

T.C
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ARI KOLONİ OPTİMİZASYON YÖNTEMİ İLE GRİ
SEVİYELİ GÖRÜNTÜ BÖLÜTLEME

Yüksek Lisans Tezi

Fatma ER

102131101

Anabilim Dalı : Elektronik Bilgisayar Eğitimi

Danışman : Doç. Dr. Abdulkadir ŞENGÜR

OCAK-2014

T.C
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ARI KOLONİ OPTİMİZASYON YÖNTEMİ İLE GRİ SEVİYELİ GÖRÜNTÜ
BÖLÜTLEME

YÜKSEK LİSANS TEZİ

Fatma ER
(102131101)

Tezin Enstitüye Verildiği Tarih : 26.12.2013

Tezin Savunulduğu Tarih : 10.01.2014

Tez Danışmanı : Doç. Dr. Abdulkadir ŞENGÜR 

Diğer Jüri Üyeleri : Doç. Dr. İbrahim TÜRKOĞLU 

Yrd. Doç. Dr. Erkan TANYILDIZI 

OCAK -2014

ÖNSÖZ

Bu tez çalışmasında, yeni geliştirilen sürü zekâsı yaklaşımlarından biri olan yapay arı koloni optimizasyon algoritması kullanılarak gri seviye dokulu görüntülerin bölütlenmesi gerçekleştirilmiştir. Önerilen yaklaşımın bölütleme algoritmalarının literatürüne zenginlik ve farklılık katacağı düşüncesindeyim.

Çalışmalarımın her aşamasında beni yönlendiren, bilgi, öneri ve yardımlarını esirgemeyen değerli hocalarım Doç. Dr. Abdulkadir ŞENGÜR ve Öğr. Gör. Kazım HANBAY' a teşekkürü bir borç bilirim.

Fatma ER
Elazığ-2014

İÇİNDEKİLER

ÖNSÖZ	II
İÇİNDEKİLER.....	III
ÖZET	IV
SUMMARY.....	V
ŞEKİLLER LİSTESİ	V
SEMBOLLER LİSTESİ	VI
KISALTMALAR LİSTESİ	VII
1. GİRİŞ	1
1.1. Görüntü Bölütleme.....	3
1.1.1. Kümeleme Metotları	4
1.1.2. Eşikleme Metodu	4
1.1.3. Kenar Çıkarma Metodu.....	5
1.2. Dalgacık Dönüşümü.....	6
1.3. Eş-Oluşum Matrisi	9
1.4. Entropi Fonksiyonu	10
2. ENİYİLEME	11
2.1. Sezgisel Optimizasyon Algoritmaları	12
2.1.1. Ateş Böceği Algoritması	13
2.1.2. Ateş Böceği Sürü Optimizasyon Algoritması	14
2.1.3. Karınca Koloni Optimizasyon Algoritması	14
2.1.4. Parçacık Sürü Optimizasyon Algoritması	15
3. YAPAY ARI KOLONİ ALGORİTMASI.....	16
3.1. Gerçek Arıların Yiyecek Arama Davranışları.....	16
3.2. Yapay Arı Koloni Algoritması.....	19
3.2.1. Yapay Arı Koloni Algoritmasının Adımları	20
3.2.2. Algoritmada Başlangıç Yiyecek Kaynaklarının Üretilmesi.....	21
4. YAPAY ARI KOLONİ ALGORİTMASI İLE GRİ SEVİYE DOKULU GÖRÜNTÜLERİN BÖLÜTLENMESİ UYGULAMALARI	23
4.1. Yapay Arı Koloni Algoritması ile Gri Seviye Dokulu Görüntülerin Bölütlenmesi Uygulama Sonuçları.....	27
5. SONUÇ.....	31
KAYNAKLAR.....	32
ÖZGEÇMİŞ.....	35

ÖZET

Gri seviye ve renkli görüntülerin sayısal olarak değerlendirilmesinde bölütleme önemli bir basamaktır. Görüntü bölütleme işlemi, verilen bir resmi benzer özelliklere sahip farklı bölgelere ayırmaktır. En temel bölütleme yöntemi eşikleme tekniği olsa da zaman içerisinde bu yöntem yetersiz kalmıştır. Bu tez çalışmasında gri seviyeli görüntülerin bölütlenmesinde dalgacık dönüşümü, entropi fonksiyonu ve yapay arı koloni algoritması kullanan yeni bir yöntem geliştirilmiştir. Görüntünün öz niteliklerini elde etmek için dalgacık dönüşümünden faydalanılmıştır. Dalgacık analizi sonuçları üzerinde optimum eşik değere ulaşmak için entropi fonksiyonu kullanılmıştır. Entropi fonksiyonu en uygun eşik değeri vermesi için yapay arı koloni algoritması ile optimize edilmiştir. Optimizasyon algoritmaları arasında yeni geliştirilen bir teknik olan ve sürü zekâsına dayanan arı koloni algoritması sayesinde en uygun eşik değeri elde edilerek görüntünün eşik değeri otomatik olarak bulunmuştur. Uygulanan yöntem bazı görüntülerde istenen sonucu vermese de özellikle hız bakımından oldukça uygun bir yöntemdir. Ayrıca yapay arı koloni algoritması ile görüntü bölütleme literatürüne zenginlik kazandırılmıştır. Geliştirilen teknik türev gibi işlemler içermediği için matematiksel karmaşıklık açısından oldukça uygundur.

Anahtar Kelimeler: Gri seviye dokulu görüntü bölütleme, Sürü zekâsı, Yapay arı koloni algoritması, Dalgacık dönüşümü, Entropi fonksiyonu

SUMMARY

GRAY SCALE IMAGE SEGMENTATION USING ARTIFICIAL BEE COLONY OPTIMIZATION ALGORITHM

Digitally evaluation of the gray scale and color images in an important step. Image segmentation process is partitioning a given image according to various features. Image thresholding is known as the basic image segmentation method but it is not enough good for all image segmentation applications. In this thesis, a new method is proposed based on wavelet transformation, entropy function and artificial bee colony algorithm for gray texture segmentation. For feature extraction, the wavelet transformation is used. The entropy function is used to find the optimum threshold on the normalized wavelet coefficients. For this purpose, an optimization procedure called the artificial bee colony algorithm is used. Artificial bee colony algorithm, which is based on the swarm intelligence is an optimization algorithm and used for finding the optimum automatic threshold for the segmentation of the input image. Based on the experimental results, the proposed method yields better segmentation results. The proposed method yields worse results for several images but the running time of the algorithm is considerable short.

Key Words: Gray texture image segmentation, Swarm intelligence, Artificial bee colony algorithm, Wavelet transform, Entropy function.

ŞEKİLLER LİSTESİ

Şekil 1.1. Görüntü işleme aşamaları.....	1
Şekil 1.2. Gürültülü resimlerin filtrelenmesi aşamaları a) Gürültülü resim b) Alçak-geçiren filtre uygulanmış resim c) Ortanca filtre uygulanmış resim.	2
Şekil 1.3. Bölütlenmiş görüntü örneği (a) Renkli görüntü (b) Doku sınıfları (c) Ham bölütleme (d) Final bölütlemesi.....	3
Şekil 1.4. İki seviyeli görüntü eşiklemeşi	5
Şekil 1.5. Çok seviyeli görüntü eşiklemeşi: (a) Çok tepeli histogram, (b) Giriş görüntüsü, (c)-(e) Giriş görüntüsünün sağ üst köşesinin sırasıyla 110,147,185 eşik değerleri için bölütlenmesi	5
Şekil 1.6. a) Orijinal kameraman görüntüsü, b) Sobel operatörü ile elde edilen kenar görüntüsü, c)Orijinal kameraman görüntüsü, b) Canny operatörü ile elde edilen kenar görüntüsü	6
Şekil 1.7. İki boyutlu dalgacık dönüşümün ilk basamağı.....	7
Şekil 1.8. İki boyutlu dalgacık dönüşümünün ikinci basamağı.....	8
Şekil 1.9. Görüntü analizi: (a) Bir seviyeli (b) İki seviyeli	8
Şekil 2.1. Sezgisel yöntemler	13
Şekil 2.2. (a) Örnek bir GSP, (b) GSP çözümü.	14
Şekil 3.1. Arıların yiyecek arama çevrimi.....	18
Şekil 3.2. YAK algoritması akış diyagram	22
Şekil 4.1. YAK ile görüntü bölütleme uygulamaları Matlab sonuçları (a) Başlangıç yiyecek kaynağı matrisi (b) Başlangıç entropi matrisi (c) Başlangıç fitness matrisi.....	24
Şekil 4.2. YAK ile görüntü bölütleme uygulamaları Matlab sonuçları (a) Güncel yiyecek kaynağı matrisi (b) Güncel entropi matrisi (c) Güncel fitness matrisi	25
Şekil 4.3. Geliştirilen bölütleme yönteminin akış şeması.	27
Şekil 4.4. Önerilen yöntemin uygulama sonuçları ve Waveseg yöntemi ile karşılaştırılması (a)Gri seviye görüntü (b) Önerilen yaklaşım kullanılarak elde edilen görüntü bölütleme sonucu (c) Waveseg bölütlemesi	28

SEMBOLLER LİSTESİ

μ	: Mikron (milimetrenin binde birine eşit uzunluk birimi)
i	: Optimizasyon parametre sayısı
j	: Üretilen yiyecek kaynağı sayısı
v_{ij}	: Yeni uygun çözüm
x_j	: Şimdiye kadar ki en iyi çözümün j. parametresi
ϕ_{ij}	: [0,1] Aralığında rastgele sayı
φ_{ij}	: [0,c] arasında rastgele üretilen sayı
k	: 1 ile yiyecek kaynağı sayısı arasında rastgele seçilen sayı
f_i	: Çözümün maliyet değeri
fitness_i	: i. kaynağın kalitesi
SN	: Görevli arı sayısı
h_i	: Düşük geçirgenlikli filtre
g_i	: Yüksek geçirgenlikli filtre
i	: İterasyon sayısı
$\Phi_{i,t}$	: Dalgacık fonksiyonu
s_i	: İşaret genişleme katsayısı
d_i	: Dalgacık katsayısı
$c_{k,d}$	: Normalleştirme sabiti
c	: Sabit sayı
p	: Görüntü seviyesi sabiti
LH_E	: LH alt bandının enerji değeri
HL_E	: HL alt bandının enerji değeri
I_I	: İdeal sayı
I_D	: Bulunan kenar noktaları
d_k	: Bulunan kenar noktalarının ideal kenar noktaları çizgilerine uzaklığı


KISALTMALAR LİSTESİ

MRI	: Magnetik Rezonans Görüntüleme
PSO	: Parçacık Sürü Optimizasyonu
GSP	: Gezgin Satıcı Problemi
YAK	: Yapay Arı Koloni

1. GİRİŞ

Nesneler tarafından yansıtılan ışık enerjisi nesnenin görüntüsünü ihtiva eder ve bir alıcı tarafından algılanarak sayısal sinyallere dönüştürülür. Sayısal görüntüler renkli ve gri seviyeli olmak üzere ikiye ayrılırlar. Gri seviyeli görüntüler 0 ile 255 sayıları arasında ifade edilerek farklı ton değerleri oluşturabilirler. Bu değerlerden 0 değeri siyah renge, 255 değeri ise beyaz renge karşılık gelir. Renkli seviyeli görüntü ise farklı spektrumlardaki gri seviyeli görüntülerin bir araya gelmesiyle oluşur. Elektromanyetik spektruma yansıyan ışık enerjisinde $0,4\mu-0,5\mu$ dalga boyu mavi, $0,5\mu-0,6\mu$ dalga boyu yeşil ve $0,6\mu-0,7\mu$ dalga boyu kırmızı renge karşılık gelir. Bu dalga boylarına sahip 3 gri görüntü üst üste konulacak olursa renkli seviyeli görüntü elde edilmiş olur.

Görüntü işleme, alıcılar tarafından algılanan görüntünün bilgisayara aktarılarak sayısallaştırılması ve üzerinde çeşitli uygulamalar yapılarak görüntüleyici çıkışa iletilmesi işlemlerini kapsar [1].




Şekil 1.1. Görüntü işleme aşamaları

Resimler genellikle analog ortamlardan dijital ortamlara aktarıldıkları için gürültü olarak adlandırılan bozukluklar içerebilirler. Görüntü işlemenin amacı, resmi gürültüsünden kurtararak hataları düzeltmek ve görüntü kalitesini arttırmaktır.

Görüntü işleme uygulamaları çok çeşitlidir;

- Görüntü iyileştirme,
- Görüntü filtreleme ve onarma,
- Görüntü sıkıştırma,
- Görüntüdeki cisimlerin algılanması,
- Görüntüdeki cisimlerin sınırlarının belirlenmesi gibi birçok görüntü işleme uygulaması vardır.



Şekil 1.2. Gürültülü resimlerin filtrelenmesi aşamaları a) Gürültülü resim b) Alçak-geçiren filtre uygulanmış resim c) Ortaçağ filtre uygulanmış resim [2].

Görüntü işleme uygulamasının önemli adımlarından biri görüntü bölütlemesidir. Görüntü bölütlemenin kullanılmasıyla yapılan bazı görüntü işleme uygulamaları şöyledir:

- Bilgisayarda görme (computer vision) uygulamaları,
- Uzaktan algılama uygulamaları: Uydu görüntüleri üzerinde nüfus yoğunluğu, yerleşim yerleri, çevre kirliliği vs. gibi çevresel şartların tespiti,
- Endüstriyel uygulamalar: Bir üretim bandında üretilen ürünün otomatik test edilmesi (Örneğin; bir kart üzerindeki devre elemanlarının varlığının veya bağlantı yollarının sağlamlığının tespiti),
- Elektron mikroskobu ile çekilmiş yarıiletken devre elemanı fotoğraflarından hasar tespiti,
- Güvenlik uygulamaları: Yüz tanıma, parmak izi tanıma, plaka tanıma,
- Banknot tanıma,
- Medikal görüntüleme: CAT, MRI, Röntgen,
- Astronomi uygulamaları,
- Radar uygulamaları,
- Uydu görüntüleri üzerinde hava gözlem ve tahmin uygulamaları,
- Jeolojik uygulamalar: Mineral ve petrol arama, sualtı görüntüleme,
- Arkeolojik uygulamalar: Nadir kalıntılara ait bulanık fotoğrafların iyileştirilmesi,
- Gazete ve fotoğraf endüstrisi uygulamaları,
- Bilgisayarda üretilen görüntüler: Fraktallar,
- Ve diğerleri.

1.1. Görüntü Bölütleme

Görüntü bölütleme, görüntüyü aralarında benzerlik gösteren belirli gruplara ayırma işlemidir. Bölütlenen alanların her biri kendi içerisinde homojen fakat diğer yakın alanlarla homojen değildir [3]. Görüntü bölütleme işleminin başarılı bir şekilde gerçekleşmiş kabul edilebilmesi için nesnelerin görüntüdeki diğer bileşenlerden bağımsız olması, ayrıca aynı doku ve renk özelliklerine sahip bölgelerin oluşturulması beklenir.

Görüntü bölütlemenin görüntü iyileştirme ve görüntü onarmadan farklı yanı görüntünün değerlendirilmesi ile ilgili bir adım olmasıdır. Görüntü bölütleme görüntü işleminin gösterim ve tanılama aşamalarına görüntüyü hazırlama işlemidir. Bu anlamda görüntü bölütleme, bir görüntüyü her biri içerisinde farklı özelliklerin tutulduğu anlamlı alanlara ayırmak olarak tarif edilebilir. Bu özellikler görüntü içerisindeki benzer parlaklıklar olabilir ve bu parlaklıklar ilgili görüntünün farklı bölgelerindeki nesneleri temsil edebilir. Görüntü içerisinde aynı parlaklıklara sahip nesne parçacıklarının belirlenmesi, sınıflandırma ve tanılama amacı için kullanılabilir. Şekil 1.3’de örnek bir bölütleme gösterilmiştir. Unutulmamalıdır ki, tüm görüntülere uygulanabilecek genel bir bölütleme yöntemi yoktur ve hiçbir bölütleme yöntemi mükemmel değildir. Başka bir deyişle, görüntü iyileştirme ve onarma problemlerinde olduğu gibi görüntü bölütleme için tasarlanan yöntemler ve bu yöntemlerin başarımları, görüntüden görüntüye ve uygulamaya dayalı olarak değişiklikler gösterebilir.



Şekil 1.3. Bölütlenmiş görüntü örneği (a) Renkli görüntü (b) Doku sınıfları (c) Ham bölütleme (d) Final bölütlemesi [4].

Görüntü bölütlemek için ortaya atılan yöntemlerden bazıları aşağıda açıklanmıştır:

1.1.1. Kümeleme Metotları

Kümeleme, N boyutlu Öklid uzayında, verilen n adet veriyi, benzerlikleri veya farklılıklarına bağlı olarak K adet gruba ayırma işlemi olarak tanımlanır. Bu n adet veri $S=\{X_1, X_2, X_3, \dots, X_n\}$ olarak gösterilirse ve K adet küme de $K=\{C_1, C_2, C_3, \dots, C_K\}$ olarak gösterilirse;

$$C_i \neq \emptyset \quad i = 1, \dots, K \quad (1.1)$$

$$C_i \cap C_j = \emptyset \quad i = 1, \dots, K, j = 1, \dots, K \text{ ve } i \neq j \quad (1.2)$$

$$\bigcup_{i=1}^K C_i = S \quad (1.3)$$

şeklinde ifade edilebilir.


Literatürde çeşitli kümeleme algoritmaları bulunmaktadır [5-7]. Kümeleme algoritmalarından en çok kullanılan K-ortalamar kümeleme algoritmasıdır. K-ortalamar yönteminin uygulanabilmesi için en önemli koşul, veri setindeki değişkenlerin en azından aralık ölçekte bulunmasıdır. Çünkü küme merkezleri oluşturulurken her bir iterasyonda oluşan kümeler için değişkenlerin ortalamaları alınır. İkinci önemli koşul ise, oluşturulacak olan küme sayısının başlangıçta biliniyor olmasıdır.

1.1.2. Eşikleme Metodu


Eşikleme metodu en temel bölütleme yöntemidir. Bu yöntem ile gri tonlu görüntülerde nesne ve arka plan renkleri arasındaki belirli bir karşıtlık farkından belirlenen eşik değerine göre bölütleme yapılır. Eşik değerin doğru seçilmesi yöntem için önemlidir. Bu seçim etkileşimli veya çeşitli eşik tanımlama algoritmalarıyla yapılır. Genel olarak önce bir eşik değeri seçilir ve işlenen piksel eşik değerinden büyükse nesne, aksi takdirde arka plan olarak değerlendirilir. Eşikleme metodu;

- İki Seviyeli Eşikleme
- Çok Seviyeli Eşikleme
- Entropi Tabanlı Eşikleme

olmak üzere çeşitlere ayrılmaktadır. Şekil 1.4’de iki seviyeli, Şekil 1.5’de çok seviyeli eşikleme yöntemleri görüntülenmektedir.



Şekil 1.4. İki seviyeli görüntü eşiklemesi [8].



Şekil 1.5. Çok seviyeli görüntü eşiklemesi: (a) Çok tepeli histogram, (b) Giriş görüntüsü, (c)-(e) Giriş görüntüsünün sağ üst köşesinin sırasıyla 110,147,185 eşik değerleri için bölütlenmesi [9].

1.1.3. Kenar Çıkarma Metodu

Kenar belirleme diğer adıyla ayırt sezme, görüntü işlemenin büyük öneme sahip konularından birisidir. Bir görüntünün kenar bölgesi görüntüdeki aydınlık veya yansımaya gibi görüntünün fiziksel görünüşünde meydana gelen önemli değişimlere ters düşer. Bu değişim kendisini parlaklık, renk ve doku olarak gösterir. Ancak bölütleme işleminde kenar ifadesi, sadece görüntüdeki parlaklık değişiklikleri ifade ederken kullanılır. Bu anlamda, görüntünün gri seviyelerinde ani değişikliklerin olduğu bölgelere kenar adı verilir.

Kenar tabanlı bölütleme yönteminde farklı algoritmalar kullanılır. Bu algoritmaların temel amacı, çeşitli kenar bulma operatörlerinin yardımı ile görüntüdeki farklı bölgelerin sınırlarını belirgin hale getirerek bu bölgeleri birbirinden ayırmaktır. Temel prensip gradyan operatörlerinin görüntüyle konvolüsyona sokularak uygulanmasıdır. Bunların içinden en önemlileri; Robert operatörü, Sobel operatörü, Prewitt operatörü, Canny operatörü, Krisch operatörüdür [10]. Bu operatörler içinden en iyi kenar bulucu Canny operatörüdür. Kenarları ayırırken görüntüdeki renk, doku veya hızlı

parlaklık deęiřiminden faydalanılır. řekil 1.6 da Sobel ve Canny operatörleri kullanılarak yapılmıř bir kenar çıkarma uygulaması görüntülenmektedir.



(a)



(b)



(c)



(d)

řekil 1.6. a) Orijinal kameraman görüntüsü, b) Sobel operatörü ile elde edilen kenar görüntüsü, c) Orijinal kameraman görüntüsü, d) Canny operatörü ile elde edilen kenar görüntüsü

Kenar tabanlı bölütlemelerde, bir doęrultudaki aydınlıktan karanlıęa geçiř hızındaki mümkün olan en büyük artıřın doęrultusunu veren her noktadaki görüntü yoğunluęunun gradyanı hesaplanır. Bu durumda elde edilen sonuç o noktadaki görüntünün ne kadar hızlı ya da yavař farklılařtıęını gösterir [11].

Kenar çıkarma yöntemine dayanarak bölütleme yapma iřlemi basit ve ucuz bir yöntem olsa da düşük kaliteli görüntüleme araçları ile edinilen birçok görüntüde bazı metotlar sahte kenarlar oluřturur. Bu nedenle bu metodun uygulanabilirlięi sınırlıdır.

1.2. Dalgacık Dönüřümü

Görüntü bölütlemelerde kaliteli sonuçlar için doku bilgilerini de elde etmek gereklidir. Bu noktada dalgacık dönüřümü kullanılarak görüntüdeki doku bilgilerinin analiz edilmesi saęlanır. Görüntüye dalgacık dönüřümü uygulayarak yatay, dikey ve diyagonal doku bilgileri elde edilir [12].

Dalgacık dönüřümü teknięinde yatay, dikey ve diyagonal öęeler içeren bir filtre bankası kullanılır. Yöntemin bu řekilde uygulanması bölge sınırlarının ayırıcı

özelliklerinin ve doku istatistiğinin daha detaylı hesaplanmasını sağlar. Dalgacık çerçeveleri analizi her (i) iterasyonunda genişletilen yüksek geçirgenlikli (g_i) ve düşük geçirgenlikli (h_i) filtreler kullanılarak görüntünün satır ve sütunları boyunca 1 boyutlu işlem ile başarılı bir şekilde Denklem (1.4)'teki gibi hesaplanabilir.

$$H_{i+1}(z) = H(z^{2^4})H_i(z), h_{i+1}(k) = [h]_{\uparrow 2^4} * h_i(k), \quad (1.4)$$

$$G_{i+1}(z) = G(z^{2^4})H_i(z), g_{i+1}(k) = [g]_{\uparrow 2^4} * h_i(k),$$

Bu genişleme filtreleri her biri ortalama sekizli alt bantlara sahip bir sinyali değerlendirmek için kullanılabilir. Dikey dalgacık analizi oluşturmak için aşağıda farklı normalleştirilmiş dalgacık fonksiyonları kullanılabilir.

$$\phi_{i,t}(k) = 2^{i/2} h_{i(k-2^i t)}, \quad (1.5)$$

$$\varphi_{i,t}(k) = 2^{i/2} g_{i(k-2^i t)}$$


Bu denklemlerdeki i ve t skala ve dönüşüm indeksini gösterir. Hızlı ve iteratif bir analiz uygulamasına aşağıdaki gibi ulaşılabilir;

$$s_{i+1} = [h]_{\uparrow 2^i} * s_i(k), \quad (1.6)$$

$$d_{i+1} = [g]_{\uparrow 2^i} * s_i(k)$$

Burada s_i ve d_i sırasıyla işaret genişleme katsayısı ve dalgacık katsayısıdır [13].


Buraya kadar anlatılan tek boyutlu sinyaller için verilen yaklaşım, iki boyutlu sinyal olan görüntü sinyali üzerinde de uygulanabilmektedir. Bu işlem için önce görüntünün her bir satırı yüksek-geçiren ve alçak-geçiren süzgeçten geçirilir. Her bir süzgecin çıktısı iki katsayısıyla aşağı-örneklenecek ara görüntüler olan L ve H'nin oluşumu sağlanır. Şekil 1.7' de iki boyutlu dalgacık dönüşümü işleminin ilk basamağı gösterilmektedir.



Şekil 1.7. İki boyutlu dalgacık dönüşümün ilk basamağı [14].


L orijinal görüntünün dikey yönünde (x-yönünde) alçak-geçiren süzgeçten, H orijinal görüntünün dikey yönünde yüksek-geçiren süzgeçten geçirilmiş halidir. Daha sonra

bu yeni görüntülerin (L ve H) her bir sütunu (y-yönünde) yüksek-geçiren ve alçak geçiren süzgeçlerden geçiriliyor. Her bir süzgecin çıkışı da daha önce olduğu gibi iki katsayısıyla aşağı-örnekleterek dört alt-görüntü elde ediliyor (LL, LH, HL ve HH). Şekil 1.8’ de iki boyutlu dalgacık dönüşüm işleminin ikinci basamağı verilmektedir.



Şekil 1.8. İki boyutlu dalgacık dönüşümünün ikinci basamağı [14].

Burada ‘LL’ görüntüsü orijinal görüntünün yatay ve dikey yönde alçak geçiren süzgeçten geçirilmiş ve iki katsayısıyla aşağı-örnekleilmiş şeklidir. ‘HL’ görüntüsü orijinal görüntünün dikey yönde yüksek geçiren, yatay yönde ise alçak geçiren süzgeçten geçirilmiş şeklidir. ‘LH’ görüntüsü dikey yönde alçak geçiren ve yatay yönde yüksek-geçiren süzgeçten geçirilmiş, ‘HH’ ise her iki yönde yüksek-geçiren süzgeçten geçirilmiş ve iki katsayısıyla aşağı-örnekleilmiş halleridir. Elde edilen alt bant görüntüleri orijinal görüntüde bulunan tüm bilgiye sahiptirler [14].



Şekil 1.9. Görüntü analizi: (a) Bir seviyeli (b) İki seviyeli [13].

Görüntü ayrıştırmasının ilk seviyesi, görüntü verisini Şekil 1.9 (a)'da gösterildiği gibi LL, HL, LH ve HH olarak belirtilen, dört alt banda ayırır. Her katsayı, orijinal görüntü ebadının dörtte birine denk gelen bir bölgeyi temsil eder. Yüksek frekanslar $\pi/2 < |\omega| < \pi$ bandını temsil ederken, düşük frekanslar $0 < |\omega| < \pi/2$ 'ye denk gelen bir bant genişliğini temsil eder. İkinci seviye ayrıştırma için ise LL alt bandı, Şekil 1.9 (b)'de gösterildiği gibi dört alt banda daha ayrılır. Yüksek frekansların ikinci seviyedeki ayrıştırması $\pi/4 < |\omega| < \pi/2$ 'ye karşılık gelirken, düşük frekansların ikinci seviye ayrıştırması $0 < |\omega| < \pi/4$ 'e karşılık gelmektedir. Bu ayrıştırmaya ihtiyaç duyulduğu kadar birçok seviyede devam edilebilir [15].

Doku temsiliinde asıl bilgi gri tonlardan elde edilir bu nedenle dalgacık dönüşümünde renk bilgisi önemli değildir. Sunulan doku analizi yönteminde ilk adım, renkli görüntüyü gri ton olarak ele alıp önceden değinilen sınıflara ayırmaktır. Renkli görüntünün gri tonları R, G ve B değerlerinin ortalaması alınarak elde edilmiştir. Doku niteliğini asıl karakterize eden bilgi orta frekanslı bölgelerdedir [16]. Bu nedenle çalışmamızda, alt bant görüntülerinden yalnızca orta frekanslı bölgeler olan yatay (LH) ve dikey (HL) ayrıntıya sahip görüntüler kullanılmıştır. Bu alt bant görüntülerinde, pencere operatörü içerisindeki piksellere ait dalgacık katsayılarının karelerinin medyan değeri alınarak enerji hesaplaması yapılır. Yatay ve dikey ayrıntıdaki görüntüler için bir enerji görüntüsü oluşturulur. Bundan sonraki aşamada elde edilen LH ve HL görüntü matrisleri kuantalanarak entropi hesaplamasında kullanılacak gri seviye eş oluşum matrisi elde edilir.

1.3. Eş-Oluşum Matrisi

Görüntünün analizinde yatay ve dikey doğrultularda sırasıyla N_x ve N_y adet pikselden oluşan bir alt pencerenin olduğunu varsayalım. Alt pencereler içindeki piksellerin G seviye ile kuantalandığını düşünelim. $L_x = \{1, 2, \dots, N_x\}$ yatay uzaysal domeni, $L_y = \{1, 2, \dots, N_y\}$ dikey uzaysal domeni, $\{0, 1, 2, \dots, G-1\}$ G adet kuantalanmış gri-tonu temsil etsin. $L_y \times L_x$ matrisi, görüntüde satır-sütun düzeninde sıralanmış alt pencereye ait piksellerin kümesidir.

Bir I görüntüsünün doku-içerik bilgisi, P_{ij} bağıl frekanslar matrisi tarafından belirlenmektedir. Bu matriste aralarında d mesafesi bulunan iki pikselden biri i , öteki de j gri tonuna sahiptir. Açık ve sıklık bilgisi taşıyan matrise literatürde *eş-oluş matrisi* ('co-

occurrence matrix') adı verilir. Bu matris, alt pencere içindeki pikseller arasındaki açısal ilişkinin ve mesafenin fonksiyonudur. 45°lik aralıklarla kuantalanmış açılar için normalize edilmemiş sıklık değerleri aşağıdaki şekilde tanımlanmıştır.

$$\begin{aligned}
 P(i,j,d,0^\circ) &= \# \left\{ \begin{array}{l} ((k,l),(m,n)) \in (L_y \times L_x) \times (L_y \times L_x) \\ |k-m|=0, \quad |l-n|=d, \quad I(k,l)=i, \quad I(m,n)=j \end{array} \right\} \\
 P(i,j,d,45^\circ) &= \# \left\{ \begin{array}{l} ((k,l),(m,n)) \in (L_y \times L_x) \times (L_y \times L_x) \\ (k-m=d, \quad l-n=-d) \text{ veya } (k-m=-d, \quad l-n=d), \quad I(k,l)=i, I(m,n)=j \end{array} \right\} \\
 P(i,j,d,90^\circ) &= \# \left\{ \begin{array}{l} ((k,l),(m,n)) \in (L_y \times L_x) \times (L_y \times L_x) \\ |k-m|=d, \quad l-n=0, \quad I(k,l)=i, \quad I(m,n)=j \end{array} \right\} \\
 P(i,j,d,135^\circ) &= \# \left\{ \begin{array}{l} ((k,l),(m,n)) \in (L_y \times L_x) \times (L_y \times L_x) \\ (k-m=d, \quad l-n=d) \text{ veya } (k-m=-d, \quad l-n=-d), \quad I(k,l)=i, I(m,n)=j \end{array} \right\}
 \end{aligned} \tag{1.7}$$

Burada #, küme içindeki eleman sayısını göstermektedir. Her bir d ve θ değeri için ayrı bir $G \times G$ kare matris oluşturulmaktadır. Aşırı hesap yükü olması nedeniyle, genellikle $d=1$ ve 2 piksel, $\theta = 0^\circ, 45^\circ, 90^\circ$, ve 135° açı değerleri için matrisler oluşturulur. Görüntüyü daha az sayıda gri-tona kuantalayarak (gri-ton adedini azaltarak) hesap yükünü hafifletmek mümkündür. Ancak, bu durumda bir miktar dokusal bilgi kaybının olacağını unutmamak gerekir [17].

1.4. Entropi Fonksiyonu

Entropi termodinamik ve bilgi teorisi alanlarında sıklıkla kullanılan geniş bir kavramdır. Bilgi teorisinde entropi kavramı bir zaman serisinin düzensizliğini belirlemek için kullanılır. Bir veri setinin entropi değeri ile düzensizliğinin orantılı olduğu söylenir [18,19]. Entropi değerinin hesaplanması için kullanılan birçok yöntem mevcuttur. İlk olarak Shannon tarafından ortaya konan entropi hesaplama metodundan sonra Norm, Eşik, Logaritmik gibi entropi hesaplama metodları da geliştirilmiştir [19]. Ayrıca zaman serilerinde entropi hesaplanması için geliştirilmiş Sample entropi ve Approximate entropi gibi iki farklı entropi metodu da bulunmaktadır [20,21]. Bu çalışmada ilk ve en temel entropi hesaplama yöntemi olan Shannon metodu üzerine bir uygulama yapılmıştır. Aşağıda Shannon metodunun matematiksel alt yapısını veren formül görülmektedir [22].

Denklem (1.8)'de verilen entropi fonksiyonu yardımıyla optimum eşik değeri bulmak için yapay arı koloni algoritmasından yararlanılmıştır.

$$H_{grey}(s, t) = \frac{1}{2}(H(E|O) + H(E|B)) = \frac{1}{2} \left[\left(- \sum_{i=0}^s \sum_{j=t+1}^{L'-1} p_{ij}^{Q_2} \log_2 p_{ij}^{Q_2} \right) + \left(- \sum_{i=s+1}^{L-1} \sum_{j=t+1}^{L'-1} p_{ij}^{Q_3} \log_2 p_{ij}^{Q_3} \right) \right] \quad (1.8)$$

2. ENİYİLEME (OPTİMİZASYON)


Optimizasyon, eniyileme anlamına gelmektedir. Bir problem için, verilen şartlar altında tüm çözümler arasından en iyi çözümü elde etme işidir. Belirli sınırlamaları sağlayacak şekilde, bilinmeyen parametre değerlerinin bulunmasını içeren herhangi bir problem, eniyileme problemi olarak adlandırılabilir [23].

Bazen tek başlarına etkisiz kalan varlıklar, birlikte hareket ettiklerinde çok zekice davranışlar sergileyebilmektedir. Bu özellik bize canlılarda sürü zekâsının varlığını gösterir. Sürü zekâsı; karıncalar, arılar, balıklar ve kuşlar gibi hayvanların birlikte yaşamak için oluşturdukları ortak zekâ yaklaşımının bilgisayar ortamında yapay olarak modellenmesidir. Örneğin, bir canlı sürüsünü oluşturan bireylerden birisi bir tehlike sezdiğinde bu tehlikeye karşı tepki verir ve bu tepki sürü içinde ilerleyip tüm bireylerin tehlikeye karşı ortak bir davranış sergilemesini sağlar. Canlıların sürü içerisindeki bu hareketleri gözlemlenerek sürü zekâsı tabanlı eniyileme algoritmaları geliştirilmiştir.

2.1. Sezgisel Optimizasyon Algoritmaları

Sezgisel algoritmalar, hedefe ulaşmak için doğal canlılardan esinlenen algoritmalarlardır. Sezgisel algoritmalar amaca ulaşmada kesin çözümün güvencesini vermemekle birlikte çözüme yakınsamayı garanti etmektedir. Anlaşılabilirlik yönünden sezgisel algoritmaların karar verici yanı çok daha basittir. Sezgisel algoritmalar, öğrenme amaçlı kesin çözümü bulma işleminin bir parçası olarak kullanılabilir. Matematik formülleriyle yapılan tanımlamalarda genellikle gerçek dünya problemlerinin en zor tarafları(hangi amaçlar ve hangi sınırlamalar kullanılmalı, hangi alternatifler test edilmeli, problem verisi nasıl toplanmalı) ihmal edilir. Model parametrelerini belirleme aşamasında kullanılan verinin hatalı olması, sezgisel yaklaşımın üretebileceği alt optimal çözümden daha büyük hatalara sebep olabilir [24].

Sezgisel eniyileme yöntemleri; biyoloji tabanlı, fizik tabanlı, sürü tabanlı, sosyal tabanlı, müzik tabanlı ve kimya tabanlı olmak üzere altı farklı grupta değerlendirilmektedir. Ayrıca bunların birleşimi olan melez yöntemler de vardır. Bahsedilen bu yöntemler Şekil 2.1’ de gösterilmiştir.



Şekil 2.1. Sezgisel yöntemler [25].

Bazı sürü zekâsı optimizasyon algoritmaları:

2.1.1. Ateş Böceği Algoritması

Ateş böceği algoritması, Dr. Xin-She Yang (Cambridge Üniversitesi,2007) tarafından geliştirilen ve tropikal iklim bölgelerindeki ateşböceklerinin sosyal davranışlarını temel alan bir meta-sezgisel eniyileme algoritmasıdır [26]. Bu algoritma en basit sürü zekâsı algoritmalarından biridir.

Bir ateş böceği diğer ateş böceklerini çekmek için ışıklarını yakıp söndürür. Yanıp sönen ışıkların üretimindeki karmaşık biyokimyasal sürecin detayları ve gerçek amacı bilim dünyasında hâlâ bir tartışma konusu olmasına rağmen, birçok araştırmacı yanıp sönen ışıkların ateşböceğine, arkadaşlarını bulmada, olası avlarını çekmede ve avcılarından kendilerini korumada yardımcı olduğuna inanmaktadır [25].

Ateş böceği algoritmasının temelini ateş böceklerinin birbirini çekmesi oluşturur. Temel varsayım bir ateş böceği ne kadar parlak olursa o kadar çekici olacağı yani diğer ateş böceklerinin ona doğru gideceğidir. Bu algortmada bütün ateş böceklerinin cinsleri göz önüne alınmamış hepsi tek cins olarak kabul edilmiştir.


2.1.2. Ateş Böceği Sürü Optimizasyon Algoritması

Ateş Böceği Sürü Optimizasyonu, K. N. Krishnanand ve D. Ghose tarafından 2005 yılında geliştirilmiştir. Çok modelli fonksiyonları optimize etmek için önerilen sürü zekâsı tabanlı bir eniyileme algoritmasıdır. Bu yöntemde bireylerin kullandığı dinamik karar alanları vardır. Ateş böcekleri komşularından aldıkları sinyallerle karar alanlarını belirlemektedirler. Bu algoritmanın ateş böceği algoritmasından farkı "komşuların yeterlilik sayısı" sınırı olmaması ve mesafeye dayalı herhangi bir algı sınırı olmamasıdır [27].

2.1.3. Karınca Koloni Optimizasyon Algoritması

Karınca koloni optimizasyonu 1990'ların başında Marco Dorigo ve arkadaşları tarafından ortaya atılmıştır [28]. Karınca koloni optimizasyonu kaynağını karıncaların beslenmelerini sağlamak için yiyecek arama hareketlerinden alır. Karıncalar yiyecek ararken yuvalarının etrafından gelişigüzel bir arama başlatırlar. Herhangi bir yiyecek kaynağı bulunduğu anda bu önce kalite ve miktar açısından değerlendirilir daha sonra yuvaya taşınır. Karınca yuvasına geri dönerken yola bulunan kaynağın kalitesi miktarı ve uzaklığıyla bağlantılı olacak şekilde feromon adı verilen sıvı bırakır. Yola bırakılan feromon diğer karıncaların kaynaktan haberdar olmasına ve kaynaktaki yiyeceğin kalitesi hakkında bilgi edinmesine yardımcı olur.

Karıncaların feromon bırakma ve takip etme mantığı üzerine kurulu olan ilk algoritma Ant System Algoritmasıdır. Bu algoritma ilk olarak gezgin satıcı problemi üzerinde denenmiştir. GSP problemi bir kişinin, verilen şehirler üzerinden sadece bir kez geçme şartıyla, tüm şehirleri dolaşarak en kısa turu bulması problemidir. Şekil 2.2' de örnek bir GSP ve çözümü gösterilmiştir.



Şekil 2.2. (a) Örnek bir GSP, (b) GSP çözümü [29].

2.1.4. Par acık S r  Optimizasyon Algoritması

Par acık s r  optimizasyonu, kuş ve balık s r lerinin davranışlarından yola  ıkılarak ortaya atılmış bir optimizasyon y ntemidir. PSO pop lasyona dayalı olasılıksal bir optimizasyon y ntemi olup  ok parametrelili ve  ok deęişkenli optimizasyon problemlerine     mler  retmek i in kullanılmaktadır.

Par acık s r  optimizasyonunda kuş topluluęu s r y , s r y  oluřturan kuřlar ise par acıęı ifade eder. Her bir kuş, koordinatlarını,   z m uzayındaki her boyutta ne kadar hızla ilerledięi bilgisini, řimdiye kadar elde ettięi en iyi uygunluk deęerini ve bu deęeri elde ettięi koordinatları hatırlamalıdır.   z m uzayında her boyuttaki hızının ve y n n n her seferinde nasıl deęiřeceęi, komřularının en iyi koordinatları ve kendi kiřisel en iyi koordinatlarının birleřiminden elde edilecektir [30].

Yukarıda da bahsedildięi gibi PSO kuş s r lerinin davranışlarının taklidi olan bir algoritmadır. Kuřların doęada,  nceden yerini bilmedikleri yiyecek kaynaklarını bulmaları bir sorunun   z m n  bulmaya benzetilmiřtir.

3. YAPAY ARI KOLONİ ALGORİTMASI

Bu bölümde öncelikle yapay arı koloni algoritmasının oluşturulmasına ilham veren gerçek arıların yiyecek arama davranışı açıklanacaktır.

3.1. Gerçek Arıların Yiyecek Arama Davranışları

Doğal bir arı kolonisinde otorite olmaksızın iş bölümü vardır, bu da arıların kendi kendilerine organize olabildiklerini gösterir. Arılar bu özellikleriyle sürü zekâsının en önemli iki şartını sağlamış olurlar. Bu şartlar; sürüyü oluşturan bireylerin kendi kendine organize olması ve aralarında iş bölümü yapabilmeleridir. Her bir iş onun için özelleşmiş arı tarafından yerine getirilmektedir. Tereshko'nun reaktif difüzyon denklemine dayalı olarak işbirlikli zekânın ortaya çıkmasını sağlayan minimal yiyecek arama modelinde üç temel bileşen vardır. Bunlar yiyecek kaynakları, görevli işçi arılar ve görevsiz işçi arılardır. Ayrıca bu minimal model bir yiyecek kaynağına yönelme ve yiyecek kaynağını bırakma olmak üzere iki modda çalışmaktadır [31]. Bu bileşenler şu şekilde açıklanabilir:

1)Yiyecek kaynağı; arıların nektar, polen veya bal elde etmek için gittikleri kaynaklardır. Bir yiyecek kaynağının değerinin belirlenmesinde yuvaya yakın olması, çeşitlilik miktarı, nektar yoğunluğu, nektarın çıkarılmasının kolaylığı gibi etkenler söz konusudur. Ancak kolaylık açısından sadece yiyecek kaynağının zenginliği gibi tek bir özellik de ele alınabilir.

2)Görevli işçi arılar; daha önceden keşfedilmiş, konumları belli kaynaklara gitmek ve kaynaktaki nektarı kovana getirmekle sorumludurlar. İşçi arılar ziyaret ettikleri kaynağın zenginliği ve konum bilgisi ile ilgili bilgiyi kovanda bekleyen diğer arılarla paylaşmakla sorumludurlar.

3) Görevsiz işçi arılar; kaynak arayışı içerisinde olan arılardır. Görevi belirsiz iki çeşit işçi arı bulunmaktadır: içsel bir dürtüye veya bir dış etmene bağlı olarak rastgele kaynak arayışında olan kâşif arılar ve görevli arıları izleyerek bu arılar tarafından paylaşılan bilgiyi kullanarak yeni bir kaynağa yönelen gözcü arılar. Kâşif arıların sayısının tüm koloniye oranı ortalama %5-10 arasındadır [32].

Arılar yiyecek kaynağı buldukları zaman bu bilgiyi birbirlerine yaptıkları dans aracılığıyla aktarırlar. Bu nedenle kovanlarda bulunan en önemli alanlardan biri dans alanıdır. Bulunan yiyecek kaynağının kalitesi ve yeri hakkındaki bilgiler dans alanında

paylaşılmaktadır. Bu dans kaynak hakkında bilgili bir arının dans alanında dans etmesi ile başlar. Diğer arılar da onun antenine dokunarak kaynağın tadı, kokusu, yönü ve zenginliğiyle ilgili bilgi alabilirler. Bu dansın amacı keşfedilen kaynağa daha çok arı yönlendirebilmektir. Bu nedenle kovanın çeşitli dans alanlarında bu dans tekrarlanarak kaynağa geri dönülür. Dans alanında yapılan danslar kaynakla ilgili bazı kriterlere göre çeşitlilik gösterebilmektedir. Bu kriterlerden en önemlisi kaynağın tatlılığıdır ve bu kriter dans eşik değerini belirler. Bunun yanında nektarın çıkarılma kolaylığı, kovandan olan uzaklık, hava koşulları ve günün hangi vaktinde olunduğu dansı etkilen diğer etmenlerdir. Tüm zengin kaynaklarla ilgili bilgiler dans alanında gözcü arılara iletildiğinden, gözcü arılar bir kaç dansı izledikten sonra hangisini tercih edeceğine karar verir. Zengin kaynaklarla ilgili daha fazla bilgi aktarımı olduğundan bu kaynakların seçilme olasılığı daha fazladır.


Kaynak bilgisini taşıyan arının diğer arılara kaynağın yönü hakkında da bilgi vermesi gerekmektedir. Yön bilgisi alındıktan sonra hedefe ulaşmada güneşten faydalanılır. Güneşin önü kapanmış olsa bile polarize gün ışığından güneşin konumunu tayin edebilmektedirler.

Kaynağın kovana olan mesafesine göre çeşitli danslar vardır:

- 1) Dairesel dans: Yön bilgisi yok. (Max. 100m)
- 2) Kuyruk dansı: (8 rakamı figürü, 100m-10km)
- 3) Titreme dansı: (Kaynak zengin ancak kovanda yeterli nektar var.)

Tüm arıların aynı zaman diliminde yiyecek arama sürecinde olmadıklarını belirtmek gerekir. Yeni arıların yiyecek aramaya katılma olasılıklarının toplam arı sayısı ile o anda yiyecek arama sürecinde olan arıların sayılarının farkıyla orantılı olduğu çalışmalarla doğrulanmıştır [33].

Farz edelim keşfedilen iki yiyecek kaynağı A ve B olsun. Başlangıçta yiyecek arama sürecindeki bir arı işsiz bir toplayıcı gibi başlayacaktır ve bu toplayıcı kovan etrafındaki herhangi bir yiyecek kaynağı bilgisine sahip değildir [34,35].



Şekil 3.1. Arıların yiyecek arama çevrimi [36].

Bir arı için iki seçenek vardır:

- i) Etraftaki yiyecekleri içgüdüyle arayan kaşif arı olabilir.(Şekil-3.1'deki K)
- ii) Sallanış dansını (waggle dance) izleyerek ve yiyecek kaynağına yönelmiş olabilir. (Şekil 3.1'deki D)

Yiyecek kaynağı keşfedildikten sonra arı kaynağın yerini belleğine alır ve hemen kaynaktaki nektardan yararlanmaya başlar. Bu yararlanmadan dolayı bu arı çalışan toplayıcı (employed forager) olur. Kaynaktan toplanan nektar kovana götürülür ve depolanır. Depolama işleminden sonra arının izleyebileceği üç yol vardır:

1. Bulduğu kaynağı terk edip bağımsız hale gelebilir, (Şekil-3.1'deki V)
2. Kaynağa dönmeyen önce diğer arılarla kaynağın yeri hakkında bilgi paylaşımında bulunabilir (Şekil-3.1'deki T1),
3. Diğer arılara kaynağın yerini bildirmeden kaynaktan nektar getirmeye devam edebilir (Şekil-3.1'deki T2). Son seçenek bir arı için sosyal davranış olarak görünmese de aslında kaynaktan nektar getiren yeteri kadar arı varsa geçerli bir yoldur.

Kendini organizasyonun temel özellikleri arılarda aşağıdaki adımlara dayanır:

i) Pozitif Geri besleme (Positive Feedback): Yiyecek kaynaklarındaki nektar miktarı gözcü arıların onları ziyaret sayısı ile gelişir.

ii) Negatif Geri besleme (Negative Feedback): Bir yiyecek kaynağının araştırma süreci terk edildiğinde arılar durdurulur.

iii) Dalgalanmalar (Fluctuations): Kaşifler, yeni yiyecek kaynaklarının keşfi için rast gele bir arama sürecini tamamlar.

iv) Çoklu Etkileşim (Multiple Interactions): Arılar dans alanında yiyecek kaynağı pozisyonları hakkındaki bilgilerini paylaşırlar [34,35].

3.2. Yapay Arı Koloni Algoritması

Doğada var olan zeki davranışlar içeren süreçlerin incelenmesi ile yeni optimizasyon metotları geliştirilmiştir. Karaboğa, arıların yiyecek arama davranışını modelleyerek Yapay Arı Kolonisi Algoritmasını geliştirmiştir [35].

Doğrusal olmayan fonksiyonların optimizasyonunda kullanılan klasik matematiksel yöntemler, gerçekleşmesinde yazılımsal ve donanımsal bazı zorlukları da beraberinde taşıyan türev ifadeleri içerir. Bu hesaplamalar içerisindeki türev ifadelerinden kaçınmak ve daha basit ve kısa yazılımla, daha kısa sürede sonuca ulaşmak için doğadaki canlıların doğal seçim davranışlarından esinlenen iterasyona dayalı optimizasyon yöntemleri ve algoritmalar geliştirilmiştir [36].

Böceklerin doğadaki davranışlarından yola çıkılarak geliştirilen bir algoritma olan sürü zekâsı yaklaşımı, doğal ortamlarında içgüdülerinden gelen problem çözme becerilerini kullanan etkili meta sezgisel yöntemler üretmek için böcek davranışlarının modellenmesine odaklanmıştır. Sürü zekâsının ana unsuru, sürüyü oluşturan üyelerin sosyal davranış biçimleridir. Üyelerin sosyal davranışına örnek olarak, doğadaki gerçek bal arılarının buldukları yiyecek kaynağının yeri ve özellikleri hakkında diğer arılara bilgi vermek amacıyla kovan içerisinde dans alanı adı verilen alanda yaptıkları danslar örnek verilebilir. Bu danslar aracılığıyla yiyecek kaynağı bulan arılar, bu kaynak ile ilgili yer, yön, kalite, uzaklık ve nektar miktarı gibi bilgileri kovadaki diğer arılarla paylaşırlar. Bu başarılı sistem sayesinde kovadaki diğer arılar, kaliteli yiyecek kaynaklarının olduğu bölgelere yönlendirilebilmektedir. Karaboğa tarafından da ifade edildiği gibi arı kolonisi temelli algoritmalarda işçi, gözcü ve kâşif arı olmak üzere üç tip arı sınıfı tanımlanmaktadır [35].

a. İşçi arılar

Algoritmada bu arılar, keşfedilmiş kaynaklara ait nektarın kovana getirilmesinden sorumludurlar. İşçi arılar aynı zamanda ziyaret ettikleri yiyecek kaynağının kalitesi, kovana uzaklığı, sahip olduğu nektar miktarı ile ilgili bilgileri kovanda bekleyen diğer arılarla paylaşırlar.

b. Gözcü arılar

Bu arılar işçi arıların kovanda yaptıkları dansa göre yiyecek kaynağı hakkında bilgi alan ve aldıkları bilgi doğrultusunda kaynak arayışında olan arılardır. Yeni kaynakların belirlenebilmesi için işçi arıların daha önceki gözlemleri takip edilerek değerlendirilmektedir.

c. Kâşif arılar

Kâşif arılar yeni yiyecek kaynağı arayışında olan, rastgele olarak çevreyi dolaşan ve sadece kendi gözlemlerini dikkate alarak yeni nektar kaynakları arayan koloni üyeleridir.

Yapay arı koloni algoritmasının temel aldığı modelde basitlik amacıyla bazı kabuller yapılmıştır. Bu modele göre, her bir kaynağın nektarı sadece bir görevli arı tarafından alınmaktadır. Ayrıca işçi arıların sayısı toplam yiyecek kaynağı sayısına eşittir. İşçi arıların sayısı da gözcü arıların sayısına eşittir. Bu algoritma da yiyecek kaynaklarının yerleri optimizasyon problemine ait olası çözümlere ve kaynakların nektar miktarları da o kaynaklarla ilgili çözümlerin kalitesine karşılık gelmektedir. Dolayısıyla bu algoritma en fazla nektara sahip kaynağın yerini bulmaya çalışarak uzaydaki çözümlerden problemin minimumunu ya da maksimumunu veren noktayı bulmaya çalışmaktadır.

3.2.1. Yapay Arı Koloni Algoritmasının Adımları

Yapay arı koloni algoritmasının temel adımları aşağıdaki gibidir:

1. Başlangıç yiyecek kaynaklarının rassal bir şekilde üretilmesi.
2. İşçi arıların bu kaynaklara rassal olarak yönlendirilmesi.
3. Olasılıksal seçimde kullanılmak üzere bulunan yeni çözüm için olasılık değerinin hesaplanması.
4. Hesaplanan olasılık değerine göre gözcü arıların yiyecek kaynağına gönderilmesi.
5. Nektarı biten kaynağın bırakılması ve kâşif arı üretimi [36].

3.2.2. Algoritmada Başlangıç Yiyecek Kaynaklarının Üretilmesi

Rastgele yiyecek kaynağı bölgesi üretme süreci optimizasyon probleminin parametrelerinin alt ve üst sınırları arasında gerçekleştirilir.

$$x_{ij} = x_j^{\min} + rand(0,1)(x_j^{\max} - x_j^{\min}) \quad (3.1)$$

Burada i üretilen yiyecek kaynağı sayısını, j ise optimizasyon parametre sayısını ifade eder. İkinci adımda işçi arı belirlenmiş olan yiyecek kaynağından nektar toplamaktadır. Aynı zamanda bulunduğu kaynağın yakınında bulunan başka bir nektar kaynağına ilişkin bir analiz yaparak, yeni kaynağın kalitesini değerlendirmektedir. $\phi, [-1,1]$ aralığında rastgele değer alan reel sayı olmak üzere yeni nektar kaynağı araştırması v_{ij} hakkında yaptığı hesaplama Denklem (3.2)'de verilmiştir.

$$v_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{kj}) \quad (3.2)$$

Problem için bulunan yeni çözüm kaynağının değeri değerlendirilirken, v_{ij} 'nin daha önceden belirlenen parametre sınırları dışına çıkması durumunda Denklem (3.3)'e göre öteleme yapılır ve çözüm maliyetinin uygunluğu Denklem (3.4)'e göre hesaplanır.

$$v_{ij} = \begin{cases} x_j^{\min}, v_{ij} < x_j^{\min} \\ v_{ij}, x_j^{\min} \leq v_{ij} \leq x_j^{\max} \\ x_j^{\max}, v_{ij} \geq x_j^{\max} \end{cases} \quad (3.3)$$

$$fitness_i = \begin{cases} 1/(1 + f_i), f_i \geq 0 \\ 1 + \text{abs}(f_i), f_i \leq 0 \end{cases} \quad (3.4)$$


İşçi arı çevrimi tamamlandıktan sonra, Denklem (3.4) kullanılarak uygunluk değerleri hesaplanan besin kaynakları “kaba seçim” (greedy selection) adı verilen olasılıksal bir seçim işlemi ile gözcü arılara devredilir. Algoritmanın son kısmı, nektarı tükenmiş yiyecek kaynağının belirlenmesidir. İşçi ve gözcü arıların arama sürecinin tamamlanması ile oluşan bir döngü sonucunda, algoritma tükenmiş bir yiyecek kaynağını belirleyebilir. Bu amaçla, arama sürecinde güncellenen sayıcılar kullanılır. Bu sayıcılar program başlangıcında verilmelidir. Eğer herhangi bir yiyecek kaynağına ait sayıcı algoritma tarafından belirlenen ve limit olarak bilinen kontrol parametresinden daha büyükse, bahsi geçen kaynak tükenmiş olarak değerlendirilir ve terk edilir. Terk edilen

alana ait işçi arı algoritmadan çıkarılır. Yeni kaynağı bulan gözcü arı ise işçi arıya dönüşür ve bulunduğu kaynaktan bal toplamaya başlar ve o kaynak için limit değeri sıfırlanır. Görevi tamamlanan işçi arı kâşif arıya dönüşür.

Her sezgisel algoritmada olduğu gibi bu algoritmada da basitlik amacıyla bazı kabuller vardır. Bu kabuller;

1. Her bir kaynağın nektarının sadece bir görevli arı tarafından alınması,
2. İşçi arıların sayısı görevli arıların sayısına eşit olması,
3. Nektarı tükenen kaynağın arısının artık kâşif arı haline dönüşmesi.

Yapay arı koloni algoritmasının akış diyagramı Şekil 3.2’de verilmiştir [37].



Şekil 3.2. YAK algoritması akış diyagramı [37].

4. YAPAY ARI KOLONİ ALGORİTMASI İLE GRİ SEVİYE DOKULU GÖRÜNTÜLERİN BÖLÜTLENMESİ UYGULAMALARI


Sunulan tez çalışmasında gri seviye dokulu görüntülerin bölütlenmesi için dalgacık dönüşümü, sürü zekâsı temelli yaklaşımlardan biri olan yapay arı koloni algoritması ve entropi tabanlı eşikleme yöntemi kullanılmıştır.

Uygulanan yöntemde başlangıçta alınan görüntü gri seviyeye dönüştürülür, daha sonra elde edilen gri seviye dokulu görüntüye 2 boyutlu dalgacık dönüşümü uygulanır. Dalgacık dönüşümü ile görüntünün yatay, dikey ve diyagonal doku özelliklerini çıkarmak amaçlanmıştır. Dalgacık dönüşümü işlemi sonucunda 4 tane alt bant elde edilir, ancak doku niteliğini asıl karakterize eden bilgi orta frekanslı bölgelerdedir. Bu nedenle, bu tez çalışmasında alt bant görüntülerinden orta frekanslı bölgeler olan yatay (LH) ve dikey (HL) ayrıntıya sahip görüntüler kullanılmıştır. Alt bant görüntü matrisleri (LH, HL) 0-255 değerleri arasına kuantalanır ve elde edilen görüntünün gri seviye eş oluşum matrisi (P) elde edilir. Gri seviye eş oluşum matrisi hesaplanırken komşuluk piksel mesafesi 1 piksel alınarak 0° , 45° , 90° ve 135° doğrultular kullanılmıştır. Gri seviye eş oluşum matrisi giriş görüntüsünün tüm karakteristiğini içinde barındırır. Bu sayede görüntü ham görüntü olmaktan çıkarak algoritmaların daha kolay işleyebileceği bir formata dönüşmüş olur.

Eş oluşum matrisi elde edildikten sonra yapay arı koloni algoritmasının arı sayısı, limit değeri, maksimum çevrim sayısı, problem boyutu, yiyecek kaynaklarının alabileceği alt ve üst değerler gibi parametreleri ayarlanır. Çalışmada arı sayısı 20, maksimum çevrim sayısı 30, geliştirilemeyen kaynağın kaçınıcı çevrimde terkedileceğini belirten limit sayısı ise 10 alınmıştır. Görüntünün her bir pikseli arı koloni algoritmasının yiyecek kaynaklarıyla eşleştirilmiştir. Gri seviye görüntülerde her bir piksel 0 ile 255 sayıları arasında değer aldığı için arı koloni algoritmasında her bir yiyecek kaynağının alabileceği en küçük değer 0, en büyük değer 255 olacak şekilde ayarlanmıştır. Görüntü 2 boyutlu bir veri olduğundan dolayı algoritmanın problem boyutu da 2'dir.

Algoritmanın parametreleri belirlendikten sonra başlangıç yiyecek kaynağı matrisi oluşturulur. Başlangıç yiyecek kaynağı matrisi oluşturmak için gerekli denklem Denklem 3.1'de verilmişti. Denklem sonucunda 20×2 boyutunda başlangıç yiyecek kaynağı matrisi elde edilir. 20 algoritmadaki yiyecek kaynağı sayısını, 2 ise problemin boyutunu temsil eder.

Elde edilen başlangıç yiyecek kaynağı matrisi kullanılarak eş oluşum matrisi entropi fonksiyonu ile optimize edilir. Entropi hesaplamasında Denklem (1.8)'de verilen shannon entropi fonksiyonu kullanılır. 20x1 boyutundaki entropi matrisinin uygunluk matrisi Denklem (3.4) kullanılarak oluşturulur. Şekil 4.1' de oluşturulan matrislerin Matlab görüntüleri verilmiştir.



Şekil 4.1. YAK ile görüntü bölütleme uygulamaları Matlab sonuçları (a) Başlangıç yiyecek kaynağı matrisi (b) Başlangıç entropi matrisi (c) Başlangıç fitness matrisi

İşçi arı safhasında başlangıç yiyecek kaynağı matrisi güncellenir. Orijinal arı koloni algoritmasında kullanılan arama denklemi Denklem (3.2)'de verilmişti. Bu çalışmada arıların yeni çözüm kaynağını daha etkili bulabilmeleri ve bulunan çözümünden en iyi şekilde yararlanabilmeleri için aşağıda verilen arama denklemi kullanılmıştır.

$$v_{ij} = x_{ij} + 2(\phi_{ij} - 0.5)(x_{ij} - x_{kj}) + \phi_{ij}(x_j - x_{kj}) \quad (4.1)$$

Bu denklemde v_{ij} yeni uygun çözümü, x_j şimdiye kadar ki en iyi çözümün j . parametresini, ϕ_{ij} $[0,1]$ aralığında rastgele sayıyı, ϕ_{ij} ise $[0,c]$ arasında rastgele üretilen sayıyı, k ise 1 ile yiyecek kaynağı sayısı arasında rastgele seçilen sayıyı göstermektedir. Bu tez çalışmasında $c=1$ olarak alınmıştır [38]. Güncel yiyecek kaynağı matrisi Denklem (4.1)' e göre oluşturulduktan sonra başlangıç yiyecek matrisi için yapılan tüm işlemler güncellenen yiyecek kaynağı matrisi için de tekrarlanır. Şekil 4.2'de güncellenen yiyecek kaynağı matrisi, bu matrisin eş oluşum matrisi ile entropiye gönderilmesi sonucu elde edilen entropi matrisi ve entropi matrisinin uygunluğunun hesaplandığı fitness matrisi verilmiştir.

```

Employed2: 20x2 double =
    245    167
    231     14
     0    217
    233    254
    161    173
     25    193
     71    189
    139    100
    244    167
    246     44
     40    100
    248     8
    244     71
    124     12
    204     25
     36    210
    108    177
    234     81
    202    242
    245     9

```

(a)

```

ObjEmp2: 20x1 double
    7.0237
    8.1829
    3.1794
     0
    5.4331
    6.9092
    6.3110
    8.5344
    6.7009
    8.8031
    4.1716
    8.0990
    4.6897
    8.5634
    8.4431
    3.4393
    7.4895
    6.2621
    8.6329
    7.1789

```

(b)

```

FitEmp2: 20x1 double =
    0.1246
    0.1089
    0.2393
    1.0000
    0.1554
    0.1264
    0.1368
    0.1049
    0.1299
    0.1020
    0.1934
    0.1099
    0.1758
    0.1046
    0.1059
    0.2253
    0.1178
    0.1377
    0.1038
    0.1223

```

(c)

Şekil 4.2. YAK ile görüntü bölütleme uygulamaları Matlab sonuçları (a) Güncel yiyecek kaynağı matrisi (b) Güncel entropi matrisi (c) Güncel fitness matrisi

Başlangıç entropi matrisinden üretilen fitness matrisi kaynak değerleri ile güncel fitness matrisi kaynak değerleri karşılaştırılır. Fitness değerleri daha büyük olan yiyecek kaynakları eskileri ile değiştirilir ve böylelikle işçi arı safhası biter.

İşçi arı safhasında yapılan tüm işlemler gözcü arı safhasında da yapılır ancak gözcü arı safhasına başlanmadan fitness değerlerinin olasılıkları hesaplanır. Olasılık değerleri hesaplanırken Denklem (4.2) kullanılır.

$$\rho_i = \frac{fitness_i}{\sum_{j=1}^{SN} fitness_j} \quad (4.2)$$

Burada $fitness_i$ i. kaynağın kalitesini, SN görevli arı sayısını gösterir. Bu olasılık hesaplama işlemine göre bir kaynağın nektar miktarı arttıkça (uygunluk değeri) bu kaynak bölgesini seçecek arı sayısı da artacaktır. Algoritmada olasılık değerleri hesaplandıktan sonra seçim işleminde her bir kaynak için $[0, 1]$ aralığında rastgele sayı üretilir ve ρ_i değeri bu üretilen sayıdan büyükse görevli arılar gibi gözcü arılar da Denklem (4.1)'i kullanarak bu kaynak bölgesinde yeni bir çözüm üretir. Yeni çözüm değerlendirilir ve kalitesi hesaplanır. Eski ve yeni çözümün uygunlukları karşılaştırılır ve iyi olan seçilir. Bu süreç tüm gözcü arılar yiyecek kaynağı bölgelerine dağılına kadar devam eder. En son elde edilen fitness matrisinde en yüksek fitness değeri shannon entropi fonksiyonunun eşik değeri olarak kabul edilir ve bu değere göre bölütleme yapılır.

Bu çalışmada shannon entropi fonksiyonu yapay arı koloni algoritması ile eğitilerek optimum entropi değeri çok hızlı bir yakınsama ile elde edilmiştir. Bu noktada optimum

çözümüne hızlı yakınsayabilme, sürü zekâsına dayanan yapay arı koloni algoritmasının belirgin bir özelliğidir.

Geliştirilen yöntemin temel işlem adımları aşağıdaki gibidir:

1. Orijinal renkli görüntü gri seviyeye dönüştürülür.
2. Gri seviye dokulu görüntünün dalgacık dönüşümü hesaplanır.
3. Dalgacık dönüşümü işleminden elde edilen LH ve HL bantları 0-255 değerleri arasına kuantalanır.
4. Bu iki görüntü matrisinden entropi hesaplamasında kullanılacak gri seviye eş oluşum matrisi elde edilir.
5. Yapay arı koloni algoritmasının arı sayısı, limit değeri ve maksimum çevrim sayısı gibi parametreleri ayarlanır.
6. Başlangıç yiyecek kaynağı matrisi üretilir ve entropi değerleri bulunur.
7. Entropi değerlerinin uygunluğu hesaplanarak fitness matrisi elde edilir.
8. İşçi arı safhasında tüm yiyecek kaynakları güncelleştirilir ve tekrar eş oluşum matrisi ile entropi fonksiyonunun optimizasyonu gerçekleştirilir.
9. Güncel entropi matrisinin de fitness değerleri hesaplanır ve elde edilen 2 fitness matrisinden fitness değerleri büyük olan yiyecek kaynakları eskileri ile değiştirilir.
10. Böylece işçi arı safhası biter.
11. Aynı işlemler gözcü arı safhasında da yapılır ancak gözcü arı safhası başlamadan fitness değerlerinin seçilme olasılıkları hesaplanır.
12. Gözcü arı safhasında en son elde edilen fitness değerlerine göre en yüksek fitness değerinin karşılığı olan yiyecek kaynağındaki büyük değer eşik değer olarak kabul edilir.
13. Elde edilen eşik değere göre bölütleme gerçekleştirilir.

Geliştirilen bölütleme yönteminin akış şeması Şekil 4.3’de verilmiştir.




Şekil 4.3. Geliştirilen bölütleme yönteminin akış şeması.

4.1. Yapay Arı Koloni Algoritması ile Gri Seviye Dokulu Görüntülerin Bölütlenmesi Uygulama Sonuçları

Bu tez çalışmasında geliştirilen bölütleme tekniğinin performansını değerlendirmek için internetten ve bilinen görüntü veri tabanlarından faydalanılmıştır. Önerilen metot Şekil 4.4’de çeşitli görüntülere uygulanmış ve sonuçlar waveseg yöntemi ile karşılaştırılmıştır. Bazı görüntüler için elde edilen sonuçlar iyi olmasa da önerilen yöntem çalışma hızı bakımından waveseg yönteminden daha hızlıdır.

Bu çalışmada shannon entropi fonksiyonu yapay arı koloni algoritması ile optimize edilerek gri seviye doku görüntülerinin eşik değerleri bulunmuştur. Kullanılan teknik ile optimum eşik değer bulma yöntemlerine bir sürü zekâsı yaklaşımı olan yapay arı koloni algoritması da eklenmiştir. Algoritmanın uygulama sonuçları ve waveseg yöntemi ile karşılaştırılması Şekil 4.4’de gösterilmiştir.



Şekil 4.4. Önerilen yöntemin uygulama sonuçları ve Waveseg yöntemi ile karşılaştırılması (a)Gri seviye görüntü (b) Önerilen yaklaşım kullanılarak elde edilen görüntü bölütleme sonucu (c) Waveseg bölütlemesi

Şekil 4.4.'ün devamı:


6




7



8



9



10



(a)

(b)

(c)

Görüntü bölütleme algoritmalarının performansını değerlendirecek belirli bir ölçüt bulunmamaktadır. Ancak, literatürde bölütleme algoritmalarının performansını değerlendirecek bazı objektif yöntemler kullanılmaktadır. Bu çalışmada elde edilen bölütleme sonuçları ile Waveseg yönteminin bölütleme sonuçları Pratt'ın önerdiği FOM (Figure Of Merit) kriteri ile ölçülerek değerlendirilmiştir. Pratt, kenar belirlemede karşılaşılan üç genel hata alanını göz önünde bulundurmaktadır. Bu hata alanları; geçerli kenar noktalarını kaçırma, kenar noktalarını bölgeleştirmede başarısızlık ve kenar noktalarındaki gürültünün sınıflandırılması. Pratt üç tip hatayı dengelemek için FOM tekniğini üretmiştir [39].

$$FOM = \frac{1}{\max\{I_D, I_I\}} \sum_{k=1}^{I_D} \frac{1}{1 + \alpha(d_k)^2} \quad (4.3)$$

Burada I_I ve I_D sırasıyla ideal sayı ve bulunan kenar noktaları, d_k ise bulunan kenar noktalarının ideal kenar noktaları çizgilerine uzaklığıdır. Ölçekleme sabiti olan $\alpha > 0$ ayırmada göreceli bir hata payını destekler ve $\alpha = 1/9$ olarak ayarlamıştır. $FOM = 1$ eşitliği bulunan kenar noktaları ve ideal kenar noktaları arasında mükemmel eşleşmeyi ifade eder. FOM kriterinin 1 sayısına yakınlığı, olması gereken bölütlemeye yakınlığı temsil eder. Tablo 1'de iki metot tarafından üretilen bölütleme sonuçlarının kalitesini göstermek için FOM değerleri verilmiştir.

Tablo 1. Önerilen teknik ve waveseg bölütlemesi için FOM kriteri sonuçları

	Önerilen metot	Waveseg
Şekil 4.4. (1)	0.4530	0.2604
Şekil 4.4. (2)	0.5322	0.3257
Şekil 4.4. (3)	0.4250	0.3041
Şekil 4.4. (4)	0.4504	0.2014
Şekil 4.4. (5)	0.4723	0.4711
Şekil 4.4. (6)	0.5054	0.2710
Şekil 4.4. (7)	0.4074	0.6839
Şekil 4.4. (8)	0.4270	0.4185
Şekil 4.4. (9)	0.4328	0.3076
Şekil 4.4. (10)	0.4229	0.3144

Şekil 4.4'de önerilen yöntem FOM sonuçları, waveseg FOM sonuçlarına göre çoğunlukla 1 sayısına daha yakındır. Bu da, önerilen teknik bölütlemesinin Waveseg metodundan daha iyi bölütleme yaptığı anlamına gelmektedir.

5. SONUÇ

Sunulan tez çalışmasında görüntü bölütlemekte kullanılan entropi tabanlı eşikleme tekniklerine yapay arı koloni algoritması entegre edilerek etkili ve hızlı çalışan bir bölütleme uygulaması gerçekleştirilmiştir. Görüntü bölütlemek için sürü zekâsı kaynaklı algoritmalarından olan yapay arı koloni algoritması ile entropi fonksiyonunun hızlı bir şekilde optimize edilmesi sağlanmıştır. Kullanılan teknik ile optimum eşik değeri bulma yöntemlerine bir sürü zekâsı yaklaşımı olan yapay arı koloni algoritması da eklenmiştir. Önerilen yaklaşım çeşitli görüntülere uygulanarak sonuçları Waveseg bölütleme tekniği ile karşılaştırılmıştır. Bazı görüntüler için elde edilen sonuçlar iyi olmasa da optimum eşik değere yakınsama hızı açısından yöntem oldukça iyidir. Sunulan bölütleme tekniğinin özellik çıkarım aşamaları güçlendirilerek çok daha etkili ve doğru bölütleme sonuçları elde edilebilecektir.

Uygulanan teknik türev gibi işlemler içermediği için matematiksel karmaşıklık açısından oldukça uygundur. Ancak, yaklaşım otomatik olarak bölütleme yapmasına rağmen, arı koloni algoritmasının parametrik olması yöntemin eksikliği olarak söylenebilir. İleride bu yönde çalışmalar yapılarak parametreden yoksun bölütleme gerçekleştiren bir yöntem geliştirmek mümkün olacaktır.

KAYNAKLAR

- [1]. **Karabatak, E.**, Nötrozofi Yaklaşımı ile renkli görüntü bölütleme, Fırat Üniversitesi Fen Bilimleri Enst. Yüksek Lisans Tezi, Şubat 2010.
- [2]. Original image courtesy of Mr. Joseph E. Pascente, Lixi, Inc.
- [3]. **Dudgeon, D.E. and Mersereau R.M.**, 1984. Multidimensional Digital Signal Processing. Englewood Cliffs, Prentice-Hall, New Jersey
- [4]. Internet: <http://spie.org/x8899.xml?pf=true&ArticleID=x8899>, Electronic Imaging & Signal Processing, Erişim tarihi: 23 Aralık 2013
- [5]. **A.K. Jain, R.C. Dubes**, Algorithms for Clustering Data. Prentice-Hal, Englewood Cliffs, NJ, 1988.
- [6]. **R. Kothari, D. Pitts**, On finding the number of clusters, Patter Recognition Letters, 20, 405-416, 1999.
- [7]. **R. O. Duda and P. E. Hart**, "Pattern Classification and Scene Analysis," Wiley-Interscience, New York, 1973
- [8]. **Recep Uslu**, 2007, Elektronik Bir Hücresel Yapay Sinir Ağı Gerçeklemesi Olan Ace16k Üzerinde Görüntü Bölütleme, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü
- [9]. **Bernd Jahne**, 2002. Digital Image Processing, Springer, Heidelberg
- [10]. **Tinku Acharya and Ajoy K. Ray**, 2005. Image Processing Principles and Applications, John Wiley & Sons, New Jersey.
- [11]. **Yatharth Saraf**, May 2006. Algorithms for Image Segmentation, Thesis, Birla Institute of Technology and Science, Pilani.
- [12]. **A. Cohen, I. Daubechies, J. C. Feauveau**, "Biorthogonal bases of compactly supported wavelets," Commun. Pure Appl.Math., v. 45,p.485–560,1992.
- [13]. **Hanbay K.**, Nötrozofi Yaklaşımı Ve Dalgacık Dönüşümü İle Renkli Doku Görüntülerinin Bölütlenmesi , Fırat Üniversitesi Fen Bilimleri Enst. Yüksek Lisans Tezi, Kasım 2010.
- [14]. **Rajabli F.**, Dar Bantlı Video İletişim Sistemlerinde Dalgacık Dönüşümünün Kullanılması, Ankara Üniversitesi Fen Bilimleri Enst. Yüksek Lisans Tezi, 2005
- [15]. **Shi Y. Q.**, and Sun, H." Image and Video Compression for Multimedia Engineering Fundamentals, Algorithms, and Standards" CRC Press, 2000.

- [16]. **Chen,J.Pappas,N.,Mojsilovic,A. Rogowitz,B.E.** “Adaptive perceptual Color-Texture image Segmentation”, IEEE Trans. IP, pp.1-13, 2004.
- [17]. **Şengür A.**, Endoskopik Görüntülerin Değerlendirilmesinde Görüntü İşleme Temelli Akıllı Karar Destek Sistemi, Fırat Üniversitesi Fen Bilimleri Enst. Doktora Tezi, 2006
- [18]. **Blesy Anu Mathew.** Entropy Of Electroencephalogram (Eeg) Signals Changes With Sleep State. University of Kentucky Master's Thesis; 2006.
- [19]. **Yıldız A, Akın M, Poyraz O, Kirbas G.** Estimation of Alertness Level by Using Wavelet Transform Method and Entropy. Signal Processing and Communications Applications Conference. p. 313–316. SIU 2009. IEEE 17th, Turkey, 2009.
- [20]. **Gómez C, Hornero R.**, Entropy and Complexity Analyses in Alzheimer's Disease: An MEG Study. The Open Biomedical Engineering Journal. p. 223-235; 2010.
- [21]. **Joshua S, Richman J, Randall M.**, Physiological time-series analysis using approximate entropy and sample entropy. Am J Physiol Heart Circ Physiol. 278: p. H2039–H2049; 2000.
- [22]. **Miano Ma., Jianhui Liang, Min Guo, Yi Fan, Yilang Yin,** SAR Image Segmentation Based on Artificial Bee Colony Algorithm, Applied Soft Computing 11 (2011) 5205-5214
- [23]. **Murty, K. G.**, 2003. Optimization Models For Decision Making, vol. 1, Chapter 1: Models for Decision Making.
- [24]. **Karaboğa, D.**, 2011. Yapay Zekâ Optimizasyon Algoritmaları. Nobel Yayın Dağıtım, Sayfa 15.
- [25]. **Akyol, S., & Alataş, B.**, 2012. Güncel Sürü Zekâsı Optimizasyon Algoritmaları. Nevşehir Üniversitesi Fen Bilimleri Enstitü Dergisi 1
- [26]. **Yang, X. S.** , 2009. Firefly Algorithms Formultimodal Optimization, Proceedings of the Stochastic Algorithms. Sapporo, Japan.
- [27]. **Krishnanand, K. N., & Ghose, D.**, 2005. Detection of Multiple Source Locations Using a Glowworm Metaphor. IEEE Swarm Intelligence Symposium.
- [28]. **Dorigo, M.**, 1992. Optimization, Learning and Natural Algorithms, PhD thesis, Dipartimento di Elettronica, Politecnico di Milano, Italy.
- [29]. Internet: <http://ab.org.tr/ab06/bildiri/53.pdf>, Erişim tarihi:15.12.2013

- [30]. **Alataş, B.**, 2007. Kaotik Haritalı Parçacık Sürü Optimizasyon Algoritmaları Geliştirme, Doktora Tezi. Fırat Üniversitesi, Fen Bilimleri Enstitüsü.
- [31]. **Tereshko, V.**, 2000. Reaction-Diffusion Model of a Honey Bee Colony's Foraging Behaviour, PPSN VI: Proceedings of the 6th International Conference on Parallel Problem Solving from Nature, 807-816, 3-540-41056-2, Springer Verlag, London, UK.
- [32]. **Karaboğa, D.**, 2011. Yapay Zekâ Optimizasyon Algoritmaları. Nobel Yayın Dağıtım, Sayfa 201,202.
- [33]. **Lucic, P.** (2002) Modeling transportation problems using concepts of swarm intelligence and soft computing, Virginia Polytechnic Institute and State Universty.
- [34]. **Karaboğa D, Baştürk B.**, 2008, On the Performance of Artificial Bee Colony (ABC) Algorithm, Applied Soft Computing, 687-697. Sayfa 1.
- [35]. **Karaboğa D.**, 2005, An Idea On Honey Bee Swarm For Numerical Optimization, Technical Report-TR06, Sayfa 2.
- [36]. **Hanbay K. , TALU M. F., Karcı A., 2012.**, Dalgacık Dönüşümü Ve Yapay Arı Koloni Algoritması İle Renkli Doku Görüntülerinin Bölütlenmesi, Siu Bildirisi, 2012.
- [37]. **Karaboğa D.,2011.**, Yapay Zeka Optimizasyon Algoritmaları, 2, 206-211.
- [38]. **G.Zhu, S.Kwong**, Gbest-guided artificial bee colony algorithm for numerical function optimization, Applied Mathematics and Computation 217 (2010) 3166-3173.
- [39]. **J.B.Kim, H.J.Kim**, Multiresolution-based watersheds for efficient image segmentation, Pattern Recognition Letters 24 (2003) 473–488.

ÖZGEÇMİŞ

08.03.1987 Elazığ doğumluyum. Liseyi Mehmet Akif ERSOY Lisesinde, lisans eğitimimi 2006-2010 yılları arasında Elazığ Fırat Üniversitesi Teknik Eğitim Fakültesi Elektronik-Bilgisayar Eğitimi Bilgisayar Öğretmenliği Bölümünde tamamladım. 2010 yılı Aralık ayında Bingöl Merkez Ticaret Meslek Lisesine Bilişim Teknolojileri öğretmeni olarak atandım. 2013 yılı Ağustos ayından itibaren Elazığ Merkez Kuyulu Ortaokulunda öğretmenlik görevimi sürdürmekteyim.