu üç aşama, sonlandırma kriteri sağlanana kadar tekrarlanır (Karaboga ve Basturk, 2007).

Yapay arı kolonisi algoritmasının sözde kodu Şekil 3.4'te verilmiştir.

```

PROCEDURE ABC
BEGIN
Kaşif arıları başlangıç yiyecek kaynaklarına gönder
WHILE Sonlandırma şartı sağlanana kadar
    İşçi arıları yiyecek kaynaklarına gönder ve kaynakların nektar miktarını belirle
    Gözcü arıların tercih ettiği kaynakların olasılık değerlerini hesapla
    Arılar tarafından terk edilen kaynakların sömürü aşamasını durdur
    Arama alanına yeni kaynakları keşfetmeleri için rastgele, kaşif arıları gönder
    O ana kadar bulunan en iyi yiyecek kaynağını hafızaya al
END
END

```

Şekil 3.4. ABC sözde kod (Karaboga, 2005)

3.5. Çok Amaçlı Optimizasyon

3.5.1. Bastırılmamış Sınıflandırılmalı Genetik Algoritma II

Deb ve ark. (2002) tarafından, bastırılmamış sınıflandırılmalı tabanlı çok amaçlı evrimsel algoritma olan NSGA-II önerilmiştir.

Hesaplama maliyeti $O(MN^2)$ olan hızlı bastırılmamış sınıflandırmayı tanımlamışlardır. N popülasyon boyutu, M amaç sayısıdır. İlk olarak her bir çözüm için; baskınlık sayısı n_p yani p çözümünü bastıran çözümlerin sayısı ve p çözümünün bastırdığı çözümlerin kümesi S_p hesaplanır. İlk bastırılmamış cephedeki tüm çözümlerin baskınlık sayısı 0 olacaktır. Ardından n_p değeri 0 olan her bir p çözümü için S_p kümesindeki her bir q elemanına bakılır ve baskınlık sayısı bir azaltılır. Eğer baskınlık sayısı 0 olan q elemanı varsa bu elemanlar ikinci bastırılmamış cephenin elemanlarıdır ve oluşturulan Q kümesine alınır. Bu işlem Q kümesindeki her bir eleman için tekrarlanarak tüm cepheler hesaplanır. Bastırılmamış sınıflandırmanın hesaplanması Şekil 3.5'deki sözde kodda gösterilmiştir (Deb ve ark., 2002).


```

HIZLI BASTIRILMAMIŞ SIRALAMA (P)
FOREACH  $p \in P$ 
     $S_p = \emptyset$ 
     $n_p = 0$ 
    FOREACH  $q \in P$ 
        IF ( $p < q$ ) THEN // p, q'yu bastırırsa
             $S_p = S_p \cup \{q\}$  // p tarafından bastırılan çözümler kümesine q eklenir
        ELSE IF ( $q < p$ ) THEN
             $n_p = n_p + 1$  // p'nin baskınlık sayacı arttırılır
    IF  $n_p = 0$  THEN // p ilk cepheye aittir
         $p_{yn} = 1$ 
         $F_1 = F_1 \cup \{p\}$ 
i = 1
    WHILE  $F_i \neq \emptyset$ 
         $Q = \emptyset$  // bir sonraki cephenin elemanlarını tutmak için kullanılır
        FOREACH  $p \in F_i$ 
            FOREACH  $q \in S_p$ 
                 $n_q = n_q - 1$ 
                IF  $n_q = 0$  THEN // q bir sonraki cepheye aittir
                     $q_{yn} = i + 1$ 
                     $Q = Q \cup \{q\}$ 
        i = i + 1
         $F_i = Q$ 

```

Şekil 3.5. Bastırılmamış sıralama sözde kodu (Deb ve ark., 2002)

Kalabalıklık mesafesinin ölçülmesi için öncelikle popülasyon, uygunluk değerine göre, artan sırada sıralanmalıdır. Ardından, her bir amaç fonksiyonu için, en büyük ve en küçük değerli çözümlerin mesafe değeri sonsuz yapılır. Diğer tüm çözümlerin mesafe değerleri, iki komşu çözümün normalize edilmiş mutlak farklarının hesaplanmasıyla belirlenir. Toplam kalabalıklık mesafesi, her bir amaca karşılık gelen mesafelerin toplanmasıyla bulunur. Kalabalıklık mesafeleri hesaplanmadan her bir amaç fonksiyonu normalize edilir. Şekil 3.6'da I bastırılmamış kümesindeki tüm çözümlerin kalabalıklık mesafelerinin hesaplanmasına ilişkin sözde kod verilmiştir (Deb ve ark., 2002).

```

KalabalıklıkMesafesiHesaplama(I)
 $l = |I|$  // I'daki çözümlerin sayısı
for each  $i$ ,  $set\ I[i]_{mesafe} = 0$  // başlangıç mesafeleri
for each amaç  $m$ 
     $I = sort(I, m)$  // her bir amaç değerine göre sıralanır
     $I[1]_{mesafe} = I[l]_{mesafe} = \infty$  // sınır noktalarının her zaman seçilmesi için
    for  $i = 2$  to  $(l - 1)$  // diğer noktalar hesaplanır
         $I[i]_{mesafe} = I[i]_{mesafe} + (I[i + 1].m - I[i - 1].m) / (f_m^{max} - f_m^{min})$ 

```

Şekil 3.6. Kalabalıklık mesafesi sözde kodu (Deb ve ark., 2002)

Şekil 3.6'daki $I[i].m$ ifadesi, I kümesindeki i . bireyin m . amaç fonksiyonu değerini ifade etmektedir. f_m^{max} ve f_m^{min} parametreleri m . amaç fonksiyonunun

maksimum ve minimum değerlerini ifade etmektedir. I kümesindeki tüm elemanların mesafeleri belirlendikten sonra çözümler birbirleriyle kıyaslanır. Küçük mesafeye sahip bir çözüm diğer çözümlere göre daha kalabalıktır (Deb ve ark., 2002).

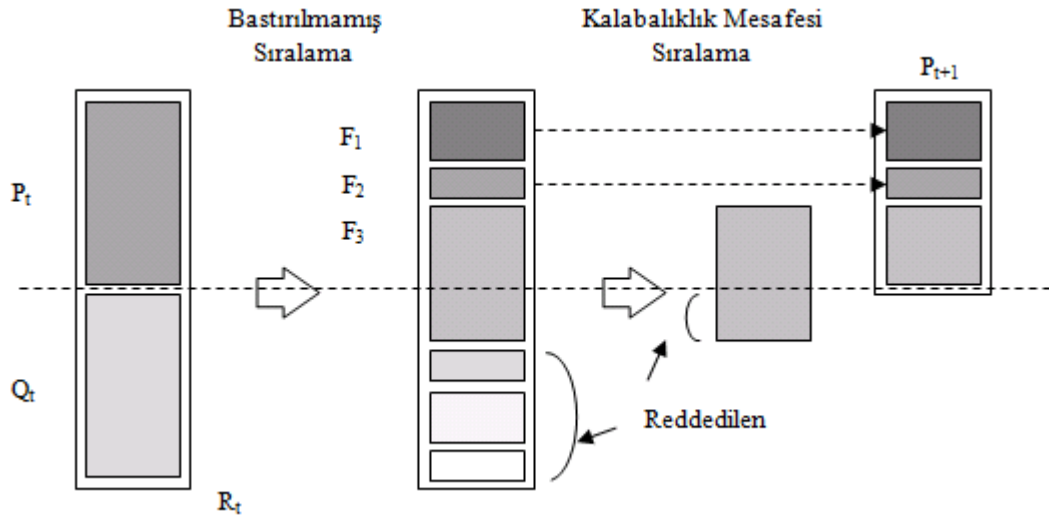
Kalabalıklık kıyaslama operatörü (\prec_n), seçim işleminde kullanılır. Popülasyondaki her bir i bireyinin; bastırılmamış yüzey numarası (i_{yn}) ve kalabalıklık mesafesi (i_{mesafe}) değerinin olduğu varsayılır. Buna göre, kısmi sıralı \prec_n , Şekil 3.7'deki gibi tanımlanır (Deb ve ark., 2002).

$$i \prec_n j \quad \text{if} (i_{yn} < j_{yn}) \text{ or } ((i_{yn} = j_{yn}) \text{ and } (i_{mesafe} > j_{mesafe}))$$

Şekil 3.7. Kısmi sıralı kalabalıklık kıyaslama operatörü tanımı (Deb ve ark., 2002)

Şekil 3.7'deki ifadeden de anlaşılacağı gibi, farklı bastırılmamış yüzey numarasına sahip iki çözümden düşük yüzey numaralı olan tercih edilir. Eğer her iki çözümde aynı cephedense o zaman daha az kalabalık bölgeye sahip çözüm tercih edilir (Deb ve ark., 2002).

İlk olarak rastgele başlangıç P_0 ebeveyn popülasyonu oluşturulur. Ardından popülasyon baskınlığa göre sıralanır. Her bir çözüme baskınlığına göre bir yüzey numarası verilir (1 en iyi). Genellikle ikili turnuva seçim yöntemi, rekombinasyon ve mutasyon işlemleri gerçekleştirilerek N boyutlu çocuk popülasyonu Q_0 elde edilir. NSGA-II algoritması Şekil 3.8'de gösterilmiştir. Öncelikle $2N$ boyutlu, $R_t = P_t \cup Q_t$ birleştirilmiş popülasyonu oluşturulur. Ardından R_t popülasyonu baskınlığa göre sıralanır. Önceki ve mevcut popülasyonlar R_t 'nin içinde olduğundan elitizm sağlanmış olur. En iyi bastırılmamış küme F_1 'e ait çözümler birleştirilmiş popülasyondaki en iyi çözümlerdir. Eğer F_1 'in boyutu N 'den küçükse, yeni popülasyon P_{t+1} için tüm F_1 seçilir. Yeni popülasyonun geri kalan elemanları yüzey numaralarına göre diğer cephelerden seçilir. Bu işlem birleştirilebilecek herhangi küme kalmayana dek sürdürülür. F_l , P_{t+1} 'e eklenecek son bastırılmamış küme olmak üzere, tam olarak N birey seçmek için F_l kümesindeki çözümler \prec_n operatörü kullanılarak azalan sırada sıralanır ve en iyi çözümler seçilerek popülasyon tamamlanır (Deb ve ark., 2002).



Şekil 3.8. NSGA-II algoritması genel şeması (Deb ve ark., 2002)

NSGA-II algoritmasının sözde kodu Şekil 3.9'da verilmiştir (Deb ve ark., 2002).

```

 $R_t = P_t \cup Q_t$  // ebeveyn ve çocuk popülasyonları birleştirilir
 $F = \text{HizliBastirilmamisSiralama}(R_t)$  //  $F = (F_1, F_2, \dots)$   $R_t$ 'nin tüm bastırılmamış cepheleri
 $P_{t+1} = \emptyset$ 
 $i = 1$ 
until  $|P_{t+1}| + |F_i| \leq N$  // ebeveyn popülasyon dolana kadar
     $\text{KalabaliklikMesafesiHesaplama}(F_i)$  //  $F_i$ 'deki kalabalıklık mesafesi hesaplanır
     $P_{t+1} = P_{t+1} \cup F_i$  // ebeveyn popülasyondaki  $i$ . bastırılmamış cephe eklenir
     $i = i + 1$  // ekleme için bir sonraki cepheye bakılır
Sort( $F_i, <_n$ ) // azalan sırada  $<_n$  kullanılarak sıralanır
 $P_{t+1} = P_{t+1} \cup F_i[1:(N - |P_{t+1}|)]$  //  $F_i$ 'nin ilk  $(N - |P_{t+1}|)$  elemanı seçilir
 $Q_{t+1} = \text{YeniPopOlustur}(P_{t+1})$  // Yeni  $Q_{t+1}$  popülasyonunun oluşturulması için
    çaprazlama ve mutasyon kullanılır
 $t = t + 1$  // nesil sayacı bir arttırılır

```

Şekil 3.9. NSGA-II algoritması sözde kodu (Deb ve ark., 2002)

3.5.2. Çok amaçlı parçacık sürü optimizasyonu

Klasik PSO'dan farklı olarak, çok amaçlı PSO'da en iyi konum belirlenirken, yalnızca bir tane en iyi söz konusu olmadığından en iyi konum, baskınlık kullanılarak belirlenir. Global en iyi konum yerine bastırılmamış çözümler kümesi getirilir. Denklem 3.4'de bir önceki global en iyi değeri, bastırılmamış çözümler kümesinden rastgele bir elemanın seçilmesiyle belirlenir. Yerel en iyi başlangıçta, her bir parçacık için rastgele üretilen konum olarak belirlenir. Ardından her olası yeni çözüm üretiminde, mevcut yerel en iyi ile bir önceki yerel en iyi baskınlık ilişkisi bakımından karşılaştırılır. Eğer yeni çözüm, mevcut çözümü bastırırsa yeni yerel en iyi olur. Eğer mevcut çözüm, yeni

çözümü bastırırsa, yerel en iyi değişmez. Eğer herhangi baskınlık durumu söz konusu değilse mevcut en iyi ile yeni çözüm arasında, yeni yerel en iyinin belirlenmesi için rastgele bir seçim yapılır. Her bir iterasyonda bastırılmamış çözümler kümesi kontrol edilir. Yeni bastırılmayan çözümler varsa kümeye eklenir ve eklenen çözümlerle kümedeki mevcut çözümler arasındaki son baskınlık durumu kontrol edilir. Eğer bastırılan çözümler varsa kümeden çıkarılır. Tüm iterasyonlar sonunda kümedeki çözümler Pareto optimal çözümlerdir (Bejinariu ve ark., 2017).

3.5.3. Çok amaçlı yapay arı kolonisi

MOABC yöntemi birkaç farklılık dışında Bölüm 3.4'de bahsedildiği gibidir. Optimal çözümlerin tutulduğu bir arşiv yapısı vardır. İşçi arı aşamasında, her bir işçi arıyla ilişkili yiyecek kaynağı için arşivden rastgele bir yiyecek kaynağı seçilir. Güncelleme işleminin ardından yeni ve mevcut çözümün uygunluk değerleri hesaplanır. Eğer yeni çözüm mevcut çözümü bastırırsa yeni çözüm mevcut çözümün yerini alır. Benzer uygulama gözcü arı aşamasında da gerçekleştirilir. Ancak, yiyecek kaynaklarının kaliteleri hesaplanırken Denklem 3.7'den yararlanılır (Akbari ve ark., 2012).

$$fit_i = \frac{Baskınlık(i)}{SN} \quad (3.7)$$

Denklem 3.7'de, $Baskınlık(i)$, i yiyecek kaynağı tarafından bastırılan yiyecek kaynaklarının sayısını gösterir. Olasılık, Denklem 3.6'deki gibi hesaplanır. Olasılığa göre yiyecek kaynağı seçildikten sonra arşivden rastgele farklı bir yiyecek kaynağı seçilir. Güncelleme işlemi işçi arı aşamasındaki gibidir (Akbari ve ark., 2012).

İşçi, gözcü ve kâşif arı aşamaları tamamlandıktan sonra arşiv güncellenir. Bunun için öncelikle arşivdeki tüm çözümlerin uygunluk değerleri hesaplanır. Çözümlerin birbirlerine olan baskınlık durumları kontrol edildikten sonra bastırılan çözümler arşivden çıkarılır. Böylece arşivde yalnızca bastırılmayan çözümler bulunur.

3.6. Çalışmada Gerçekleştirilen Görüntü Zenginleştirme Yöntemleri

Bu tez çalışmasında düşük kontrastlı, renkli görüntülerin; ABC, PSO, GA, NSGA-II, MOPSO ve MOABC yöntemleri kullanılarak zenginleştirilmeleri hedeflenmiştir. Tüm yöntemlerde ortak olarak, girdi görüntüsü RGB renk uzayından HSV renk uzayına dönüştürülmüş ve V (değer) bileşeni ayrılarak tüm işlemler bu bileşene uygulanmıştır. Çok amaçlı yöntemlerle gerçekleştirilen zenginleştirme işlemi için iki adet amaç fonksiyonu belirlenmiştir. Bu amaç fonksiyonları, Wu (2011) tarafından önerilen kontrast kazancı ve ton bozulmasıdır. Tek amaçlı yöntemlerle gerçekleştirilen zenginleştirme işlemlerinde, bu iki amacın birleşiminden oluşan uygunluk fonksiyonu kullanılmıştır. Wu (2011) tarafından önerilen içerikten bağımsız kontrast Denklem 3.8'de tanımlanmıştır.

$$C(p) = p_0(x_1 - x_0) + \sum_{k=1}^{K-1} p_k(x_k - x_{k-1}) \quad 0 < K \leq L \quad k = 1, \dots, K - 1 \quad (3.8)$$

Denklem 3.8'de K görüntüde bulunan gri seviye değerlerini, $L = 2^b$ olmak üzere b girdi görüntüsündeki bir pikselin gri seviye değerinin ifade edilmesi için gerekli biti temsil etmektedir. Ayrıca x_k gri seviye değerlerini ve p_k bu değerlerin olasılığını göstermektedir. Dönüşüm fonksiyonu Denklem 3.9'da tanımlanmıştır (Bejinariu ve ark., 2017).

$$T: \{0,1, \dots, L\} \rightarrow \{0,1, \dots, \bar{L}\} \quad (3.9)$$

Yukarıdaki ifadede \bar{L} dönüştürülmüş histogramdaki gri seviye değerlerinin sayısını göstermektedir. Dönüşüm fonksiyonu Denklem 3.10'daki gibi ifade edilmiştir (Bejinariu ve ark., 2017).

$$T(i) = \sum_{j=0}^i s_j, \quad 0 \leq i < L, \quad s_j \in \{0,1, \dots, \bar{L}\}, \quad \sum_{j=0}^{L-1} s_j < \bar{L} \quad (3.10)$$

Denklem 3.10'da s_j , her bir j piksel değerinin içerikten bağımsız kontrast değeri olup piksel durumu değerlendirilmeksizin çıkış gri seviye değerindeki değişim oranını ifade etmektedir. Denklem 3.8 ve Denklem 3.10 kullanılarak tanımlanan kontrast

kazancı Denklem 3.11’de ifade edilmiştir. Kontrastın zenginleştirilmesi için G değerinin maksimize edilmesi gerekmektedir (Bejinariu ve ark., 2017).

$$G(s) = \sum_{j=0}^{L-1} p_j s_j \quad (3.11)$$

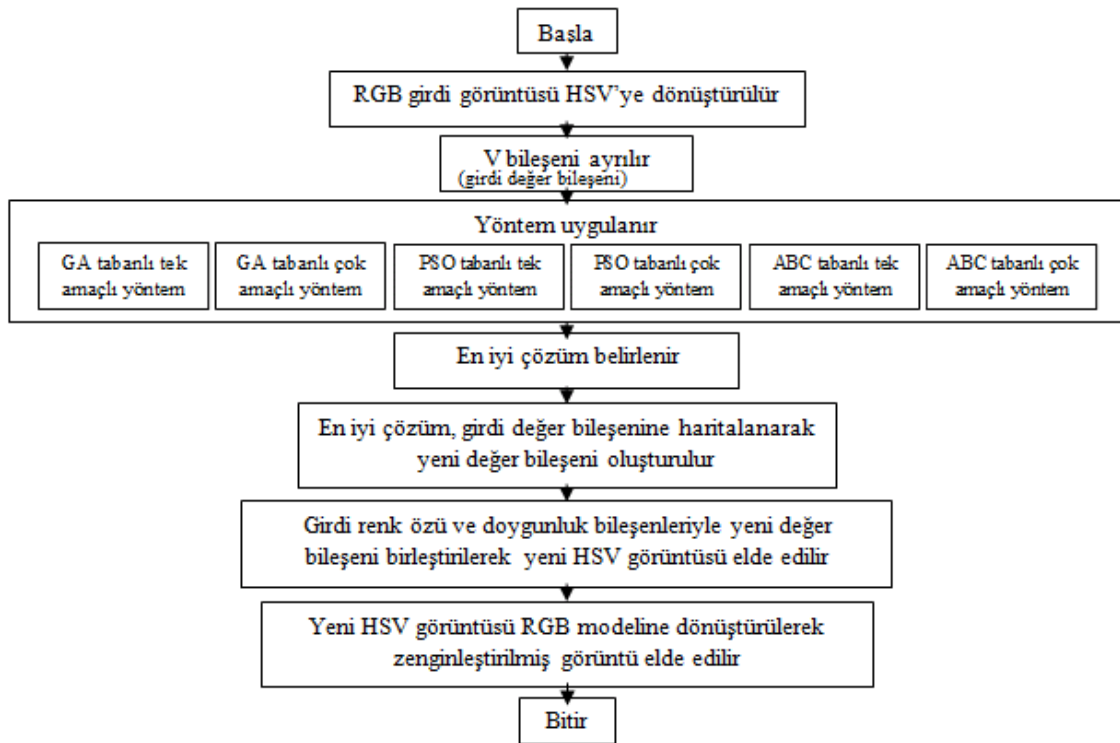
Zenginleştirilmiş görüntüde yapay görünümlere ve aşırı abartılmış kontrasta sebebiyet vermemek için ton doğruluğu göz önünde bulundurulmalıdır. Bunu gerçekleştirmek için Wu (2011) tarafından önerilen ton bozulması fonksiyonu Denklem 3.12’de tanımlanmıştır (Bejinariu ve ark., 2017). D değerinin minimize edilmesi hedeflenmektedir. Ton bozulması hesaplanırken, daha net sonuçlar elde etmek için $[0,255]$ aralığında tamsayı değerler kullanılmıştır. Tez çalışmasında gerçekleştirilen tek amaçlı yöntemlerde kullanılan uygunluk fonksiyonu Denklem 3.13’de verilmiştir.

$$D(s) = \max_{1 \leq i, j \leq L} \{ |j - i| \mid T(i) = T(j) ; p_i > 0, p_j > 0 \} \quad (3.12)$$

$$\max_s \{ G(s) - \lambda D(s) \} \quad (3.13)$$

Denklem 3.13’de λ , iki optimizasyon parametresi arasındaki önem dengesini belirleyen çarpandır (Bejinariu ve ark., 2017). Uygulanan yöntemlerde problem boyutu, Bejinariu ve ark. (2017) çalışmalarındaki gibi, girdi görüntüsünde bulunan gri seviye değeri sayısı kadardır. Bu sebeple girdi görüntüsüne göre değişkenlik göstermektedir. Normalize değerler kullanıldığı için değer aralığı $[0,1]$ ’dir. Uygulanan tüm yöntemlerde, problemin olası çözümlerinin tanımında, Hashemi ve ark. (2010) çalışmalarında olduğu gibi gri seviye değerler kullanılmıştır.

Tez çalışmasında gerçekleştirilen tek ve çok amaçlı görüntü zenginleştirme yöntemlerinin genel akış şeması Şekil 3.10’da verilmiştir.



Şekil 3.10. Tek ve çok amaçlı yöntemlerin genel akış şeması

Tüm yöntemlerde olduğu gibi, öncelikle RGB formatındaki renkli girdi görüntüsü, HSV renk uzayına dönüştürülür. HSV formatına dönüştürülen görüntüden V bileşeni ayrıştırılır. Bundan sonra uygulanan tüm işlemler V bileşeni üzerinde gerçekleştirilir.

Kontrast kazancı ve ton bozulması değerlerinin belirlenmesi için girdi görüntüsünde bulunan gri seviye değerleri ($[0,1]$ aralığına normalize edilmiş) tespit edilir. Bu gri seviye değerlerinin görüntüde bulunma olasılıkları hesaplanır.

3.6.1. Genetik algoritma tabanlı tek amaçlı yöntem ile görüntü zenginleştirme

İlk olarak başlangıç popülasyonu $[0,1]$ aralığında rastgele değerlerle, artan sırada oluşturulur. Bireylerin sıralı genlerle oluşturulmasının sebebi, eski gri seviye değerlerine yenilerinin haritalanmasını kolaylaştırmaktır. Başlangıç popülasyonu oluşturulduktan sonra maksimum nesil sayısına ulaşılan kadar öncelikle, popülasyondaki her bir bireyin uygunluk değeri Denklem 3.13'e göre belirlenir. Belirlenen uygunluk değerlerinden faydalanılarak ikili turnuva seçim yöntemiyle çaprazlanacak bireyler belirlenir. Tekli aritmetik rekombinasyon uygulanarak çocuk bireyler elde edilir. Mutasyon işlemi, rastgele mutasyon oranınca belirlenen bireylere,

mutant gen oranı kadar genin rastgele $[0,1]$ aralığında bir değerle, mevcut değerlerinin değiştirilmesiyle gerçekleştirilir. Mutasyon işlemi sırasında, mutasyona uğrayan genlerin değer aralıklarının dışına çıkıp çıkmadıkları kontrol edilir. Değer aralıklarının dışına çıkan genler sınır değerlere çekilir.

Maksimum nesil sayısına ulaşıldığında en yüksek uygunluk değerine sahip birey optimal çözüm olarak seçilir. Eski gri seviye değerlerine seçilen bireyin genleri haritalanarak zenginleştirilmiş görüntü oluşturulur. Oluşturulan zenginleştirilmiş görüntü ile girdi görüntüsünün H ve S bileşenleri birleştirilerek zenginleştirilmiş HSV görüntüsü oluşturulur. Oluşturulan bu görüntü de RGB renk uzayına dönüştürülür.

3.6.2. Genetik algoritma tabanlı çok amaçlı yöntem ile görüntü zenginleştirme

Başlangıç aşamasında öncelikle başlangıç popülasyonu $[0,1]$ aralığında rastgele değerlerle, artan sırada oluşturulur. Başlangıç popülasyonundaki her bir bireyin kontrast kazancı ve ton bozulması değerleri sırasıyla Denklem 3.11 ve Denklem 3.12'ye göre belirlenir. Çözümlerin ait olduğu cepheler ve yüzey numaraları da belirlendikten sonra kalabalıklık mesafeleri hesaplanır. Belirlenen yüzey numaraları ve kalabalıklık mesafelerinden faydalanılarak ikili turnuva seçim yöntemiyle çaprazlanacak bireyler belirlenir. Ancak klasik NSGA-II yönteminden farklı olarak, hem yüzey numaraları hem de kalabalıklık mesafeleri aynı olan bireylerden ton bozulması düşük olan ve eğer yüzey numaraları, kalabalıklık mesafeleri ve ton bozulmaları da eşitse kontrast kazancı büyük olan birey seçilir. Tekli aritmetik rekombinasyon uygulanarak çocuk bireyler elde edilir. Mutasyon uygulanacak bireyler mutasyon oranına göre belirlenir. Ardından bu bireylerin mutant gen oranına göre rastgele genleri seçilir. Seçilen genler $[0,1]$ aralığında rastgele başka bir değerle değiştirilir. Mutasyon işlemi sırasında, mutasyona uğrayan genlerin değer aralıklarının dışına çıkıp çıkmadıkları kontrol edilir. Değer aralıklarının dışına çıkan genler sınır değerlere çekilir.

Başlangıç aşamasından sonra maksimum nesil sayısına ulaşılan kadar, ilk iterasyonda, öncelikle başlangıç aşamasından elde edilen yeni popülasyon ve başlangıç popülasyonu birleştirilerek toplam popülasyon elde edilir. İlk iterasyondan sonra toplam popülasyonu, önceki nesilden elde edilen popülasyon ve yeni oluşturulan popülasyon birleştirilerek oluşturulur. Toplam popülasyonundaki her bir bireyin kontrast kazancı ve ton bozulması değerleri sırasıyla Denklem 3.11 ve Denklem 3.12'e göre belirlenir. Çözümlerin ait olduğu cepheler ve yüzey numaraları da belirlendikten sonra

kalabalıklık mesafeleri hesaplanır. Popülasyon, yüzey numarası ve kalabalıklık mesafelerine göre oluşturulur. Oluşturulan popülasyonun amaç fonksiyonu değerleri hesaplanır. Popülasyondaki bireyleri ait olduğu cepheler ve yüzey numarası değerleri belirlenir. Popülasyondaki tüm bireylerin kalabalıklık mesafeleri hesaplanır. Başlangıç aşamasında olduğu gibi seçim, rekombinasyon ve mutasyon işlemleri uygulanarak yeni popülasyon oluşturulur.

Maksimum nesil sayısına ulaşıldığında, çözüm kümesinde birinci cephedeki bireylerden en büyük CEF değerine sahip birey seçilir. Çok amaçlı yöntemlerde çözüm kümesinden bir çözüm seçilirken, renkli görüntülerin kalitelerinin ölçümünde kullanılması sebebiyle CEF değeri temel alınmıştır. Eski gri seviye değerlerine seçilen bireyin genleri haritalanarak zenginleştirilmiş görüntü oluşturulur. Oluşturulan zenginleştirilmiş görüntü ile girdi görüntüsünün H ve S bileşenleri birleştirilerek zenginleştirilmiş HSV görüntüsü oluşturulur. Oluşturulan bu görüntü de RGB renk uzayına dönüştürülür.

3.6.3. Parçacık sürü optimizasyonu tabanlı tek amaçlı yöntem ile görüntü zenginleştirme

Denklem 3.4'deki w değişkeni, Gorai ve Ghosh (2009)'un çalışmalarında uyguladıkları gibi Denklem 3.14'te verilen formülle belirlenir.

$$w^t = w_{max} - \frac{w_{max} - w_{min}}{t_{max}} \times t \quad (3.14)$$

Denklem 3.14'te t mevcut iterasyonu ifade eder. Kontrast kazancı ve ton bozulması değerlerinin belirlenmesi için girdi görüntüsünde bulunan gri seviye değerleri ([0,1] aralığına normalize edilmiş) tespit edilir. Bu gri seviye değerlerinin görüntüde bulunma olasılıkları hesaplanır.

Parçacıkların konum değerlerine başlangıçta, girdi görüntüsünde bulunan gri seviye değerli kadar, [0,1] aralığında ve rastgele değerler verilir. Başlangıç aşamasında tüm parçacıkların uygunluk değerleri Denklem 3.13'e göre hesaplanır. Parçacıkların x_{best} değerlerine başlangıçta kendi konum değerleri, $x_{g_{best}}$ değerine en yüksek uygunluk değerli konum vektörü verilir.

Başlangıç aşamasından sonra, maksimum iterasyona erişene kadar her iterasyonda, Denklem 3.4'deki r_1 ve r_2 parametrelerine her bir bireyin tüm bileşenleri için, rastgele $[0,0.001]$ aralığında değerler verilir. $x_{g_{best}}$ 'in uygunluk değeri hesaplanır. Her bir parçacığın x_{best} ve konum vektörlerinin uygunluk değerleri hesaplanarak x_{best} değerleri ve $x_{g_{best}}$ değeri güncellenir. w parametresi hesaplanır. Her bir parçacığın hızı hesaplanarak konumları güncellenir. Her bir parçacık için konum vektörleri güncellendikten sonra değer aralıklarının dışına çıkılıp çıkılmadığı kontrol edilir. Konum vektörleri sıralanır.

Maksimum iterasyon sayısına ulaşıldığında en yüksek uygunluk değerine sahip parçacık optimal çözüm olarak seçilir. Eski gri seviye değerlerine seçilen bireyin genleri haritalanarak zenginleştirilmiş görüntü oluşturulur. Oluşturulan zenginleştirilmiş görüntü ile girdi görüntüsünün H ve S bileşenleri birleştirilerek zenginleştirilmiş HSV görüntüsü oluşturulur. Oluşturulan bu görüntü de RGB renk uzayına dönüştürülür.

3.6.4. Parçacık sürü optimizasyonu tabanlı çok amaçlı yöntem ile görüntü zenginleştirme

Parçacıkların konum değerlerine başlangıçta, Bejinariu ve ark. (2017) çalışmalarından farklı olarak görüntüdeki gri seviye değerlerini ifade eden, $[0,1]$ aralığında rastgele, artan sırada değerler verilir. Konum vektörünün uzunluğu girdi görüntüsündeki gri seviye değeri sayısı kadardır. Başlangıç aşamasında tüm parçacıkların amaç fonksiyonları, Denklem 3.11 ve Denklem 3.12'ye göre hesaplanır. Parçacıkların x_{best} değerlerine başlangıçta kendi konum değerleri verilir.

Başlangıç aşamasından sonra, maksimum iterasyona erişene kadar her iterasyonda, Denklem 3.4'teki r_1 ve r_2 parametrelerine her bir parçacık konumunun tüm bileşenleri için, rastgele $[0,0.001]$ aralığında değerler verilir. Her bir parçacığın x_{best} ve konum vektörlerinin ton bozulması ve kontrast kazancı değerleri hesaplanarak x_{best} değerleri baskınlık ilişkisine göre güncellenir. Bastırılmayan çözümler tespit edilerek çözüm kümesine eklenir. $x_{g_{best}}$ değeri için çözüm kümesinden, Bejinariu ve ark. (2017)'nin çalışmalarından farklı olarak, renkli görüntülerin kalitelerinin ölçümünde kullanılan, CEF değeri en büyük olan çözüm seçilir. Her bir parçacığın hızı hesaplanarak konumları güncellenir. Her bir parçacık için konum vektörleri güncellendikten sonra değer aralıklarının dışına çıkılıp çıkılmadığı kontrol edilir.

Maksimum iterasyon sayısına ulaşıldığında $x_{g_{best}}$ optimal çözüm olarak seçilir. Eski gri seviye değerlerine seçilen bireyin genleri haritalanarak zenginleştirilmiş görüntü oluşturulur. Oluşturulan zenginleştirilmiş görüntü ile girdi görüntüsünün H ve S bileşenleri birleştirilerek zenginleştirilmiş HSV görüntüsü oluşturulur. Oluşturulan bu görüntü de RGB renk uzayına dönüştürülür.

3.6.5. Yapay arı kolonisi tabanlı tek amaçlı yöntem ile görüntü zenginleştirme

Başlangıç aşamasında öncelikle konum değerlerine rastgele başlangıç değerleri verilir. Terk edilen yiyecek kaynaklarının belirlenmesi için “kaynak bırakma” vektörü oluşturulup her bir kaynak için başlangıçta 0 değeri verilir. Bu değer kaynak güncellendiğinde sıfırlanıp aksi durumda bir arttırılır. Limit değeri problem boyutu ile işçi arı sayısının çarpımı olarak belirlenmiştir. Ardından tüm konumların uygunluk değerleri Denklem 3.13’e göre hesaplanır. Uygunluk değeri en büyük olan çözüm en iyi çözüm olarak belirlenir.

Maksimum iterasyona ulaşılan kadar öncelikle işçi arı aşamasında, her bir işçi arı ile ilişkili yiyecek kaynağı konumunun yeni oluşturulan aday yiyecek kaynağı konumuyla karşılaştırılması için rastgele bir boyut ve bir birey belirlenir. Denklem 3.5 kullanılarak yeni bir aday konum oluşturulur. Aday konumun uygunluk değeri hesaplanır. Yeni konum, mevcut konumla kıyaslanarak güncelleme işlemi gerçekleştirilir. Gözcü arı aşamasında öncelikle uygunlukların olasılıkları Denklem 3.6’ya göre hesaplanır. Her bir birey için rastgele bir birey ve hesaplanan olasılığa göre bir birey seçilir. Rastgele bir konum indisi belirlenir. Denklem 3.5’e göre oluşturulan adayın uygunluğu hesaplanarak olasılığa göre seçilen bireyin uygunluğu ile karşılaştırılır. Karşılaştırma sonucuna göre güncelleme gerçekleştirilir. Kâşif arı aşamasında ise eğer terk edilen yiyecek kaynağı varsa bunların yerine rastgele konumlar oluşturulur.

Maksimum iterasyon sayısına ulaşıldığında en yüksek uygunluk değerine sahip konum optimal çözüm olarak seçilir. Eski gri seviye değerlerine seçilen bireyin genleri haritalanarak zenginleştirilmiş görüntü oluşturulur. Oluşturulan zenginleştirilmiş görüntü ile girdi görüntüsünün H ve S bileşenleri birleştirilerek zenginleştirilmiş HSV görüntüsü oluşturulur. Oluşturulan bu görüntü de RGB renk uzayına dönüştürülür.

3.6.6. Yapay arı kolonisi tabanlı çok amaçlı yöntem ile görüntü zenginleştirme

Başlangıç aşamasında öncelikle konum değerlerine rastgele başlangıç değerleri verilir. Terk edilen yiyecek kaynaklarının belirlenmesi için “kaynak bırakma” vektörü oluşturulup her bir kaynak için başlangıçta 0 değeri verilir. Bu değer kaynak güncellendiğinde sıfırlanıp aksi durumda bir arttırılır. Limit değeri problem boyutu ile işçi arı sayısının çarpımı olarak belirlenmiştir. Ardından tüm konumların ton bozulması ve kontrast kazançları, Denklem 3.11 ve Denklem 12’ye göre hesaplanır. Bastırılmayan çözümler tespit edilip çözüm kümesine eklenir.

Maksimum iterasyona ulaşılan kadar öncelikle işçi arı aşamasında, her bir işçi arı ile ilişkili yiyecek kaynağı konumunun yeni oluşturulan aday yiyecek kaynağı konumuyla karşılaştırılması için rastgele bir boyut ve çözüm kümesinden rastgele bir birey belirlenir. Denklem 3.5 kullanılarak yeni bir aday konum oluşturulur. Aday konumun ton bozulması ve kontrast kazancı hesaplanır. Yeni konum, mevcut konumla baskınlık ilişkisine göre kıyaslanarak güncelleme işlemi gerçekleştirilir. Gözcü arı aşamasında öncelikle amaçlara göre olasılıklar, Denklem 3.6 ve Denklem 3.7’den faydalanarak hesaplanır. Her bir gözcü arıyla ilişkili yiyecek kaynağı konumu için rastgele bir birey çözüm kümesinden seçilir. Hesaplanan olasılığa göre başka bir birey koloniden seçilir. Rastgele bir konum indisi belirlenir. Denklem 3.5’e göre oluşturulan adayın ton bozulması ve kontrast kazancı hesaplanılır. Ardından olasılığa göre seçilen bireyle ilişkili yiyecek kaynağı konumu ile aday konum baskınlık ilişkisine göre karşılaştırılır. Karşılaştırma sonucuna göre güncelleme gerçekleştirilir. Kaşif arı aşamasında ise eğer terk edilen yiyecek kaynağı varsa bunların yerine rastgele konumlar oluşturulur.

Maksimum iterasyon sayısına ulaşıldığında çözüm kümesi güncellenerek en büyük CEF değerine sahip kaynak, optimal çözüm olarak seçilir. Eski gri seviye değerlerine seçilen bireyin genleri haritalanarak zenginleştirilmiş görüntü oluşturulur. Oluşturulan zenginleştirilmiş görüntü ile girdi görüntüsünün H ve S bileşenleri birleştirilerek zenginleştirilmiş HSV görüntüsü oluşturulur. Oluşturulan bu görüntü de RGB renk uzayına dönüştürülür.

3.7. Çalışmada Kullanılan Kalite Metrikleri

3.7.1. Pik sinyal gürültü oranı

Pik sinyal gürültü oranı, maksimum sinyal gücünün gürültüye oranıdır. Görüntülere uygulandığında, sinyal girdi görüntüsünü, gürültü ise çıktı görüntüsündeki hatayı temsil eder. PSNR hesaplanırken ortalama karesel hata (MSE)'dan faydalanılır. MSE, girdi görüntüsü ile çıktı görüntüsü arasındaki ortalama hatayı verir. MSE ne kadar düşüğe çıktı görüntüsünün kalitesi o kadar yüksektir. Dolayısıyla PSNR ne kadar yüksekse çıktı görüntüsünün kalitesi de o kadar yüksektir (Mondal ve ark., 2018). Denklem 3.15'de PSNR formülü verilmiştir.

$$\text{PSNR} = 10 \log_{10}(P^2/\text{MSE}) \quad (3.15)$$

$$\text{MSE} = \sum_{m,n} [X(m,n) - Y(m,n)]^2 / N \quad (3.16)$$

Denklem 3.15'de P görüntüde bulunan piksellerin alabileceği en büyük değeri, Denklem 3.16'da MSE ortalama karesel hatayı, X girdi görüntüsünü, Y çıktı görüntüsünü, m ve n gri seviye değerlerinin sırasıyla apsis ve ordinat eksenlerindeki konumlarını, N ise görüntü boyutunu ifade etmektedir.

3.7.2. Yapısal benzerlik indeksi

Yapısal benzerlik indeksi (SSIM), Wang ve ark. (2004) tarafından önerilen, görüntüdeki yapısal bilgiyi kullanan kalite metriğidir. Üç terimin bileşiminden oluşur: parlaklık, kontrast ve yapısal terim. SSIM, $[-1,1]$ aralığında değer alır. Eğer iki görüntü birbirine eşitse en yüksek değer olan 1 değerini alır. Orijinal görüntüye oranla daha yüksek yapısal kayba uğrayan zenginleştirilmiş görüntü daha düşük SSIM değeri alırken daha düşük kaybı olan zenginleştirilmiş görüntü daha yüksek SSIM değeri alır (Prabha ve Kumar, 2017). Denklem 3.17'de SSIM formülü verilmiştir.

$$\text{SSIM} = \frac{(2\mu_a\mu_b + C_1)(2\sigma_{ab} + C_2)}{(\mu_a^2 + \mu_b^2 + C_1)(\sigma_a^2 + \sigma_b^2 + C_2)} \quad (3.17)$$

$$\mu_a = \frac{1}{N} \sum_{x=1}^N a_x, \quad \mu_b = \frac{1}{N} \sum_{x=1}^N b_x \quad (3.18)$$

$$\sigma_a^2 = \frac{1}{N-1} \sum_{x=1}^N (a_x - \mu_a)^2, \sigma_b^2 = \frac{1}{N-1} \sum_{x=1}^N (b_x - \mu_b)^2, \sigma_{ab}^2 = \frac{1}{N-1} \sum_{x=1}^N (a_x - \mu_a)(b_x - \mu_b) \quad (3.19)$$

Denklem 3.17’de a orijinal görüntüyü, b zenginleştirilmiş görüntüyü ifade etmektedir. Denklem 3.18 ve 3.19’da a_x a, b_x b görüntüsündeki piksel değerini, μ_a a, μ_b b görüntüsünün ortalaması, σ_a a, σ_b b görüntüsündeki standart sapmayı, σ_{ab} a ve b görüntülerinin kovaryansını, C_1 ve C_2 sabit değerleri ifade etmektedir.

3.7.3. Kontrast geliştirme indeksi

CII, işlenen görüntünün orijinal görüntüye oranla kontrastında meydana gelen gelişmenin oranının ölçülmesinde kullanılmaktadır (Raju ve Nair, 2014). CII formülü (Zeng ve ark., 2004) Denklem 3.20’de verilmiştir.

$$CII = \frac{C_0}{C_1} \quad (3.20)$$

$$C_0 = \frac{X_{Omax} - X_{Omin}}{X_{Omax} + X_{Omin}} \quad (3.21)$$

$$C_1 = \frac{X_{Imax} - X_{Imin}}{X_{Imax} + X_{Imin}} \quad (3.22)$$

Denklem 3.20’de çıktı görüntüsündeki ortalama kontrast C_0 ve girdi görüntüsündeki ortalama kontrast değeri C_1 ile gösterilmiştir. Görüntüler, 3x3 boyutlarında bir pencere kullanılarak taranır. Her seferinde pencere içerisindeki ortalama kontrast Denklem 3.21 ve Denklem 3.22’ye göre hesaplanır. Denklem 3.21’de X_{Omax} , çıktı görüntüsüne uygulanan penceredeki en büyük piksel değeri, X_{Omin} penceredeki en küçük piksel değerini ifade etmektedir. Denklem 3.22’de X_{Imax} , girdi görüntüsüne uygulanan penceredeki en büyük piksel değeri, X_{Imin} penceredeki en küçük piksel değerini ifade etmektedir (Raju ve Nair, 2014). CII ile görüntü kalitesi arasında doğru orantı olup CII değerinin yüksek olması görüntü kalitesinin yüksek olduğu anlamına gelmektedir.

3.7.4. Renk zenginleştirme faktörü

Renklilik, Hunt (1977) tarafından, bir bölgeden algılanan rengin daha az veya daha çok kromatik görünmesine dayanan bir görsel algı niteliği olarak tanımlanmıştır.

Renklilik metriği (CM), Süsstrunk ve Winkler (2004) tarafından önerilen, renkli görüntü kalite metriğidir. Denklem 3.23’de formülü verilmiştir.

$$CM = \sqrt{\sigma_{\alpha}^2 + \sigma_{\beta}^2} + 0.3 \times \sqrt{\mu_{\alpha}^2 + \mu_{\beta}^2} \quad (3.23)$$

$$\alpha = R - G \quad (3.24)$$

$$\beta = \frac{R+G}{2} - B \quad (3.25)$$

Denklem 3.23’de σ standart sapmayı, μ ortalamayı, Denklem 3.24’te R kırmızı renk kanalını, G yeşil renk kanalını ve Denklem 3.25’te B , mavi renk kanalını göstermektedir.

$$CEF = \frac{CM_O}{CM_I} \quad (3.26)$$

Renk zenginleştirme faktörü (CEF), renkli görüntülerin kalitesinin ölçülmesinde kullanılır (Lal ve ark., 2015). Sonuç görüntüsünün CM değerinin orijinal görüntünün CM değerine oranı ile hesaplanır. Denklem 3.26’da renk zenginleştirme faktörünün formülü verilmiştir. Denklem 3.26’da CM_O çıktı görüntüsünün renklilik metriğini, CM_I girdi görüntüsünün renklilik metriğini ifade etmektedir.

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu tez çalışmasında, renkli ve düşük kontrasta sahip görüntülerin, tek ve çok amaçlı optimizasyon yöntemleri ile zenginleştirilmesi hedeflenmiştir. Bu işlem; GA, NSGA-II, PSO, MOPSO, ABC ve MOABC algoritmaları kullanılarak gerçekleştirilmiştir.

8 adet standart test görüntüsüne, çalışmada gerçekleştirilen tek ve çok amaçlı yöntemler ile HE, CS ve CLAHE geleneksel yöntemleri uygulanarak karşılaştırma yapılmıştır. Elde edilen zenginleştirilmiş görüntülerin objektif değerlendirmesi, 3. Bölümde açıklanan kalite metrikleri kullanılarak gerçekleştirilmiştir.

Uygulanan tüm optimizasyon yöntemlerinde, amaç fonksiyonlarının eşit sayıda hesaplanması sağlanmıştır. Bu sebeple literatürdeki PSO tabanlı çok amaçlı yaklaşımda kullanılan 50 parçacık ve 100 iterasyon ayarlamasına uygun olarak; GA ve NSGA-II yöntemlerinde, popülasyondaki birey sayısı 100 ve maksimum nesil sayısı 50, PSO ve MOPSO yöntemlerinde, parçacık sayısı 50 ve maksimum iterasyon sayısı 100 ve ABC ve MOABC yöntemlerinde ise, kolonideki toplam arı sayısı, 50 işçi 50 gözcü olmak üzere 100, maksimum iterasyon sayısı 50 olarak belirlenmiştir. GA ve NSGA-II yöntemlerinde deneysel çalışmalar sonucunda; çaprazlama oranı 0.9, mutasyon oranı 0.3, mutant gen oranı 0.01 ve rekombinasyon katsayısı (α) 0.5 olarak belirlenmiştir. PSO ve MOPSO yöntemlerinde; Denklem 3.14'deki w_{max} ve w_{min} değerleri deneysel çalışmalar sonucunda, sırasıyla 0.001 ve 0.0001 olarak belirlenmiştir. Denklem 3.4'deki c_1 ve c_2 katsayıları, Gorai ve Ghosh (2009) çalışmalarındaki gibi [0,2] aralığında rastgele olarak belirlenmiştir. Ayrıca GA, PSO ve ABC yöntemlerinde amaç katsayısı (λ) deneysel çalışmalar sonucunda, 0.001 olarak belirlenmiştir.

Çalışmada kullanılan standart test görüntüleri Çizelge 4.1'de verilmiştir. Test görüntülerinden “4.1.01”, “4.1.02”, “4.1.06” ve “lena” görüntüleri (SIPI Image Database) veritabanından, “image18” ve “image23” görüntüleri (Retinex Image Processing) veritabanından ve “kodim04” ve “kodim21” görüntüleri ise (True Color Kodak Images) veritabanından alınmış görüntü isimleri değiştirilmeden dosya isimlerinde olduğu gibi bırakılmıştır.

Çizelge 4.1. Test görüntüleri

	
4.1.01	4.1.02
	
4.1.06	Image18
	
Image23	Kodim04
	
Kodim21	Lena

Çizelge 4.1’de verilen “Kodim04” ve “Kodim21” görüntülerinin orijinal boyutları 512x768 olup hesaplama süresini kısaltmak için 256x384’e küçültülmüştür.

Çalışmada gerçekleştirilen tüm yöntemler; PSNR, SSIM, CII ve CEF kalite metrikleri kullanılarak değerlendirilmiştir. Çalışmada kullanılan tüm test görüntülerinin değerlendirme sonuçları ve 10 farklı çalıştırmadan elde edilen sonuçların; minimum, maksimum, ortalama, standart sapma ve ortanca değerleri çizelgelerde verilmiştir. Çizelgelerde koyu renkle gösterilen değerler, buldukları kalite metriği sütununda, 10 çalıştırma içerisinde en iyi değeri ifade etmektedir. Çizelgede en çok sayıda kalite metriğinde en yüksek değeri alan çalıştırma, karşılaştırma için seçilen çalıştırma olup, “*” sembolü ile işaretlenmiştir. Bir görüntü için birden fazla işaretli çalıştırma olması durumunda, işaretli çalıştırmalardan amaç değeri daha iyi olan, amaç değerleri de aynıysa biri rastgele seçilmiştir. 10 farklı çalıştırma içerisinde seçilen görüntüler orijinalleriyle birlikte verilmiştir. Seçilen görüntülerin değer (V) bileşenlerinin histogram grafikleri ve çok amaçlı yaklaşımların seçilen sonuçlarının Pareto yüzeyleri de verilmiştir. Pareto yüzey grafiklerinde, ordinat ekseninde kontrast kazancı aşağı doğru artan, abscis ekseninde ton bozulması sola doğru azalan sırada verilmiştir. Ayrıca genel bir sayısal değerlendirme yapabilmek için her bir kalite metriği ayrı ayrı dikkate alınarak, her bir görüntüde tüm yöntemlerle elde edilen değerlerin ortalamaları alınmış ve tek tek yöntemlerin bu ortalamaya göre durumları değerlendirilmiştir. Tek ve çok amaçlı yöntemlerin ve klasik yöntemlerin de kendi içlerinde ortalamaları alınmıştır. Böylece hem tek ve çok amaçlı yöntemlerin birbiriyle hem de çalışmada gerçekleştirilen yöntemlerin klasik yöntemlerle karşılaştırılması yapılmıştır.

Çizelge 4.2’de “4.1.01” test görüntüsünün, genetik algoritma tabanlı tek amaçlı zenginleştirme yönteminin uygulandığı 10 farklı çalıştırmadan elde edilen sayısal değerlendirme sonuçları örnek olarak verilmiştir. Aynı şekilde, tüm yöntemlerde tüm test görüntüleri için 10 farklı çalıştırma gerçekleştirilmiştir.

Çizelge 4.2. “4.1.01” test görüntüsü sayısal değerlendirme sonuçları

4.1.01	PSNR	SSIM	CII	CEF	Kazanç	Bozulma
1	17.3812	0.8798	0.8461	1.354433	0.0063	2
2	19.2891	0.9069	0.9068	1.287206	0.0065	2
3	20.48235	0.918074	0.889748	1.239924	0.007025	2
4	16.39586	0.864251	0.905853	1.411222	0.006477	2
5	20.46869	0.907041	0.867322	1.240014	0.007383	3
6	17.76037	0.893835	0.900129	1.351681	0.006589	2
7	19.34286	0.904404	0.867891	1.280615	0.006664	2
8	20.55972	0.927703	1.050774	1.261489	0.006233	2
9*	22.62048	0.948071	0.984091	1.204988	0.006079	2
10	17.7343	0.888856	0.883963	1.337218	0.006429	2

Çizelge 4.3’de genetik algoritma tabanlı tek amaçlı zenginleştirme yönteminin uygulandığı 8 test görüntüsünün her birinin 10 farklı çalıştırmadan elde edilen sonuçlarının, kalite metriklerine ve amaçlara göre standart sapma, minimum, maksimum, ortalama ve ortanca değerleri verilmiştir.

Çizelge 4.3. Genetik algoritma tabanlı tek amaçlı zenginleştirme yöntemin 8 test görüntüsüne uygulanmasından elde edilen istatistiksel sonuçlar

		PSNR	SSIM	CII	CEF	Kazanç	Bozulma
4.1.01	Standart S.	1.892169	0.024079	0.061641	0.064592	0.000385	0.316
	Minimum	16.39586	0.864251	0.8461	1.204988	0.006079	2
	Maksimum	22.62048	0.948071	1.050774	1.411222	0.007383	3
	Ortalama	19.20349	0.903893	0.910267	1.296879	0.006568	2.1
	Ortanca	19.31598	0.905652	0.894939	1.283911	0.006489	2
4.1.02	Standart S.	1.805764	0.035065	0.079211	0.083084	0.000296	0
	Minimum	18.70413	0.81078	0.905671	1.224181	0.006021	2
	Maksimum	25.65442	0.946484	1.12853	1.54699	0.006983	2
	Ortalama	21.49685	0.888789	0.999214	1.398438	0.006516	2
	Ortanca	21.28155	0.887948	0.996815	1.402695	0.006512	2
4.1.06	Standart S.	1.184332	0.037955	0.17544	0.032862	0.000192	0
	Minimum	16.01653	0.787617	1.809168	0.716343	0.005572	2
	Maksimum	19.94151	0.921194	2.419424	0.811727	0.006116	2
	Ortalama	17.57292	0.859042	2.146391	0.764654	0.005815	2
	Ortanca	17.70413	0.86823	2.154507	0.769899	0.005785	2
İmage18	Standart S.	2.72836	0.016868	0.095769	0.100354	0.000281	0
	Minimum	21.59038	0.915573	0.861332	1.066702	0.004638	2
	Maksimum	31.54765	0.976826	1.116571	1.405954	0.005426	2
	Ortalama	26.18286	0.957747	0.97492	1.174018	0.00486	2
	Ortanca	26.31928	0.961098	0.945328	1.168432	0.004726	2
İmage23	Standart S.	3.010886	0.005909	0.048183	0.051098	0.000329	0.421
	Minimum	28.537	0.972951	0.922385	0.937371	0.003577	2
	Maksimum	39.74075	0.991343	1.063779	1.140326	0.004624	3
	Ortalama	34.50037	0.981743	1.006416	1.04748	0.004316	2.8
	Ortanca	34.29947	0.983099	1.007938	1.05367	0.004372	3
Kodim04	Standart S.	3.672652	0.005659	0.059304	0.039222	0.000326	0.516
	Minimum	25.01342	0.970081	1.0265	0.910901	0.004	2
	Maksimum	38.8672	0.9872	1.202032	1.044409	0.004837	3
	Ortalama	32.88205	0.980765	1.105909	0.991642	0.004486	2.6
	Ortanca	32.81517	0.981303	1.1058	0.99197	0.00465	3
Kodim21	Standart S.	3.799802	0.011132	0.095708	0.043121	0.000569	0.483
	Minimum	23.94541	0.952745	1.186736	0.894137	0.004486	2
	Maksimum	33.25958	0.983356	1.505844	1.008102	0.006079	3
	Ortalama	28.20781	0.969696	1.304078	0.947531	0.005374	2.7
	Ortanca	26.56622	0.971683	1.264456	0.944508	0.005563	3
Lena	Standart S.	1.233283	0.01365	0.163289	0.031976	0.000138	0
	Minimum	16.06661	0.888809	1.613397	0.883368	0.005318	2
	Maksimum	19.82782	0.930849	2.171928	0.977825	0.00569	2
	Ortalama	18.33253	0.915959	1.901073	0.922473	0.005491	2
	Ortanca	18.56748	0.91952	1.89972	0.919409	0.005482	2

Çizelge 4.4’de parçacık sürü optimizasyonu tabanlı tek amaçlı zenginleştirme yönteminin uygulandığı 8 test görüntüsünün her birinin 10 farklı çalıştırmadan elde edilen sonuçlarının, kalite metriklerine ve amaçlara göre standart sapma, minimum, maksimum, ortalama ve ortanca değerleri verilmiştir.

Çizelge 4.4. Parçacık sürü optimizasyonu tabanlı tek amaçlı zenginleştirme yönteminin 8 test görüntüsüne uygulanmasından elde edilen istatistiksel sonuçlar

		PSNR	SSIM	CII	CEF	Kazanç	Bozulma
4.1.01	Standart S.	1.424276	0.024717	0.049998	0.053491	0.000267	0
	Minimum	17.0527	0.8644	0.8724	1.243878	0.006	2
	Maksimum	20.8949	0.9372	1.0366	1.382514	0.0068	2
	Ortalama	18.88368	0.89895	0.96746	1.311109	0.00646	2
	Ortanca	18.74205	0.9033	0.97895	1.317153	0.0065	2
4.1.02	Standart S.	1.410626	0.028147	0.069278	0.098834	0.000286	0
	Minimum	16.0534	0.7662	0.8257	1.459056	0.0063	2
	Maksimum	20.1424	0.8449	1.042	1.748821	0.0073	2
	Ortalama	18.65644	0.81326	0.93295	1.555532	0.00678	2
	Ortanca	19.2638	0.8205	0.93825	1.509679	0.0067	2
4.1.06	Standart S.	0.613225	0.014988	0.137984	0.021833	0.000408	0.316
	Minimum	16.3883	0.8338	1.9749	0.723083	0.005	1
	Maksimum	18.3588	0.8793	2.4108	0.795645	0.0061	2
	Ortalama	17.71695	0.85834	2.22326	0.771246	0.00562	1.9
	Ortanca	17.9091	0.8629	2.2562	0.778918	0.00575	2
İmage18	Standart S.	2.756968	0.019286	0.115108	0.096355	0.000348	0
	Minimum	20.6083	0.9103	0.851	1.09121	0.0044	2
	Maksimum	29.0242	0.9746	1.2329	1.36625	0.0054	2
	Ortalama	24.94799	0.94676	1.04787	1.200475	0.00489	2
	Ortanca	24.47775	0.94845	1.07025	1.200334	0.00495	2
İmage23	Standart S.	3.352219	0.009358	0.045815	0.051366	0.000241	0.516
	Minimum	30.221	0.9669	0.9293	0.971395	0.0039	2
	Maksimum	38.8189	0.9933	1.1	1.129558	0.0046	3
	Ortalama	34.64995	0.98136	0.99767	1.066898	0.00434	2.6
	Ortanca	33.6186	0.9837	0.98735	1.078709	0.00435	3
kodim04	Standart S.	2.818615	0.006373	0.054818	0.038077	0.000302	0.483
	Minimum	24.7176	0.9629	1.1603	0.921991	0.0038	2
	Maksimum	32.803	0.9827	1.3386	1.045715	0.0049	3
	Ortalama	28.44237	0.97268	1.23474	0.971066	0.00453	2.3
	Ortanca	29.2997	0.973	1.22285	0.969793	0.0046	2
Kodim21	Standart S.	4.045673	0.011817	0.058437	0.048416	0.000495	0.483
	Minimum	22.0828	0.9511	1.2062	0.865795	0.0041	2
	Maksimum	33.8231	0.9832	1.3867	1.005963	0.0059	3
	Ortalama	27.38204	0.9658	1.30733	0.936536	0.00511	2.3
	Ortanca	26.52205	0.96215	1.314	0.925941	0.0052	2
Lena	Standart S.	1.3152	0.020908	0.174567	0.028887	0.000267	0
	Minimum	15.8203	0.8559	1.7883	0.876326	0.0052	2
	Maksimum	19.9359	0.926	2.3557	0.957596	0.0063	2
	Ortalama	16.92306	0.88824	2.04925	0.90231	0.00567	2
	Ortanca	16.40075	0.88815	1.99025	0.894551	0.00565	2

Çizelge 4.5’de yapay arı kolonisi tabanlı tek amaçlı zenginleştirme yönteminin uygulandığı 8 test görüntüsünün her birinin 10 farklı çalıştırmadan elde edilen sonuçlarının, kalite metriklerine ve amaçlara göre standart sapma, minimum, maksimum, ortalama ve ortanca değerleri verilmiştir.

Çizelge 4.5. Yapay arı kolonisi tabanlı tek amaçlı zenginleştirme yönteminin 8 test görüntüsüne uygulanmasından elde edilen istatistiksel sonuçlar

		PSNR	SSIM	CII	CEF	Kazanç	Bozulma
4.1.01	Standart S.	1.493028	0.023572	0.049452	0.049693	0.000126	0
	Minimum	16.9953	0.8725	0.8997	1.225341	0.0069	2
	Maksimum	21.822	0.9409	1.0398	1.385371	0.0072	2
	Ortalama	19.31043	0.90618	0.95559	1.293742	0.00704	2
	Ortanca	19.38835	0.90295	0.95495	1.28798	0.007	2
4.1.02	Standart S.	1.521548	0.04247	0.094113	0.089931	0.000336	0
	Minimum	17.0893	0.7588	0.7798	1.360526	0.0066	2
	Maksimum	22.2506	0.9027	1.0909	1.660365	0.0077	2
	Ortalama	18.80152	0.82055	0.92343	1.547131	0.00712	2
	Ortanca	18.8142	0.82065	0.9227	1.539837	0.0072	2
4.1.06	Standart S.	1.598438	0.038228	0.170233	0.0509	0.000303	0
	Minimum	14.9608	0.7796	1.9189	0.675928	0.0053	2
	Maksimum	19.7231	0.8992	2.4328	0.835703	0.0063	2
	Ortalama	17.77186	0.85899	2.12766	0.765151	0.00584	2
	Ortanca	17.6161	0.86835	2.08525	0.767338	0.00595	2
İmage18	Standart S.	2.580179	0.020727	0.063382	0.101379	0.000223	0
	Minimum	20.8215	0.9162	0.9083	1.069699	0.0045	2
	Maksimum	28.5285	0.9733	1.0996	1.376762	0.0053	2
	Ortalama	24.47798	0.94619	0.98875	1.241218	0.00481	2
	Ortanca	25.06565	0.9508	0.98255	1.211528	0.0048	2
İmage23	Standart S.	3.728162	0.012069	0.053997	0.063005	0.000363	0.422
	Minimum	27.6659	0.9478	0.935	0.984794	0.0038	2
	Maksimum	38.369	0.9849	1.1087	1.157779	0.0049	3
	Ortalama	33.17758	0.97267	1.0077	1.063832	0.00446	2.8
	Ortanca	32.3398	0.9741	1.00695	1.058748	0.00455	3
Kodim04	Standart S.	3.896638	0.009519	0.07816	0.0521	0.000348	0.516
	Minimum	23.6205	0.9611	1.1019	0.919275	0.0043	2
	Maksimum	36.5433	0.9871	1.3338	1.095617	0.0053	3
	Ortalama	28.8738	0.97147	1.19425	0.978707	0.00489	2.6
	Ortanca	29.3961	0.9706	1.1981	0.980514	0.00495	3
Kodim21	Standart S.	3.736322	0.020482	0.110442	0.055326	0.000513	0.483
	Minimum	20.6833	0.9162	1.1593	0.852576	0.0044	2
	Maksimum	32.3178	0.9764	1.5443	0.99902	0.0063	3
	Ortalama	26.32846	0.95695	1.36863	0.935426	0.00565	2.7
	Ortanca	26.28815	0.9646	1.37745	0.937223	0.00565	3
Lena	Standart S.	1.523321	0.015322	0.111202	0.038971	0.000165	0
	Minimum	16.2156	0.8859	1.7701	0.853412	0.0052	2
	Maksimum	21.9559	0.944	2.0771	0.973358	0.0058	2
	Ortalama	18.50965	0.91325	1.92463	0.92709	0.00546	2
	Ortanca	18.205	0.91425	1.94695	0.924425	0.00545	2

Çizelge 4.6’da genetik algoritma tabanlı çok amaçlı zenginleştirme yönteminin uygulandığı 8 test görüntüsünün her birinin 10 farklı çalıştırmadan elde edilen sonuçlarının, kalite metriklerine ve amaçlara göre standart sapma, minimum, maksimum, ortalama ve ortanca değerleri verilmiştir.

Çizelge 4.6. Genetik algoritma tabanlı çok amaçlı zenginleştirme yönteminin 8 test görüntüsüne uygulanmasından elde edilen istatistiksel sonuçlar

		PSNR	SSIM	CII	CEF	Kazanç	Bozulma
4.1.01	Standart S.	1.330134	0.028403	0.040031	0.048534	0.000232	0.483
	Minimum	16.06478	0.826574	0.953177	1.27597	0.007703	2
	Maksimum	20.18158	0.914773	1.088648	1.428205	0.008401	3
	Ortalama	17.64078	0.863454	1.005617	1.359624	0.008037	2.3
	Ortanca	17.1561	0.856741	1.003158	1.375197	0.008064	2
4.1.02	Standart S.	1.256176	0.038635	0.095883	0.08844	0.000264	0.422
	Minimum	16.20926	0.72463	0.759455	1.444648	0.007423	2
	Maksimum	20.38273	0.864647	1.070323	1.728523	0.008059	3
	Ortalama	18.25178	0.779987	0.875789	1.577606	0.007693	2.2
	Ortanca	18.52113	0.778687	0.868437	1.553083	0.007541	2
4.1.06	Standart S.	0.927988	0.023735	0.091111	0.029176	0.000413	0.699
	Minimum	16.81657	0.81443	2.054019	0.735054	0.006116	2
	Maksimum	20.02292	0.883724	2.382472	0.834664	0.007274	4
	Ortalama	18.78468	0.862173	2.208491	0.78944	0.00654	2.4
	Ortanca	18.9852	0.870738	2.202656	0.794346	0.006417	2
İmage18	Standart S.	1.882446	0.030616	0.072925	0.092551	0.00034	0.527
	Minimum	18.61215	0.846425	0.922771	1.262679	0.004823	2
	Maksimum	24.51136	0.93051	1.152656	1.509205	0.005793	3
	Ortalama	21.34678	0.900972	1.036529	1.345031	0.005374	2.5
	Ortanca	21.3599	0.909775	1.02021	1.308387	0.005496	2.5
İmage23	Standart S.	1.897995	0.021568	0.054942	0.049526	0.000153	0.816
	Minimum	23.55583	0.899862	0.887891	1.13327	0.004799	2
	Maksimum	29.94208	0.968715	1.03974	1.297955	0.005313	5
	Ortalama	27.73407	0.940418	0.978573	1.176104	0.005063	3
	Ortanca	28.3414	0.944845	0.982812	1.157608	0.005062	3
Kodim04	Standart S.	2.642356	0.007649	0.084329	0.063932	0.000298	0.632
	Minimum	21.47421	0.940411	1.14574	0.889832	0.004595	2
	Maksimum	29.95898	0.963917	1.392474	1.110692	0.00558	4
	Ortalama	26.36981	0.950975	1.280687	0.983083	0.005179	2.8
	Ortanca	26.52541	0.948127	1.309639	0.981355	0.005238	3
Kodim21	Standart S.	2.357029	0.040836	0.102485	0.04945	0.000738	0.516
	Minimum	24.85366	0.853124	1.215738	0.914268	0.005119	2
	Maksimum	31.76405	0.977148	1.525055	1.062265	0.007424	3
	Ortalama	27.73363	0.924266	1.335831	0.966908	0.006198	2.4
	Ortanca	27.11251	0.930433	1.328319	0.959992	0.006091	2
Lena	Standart S.	0.926694	0.007384	0.046771	0.024287	0.000155	0.483
	Minimum	16.17282	0.877305	1.94545	0.886801	0.005742	2
	Maksimum	19.38518	0.900505	2.081502	0.946322	0.006204	3
	Ortalama	17.74199	0.888894	2.003741	0.919414	0.005937	2.3
	Ortanca	17.5882	0.887434	1.993045	0.919642	0.005938	2

Çizelge 4.7’de parçacık sürü optimizasyonu tabanlı çok amaçlı zenginleştirme yönteminin uygulandığı 8 test görüntüsünün her birinin 10 farklı çalıştırmadan elde edilen sonuçlarının, kalite metriklerine ve amaçlara göre standart sapma, minimum, maksimum, ortalama ve ortanca değerleri verilmiştir.

Çizelge 4.7. Parçacık sürü optimizasyonu tabanlı çok amaçlı zenginleştirme yönteminin 8 test görüntüsüne uygulanmasından elde edilen istatistiksel sonuçlar

		PSNR	SSIM	CII	CEF	Kazanç	Bozulma
4.1.01	Standart S.	1.093451	0.022057	0.107128	0.039937	0.000416	0.843
	Minimum	16.20862	0.858303	0.815445	1.287955	0.005614	1
	Maksimum	19.83094	0.921122	1.191476	1.418768	0.007191	4
	Ortalama	17.90764	0.882627	0.945227	1.344261	0.006446	2.4
	Ortanca	17.69989	0.879968	0.948121	1.345708	0.006512	2
4.1.02	Standart S.	1.245559	0.044623	0.073343	0.075138	0.00026	0.675
	Minimum	17.22046	0.750279	0.776729	1.404946	0.006404	2
	Maksimum	21.29653	0.87423	1.007279	1.649083	0.007378	4
	Ortalama	19.17481	0.823488	0.904456	1.519864	0.006758	2.3
	Ortanca	19.26243	0.8351	0.903888	1.511327	0.006688	2
4.1.06	Standart S.	0.942316	0.01394	0.11463	0.025348	0.000321	0.422
	Minimum	17.45699	0.850684	1.943029	0.748036	0.005151	2
	Maksimum	20.44437	0.887463	2.274909	0.838975	0.006259	3
	Ortalama	18.44102	0.871803	2.144144	0.790266	0.005862	2.2
	Ortanca	18.05514	0.87548	2.146989	0.78886	0.005793	2
İmage18	Standart S.	1.073326	0.014517	0.105249	0.090179	0.000229	0.666
	Minimum	20.0403	0.896635	0.869153	1.116275	0.00472	2
	Maksimum	23.39471	0.949026	1.242981	1.417048	0.005325	4
	Ortalama	22.17492	0.923526	1.029359	1.278278	0.005089	3
	Ortanca	22.11432	0.924884	1.04186	1.287664	0.005201	3
İmage23	Standart S.	1.866359	0.03022	0.063437	0.032762	0.000269	1.354006
	Minimum	25.24652	0.876542	0.859675	1.113071	0.00435	2
	Maksimum	31.30002	0.982493	1.047207	1.214134	0.00522	7
	Ortalama	29.33276	0.952914	0.949585	1.141202	0.004675	3.5
	Ortanca	29.58604	0.962947	0.966102	1.134387	0.004642	3
kodim04	Standart S.	3.226996	0.012241	0.102794	0.03783	0.000266	1.197
	Minimum	23.46168	0.951099	1.117175	0.920049	0.004301	2
	Maksimum	32.82361	0.988765	1.420462	1.047368	0.00503	6
	Ortalama	29.33558	0.969069	1.240765	0.987142	0.004649	3.1
	Ortanca	30.64924	0.973887	1.223596	0.983488	0.00458	3
Kodim21	Standart S.	2.739608	0.015028	0.07257	0.040579	0.000502	0.699
	Minimum	23.40898	0.933748	1.179817	0.88964	0.004311	2
	Maksimum	31.62693	0.985848	1.405416	1.023917	0.005945	4
	Ortalama	27.58874	0.963584	1.295127	0.950582	0.005101	2.6
	Ortanca	28.22394	0.965252	1.311168	0.955143	0.005081	2.5
Lena	Standart S.	1.025738	0.019261	0.13274	0.031055	0.000125	0.707
	Minimum	16.50694	0.871339	1.806527	0.883557	0.005395	2
	Maksimum	19.21081	0.925746	2.218329	0.993083	0.005828	4
	Ortalama	17.88283	0.900031	1.979571	0.927529	0.005601	2.5
	Ortanca	17.78098	0.900813	1.936295	0.921713	0.005594	2

Çizelge 4.8’de yapay arı kolonisi tabanlı çok amaçlı zenginleştirme yönteminin uygulandığı 8 test görüntüsünün her birinin 10 farklı çalıştırmadan elde edilen sonuçlarının, kalite metriklerine ve amaçlara göre standart sapma, minimum, maksimum, ortalama ve ortanca değerleri verilmiştir.

Çizelge 4.8. Yapay arı kolonisi tabanlı çok amaçlı zenginleştirme yönteminin 8 test görüntüsüne uygulanmasından elde edilen istatistiksel sonuçlar

		PSNR	SSIM	CII	CEF	Kazanç	Bozulma
4.1.01	Standart S.	1.397424	0.032826	0.038977	0.057097	0.000341	0.483
	Minimum	15.22088	0.817943	0.900727	1.302524	0.006789	2
	Maksimum	19.03276	0.912776	1.041899	1.459582	0.007816	3
	Ortalama	17.57875	0.871921	0.986539	1.3585	0.00748	2.3
	Ortanca	18.30343	0.884575	0.99443	1.327642	0.007523	2
4.1.02	Standart S.	1.25439	0.033123	0.090411	0.084288	0.000277	0.699
	Minimum	16.45719	0.739816	0.807011	1.437576	0.006911	2
	Maksimum	20.5721	0.851248	1.092844	1.710629	0.007745	4
	Ortalama	18.1898	0.799863	0.930911	1.584489	0.007263	2.6
	Ortanca	18.11215	0.795304	0.917267	1.586306	0.007225	2.5
4.1.06	Standart S.	1.22948	0.023506	0.199134	0.032227	0.000209	0.316
	Minimum	17.5679	0.868605	1.614225	0.745812	0.005374	2
	Maksimum	21.95575	0.942191	2.245863	0.86102	0.006039	3
	Ortalama	19.11967	0.8855	2.075442	0.808518	0.005775	2.1
	Ortanca	18.85563	0.874955	2.161101	0.8171	0.005751	2
İmage18	Standart S.	1.453627	0.027211	0.052607	0.080287	0.000362	0.471
	Minimum	17.98493	0.855777	0.939055	1.293836	0.00481	2
	Maksimum	22.34779	0.936816	1.10616	1.545531	0.006086	4
	Ortalama	20.22226	0.899957	0.984628	1.396093	0.005322	3
	Ortanca	20.68483	0.913546	0.965572	1.386089	0.00528	3
İmage23	Standart S.	4.49486	0.017651	0.072119	0.080773	0.000236	0.849
	Minimum	23.4855	0.938354	0.848523	1.021009	0.004285	2
	Maksimum	38.40986	0.990301	1.058196	1.280414	0.005011	5
	Ortalama	29.84806	0.958158	0.959676	1.142213	0.004613	3.5
	Ortanca	28.10086	0.955285	0.966408	1.161814	0.004655	3.5
Kodim04	Standart S.	4.165218	0.010591	0.12845	0.058855	0.000414	0.632
	Minimum	21.2112	0.94949	1.003335	0.886313	0.00382	2
	Maksimum	35.82562	0.986897	1.467448	1.089414	0.005186	4
	Ortalama	29.33515	0.969857	1.187041	0.99929	0.004789	2.8
	Ortanca	30.3902	0.971659	1.174098	1.00615	0.004906	3
Kodim21	Standart S.	2.666538	0.015949	0.105138	0.03213	0.000634	0.632
	Minimum	24.20863	0.935104	1.164497	0.908679	0.004299	2
	Maksimum	32.80407	0.980583	1.488245	0.99609	0.00596	4
	Ortalama	28.40715	0.96332	1.319655	0.962518	0.005396	2.8
	Ortanca	28.2569	0.96956	1.314512	0.974394	0.005743	3
Lena	Standart S.	0.818058	0.012525	0.060628	0.02751	0.000179	0.707
	Minimum	16.49328	0.873289	1.920156	0.884404	0.005517	2
	Maksimum	18.68882	0.909387	2.087343	0.962718	0.006109	4
	Ortalama	17.72121	0.895452	2.01385	0.929326	0.005709	2.5
	Ortanca	17.83763	0.899016	2.031512	0.934436	0.005664	2

Çizelge 4.9'da Bejinariu ve ark. (2017) tarafından önerilen PSO tabanlı çok amaçlı yönteminin uygulandığı 8 test görüntüsünün her birinin 10 farklı çalıştırmadan elde edilen sonuçlarının, kalite metriklerine ve amaçlara göre standart sapma, minimum, maksimum, ortalama ve ortanca değerleri verilmiştir.

Çizelge 4.9. Literatürdeki parçacık sürü optimizasyonu tabanlı çok amaçlı zenginleştirme yönteminin 8 test görüntüsüne uygulanmasından elde edilen istatistiksel sonuçlar

		PSNR	SSIM	CII	CEF	Kazanç	Bozulma
4.1.01	Standart S.	1.306183	0.019819	0.060723	0.050329	0.000488	0.948
	Minimum	16.4217	0.8673	0.8893	1.249944	0.0061	1
	Maksimum	20.6556	0.9235	1.0958	1.408854	0.0076	4
	Ortalama	18.27874	0.89401	1.0013	1.336415	0.00666	2.3
	Ortanca	18.07215	0.8946	1.0115	1.327303	0.0065	2
4.1.02	Standart S.	1.014607	0.023505	0.045943	0.062921	0.000204	0.875
	Minimum	17.3249	0.7971	0.8459	1.433889	0.0063	1
	Maksimum	20.6693	0.864	1.0049	1.645054	0.0069	4
	Ortalama	19.28168	0.83717	0.93462	1.514436	0.00652	2.1
	Ortanca	19.3341	0.8376	0.9329	1.506221	0.0065	2
4.1.06	Standart S.	0.94507	0.016236	0.158457	0.034831	0.000303	0.994
	Minimum	16.7879	0.8432	2.0511	0.720186	0.0052	1
	Maksimum	20.0911	0.897	2.5319	0.830555	0.0061	3
	Ortalama	18.08004	0.86679	2.22817	0.781589	0.00574	2.1
	Ortanca	18.09445	0.87	2.19535	0.783437	0.0058	2.5
İmage18	Standart S.	2.019411	0.022414	0.073124	0.093031	0.000231	1.1
	Minimum	18.7732	0.8804	0.9813	1.145241	0.0047	1
	Maksimum	25.9158	0.9678	1.2047	1.479847	0.0056	4
	Ortalama	22.20279	0.92207	1.06463	1.292689	0.00527	2.9
	Ortanca	22.50605	0.92415	1.04465	1.288929	0.0053	3
İmage23	Standart S.	3.344647	0.012776	0.06237	0.051116	0.000145	0.919
	Minimum	25.7574	0.9402	0.8859	1.047255	0.0044	2
	Maksimum	37.0291	0.9785	1.0653	1.215521	0.0048	5
	Ortalama	29.8819	0.95949	0.96404	1.14088	0.00461	3.2
	Ortanca	29.4437	0.9579	0.94625	1.142801	0.0046	3
kodim04	Standart S.	3.372383	0.008974	0.089241	0.05952	0.00012	0.483
	Minimum	21.5673	0.9464	1.0794	0.888016	0.0046	2
	Maksimum	31.5474	0.9786	1.4163	1.0986	0.005	3
	Ortalama	27.86891	0.96603	1.25055	0.986521	0.00471	2.7
	Ortanca	29.08675	0.967	1.2531	0.986371	0.0047	3
Kodim21	Standart S.	3.916567	0.023811	0.088458	0.062071	0.000383	0.919
	Minimum	19.0289	0.9024	1.2659	0.817587	0.0049	2
	Maksimum	31.7579	0.9828	1.5846	1.014389	0.0061	5
	Ortalama	25.19474	0.94613	1.41768	0.920733	0.00543	3.2
	Ortanca	24.82455	0.95155	1.42645	0.920831	0.00535	3
Lena	Standart S.	0.892799	0.011625	0.098164	0.015628	0.000163	0.675
	Minimum	16.5198	0.8813	1.8649	0.880978	0.0053	1
	Maksimum	19.2562	0.9162	2.1072	0.929363	0.0059	3
	Ortalama	17.52175	0.89847	1.96759	0.908255	0.0057	2.3
	Ortanca	17.11105	0.8991	1.93735	0.909276	0.0057	2

Çalışmada gerçekleştirilen tek ve çok amaçlı zenginleştirme yöntemleri, klasik yöntemlerle, PSNR, SSIM, CII ve CEF kalite metriklerine göre karşılaştırılmıştır. Karşılaştırma için aynı test görüntülerine; HE, CS ve CLAHE yöntemleri uygulanmıştır. Çizelge 4.10'da 8 test görüntüsüne klasik yöntemlerin uygulanması sonucunda elde edilen kalite değerleri verilmiştir. Çizelge 4.10'da koyu renkle gösterilen değerler, buldukları kalite metriği sütunundaki en iyi değerleri ifade etmektedir.

Çizelge 4.10. Klasik zenginleştirme yöntemlerinin 8 test görüntüsüne uygulanmasından elde edilen sayısal değerlendirme sonuçları

		PSNR	SSIM	CII	CEF	Kazanç	Bozulma
4.1.01	HE	12.3488	0.711	1.3791	1.694619	0.0169	0
	CS	24.1297	0.9666	1.1963	1.179873	0.0061	0
	CLAHE	16.8984	0.7882	1.3028	1.420483	0.3328	0
	Ortalama	17.7923	0.8219333	1.2927333	1.4316583	0.1186	0
4.1.02	HE	8.698	0.432	0.8826	2.759522	0.0171	0
	CS	17.1788	0.8357	1.114	1.628585	0.0071	0
	CLAHE	14.7616	0.6075	1.068	1.895426	0.2139	0
	Ortalama	13.546133	0.6250667	1.0215333	2.094511	0.079367	0
4.1.06	HE	18.2109	0.7714	2.7385	0.772735	0.0159	0
	CS	16.0126	0.7864	2.98	0.792975	0.0059	0
	CLAHE	21.3877	0.8139	2.0898	0.947984	0.5687	0
	Ortalama	18.537067	0.7905667	2.6027667	0.837898	0.196833	0
İmage18	HE	10.1285	0.5628	1.5019	2.056160	0.0156	0
	CS	19.4836	0.8912	1.4024	1.272676	0.0063	0
	CLAHE	14.0837	0.6067	1.5367	1.835454	0.2845	0
	Ortalama	14.565267	0.6869	1.4803333	1.72143	0.102133	0
İmage23	HE	11.0148	0.5507	0.9289	2.272316	0.0167	0
	CS	44.1446	0.9941	1.0964	0.977051	0.0039	0
	CLAHE	14.7039	0.6351	1.0227	1.792606	0.3291	0
	Ortalama	23.287767	0.7266333	1.016	1.6806577	0.116567	0
Kodim04	HE	15.4235	0.6803	3.0136	1.153296	0.0156	0
	CS	22.75	0.9273	1.7788	1.005589	0.0058	0
	CLAHE	17.8979	0.7122	2.6329	1.033443	0.5430	0
	Ortalama	18.690467	0.7732667	2.4751	1.0641093	0.188133	0
Kodim21	HE	16.4418	0.5899	2.32	1.053665	0.0234	0
	CS	21.6886	0.95	1.6662	0.872808	0.0045	0
	CLAHE	19.5388	0.7866	1.8071	1.072491	0.6871	0
	Ortalama	19.223067	0.7755	1.9311	0.9996547	0.238333	0
Lena	HE	12.4307	0.7138	3.1198	0.856515	0.0156	0
	CS	16.9584	0.8697	2.7433	0.986194	0.0059	0
	CLAHE	18.292	0.7849	2.3956	0.952691	0.7038	0
	Ortalama	15.8937	0.7894667	2.7529	0.9318	0.241767	0

HE yöntemi; görsel olarak değerlendirildiğinde “4.1.01”, “4.1.02” ve “image23” test görüntülerinde yüksek kontrast elde etmiş ve görüntüdeki pek çok detayı belirgin hale getirmiş “image18” ve “lena” test görüntülerinin de kontrastını yükseltmiştir. Ancak, “kodim04” ve “kodim21” görüntülerinde çok fazla bozulmaya ve gürültüye sebep olmuştur. “4.1.06” test görüntüsünde yapısal bozulmalar gözlemlenmiştir. Bu durum, PSNR ve SSIM metriklerinin klasik yöntemler dikkate alındığında ortalamanın altında sonuç vermesiyle de desteklenmektedir. CII ve CEF metrikleri ortalamanın üstünde sonuç vermiştir. Kontrast kazancı ortalamanın altında olup ton bozulması, tüm test görüntülerinde alınabilecek en düşük değeri almıştır.

CS yöntemi, tüm test görüntülerinde ortalama düzeyde kontrast iyileştirmiştir. “kodim04” görüntüsünde diğer yöntemlerden daha iyi kontrast elde etmiştir. PSNR ve SSIM metriklerinde diğer klasik yöntemlere göre ortalamanın üstünde, CII ve CEF metriklerinde ise altında değer vermiştir. Kontrast kazancı ortalamanın altında olup ton bozulması, tüm test görüntülerinde alınabilecek en düşük değeri almıştır.

CLAHE yöntemi; “image23”, “kodim21” ve “lena” test görüntülerinde yapısal bozulmaya sebep olmuştur. Bu durum SSIM metriğinin diğer klasik yöntemler dikkate alındığında ortalamanın altında kalmasıyla desteklenmektedir. Buna karşın “4.1.01”, “4.1.02”, “image18”, “image23” test görüntülerinde herhangi belirgin gürültü olmaksızın başarılı bir kontrast zenginleştirme gerçekleştirmiştir. PSNR ve CII kalite metriklerinin diğer klasik yöntemlere bakıldığında ortalamanın üstünde sonuç vermesi bu durumu desteklemektedir. CEF kalite metriği ortalamanın üstünde sonuç vermiştir. Kontrast kazancı ortalamanın üstünde olup ton bozulması, tüm test görüntülerinde alınabilecek en düşük değeri almıştır.

Süre açısından değerlendirildiğinde tüm klasik görüntü zenginleştirme yöntemleri çalışmada karşılaştırılan optimizasyon tabanlı yöntemlerden oldukça hızlı sonuç üretmektedir.

Çalışmada gerçekleştirilen GA, PSO, ABC, NSGA-II, MOPSO ve MOABC tabanlı görüntü zenginleştirme yöntemleri ile klasik HE, CS ve CLAHE yöntemleri, PSNR, SSIM, CII ve CEF kalite metriklerine göre karşılaştırılmıştır. Karşılaştırma sonuçları çizelgelerde verilmiştir. Çizelgelerde çalışmada gerçekleştirilen yöntemler için verilen kalite metriği değerleri, 10 farklı çalıştırmadan elde edilen sonuçların ortalamalarıdır. Çizelgelerde koyu renkle gösterilen değerler, buldukları kalite metriği sütunundaki en iyi değeri ifade etmektedir. Ayrıca çizelgelerin son sütunlarında, tüm yöntemlerin 4 kalite metriğine göre Friedman testi (Friedman, 1937) sonuçları

verilmiştir. Friedman testi ile, 4 farklı kalite metriğine göre yöntemlerin başarı sıralamaları hesaplanmıştır. Tüm kalite metriklerinde daha büyük değerli yöntem daha iyi olduğundan sıralaması büyük olanın başarısı daha yüksektir. Elde edilen tüm sonuç görüntüleri, orijinal görüntüler ve bu görüntülerin histogram grafikleri çizelgelerde verilmiştir. Ayrıca çok amaçlı yöntemlerin Pareto yüzeyleri de çizelgelerde verilmiştir.

Çizelge 4.11’de “4.1.01” test görüntüsü için tüm yöntemlerin sayısal karşılaştırması verilmiştir. Çizelge 4.12’de orijinal ve tüm yöntemlerden elde edilen görüntüler verilmiştir. Çizelge 4.13’de orijinal ve tüm yöntemlerden elde edilen histogram grafikleri verilmiştir. Çizelge 4.14’de çok amaçlı yöntemlerden elde edilen Pareto yüzeyler verilmiştir.

Çizelge 4.11. “4.1.01” test görüntüsü için tüm yöntemlerin sayısal karşılaştırması

4.1.01	PSNR	SSIM	CII	CEF	Kazanç	Bozulma	Sıralama
GA	19.20349	0.903893	0.910267	1.296879	0.006568	2.1	5
PSO	18.88368	0.89895	0.96746	1.311109	0.00646	2	5.5
ABC	19.31043	0.90618	0.95559	1.293742	0.00704	2	5.75
NSGA-II	17.64078	0.863454	1.005617	1.359624	0.008037	2.3	5.5
MOPSO	17.90764	0.882627	0.945227	1.344261	0.006446	2.4	4.5
MOABC	17.57875	0.871921	0.986539	1.3585	0.00748	2.3	4.75
HE	12.3488	0.711	1.3791	1.694619	0.0169	0	5.5
CS*	24.1297	0.9666	1.1963	1.179873	0.0061	0	7.25
CLAHE	16.8984	0.7882	1.3028	1.420483	0.3328	0	5.5
MOPSO (Bejinariu ve ark., 2017)	18.27874	0.89401	1.0013	1.336415	0.00666	2.3	5.75
Ortalama	18.218041	0.8686835	1.06502	1.3595505	0.037369	1.590909	

“4.1.01” test görüntüsü sayısal olarak değerlendirildiğinde, PSNR kalite metriğinde en yüksek sonucun CS yöntemiyle elde edildiği görülmektedir. Görsel olarak değerlendirme yapıldığında da CS yöntemi uygulanan görüntünün, diğer yöntemlerle elde edilen görüntülere oranla daha az gürültü barındırdığı gözlemlenmiştir. Tek amaçlı yaklaşımların, çok amaçlı yaklaşımlara oranla daha yüksek PSNR değeri verdiği Çizelge 4.11’den görülmektedir. HE yöntemi ise en düşük PSNR değerini almıştır. Görsel olarak değerlendirildiğinde, diğer yöntemlerin uygulandığı görüntülere oranla en fazla gürültüye sahip görüntünün HE yöntemiyle elde edilen görüntü olması da bu sonucu desteklemektedir.

SSIM metriğinde en yüksek sonuç CS yöntemi ile, en düşük sonuç ise HE yöntemi ile elde edilmiştir. Bu durum, yapısal bozulmanın en çok HE ve en az CS yönteminin uygulandığı görüntüde olduğunu göstermektedir. Tek amaçlı yaklaşımların SSIM değerleri, çok amaçlı yaklaşımlardan daha yüksek olup bu durum, tek amaçlı












yaklaşımlarda çok amaçlı yaklaşımlara oranla daha az yapısal kaybın olduğunu göstermektedir.

CII metriğinde en yüksek değer HE, en düşük değer ise GA yöntemleriyle elde edilmiştir. Görsel olarak bakıldığında, kontrastında en çok artış olan görüntünün HE yöntemiyle elde edilen, en az artış olanın ise GA ile elde edilen görüntü olduğu gözlemlenmiştir. Çok amaçlı yaklaşımların, tek amaçlı yaklaşımlardan daha yüksek CII değerine sahip olması çok amaçlı yaklaşımların daha çok kontrast artışı sağladığını göstermektedir.

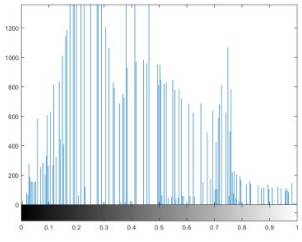
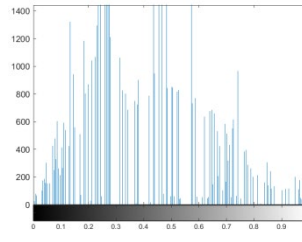
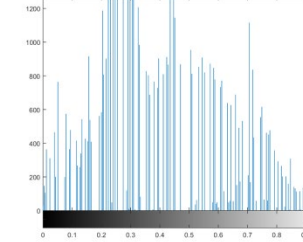
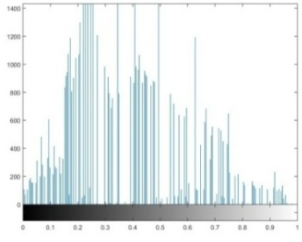
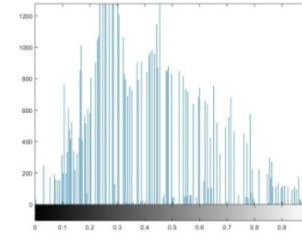
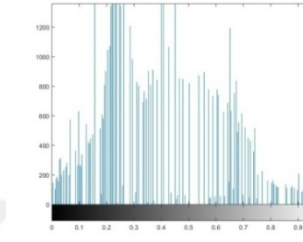
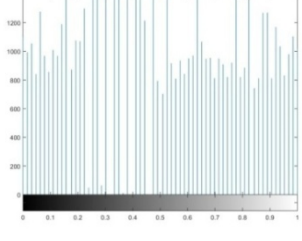
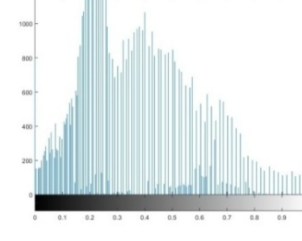
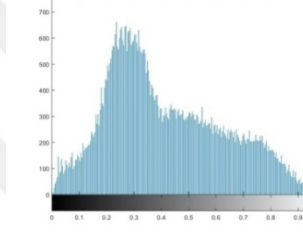
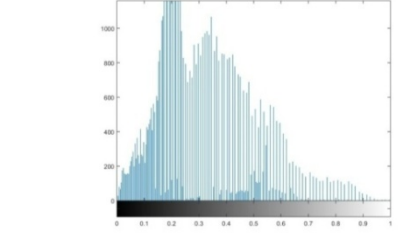
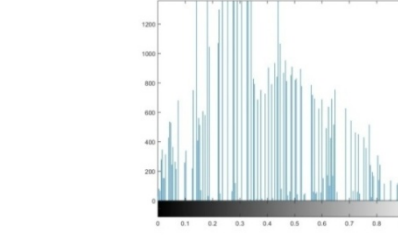
En yüksek CEF değerini HE yöntemi, en düşük CEF değerini ise CS yöntemi vermiştir. Çok amaçlı yaklaşımların renkliliği, tek amaçlı yaklaşımlara oranda daha fazla artmıştır.

Kontrast kazancının en yüksek olduğu görüntü CLAHE olup en düşük olduğu görüntü ise CS yöntemi olmuştur. Görsel açıdan değerlendirildiğinde CLAHE yöntemiyle elde edilen görüntüde her ne kadar parlaklık artışı sağlansa da kontrastında bu başarı sağlanamamıştır. Çok amaçlı yaklaşımların tek amaçlı yaklaşımlara göre kontrast kazançları ve ton bozulmaları nispeten daha yüksektir. Kontrastın arttıkça bozulmanın da artması beklenen bir sonuç olup çok amaçlı yöntemlerle amaçlar arasındaki denge sağlanmıştır.

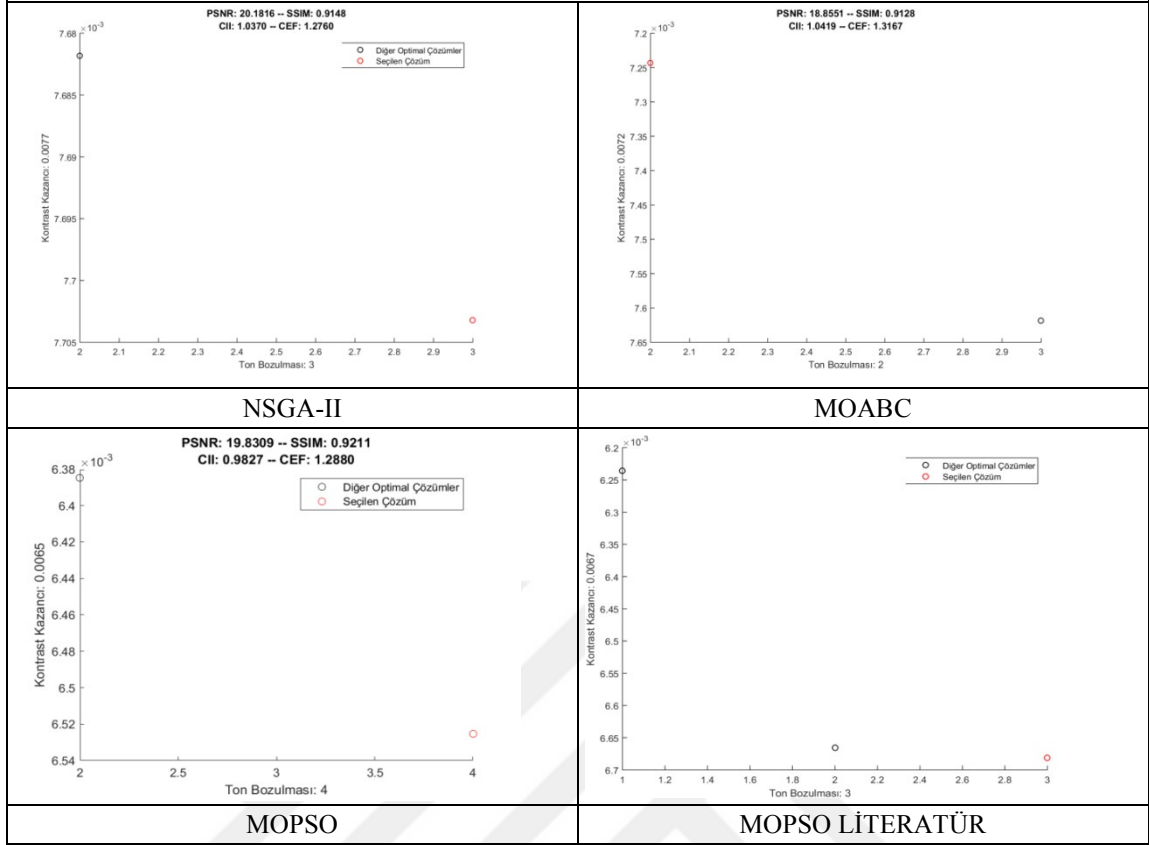
Çizelge 4.12. "4.1.01" test görüntüsü için elde edilen sonuç görüntüleri

		
NSGA-II	MOPSO	MOABC
		
GA	PSO	ABC
		
HE	CS	CLAHE
		
Orijinal		MOPSO (Bejinariu ve ark., 2017)

Çizelge 4.13. “4.1.01” test görüntüsü için elde edilen değer bileşeni histogram grafikleri

		
NSGA-II	MOPSO	MOABC
		
GA	PSO	ABC
		
HE	CS	CLAHE
		
Orjinal	MOPSO (Bejinariu ve ark., 2017)	

Çizelge 4.14. “4.1.01” test görüntüsü için çok amaçlı yöntemlerin Pareto yüzeyleri



Çizelge 4.15’de “4.1.02” test görüntüsü için tüm yöntemlerin sayısal karşılaştırması verilmiştir. Çizelge 4.16’da orijinal ve tüm yöntemlerden elde edilen görüntüler verilmiştir. Çizelge 4.17’de orijinal ve tüm yöntemlerden elde edilen histogram grafikleri verilmiştir. Çizelge 4.18’de çok amaçlı yöntemlerden elde edilen Pareto yüzeyler verilmiştir.

Çizelge 4.15. “4.1.02” test görüntüsü için tüm yöntemlerin sayısal karşılaştırması

4.1.02	PSNR	SSIM	CH	CEF	Kazanç	Bozulma	Sıralama
GA*	21.49685	0.888789	0.999214	1.398438	0.006516	2	7.25
PSO	18.65644	0.81326	0.93295	1.555532	0.00678	2	5.5
ABC	18.80152	0.82055	0.92343	1.547131	0.00712	2	5.25
NSGA-II	18.25178	0.779987	0.875789	1.577606	0.007693	2.2	3.75
MOPSO	19.17481	0.823488	0.904456	1.519864	0.006758	2.3	5.25
MOABC	18.1898	0.799863	0.930911	1.584489	0.007263	2.6	5
HE	8.698	0.432	0.8826	2.759522	0.0171	0	3.5
CS*	17.1788	0.8357	1.114	1.628585	0.0071	0	7.25
CLAHE	14.7616	0.6075	1.068	1.895426	0.2139	0	5.5
MOPSO (Bejinariu ve ark., 2017)	19.28168	0.83717	0.93462	1.514436	0.00652	2.1	6.75
Ortalama	17.449128	0.7638307	0.956597	1.6981029	0.026661	1.563636	

“4.1.02” test görüntüsünde PSNR ve SSIM kalite metriklerinde en yüksek değer GA, en düşük değer ise HE yöntemiyle elde edilmiş olup bu durum GA ile elde edilen

görüntüde diğer yöntemlere göre daha düşük, HE ile elde edilen görüntüde ise daha yüksek yapısal bozulma ve gürültü olduğunu göstermektedir. Ancak görsel olarak değerlendirildiğinde HE yöntemiyle elde edilen görüntü GA ile elde edilen görüntüden daha yüksek kontrast ve parlaklığa sahiptir. Bu metriklerde tek ve çok amaçlı yaklaşımlar benzer sonuçlar vermiştir.

CII metriğinde en yüksek değer CS yöntemi, en düşük değer ise NSGA-II yöntemi ile elde edilmiştir. Görsel açıdan bakıldığında CS yönteminde kontrastın NSGA-II yönteminden daha yüksek olduğu görülmektedir. Tek amaçlı yöntemler, çok amaçlı yöntemlere göre genellikle daha yüksek CII değeri elde etmiştir.


CEF metriğinde en yüksek değer HE, en düşük değer GA yöntemiyle elde edilmiştir. Çok amaçlı yaklaşımların renkliliği tek amaçlı yaklaşımlara benzer sonuçlar üretmiştir.

Kontrast kazancında en yüksek değer CLAHE, en düşük değer ise GA yöntemiyle elde edilmiştir. Çok amaçlı yaklaşımlar tek amaçlı yaklaşımlara göre daha yüksek kontrast kazancı ve ton bozulması elde etmişlerdir.


Çizelge 4.16. "4.1.02" test görüntüsü için elde edilen sonuç görüntüleri

		
NSGA-II	MOPSO	MOABC
		
GA	PSO	ABC
		
HE	CS	CLAHE
		
Orijinal	MOPSO (Bejinarıu ve ark., 2017)	

Çizelge 4.17. “4.1.02” test görüntüsü için elde edilen değer bileşeni histogram grafikleri



Çizelge 4.18. “4.1.02” test görüntüsü için çok amaçlı yöntemlerin Pareto yüzeyleri



Çizelge 4.19’da “4.1.06” test görüntüsü için tüm yöntemlerin sayısal karşılaştırması verilmiştir. Çizelge 4.20’de orijinal ve tüm yöntemlerden elde edilen görüntüler verilmiştir. Çizelge 4.21’de orijinal ve tüm yöntemlerden elde edilen histogram grafikleri verilmiştir. Çizelge 4.22’de çok amaçlı yöntemlerden elde edilen Pareto yüzeyler verilmiştir.

Çizelge 4.19. “4.1.06” test görüntüsü için tüm yöntemlerin sayısal karşılaştırması

4.1.06	PSNR	SSIM	CII	CEF	Kazanç	Bozulma	Sıralama
GA	17.57292	0.859042	2.146391	0.764654	0.005815	2	3.5
PSO	17.71695	0.85834	2.22326	0.771246	0.00562	1.9	4.25
ABC	17.77186	0.85899	2.12766	0.765151	0.00584	2	3.5
NSGA-II	18.78468	0.862173	2.208491	0.78944	0.00654	2.4	6.75
MOPSO	18.44102	0.871803	2.144144	0.790266	0.005862	2.2	6.75
MOABC*	19.11967	0.8855	2.075442	0.808518	0.005775	2.1	7.25
HE	18.2109	0.7714	2.7385	0.772735	0.0159	0	5
CS	16.0126	0.7864	2.98	0.792975	0.0059	0	5.25
CLAHE	21.3877	0.8139	2.0898	0.947984	0.5687	0	6.25
MOPSO (Bejinariu ve ark., 2017)	18.08004	0.86679	2.22817	0.781589	0.00574	2.1	6.5
Ortalama	18.309834	0.8434338	2.2961858	0.7984558	0.057955	1.518182	

“4.1.06” test görüntüsünde PSNR metriğinde en yüksek sonuç CLAHE, en düşük sonuç ise CS yöntemiyle elde edilmiştir. Çok amaçlı yöntemler tek amaçlı yöntemlerden daha yüksek PSNR değeri elde etmiştir.

SSIM metriğinde en yüksek değeri literatürdeki MOPSO, en düşük değeri ise HE yöntemi vermiştir. HE yöntemindeki yapısal bozulma görsel değerlendirme sonucuda da tespit edilmiştir. Çok amaçlı yaklaşımlar tek amaçlı yöntemlerden daha yüksek SSIM değeri elde etmişlerdir.

CII metriğinde en yüksek sonuç CS, en düşük sonuç ise MOABC yöntemiyle elde edilmiştir. Ancak genel olarak sonuçlar birbirine yakındır. Görsel değerlendirme yapıldığında CS yöntemiyle elde edilen görüntünün kontrastını diğer yöntemlerle elde edilen görüntülerden daha yüksek, MOABC yöntemiyle elde edilen görüntünün kontrastının ise daha düşük olduğu görülmüştür. Bu durum, Çizelge 4.17’deki histogram grafiklerinden de anlaşılmaktadır.


En yüksek CEF değerini CLAHE yöntemiyle elde edilen görüntü alırken en düşük değeri ise GA yöntemiyle elde edilen görüntü almıştır. Çok amaçlı yaklaşımların renkliliğindeki artış tek amaçlı yaklaşımlardan fazladır.

Kontrast kazancı en yüksek olan görüntü CLAHE ile elde edilmiştir. PSO yöntemiyle elde edilen görüntü ise kontrast kazancında en düşük değeri almıştır. Tek ve çok amaçlı yaklaşımlar birbirine yakın kazanç ve bozulma değerleri elde etmiştir.

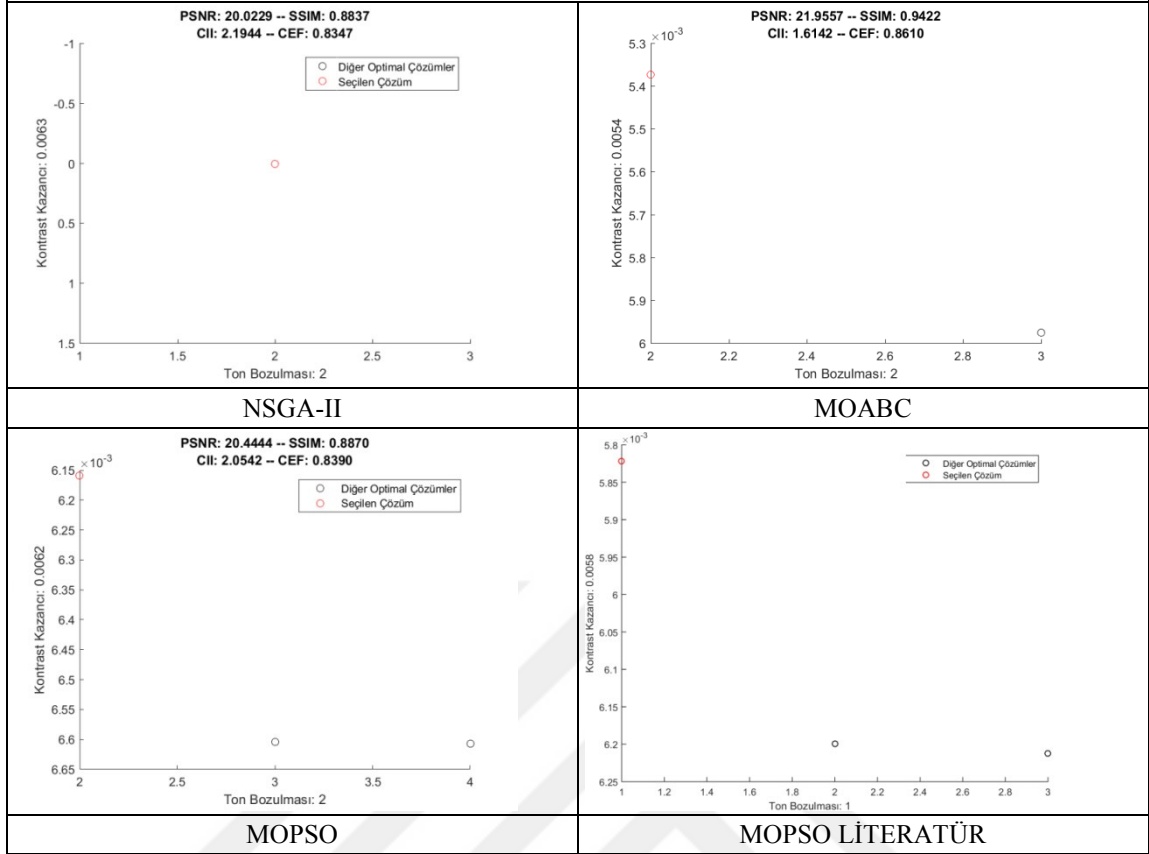
Çizelge 4.20. "4.1.06" test görüntüsü için elde edilen sonuç görüntüleri

		
NSGA-II	MOPSO	MOABC
		
GA	PSO	ABC
		
HE	CS	CLAHE
		
Orijinal	MOPSO (Bejinariu ve ark., 2017)	

Çizelge 4.21. “4.1.06” test görüntüsü için elde edilen değer bileşeni histogram grafikleri



Çizelge 4.22. “4.1.06” test görüntüsü için çok amaçlı yöntemlerin Pareto yüzeyleri



Çizelge 4.23’de “image18” test görüntüsü için tüm yöntemlerin sayısal karşılaştırması verilmiştir. Çizelge 4.24’de orijinal ve tüm yöntemlerden elde edilen görüntüler verilmiştir. Çizelge 4.25’de orijinal ve tüm yöntemlerden elde edilen histogram grafikleri verilmiştir. Çizelge 4.26’da çok amaçlı yöntemlerden elde edilen Pareto yüzeyler verilmiştir.

Çizelge 4.23. “image18” test görüntüsü için tüm yöntemlerin sayısal karşılaştırması

İmage18	PSNR	SSIM	CII	CEF	Kazanç	Bozulma	Sıralama
GA	26.18286	0.957747	0.97492	1.174018	0.00486	2	5.5
PSO*	24.94799	0.94676	1.04787	1.200475	0.00489	2	6.5
ABC	24.47798	0.94619	0.98875	1.241218	0.00481	2	5.5
NSGA-II	21.34678	0.900972	1.036529	1.345031	0.005374	2.5	5.5
MOPSO	22.17492	0.923526	1.029359	1.278278	0.005089	3	5.5
MOABC	20.22226	0.899957	0.984628	1.396093	0.005322	3	4.5
HE	10.1285	0.5628	1.5019	2.05616	0.0156	0	5.25
CS	19.4836	0.8912	1.4024	1.272676	0.0063	0	4.5
CLAHE	14.0837	0.6067	1.5367	1.835454	0.2845	0	5.75
MOPSO* (Bejinariu ve ark., 2017)	22.20279	0.92207	1.06463	1.292689	0.00527	2.9	6.5
Ortalama	20.525138	0.8557922	1.1567686	1.4092092	0.031534	1.763636	

“image18” test görüntüsünde PSNR ve SSIM metrikleri, GA yönteminde en yüksek, HE yönteminde ise en düşük değeri almıştır. Çok amaçlı yöntemler tek amaçlı













yöntemlere göre daha düşük PSNR ve SSIM değerleri elde etmiştir. Bu metrikler klasik yöntemlerde optimizasyon tabanlı yöntemlere göre oldukça düşük değerler almıştır.

CII metriğinde en yüksek değer CLAHE yöntemi, en düşük değer ise GA yöntemiyle elde edilmiştir. Görsel değerlendirme yapıldığında, diğer yöntemlere göre CLAHE yönteminin daha yüksek, GA yönteminin ise daha düşük kontrasta sahip olduğu sonucuna varılmıştır.


CEF metriğinde en yüksek değeri HE, en düşük değeri GA yöntemleri vermiştir. Çok amaçlı yaklaşımlar tek amaçlı yaklaşımlardan daha yüksek renklilik artışına sahiptir.

Kontrast kazancı en yüksek olan görüntü CLAHE yönteminin, en düşük görüntü ise ABC yönteminin uygulandığı görüntüdür. Çok amaçlı yaklaşımların kontrast kazancı tek amaçlı yaklaşımlardan daha yüksektir. Tek amaçlı yaklaşımların ton bozulması çok amaçlı yaklaşımlardan daha düşüktür. Görsel değerlendirmede tek ve çok amaçlı yaklaşımlarla genel olarak benzer sonuçlar alındığı görülmüştür.


Çizelge 4.24. "image18" test görüntüsü için elde edilen sonuç görüntüleri

		
NSGA-II	MOPSO	MOABC
		
GA	PSO	ABC
		
HE	CS	CLAHE
		
Orijinal	MOPSO (Bejinariu ve ark., 2017)	

Çizelge 4.25. “image18” test görüntüsü için elde edilen değer bileşeni histogram grafikleri



Çizelge 4.26. “image18” test görüntüsü için çok amaçlı yöntemlerin Pareto yüzeyleri



Çizelge 4.27’de “image23” test görüntüsü için tüm yöntemlerin sayısal karşılaştırması verilmiştir. Çizelge 4.28’de orijinal ve tüm yöntemlerden elde edilen görüntüler verilmiştir. Çizelge 4.29’da orijinal ve tüm yöntemlerden elde edilen histogram grafikleri verilmiştir. Çizelge 4.30’da çok amaçlı yöntemlerden elde edilen Pareto yüzeyler verilmiştir.

Çizelge 4.27. “image23” test görüntüsü için tüm yöntemlerin sayısal karşılaştırması

İmage23	PSNR	SSIM	CII	CEF	Kazanç	Bozulma	Sıralama
GA	34.50037	0.981743	1.006416	1.04748	0.004316	2.8	6.5
PSO	34.64995	0.98136	0.99767	1.066898	0.00434	2.6	6.75
ABC	33.17758	0.97267	1.0077	1.063832	0.00446	2.8	6.25
NSGA-II	27.73407	0.940418	0.978573	1.176104	0.005063	3	4.75
MOPSO	29.33276	0.952914	0.949585	1.141202	0.004675	3.5	4
MOABC	29.84806	0.958158	0.959676	1.142213	0.004613	3.5	5
HE	11.0148	0.5507	0.9289	2.272316	0.0167	0	3.25
CS*	44.1446	0.9941	1.0964	0.977051	0.0039	0	7.75
CLAHE	14.7039	0.6351	1.0227	1.792606	0.3291	0	5.5
MOPSO (Bejinariu ve ark., 2017)	29.8819	0.95949	0.96404	1.14088	0.00461	3.2	5.25
Ortalama	28.898799	0.8926653	0.991166	1.2820582	0.035099	2.2	



“image23” test görüntüsünde PSNR, SSIM ve CII metriklerinde en yüksek değer CS, en düşük değer ise HE yöntemiyle elde edilmiştir. Tek amaçlı yaklaşımlar çok amaçlı yaklaşımlardan daha yüksek değer almıştır.

CEF metriğinde en yüksek değer HE, en düşük değer CS yönteminde alınmıştır. Çok amaçlı yaklaşımların renkliliğindeki artış tek amaçlı yaklaşımlardan fazladır.


Kontrast kazancında en yüksek değeri CLAHE, en düşük değeri ise CS yöntemi elde etmiştir. Çok amaçlı yaklaşımların kazancı ve bozulması tek amaçlı yaklaşımlardan yüksektir.

Görsel değerlendirme yapıldığında görüntüdeki detayların genel olarak HE ve CLAHE yöntemlerinde, optimizasyon tabanlı yöntemler ele alındığında ise MOPSO yönteminde daha başarılı belirginleştirildiği gözlemlenmiştir.


Çizelge 4.28. “image23” test görüntüsü için elde edilen sonuç görüntüleri

		
NSGA-II	MOPSO	MOABC
		
GA	PSO	ABC
		
HE	CS	CLAHE
		
Orijinal		MOPSO (Bejinariu ve ark., 2017)

Çizelge 4.29. “image23” test görüntüsü için elde edilen değer bileşeni histogram grafikleri



Çizelge 4.30. “image23” test görüntüsü için çok amaçlı yöntemlerin Pareto yüzeyleri



Çizelge 4.31’de “kodim04” test görüntüsü için tüm yöntemlerin sayısal karşılaştırması verilmiştir. Çizelge 4.32’de orijinal ve tüm yöntemlerden elde edilen görüntüler verilmiştir. Çizelge 4.33’de orijinal ve tüm yöntemlerden elde edilen histogram grafikleri verilmiştir. Çizelge 4.34’de çok amaçlı yöntemlerden elde edilen Pareto yüzeyler verilmiştir.

Çizelge 4.31. “kodim04” test görüntüsü için tüm yöntemlerin sayısal karşılaştırması

Kodim04	PSNR	SSIM	CII	CEF	Kazanç	Bozulma	Sıralama
GA*	32.88205	0.980765	1.105909	0.991642	0.004486	2.6	6.75
PSO	28.44237	0.97268	1.23474	0.971066	0.00453	2.3	5
ABC	28.8738	0.97147	1.19425	0.978707	0.00489	2.6	5
NSGA-II	26.36981	0.950975	1.280687	0.983083	0.005179	2.8	4.5
MOPSO	29.33558	0.969069	1.240765	0.987142	0.004649	3.1	6.25
MOABC	29.33515	0.969857	1.187041	0.99929	0.004789	2.8	6
HE	15.4235	0.6803	3.0136	1.153296	0.0156	0	5.5
CS	22.75	0.9273	1.7788	1.005589	0.0058	0	5.5
CLAHE	17.8979	0.7122	2.6329	1.033443	0.5430	0	5.5
MOPSO (Bejinariu ve ark., 2017)	27.86891	0.96603	1.25055	0.986521	0.00471	2.7	5
Ortalama	25.917907	0.9100646	1.5919242	1.0089779	0.054738	1.954545	

“kodim04” test görüntüsünde PSNR ve SSIM metriklerinde en yüksek değer GA yöntemiyle, en düşük değer ise HE yöntemiyle alınmıştır. Görsel açıdan bakıldığında HE yöntemiyle elde edilen görüntüde meydana gelen yazpısal bozulmalar ve gürültüler bu durumu desteklemektedir. Ayrıca CLAHE yöntemiyle elde edilen görüntüde de bariz bozulmalar gözlemlenmiştir.


CII ve CEF metriklerinde en yüksek değer HE yöntemiyle elde edilirken CII metriğinde en düşük değer GA, CEF metriğinde en düşük değer PSO yöntemiyle elde edilmiştir.

Kontrast kazancı en yüksek olan görüntü CLAHE yöntemiyle elde edilen görüntü olurken en düşük görüntü ise GA yöntemiyle elde edilen görüntü olmuştur. Çok amaçlı yaklaşımlar tek amaçlı yaklaşımlara göre daha yüksek kazanç ve bozulma değeri elde etmişlerdir.


Çizelge 4.32. "kodim04" test görüntüsü için elde edilen sonuç görüntüleri

		
NSGA-II	MOPSO	MOABC
		
GA	PSO	ABC
		
HE	CS	CLAHE
		
Orijinal	MOPSO (Bejinariu ve ark., 2017)	

Çizelge 4.33. “kodim04” test görüntüsü için elde edilen değer bileşeni histogram grafikleri



Çizelge 4.34. “kodim04” test görüntüsü için çok amaçlı yöntemlerin Pareto yüzeyleri



Çizelge 4.35’de “kodim21” test görüntüsü için tüm yöntemlerin sayısal karşılaştırması verilmiştir. Çizelge 4.36’da orijinal ve tüm yöntemlerden elde edilen görüntüler verilmiştir. Çizelge 4.37’de orijinal ve tüm yöntemlerden elde edilen histogram grafikleri verilmiştir. Çizelge 4.38’de çok amaçlı yöntemlerden elde edilen Pareto yüzeyler verilmiştir.

Çizelge 4.35. “kodim21” test görüntüsü için tüm yöntemlerin sayısal karşılaştırması


Kodim21	PSNR	SSIM	CII	CEF	Kazanç	Bozulma	Sıralama
GA	28.20781	0.969696	1.304078	0.947531	0.005374	2.7	6.5
PSO	27.38204	0.9658	1.30733	0.936536	0.00511	2.3	5.5
ABC	26.32846	0.95695	1.36863	0.935426	0.00565	2.7	5
NSGA-II	27.73363	0.924266	1.335831	0.966908	0.006198	2.4	6
MOPSO	27.58874	0.963584	1.295127	0.950582	0.005101	2.6	5.5
MOABC*	28.40715	0.96332	1.319655	0.962518	0.005396	2.8	7
HE	16.4418	0.5899	2.32	1.053665	0.0234	0	5.25
CS	21.6886	0.95	1.6662	0.872808	0.0045	0	4.25
CLAHE	19.5388	0.7866	1.8071	1.072491	0.6871	0	5.75
MOPSO (Bejinariu ve ark., 2017)	25.19474	0.94613	1.41768	0.920733	0.00543	3.2	4.25
Ortalama	24.851177	0.9016246	1.5141631	0.9619198	0.068967	1.945455	

“kodim21” test görüntüsünde PSNR ve SSIM metriklerinde en yüksek değer GA, en düşük değer ise HE yöntemiyle elde edilmiştir. Görsel değerlendirmede HE yöntemiyle elde edilen görüntüdeki yapısal bozulma ve gürültü bu durumu desteklemektedir. Ayrıca CLAHE yönteminde de yapısal bozulma ve gürültüler gözlemlenmiştir.


CII metriğinde en yüksek değer HE, en düşük değer ise MOPSO yöntemiyle elde edilmiştir. CEF metriğinde ise en yüksek değer CLAHE, en düşük değer CS yöntemiyle elde edilmiştir.

Kontrast kazancında en yüksek değeri CLAHE, en düşük değeri ise CS yöntemi elde etmiştir.


Çizelge 4.36. “kodim21” test görüntüsü için elde edilen sonuç görüntüleri

		
NSGA-II	MOPSO	MOABC
		
GA	PSO	ABC
		
HE	CS	CLAHE
		
Orijinal		MOPSO (Bejinariu ve ark., 2017)

Çizelge 4.37. “kodim21” test görüntüsü için elde edilen değer bileşeni histogram grafikleri



Çizelge 4.38. “kodim21” test görüntüsü için çok amaçlı yöntemlerin Pareto yüzeyleri














Çizelge 4.39’da “lena” test görüntüsü için tüm yöntemlerin sayısal karşılaştırması verilmiştir. Çizelge 4.40’da orijinal ve tüm yöntemlerden elde edilen görüntüler verilmiştir. Çizelge 4.41’de orijinal ve tüm yöntemlerden elde edilen histogram grafikleri verilmiştir. Çizelge 4.42’de çok amaçlı yöntemlerden elde edilen Pareto yüzeyler verilmiştir.

Çizelge 4.39. “lena” test görüntüsü için tüm yöntemlerin sayısal karşılaştırması


Lena	PSNR	SSIM	CII	CEF	Kazanç	Bozulma	Sıralama
GA	18.33253	0.915959	1.901073	0.922473	0.005491	2	6.25
PSO	16.92306	0.88824	2.04925	0.90231	0.00567	2	3.75
ABC*	18.50965	0.91325	1.92463	0.92709	0.00546	2	6.75
NSGA-II	17.74199	0.888894	2.003741	0.919414	0.005937	2.3	5
MOPSO	17.88283	0.900031	1.979571	0.927529	0.005601	2.5	6.5
MOABC	17.72121	0.895452	2.01385	0.929326	0.005709	2.5	6.25
HE	12.4307	0.7138	3.1198	0.856515	0.0156	0	3.25
CS	16.9584	0.8697	2.7433	0.986194	0.0059	0	6.25
CLAHE*	18.292	0.7849	2.3956	0.952691	0.7038	0	6.75
MOPSO (Bejinariu ve ark., 2017)	17.52175	0.89847	1.96759	0.908255	0.0057	2.3	4.25
Ortalama	17.231412	0.8668696	2.2098405	0.9231797	0.070033	1.6	

“lena” test görüntüsünde PSNR metriğinde en yüksek değer ABC, en düşük değer ise HE yöntemiyle elde edilmiştir. SSIM metriğinde en yüksek değeri GA, en düşük değeri HE yöntemi almıştır. CII metriğinde en yüksek değer HE, en düşük değer GA yöntemiyle elde edilmiştir. CEF metriğinde en yüksek değer CS, en düşük değer HE yöntemiyle elde edilmiştir. Kontrast kazancında en yüksek değeri CLAHE, en düşük değeri ise ABC yöntemi elde etmiştir.


Çizelge 4.40. “lena” test görüntüsü için elde edilen sonuç görüntüleri

		
NSGA-II	MOPSO	MOABC
		
GA	PSO	ABC
		
HE	CS	CLAHE
		
Orijinal	MOPSO (Bejinariu ve ark., 2017)	

Çizelge 4.41. "lena" test görüntüsü için elde edilen değer bileşeni histogram grafikleri



Çizelge 4.42. “Lena” test görüntüsü için çok amaçlı yöntemlerin Pareto yüzeyleri



Çizelge 4.43’de çalışmada gerçekleştirilen tek ve çok amaçlı optimizasyon tabanlı yöntemlerin ve literatürdeki PSO tabanlı çok amaçlı yöntemin, “4.1.01” test görüntüsü için 10 farklı çalıştırma süreleri saniye cinsinden ve bunların ortalamaları verilmiştir.

Çizelge 4.43 Optimizasyon tabanlı yöntemlerin yürütme süreleri

Çalıştırma	Süre						
	ABC	GA	PSO	Literatür	MOABC	NSGA-II	MOPSO
1	643.27	568.23	4142.47	2707.41	896.2	1745.77	2080.77
2	583.13	569.53	4672.04	2444.42	885.04	1725.02	2114.27
3	595.22	570.69	4641.09	2636.14	888.03	1994.42	2111.33
4	644.66	611.21	4275.91	2445.7	879.57	1725.58	2101.91
5	643.23	574.58	4310.88	2541.3	924.47	1727.22	2139.37
6	578.88	573.02	4363.72	2594.3	901.52	1764.43	2095.58
7	576.46	571.08	4922.19	2454.05	898.91	1766.54	2116.69
8	575.79	586.19	7869.37	2509.04	901.37	1735.79	2077.45
9	576.29	569.44	4945.43	2355.54	895.31	1735.2	2155.24
10	576.04	570.38	4435.36	2448.82	915.45	2025.52	2160.42
Ortalama	599.297	576.435	4857.846	2513.672	898.587	1794.549	2115.303

Çizelge 4.44’de klasik yöntemlerin “4.1.01” test görüntüsüne uygulanma süreleri saniye cinsinden verilmiştir.

Çizelge 4.44 Klasik yöntemlerin yürütme süreleri

	HE	CS	CLAHE
Süre	0.04	0.04	0.06

GA tabanlı tek amaçlı yaklaşım kullanılarak gerçekleştirilen zenginleştirme işlemi sonucunda, “4.1.02” test görüntüsü dışında tüm test görüntülerinin kontrastında, çok belirgin olmamakla birlikte bir miktar artış gözlemlenmiştir. Genel olarak kalite metriklerinden PSNR ve SSIM çalışmadaki diğer yöntemlere göre ortalamanın üstünde olup CII ve CEF değerleri ortalamanın altında kalmıştır. Bu da kontrastın ve renkliliğin istenilen ölçüde arttırılmadığını ancak görüntülerde belirgin gürültü ve yapısal bozulmaya da rastlanmadığını göstermektedir. Ayrıca kontrast kazancı ve ton bozulması, diğer yöntemlere göre ortalamanın altında kalmıştır. Optimizasyon tabanlı yöntemler içerisinde en hızlı sonuç üreten yöntem olması açısından da avantajlıdır.

PSO tabanlı tek amaçlı yaklaşım ile tüm test görüntülerinde, kontrast artışı gözlemlenmiştir. PSO tabanlı tek amaçlı yaklaşım ile PSNR ve SSIM kalite metriklerinde, çalışmadaki diğer yöntemlere göre genellikle ortalamanın üstünde değerler elde edilirken CII ve CEF metriklerinde görüntülerin yarısında ortalamanın altında yarısında ise ortalamanın üstünde değerler elde edilmiştir. Kontrast kazancı ve ton bozulması ortalamanın altında değerler almıştır. Süre açısından değerlendirildiğinde, karşılaştırılan tüm yöntemler içerisinde en uzun sürede sonuç üretmesi açısından dezavantajlıdır.

ABC tabanlı tek amaçlı yaklaşım ile, tüm test görüntülerinde kontrast artışı gözlemlenmiştir. PSNR ve SSIM metriklerinde, çalışmada karşılaştırılan tüm yaklaşımlara göre ortalamanın üstünde değerler elde edilirken CII ve CEF metriklerinde ortalamanın altında değerler alınmıştır. Kontrast kazancı ve ton bozulması ise ortalamanın altında sonuç vermiştir. Çalışmada gerçekleştirilen optimizasyon tabanlı tüm yöntemler içinde en hızlı sonuç üreten ikinci yaklaşım olması avantaj sağlamaktadır.

GA tabanlı çok amaçlı yaklaşım ile, tüm test görüntülerinin kontrastlarında yükselme gözlemlenmiştir. PSNR ve SSIM kalite metrikleri, çalışmadaki diğer yaklaşımlar dikkate alındığında ortalamanın üstünde, CII ve CEF kalite metrikleri ise ortalamanın altında sonuç vermiştir. Kontrast kazancı ve ton bozulması, ortalamanın altında sonuç vermiştir. Ayrıca, GA ve ABC tabanlı tek amaçlı ve ABC tabanlı çok amaçlı yaklaşımlara göre daha uzun sürede sonuç üretmektedir.

PSO tabanlı çok amaçlı yaklaşım ile elde edilen görüntülerin kontrastında bir miktar artış gözlemlenmiştir. PSNR ve SSIM metrikleri çalışmada karşılaştırılan diğer yöntemler dikkate alındığında ortalamanın üstünde, CII ve CEF metrikleri ise ortalamanın altında değer almıştır. Kontrast kazancı ve ton bozulması ortalamanın altında sonuç vermiştir. Literatürdeki PSO tabanlı çok amaçlı yaklaşımdan hızlı sonuç üretse de çalışmada gerçekleştirilen çok amaçlı yöntemler içerisinde en yavaşıdır.

ABC tabanlı çok amaçlı yaklaşım kullanılarak gerçekleştirilen zenginleştirme uygulaması sonucunda tüm test görüntülerinin kontrastında düşük oranda iyileşme görülmektedir. CII ve CEF metrikleri çalışmada karşılaştırılan diğer yöntemlere göre ortalamanın altında, PSNR ve SSIM metriği ortalamanın üstünde sonuç vermiştir. Kontrast kazancı ve ton bozulması ortalamanın altında değer almıştır. Çok amaçlı yaklaşımlar içinde en kısa sürede sonuç üreten yaklaşımdır.

Literatürdeki PSO tabanlı çok amaçlı yaklaşım görsel olarak, çalışmada karşılaştırılan tek ve çok amaçlı yaklaşımlara benzer sonuçlar vermiştir. PSNR ve SSIM metriklerinde çalışmada karşılaştırılan yaklaşımlara göre ortalamanın üstünde, CII ve CEF metriklerinde ise ortalamanın altında değer vermiştir. Kontrast kazancı ve ton bozulması ortalamanın altındadır. Çalışmada kullanılan tüm yöntemler içerisinde PSO tabanlı tek amaçlı yaklaşımdan sonra en yavaş sonuç üreten yöntemdir.

Tek ve çok amaçlı yöntemler karşılaştırıldığında PSNR metriğinde, test görüntülerinin 6'sı tek amaçlı yaklaşımlarda 2'si ise çok amaçlı yaklaşımlarda daha yüksek sonuçlar vermiştir. SSIM metriğinde test görüntülerinin 7'si tek amaçlı yaklaşımlarda 1'i ise çok amaçlı yaklaşımlarda daha yüksek sonuç elde etmiştir. CII metriğinde görüntülerin yarısı tek amaçlı yaklaşımlarda yarısı ise çok amaçlı yaklaşımlarda daha yüksek değer almıştır. CEF metriğinde tüm görüntülerde çok amaçlı yaklaşımlar daha yüksek değer almıştır. Kontrast kazancı tüm görüntülerde çok amaçlı yaklaşımlarda daha yüksek olup ton bozulması ise tüm görüntülerde tek amaçlı yaklaşımlarda daha düşüktür. Görsel olarak değerlendirildiğinde benzer sonuçların elde edildiği görülmüştür. Tek amaçlı yaklaşımlarda, uygunluk fonksiyonunda amaçlar arasındaki dengeyi sağlayan λ katsayısının belirlenmesi bir zorluk oluşturmaktadır. Çok amaçlı yaklaşımlarda bu denge kendiliğinden sağlanmaktadır. Tek amaçlı yaklaşımlar, çok amaçlı yaklaşımlara oranla daha hızlı sonuç üretseler de PSO oldukça yavaş sonuç vermektedir.

Klasik yöntemlerle çalışmada gerçekleştirilen yöntemler karşılaştırıldığında PSNR metriğinde test görüntülerinin 7'si optimizasyon tabanlı yöntemlerde 1'i ise

klasik yöntemlerde daha yüksek sonuç almıştır. SSIM metriğinde test görüntülerinin tümü optimizasyon tabanlı yöntemlerde daha yüksek sonuç almıştır. CII ve CEF metriklerinde test görüntülerinin tümü klasik yöntemlerde daha yüksek sonuç almıştır. Klasik yöntemlerin kontrast kazancı, tüm görüntülerde optimizasyon tabanlı yöntemlerden daha yüksek, ton bozulması ise daha düşüktür. Klasik yöntemlerle karşılaştırıldığında optimizasyon tabanlı yöntemlerin daha tutarlı sonuçlar ürettiği gözlemlenmiştir. Örneğin, HE ve CLAHE yöntemleri bazı görüntülerde bozulmalara sebebiyet verirken bazı görüntülerde başarılı sonuçlar elde etmiştir. Öte yandan optimizasyon tabanlı yaklaşımlar, tüm test görüntülerinde benzer sonuçlar elde etmiştir. Klasik yöntemler, optimizasyon tabanlı ve literatürdeki optimizasyon tabanlı yöntemlere göre çok daha hızlı sonuç üretmektedir.

Literatürdeki PSO tabanlı çok amaçlı yaklaşımla optimizasyon tabanlı yöntemler karşılaştırıldığında PSNR metriğinde test görüntülerinin 7'si optimizasyon tabanlı yöntemlerde 1'i ise literatürdeki yöntemde daha yüksek sonuç vermiştir. SSIM metriğinde test görüntülerinin 5'i optimizasyon tabanlı yöntemlerde 3'ü ise literatürdeki yöntemde daha yüksek sonuç vermiştir. CII metriğinde test görüntülerinin 2'si optimizasyon tabanlı yöntemlerde 6'sı ise literatürdeki yöntemde daha yüksek sonuç vermiştir. CEF metriğinde test görüntülerinin 3'ü optimizasyon tabanlı yöntemlerde 5'i ise literatürdeki yöntemde daha yüksek sonuç vermiştir. Kontrast kazancı test görüntülerinin 5'inde optimizasyon tabanlı yöntemlerde 3'ünde ise literatürdeki yöntemde daha yüksek sonuç vermiş olup ton bozulması ise tüm görüntülerde optimizasyon tabanlı yöntemlerde daha düşüktür. Görsel açıdan bakıldığında sonuçların benzer olduğu söylenebilir.

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Bu çalışmada düşük kontrastlı, renkli görüntüler, 3 farklı metasezgisel algoritmanın kullanıldığı tek ve çok amaçlı yaklaşımla zenginleştirilmiştir. Çok amaçlı yöntemlerle gerçekleştirilen zenginleştirme işleminde, iki farklı amaç fonksiyonu kullanılmıştır. Tek amaçlı yöntemlerle gerçekleştirilen zenginleştirme işleminde, çok amaçlı yaklaşımlarda kullanılan amaç fonksiyonlarının birleşiminden oluşan bir uygunluk fonksiyonu kullanılmıştır.

Çalışmada düşük kontrastlı, renkli görüntülere ait kontrastlarının, görüntülerde herhangi yapay görünüme ve abartılı kontrasta sebebiyet vermeden yükseltilmesi hedeflenmiştir.

Çalışmada gerçekleştirilen tek ve çok amaçlı yaklaşımlar, 8 adet renkli test görüntüsüne uygulanmıştır. Elde edilen zenginleştirilmiş görüntülerin kaliteleri, 4 farklı kalite metriği kullanılarak değerlendirilmiştir. Sonuçlar, 3 farklı klasik görüntü zenginleştirme yöntemiyle elde edilen sonuçlarla karşılaştırılmıştır.

Kalite metrikleri ayrı ayrı ele alındığında, PSNR ve SSIM kalite metriklerinde gerçekleştirilen yaklaşımlar, klasik yöntemlere göre daha yüksek değerler elde etmiştir. CII ve CEF kalite metriklerinde ise klasik yöntemler, gerçekleştirilen yöntemlere göre daha yüksek değerler almışlardır.

Tek ve çok amaçlı yaklaşımlar karşılaştırıldığında genel olarak sonuçların birbirine yakın olduğu ve tek amaçlı yöntemlerin çok amaçlı yöntemlerden genellikle daha yüksek kalite metrik değerlerine sahip oldukları görülmüştür. Gerçekleştirilen GA, PSO ve ABC tabanlı yöntemlerde; PSNR ve SSIM kalite metriklerinde tek amaçlı yaklaşım, çok amaçlı yaklaşımdan daha yüksek sonuçlar vermiştir. CEF kalite metriğinde ise çok amaçlı yaklaşım, tek amaçlı yaklaşımdan daha yüksek sonuçlar vermiştir. CII kalite metriği ise görüntülerin yarısında tek amaçlı yaklaşımlarda, diğer yarısında ise çok amaçlı yaklaşımlarda daha yüksek sonuçlar vermiştir.

Gerçekleştirilen PSO tabanlı çok amaçlı yaklaşım; PSNR ve SSIM kalite metriklerinde literatürdeki PSO tabanlı çok amaçlı yaklaşımla benzer sonuçları vermiş olup CEF kalite metriğinde literatürden daha yüksek, CII kalite metriğinde ise daha düşük sonuçlar vermiştir. Ayrıca gerçekleştirilen PSO tabanlı tek amaçlı yaklaşım, PSNR ve SSIM kalite metriklerinde literatürdeki PSO tabanlı çok amaçlı yaklaşımdan

daha yüksek sonuçları vermiş olup CII ve CEF kalite metriklerinde literatürden daha düşük sonuçlar vermiştir.

Elde edilen sonuç görüntüleri görsel olarak değerlendirildiğinde, klasik yöntemlerden HE ve CLAHE yöntemlerinde bazı görüntülerde bozulmaların olduğu gözlemlenmiştir. CS yöntemi ise gerçekleştirilen yöntemlere benzer sonuçlar vermiştir. Genel olarak tek ve çok amaçlı yaklaşımlardan elde edilen sonuç görüntülerin doğal görünümüne sahip olduğu gözlemlenmiştir.

Bu tez çalışmasında, düşük kontrastlı, renkli görüntülerin zenginleştirilmesi için görüntülerin kontrastlarının, görüntülerde herhangi yapay görünüme ve abartılı kontrasta sebebiyet vermeden artırılması hedeflenmiştir. Farklı görüntülere aynı işlemi uygulamak yerine, zenginleştirme işleminin görüntü özelinde uygulanması için optimizasyon tabanlı yaklaşımlar kullanılmıştır. Tek ve çok amaçlı optimizasyon yöntemleri, görüntülerin kontrastını artırırken görüntülerde meydana gelen bozulmaları da azaltacak, optimal gri seviye değerlerini bulmaya çalışır.

Gerçekleştirilen tek ve çok amaçlı yaklaşımların histogram grafikleri incelendiğinde, kontrastın başarılı bir şekilde yükseltildiği görülmektedir. Düşük kontrastlı girdi görüntülerinde dar aralıkta olan histogram grafikleri, gerçekleştirilen tek ve çok amaçlı yaklaşımlardan elde edilen zenginleştirilmiş görüntülerde daha geniş bir aralığa yayılmıştır. Bu durum, düşük kontrastlı girdi görüntülerinin kontrastlarının, gerçekleştirilen tek ve çok amaçlı yaklaşımlarla yükseltildiğini göstermektedir.

Optimizasyon tabanlı yaklaşımlar, klasik yaklaşımlara göre yavaş çalıştığı için gerçek zamanlı uygulamalara uygun değildir.

5.2 Öneriler

Tez çalışması kapsamında geliştirilen yöntemler ve elde edilen sonuçlar dikkate alındığında, bir dönüşüm fonksiyonu kullanılarak çalışmanın etkinliği artırılabilir, Geliştirilen tek ve çok amaçlı zenginleştirme yöntemleri, farklı renk modelleri üzerinde uygulanarak sonuçları incelenebilir, düşük kontrastlı görüntüler üzerine uygulanan bu çalışma, abartılı kontrasta sahip görüntüleri de kapsayacak şekilde genişletilebilir.

KAYNAKLAR

- Agrawal, S. ve Panda, R., 2012, An efficient algorithm for gray level image enhancement using cuckoo search, *International Conference on Swarm, Evolutionary, and Memetic Computing*, 82-89.
- Akbari, R., Hedayatzadeh, R., Ziarati, K. ve Hassanizadeh, B., 2012, A multi-objective artificial bee colony algorithm, *Swarm and Evolutionary Computation*, 2, 39-52.
- Amouzgar, K., 2012, Multi-objective optimization using genetic algorithms.
- Arora, R. K., 2015, Optimization: algorithms and applications, Chapman and Hall/CRC, p.
- Bäck, T. ve Hoffmeister, F., 1991, Extended selection mechanisms in genetic algorithms.
- Ballard, D. H. ve Brown, C. M., 1982, Computer vision. 1982, *Prentice-Hall, Englewood Cliffs, NJ*.
- Bejinariu, S.-I., Costin, H., Rotaru, F., Luca, R., Niță, C. ve Costin, D., 2017, Image enhancement by multiobjective optimization and bio-inspired heuristics, *E-Health and Bioengineering Conference (EHB), 2017*, 442-445.
- Braik, M., Sheta, A. ve Ayesh, A., 2007a, Particle swarm optimisation enhancement approach for improving image quality, *International Journal of Innovative Computing and Applications*, 1 (2), 138-145.
- Braik, M., Sheta, A. F. ve Ayesh, A., 2007b, Image Enhancement Using Particle Swarm Optimization, *World congress on engineering*, 978-988.
- Chandler, D. M. ve Hemami, S. S., 2007, VSNR: A wavelet-based visual signal-to-noise ratio for natural images, *IEEE transactions on image processing*, 16 (9), 2284-2298.
- Chen, J., Yu, W., Tian, J., Chen, L. ve Zhou, Z., 2018, Image contrast enhancement using an artificial bee colony algorithm, *Swarm and Evolutionary Computation*, 38, 287-294.
- Coelho, L. d. S., Sauer, J. G. ve Rudek, M., 2009, Differential evolution optimization combined with chaotic sequences for image contrast enhancement, *Chaos, Solitons & Fractals*, 42 (1), 522-529.
- Davis, L. S., 1975, A survey of edge detection techniques, *Computer graphics and image processing*, 4 (3), 248-270.
- Deb, K., 1999, An introduction to genetic algorithms, *Sadhana*, 24 (4-5), 293-315.
- Deb, K., Pratap, A., Agarwal, S. ve Meyarivan, T., 2002, A fast and elitist multiobjective genetic algorithm: NSGA-II, *IEEE transactions on evolutionary computation*, 6 (2), 182-197.
- Deb, K., 2014, Multi-objective optimization, In: Search methodologies, Eds: Springer, p. 403-449.
- Draa, A. ve Bouaziz, A., 2014, An artificial bee colony algorithm for image contrast enhancement, *Swarm and Evolutionary Computation*, 16, 69-84.
- Eberhart, R. ve Kennedy, J., 1995, A new optimizer using particle swarm theory, *MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science*, 39-43.
- Eberhart, R., Simpson, P. ve Dobbins, R., 1996, Computational intelligence PC tools, Academic Press Professional, Inc., p.
- Eiben, A. E. ve Smith, J. E., 2003, Introduction to evolutionary computing, Springer, p.
- Friedman, M., 1937, The Use of Ranks to Avoid the Assumption of Normality Implicit in the Analysis of Variance, *Journal of the American Statistical Association*, 32 (200), 675-701.

- Goldberg, D. E. ve Deb, K., 1991, A comparative analysis of selection schemes used in genetic algorithms, In: Foundations of genetic algorithms, Eds: Elsevier, p. 69-93.
- Gonzalez, R. C. ve Woods, R. E., 2002, Digital Image Processing, New Jersey, prentice Hall.
- Gonzalez, R. C. ve Woods, R. E., 2006, Digital Image Processing (3rd Edition), Prentice-Hall, Inc., p.
- Gonzalez, R. C., Woods, R. E. ve Eddins, S. L., 2009, Digital Image Processing Using MATLAB®, Gatesmark Publishing, p.
- Gonzalez, T. F., 2007, Handbook of approximation algorithms and metaheuristics, Chapman and Hall/CRC, p.
- Gorai, A. ve Ghosh, A., 2009, Gray-level image enhancement by particle swarm optimization, *Nature & Biologically Inspired Computing, 2009. NaBIC 2009. World Congress on*, 72-77.
- Gorai, A. ve Ghosh, A., 2011, Hue-preserving color image enhancement using particle swarm optimization, *Recent Advances in Intelligent Computational Systems (RAICS), 2011 IEEE*, 563-568.
- Hashemi, S., Kiani, S., Noroozi, N. ve Moghaddam, M. E., 2010, An image contrast enhancement method based on genetic algorithm, *Pattern Recognition Letters*, 31 (13), 1816-1824.
- Holland, J., 1992, Adaptation in Natural and Artificial Systems, 1992 ed, MIT Press, Cambridge, MA.
- Hunt, R. W. G., 1977, The Specification of Colour Appearance. I. Concepts and Terms, *Color Research & Application*, 2 (2), 55-68.
- Joshi, P. ve Prakash, S., 2015, An efficient technique for image contrast enhancement using artificial bee colony, *Identity, Security and Behavior Analysis (ISBA), 2015 IEEE International Conference on*, 1-6.
- Karaboga, D., 2005, An idea based on honey bee swarm for numerical optimization, *Technical report-tr06, Erciyes university, engineering faculty, computer*
- Karaboga, D. ve Basturk, B., 2007, A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm, *Journal of Global Optimization*, 39 (3), 459-471.
- Kaur, J., 2012, Comparative analysis for contrast enhancement using histogram equalization techniques, *Journal of Global Research in Computer Science*, 3 (5), 30-32.
- Kaveh, A., 2014, Advances in metaheuristic algorithms for optimal design of structures, Springer, p.
- Kennedy, J. ve Eberhart, R., 1995, Particle swarm optimization, *Proceedings of ICNN'95 - International Conference on Neural Networks*, 1942-1948 vol.1944.
- Kim, H.-J., Lee, J.-M., Lee, J.-A., Oh, S.-G. ve Kim, W.-Y., 2006, Contrast enhancement using adaptively modified histogram equalization, *Pacific-Rim Symposium on Image and Video Technology*, 1150-1158.
- Lal, S., Narasimhadhan, A. V. ve Kumar, R., 2015, Automatic Method for Contrast Enhancement of Natural Color Images, *Journal of Electrical Engineering and Technology*, 10 (3), 1233-1243.
- Levkowitz, H., 1988, Color in computer graphic representation of two-dimensional parameter distributions.
- Lim, J. S., 1990, Two-dimensional signal and image processing, *Englewood Cliffs, NJ, Prentice Hall, 1990, 710 p.*

- Lowe, D. G., 2004, Distinctive image features from scale-invariant keypoints, *International journal of computer vision*, 60 (2), 91-110.
- McAndrew, A., 2004, An introduction to digital image processing with matlab notes for scm2511 image processing, *School of Computer Science and Mathematics, Victoria University of Technology*, 264.
- Michalewicz, Z., 1996, Genetic Algorithms+ Data Structures= Evolution Programs, Springer Science & Business Media, p.
- Mitchell, M., 1998, An introduction to genetic algorithms, MIT press, p.
- Mondal, S. K., Chatterjee, A. ve Tudu, B., 2018, A Hybrid Particle Swarm Optimization and Artificial Bee Colony Algorithm for Image Contrast Enhancement, *Proceedings of the International Conference on Computing and Communication Systems*, 277-285.
- Munteanu, C. ve Lazarescu, V., 1999, Improving mutation capabilities in a real-coded genetic algorithm, *Workshops on Applications of Evolutionary Computation*, 138-149.
- Munteanu, C. ve Rosa, A., 2000, Towards automatic image enhancement using genetic algorithms, *Evolutionary Computation, 2000. Proceedings of the 2000 Congress on*, 1535-1542.
- Munteanu, C. ve Rosa, A., 2004, Gray-scale image enhancement as an automatic process driven by evolution, *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 34 (2), 1292-1298.
- Niblack, W., 1986, An introduction to digital image processing, Prentice-Hall Englewood Cliffs, p.
- Peli, E., 1990, Contrast in complex images, *JOSA A*, 7 (10), 2032-2040.
- Poddar, S., Tewary, S., Sharma, D., Karar, V., Ghosh, A. ve Pal, S. K., 2013, Non-parametric modified histogram equalisation for contrast enhancement, *IET Image Processing*, 7 (7), 641-652.
- Prabha, D. S. ve Kumar, J. S., 2017, An efficient image contrast enhancement algorithm using genetic algorithm and fuzzy intensification operator, *Wireless Personal Communications*, 93 (1), 223-244.
- Pratt, W. K., 1991, Digital image processing john wiley & sons, Inc., New York.
- Pratt, W. K., 2006, Image Enhancement, In: Digital Image Processing, Eds: John Wiley & Sons, Inc., p. 247-305.
- Qinqing, G., Dexin, C., Guangping, Z. ve Ketai, H., 2011, Image enhancement technique based on improved PSO algorithm, *Industrial Electronics and Applications (ICIEA), 2011 6th IEEE Conference on*, 234-238.
- Raju, A., 2013, A comparative analysis of histogram equalization based techniques for contrast enhancement and brightness preserving.
- Raju, G. ve Nair, M. S., 2014, A fast and efficient color image enhancement method based on fuzzy-logic and histogram, *AEU - International Journal of Electronics and Communications*, 68 (3), 237-243.
- Ramponi, G., Strobel, N. K., Mitra, S. K. ve Yu, T.-H., 1996, Nonlinear unsharp masking methods for image contrast enhancement, *Journal of Electronic Imaging*, 5 (3), 353-367.
- Retinex Image Processing, Retinex Image Processing, <https://dragon.larc.nasa.gov/retinex/pao/news/>: [18.12.2018].
- Saitoh, F., 1999, Image contrast enhancement using genetic algorithm, *Systems, Man, and Cybernetics, 1999. IEEE SMC'99 Conference Proceedings. 1999 IEEE International Conference on*, 899-904.

- Santhi, K. ve Banu, R. W., 2015, Adaptive contrast enhancement using modified histogram equalization, *Optik-International Journal for Light and Electron Optics*, 126 (19), 1809-1814.
- Sheet, D., Garud, H., Suveer, A., Mahadevappa, M. ve Chatterjee, J., 2010, Brightness preserving dynamic fuzzy histogram equalization, *IEEE Transactions on Consumer Electronics*, 56 (4).
- Sheikh, H. ve Bovik, A., 2006, Image information and visual quality, *Image Processing, IEEE Transactions on*, 15 (2), 430-444.
- Sheikh, H. R., Bovik, A. C. ve De Veciana, G., 2005, An information fidelity criterion for image quality assessment using natural scene statistics, *IEEE transactions on image processing*, 14 (12), 2117-2128.
- Shi, Y. ve Eberhart, R., 1998, A modified particle swarm optimizer, *Evolutionary Computation Proceedings, 1998. IEEE World Congress on Computational Intelligence., The 1998 IEEE International Conference on*, 69-73.
- Shyu, M.-S. ve Leou, J.-J., 1998, A genetic algorithm approach to color image enhancement, *Pattern Recognition*, 31 (7), 871-880.
- Singh, D. P. ve Khare, A., 2013, Evolutionary Image Enhancement Using Multi-Objective Genetic Algorithm, *International Journal of Image, Graphics and Signal Processing*, 6 (1), 61.
- SIPI Image Database, Volume 3: Miscellaneous, <http://sipi.usc.edu/database/database.php?volume=misc>: [15.12.2018].
- Sivanandam, S. ve Deepa, S., 2007, Introduction to genetic algorithms, Springer Science & Business Media, p.
- Süsstrunk, S. ve Winkler, S., 2004, Color Image Quality on the Internet, in *Proc. SPIE*.
- Trahanias, P. ve Venetsanopoulos, A., 1992, Color image enhancement through 3-D histogram equalization, *11th IAPR International Conference on Pattern Recognition. Vol. III. Conference C: Image, Speech and Signal Analysis*, 545-548.
- True Color Kodak Images, Kodak Lossless True Color Image Suite, <http://r0k.us/graphics/kodak/>: [18.12.2018].
- Tubbs, J. D., 1987, A note on parametric image enhancement, *Pattern Recognition*, 20 (6), 617-621.
- Vanzo, A., Ramponi, G. ve Sicaranza, G., 1994, An image enhancement technique using polynomial filters, *Image Processing, 1994. Proceedings. ICIP-94., IEEE International Conference*, 477-481.
- Venkatalakshmi, K. ve Shalinie, S. M., 2010, A customized particle swarm optimization algorithm for image enhancement, *Communication Control and Computing Technologies (ICCCCT), 2010 IEEE International Conference on*, 603-607.
- Wang, C. ve Ye, Z., 2005, Brightness preserving histogram equalization with maximum entropy: a variational perspective, *IEEE Transactions on Consumer Electronics*, 51 (4), 1326-1334.
- 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.
- Wu, X., 2011, A linear programming approach for optimal contrast-tone mapping, *IEEE transactions on image processing*, 20 (5), 1262-1272.
- Yang, X.-S., 2010, Nature-inspired metaheuristic algorithms, Luniver press, p.
- Yimit, A., Hagihara, Y., Miyoshi, T. ve Hagihara, Y., 2013, Automatic image enhancement by artificial bee colony algorithm, *International Conference on Graphic and Image Processing (ICGIP 2012)*, 87681R.

- Zeng, P., Dong, H., Chi, J. ve Xu, X., 2004, An approach for wavelet based image enhancement, *Robotics and Biomimetics, 2004. ROBIO 2004. IEEE International Conference on*, 574-577.
- Zheng, Y.-l., Ma, L.-h., Zhang, L.-y. ve Qian, J.-x., 2003, Empirical study of particle swarm optimizer with an increasing inertia weight, *Evolutionary Computation, 2003. CEC'03. The 2003 Congress on*, 221-226.



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Aybüke BABADAĞ
Uyruğu : T.C.
Doğum Yeri ve Tarihi : Meram / 13.10.1994
Telefon : 05344290710
Faks : -
e-mail : aybuke.babadag@yandex.com

EĞİTİM

Derece	Adı. İlçe. İl	Bitirme Yılı
Lise	: Selçuklu Atatürk Lisesi, Selçuklu, KONYA	2012
Üniversite	: Selçuk Üniversitesi – Bilgisayar Mühendisliği, Selçuklu, KONYA	2016
Yüksek Lisans :	Selçuk Üniversitesi – Bilgisayar Mühendisliği ABD, Selçuklu, KONYA	Devam ediyor

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2019	Konya Teknik Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi	Arş. Gör.

YABANCI DİLLER

YDS C Sınıfı 78,75 (İngilizce)
 YÖKDİL 95 (İngilizce)

BELİRTMEK İSTEĞİNİZ DİĞER ÖZELLİKLER

2016 – Selçuk Üniversitesi Bilgisayar Mühendisliği Bölümü Bölüm 3.sü

YAYINLAR

Uluslar Arası Konferanslarda Sunulan Yayınlar

1. BABADAĞ, A., BAYKAN, Ö.K., 2018, Yapay arı kolonisi tabanlı çok amaçlı görüntü zenginleştirme. International Eurasian Conference on Science, Engineering and Technology (EURASIANSCIENTECH). Ankara, TÜRKİYE. (Yüksek lisans tezinden yapılmıştır)